

UNIVERSIDADE FEDERAL DE ALFENAS

MARCIO ALOISIO DA SILVA JÚNIOR

A DINÂMICA ESPACIAL DA AGRICULTURA NO BRASIL EM 2008 E  
2018

Alfenas/MG

2021

MARCIO ALOISIO DA SILVA JÚNIOR

A DINÂMICA ESPACIAL DA AGRICULTURA NO BRASIL EM 2008 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: Ciências Agrárias I.

Orientadora: Prof<sup>ª</sup>. Dr<sup>ª</sup>. Patrícia de Siqueira Ramos.

Coorientador: Prof. Dr. Lincoln Frias.

Alfenas/MG

2021

Dados Internacionais de Catalogação-na-Publicação (CIP)  
Sistema de Bibliotecas da Universidade Federal de Alfenas

Silva Júnior, Marcio Aloisio.  
S586d A dinâmica espacial da agricultura no Brasil em 2008 e 2018. / Marcio  
Aloisio Silva Júnior. -- Alfenas/MG, 2021.  
99f.: il. --

Orientadora: Patrícia de Siqueira Ramos.  
Dissertação (Mestrado em Estatística Aplicada e Biometria) -  
Universidade Federal de Alfenas, 2021.  
Bibliografia.

1. Análise espacial (Estatística). 2. Estatística agrícola. 3.  
Produtividade agrícola. I. Ramos, Patrícia de Siqueira. II. Título.

CDD-519

MARCIO ALOISIO DA SILVA JÚNIOR

A DINÂMICA ESPACIAL DA AGRICULTURA NO BRASIL EM 2008 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: 28 de abril de 2021.

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

Profa. Dra. Adriana Dias  
Instituição: Universidade Federal de Alfenas - UNIFAL-MG

Prof. Dr. Denismar Alves Nogueira  
Instituição: Universidade Federal de Alfenas - UNIFAL-MG



Documento assinado eletronicamente por **Denismar Alves Nogueira, Professor do Magistério Superior**, em 28/04/2021, às 16:56, 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 **Patrícia de Siqueira Ramos, Professor do Magistério Superior**, em 28/04/2021, às 16:57, 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 **Adriana Dias, Professor do Magistério Superior**, em 28/04/2021, às 16:57, 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](https://sei.unifal-mg.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0502524** e o código CRC **3EDAFF90**.

*Dedico este trabalho aos meus familiares,  
amigos e professores que tornaram possível  
a realização desse sonho.*

## AGRADECIMENTOS

Às Universidades Públicas e seu relevante papel em nossa sociedade. Aqui, destaco a UNIFAL-MG que esteve presente em sete dos meus vinte e seis anos.

Aos inúmeros pesquisadores e cientistas que dia após dia permanecem firmes na defesa à Ciência, especialmente no momento que vivemos.

Aos meus orientadores Patrícia e Lincoln, que me acompanham há anos e foram essenciais em minha formação como um todo, não somente a acadêmica.

Aos professores que aceitaram o convite para compor as bancas da qualificação e da defesa de dissertação: Adriele, Adriana, Danilo, Denismar e Flávio.

Aos professores que conduziram com maestria as disciplinas que cursei durante o mestrado.

A todos meus familiares, especialmente meus pais (Marcio e Paula), minha irmã (Amanda) e a Ana Karen, por me acompanharem em mais uma conquista.

Aos amigos e colegas que estiveram presentes, ainda que fisicamente distantes, em todos os momentos ao longo dessa caminhada.

Enfim, a todos que fizeram parte dessa conquista!

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

*“Happiness only real  
when shared.”  
(Christopher McCandless)*

## RESUMO

Dada a influência da agricultura na sociedade e os fatores que podem contribuir para a concentração espacial de culturas agrícolas, tais como condições climáticas, tipos de solo e topografia, tem-se a importância da compreensão da dinâmica espacial de diferentes culturas agrícolas. Tal compreensão permite a identificação de regiões produtoras estratégicas, além de servir como subsídio para políticas públicas do setor. A compreensão da dinâmica espacial de culturas agrícolas no Brasil torna-se ainda mais relevante, tendo em vista as diferentes características observadas ao longo de seu território e o fato de ser o país um dos maiores exportadores de produtos agrícolas do mundo. Com isso, o objetivo desse trabalho é realizar, por meio da análise exploratória de dados espaciais, uma análise comparativa da dependência espacial da produção de diferentes culturas agrícolas no Brasil, nos anos de 2008 e 2018. Para tanto, utiliza-se de dados da Produção Agrícola Municipal (PAM) do IBGE, da qual foram selecionadas as 12 culturas com os maiores valores totais, em reais, da produção em 2018. Tais culturas foram: algodão, arroz, banana, café, cana-de-açúcar, feijão, fumo, laranja, mandioca, milho, soja e tomate. A variável utilizada para a análise espacial foi a quantidade produzida (em toneladas), adotando como unidades geográficas os municípios. Entre os resultados, tem-se que todas as culturas apresentaram autocorrelação espacial positiva, segundo o teste do *I* de Moran global, destacando em ambos os anos o baixo valor da estatística observado para a cultura tomate. Os maiores valores observados em tal estatística foram para a cana-de-açúcar, o café e o milho em 2018, e para o fumo, o café e a cana-de-açúcar em 2008. Por meio dos mapas temáticos e dos mapas LISA foram identificados, para cada uma das culturas, os agrupamentos espaciais de municípios com quantidades produzidas acima da média, bem como aqueles municípios que se destacam em relação a seus vizinhos. De modo geral, a análise comparativa das culturas evidenciou a formação de três grupos, segundo a dinâmica espacial entre os dois anos. O primeiro grupo é formado pelas culturas que tendem a se concentrar em áreas específicas do território, enquanto que o segundo grupo é composto por culturas que em 2018 expandiram as áreas em destaque que apresentavam em 2008. Por fim, o terceiro e último grupo apresenta como culturas aquelas que apresentaram agrupamentos com menores extensões e mais espaçados entre si.

**Palavras-chave:** Análise exploratória de dados espaciais. *I* de Moran. Zoneamento agrícola.

## ABSTRACT

Given the influence of agriculture on society and the factors that can contribute to the spatial concentration of crops, such as climatic conditions, soil types, and topography, it is important to understand the spatial dynamics of different agricultural cultures. Such understanding allows the identification of strategic producing regions, in addition to serving as a subsidy for public policies in the sector. The understanding of the spatial dynamics of crops in Brazil becomes even more relevant, considering the different characteristics observed throughout its territory and the fact that the country is one of the largest exporters of agricultural products in the world. Thus, the objective of this work is to carry out, through exploratory analysis of spatial data, a comparative analysis of the spatial dependence of the production of different crops in Brazil, in the years of 2008 and 2018. For that, we use data from the Municipal Agricultural Production (PAM) of IBGE, from which the 12 crops were selected with the highest total values, in reais, of the production in 2018. Such crops were: cotton, rice, bananas, coffee, sugar cane, beans, tobacco, orange, cassava, corn, soybeans, and tomatoes. The variable used for spatial analysis was the quantity produced (in tons), adopting municipalities as geographic units. Among the results, it was found that all cultures showed positive spatial autocorrelation, according to the test of Moran's  $I$  global, highlighting in both years the low value of the statistic observed for the tomato culture. The highest values observed in such a statistic were for sugarcane, coffee, and corn at 2018, and for tobacco, coffee, and sugarcane at 2008. Through thematic maps and LISA maps, for each culture, the spatial groupings of municipalities with above-average produced quantities were identified, as well as those municipalities that stand out with their neighbors. In general, the comparative analysis of cultures showed the formation of three groups, according to the spatial dynamics between the two years. The first group is made up of cultures that tend to concentrate in specific areas of the territory, while the second group is made up of cultures that in 2018 expanded the highlighted areas they presented in 2008. Finally, the third and last group presents as cultures those that presented clusters with smaller extensions and more spaced from each other.

**Keywords:** Agricultural zoning. Exploratory spatial data analysis. Moran's  $I$ .

## LISTA DE FIGURAS

Figura 1 – Quantidade produzida, em tonelada, dos municípios brasileiros em 2015 segundo o Nexo Jornal . . . . .	13
Figura 2 – Representação gráfica das convenções de contiguidade para a matriz de ponderação espacial . . . . .	19
Figura 3 – Diagrama de dispersão de Moran para o índice de exclusão/inclusão social dos distritos de São Paulo segundo o censo de 1991 . . . . .	22
Figura 4 – Diagrama de dispersão de Moran de situação hipotética a fim de evidenciar <i>outliers</i> e pontos de alavancagem . . . . .	23
Figura 5 – Mapa LISA da produtividade do café - Sul e Sudoeste de Minas Gerais em 2012 . . . . .	25
Figura 6 – Porcentagem da quantidade produzida, em toneladas, das culturas em cada região do país nos anos de 2008 e 2018 . . . . .	29
Figura 7 – Mapas temáticos para a quantidade de algodão produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	34
Figura 8 – Mapas temáticos para a quantidade de arroz produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	35
Figura 9 – Mapas temáticos para a quantidade de banana produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	37
Figura 10 – Mapas temáticos para a quantidade de café produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	38
Figura 11 – Mapas temáticos para a quantidade de cana-de-açúcar produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	40
Figura 12 – Mapas temáticos para a quantidade de feijão produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	42
Figura 13 – Mapas temáticos para a quantidade de fumo produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	43
Figura 14 – Mapas temáticos para a quantidade de laranja produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	44
Figura 15 – Mapas temáticos para a quantidade de mandioca produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	46
Figura 16 – Mapas temáticos para a quantidade de milho produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	47
Figura 17 – Mapas temáticos para a quantidade de soja produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	49
Figura 18 – Mapas temáticos para a quantidade de tomate produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	50

Figura 19 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de algodão produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	60
Figura 20 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de arroz produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	61
Figura 21 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de banana produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	62
Figura 22 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de café produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	63
Figura 23 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de cana-de-açúcar produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	64
Figura 24 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de feijão produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	65
Figura 25 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de fumo produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	66
Figura 26 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de laranja produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	67
Figura 27 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de mandioca produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	68
Figura 28 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de milho produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	69
Figura 29 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de soja produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	70
Figura 30 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de tomate produzida, em toneladas, nos anos de 2008 e 2018 . . . . .	71

## LISTA DE TABELAS

Tabela 1 – Quantidades totais produzidas e valores totais da produção das culturas agrícolas ordenadas segundo o valor total da produção no ano de 2018	26
Tabela 2 – Medidas resumo da quantidade produzida (em toneladas) das culturas agrícolas em 2008 . . . . .	30
Tabela 3 – Medidas resumo da quantidade produzida (em toneladas) das culturas agrícolas em 2018 . . . . .	31
Tabela 4 – I de Moran global para as culturas nos anos de 2008 e 2018 e pseudo-valores- $p$ . . . . .	32

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> . . . . .	<b>12</b>
<b>2</b>	<b>REFERENCIAL TEÓRICO</b> . . . . .	<b>13</b>
2.1	AGRICULTURA . . . . .	14
2.2	ANÁLISE ESPACIAL . . . . .	16
2.2.1	Matriz de Ponderação Espacial . . . . .	18
2.2.2	Análise Exploratória de Dados Espaciais . . . . .	20
2.2.3	Autocorrelação Espacial Global . . . . .	20
2.2.4	Autocorrelação Espacial Local . . . . .	23
<b>3</b>	<b>MATERIAL E MÉTODOS</b> . . . . .	<b>26</b>
<b>4</b>	<b>RESULTADOS E DISCUSSÃO</b> . . . . .	<b>29</b>
4.1	ALGODÃO . . . . .	33
4.2	ARROZ . . . . .	35
4.3	BANANA . . . . .	36
4.4	CAFÉ . . . . .	38
4.5	CANA-DE-AÇÚCAR . . . . .	39
4.6	FEIJÃO . . . . .	41
4.7	FUMO . . . . .	42
4.8	LARANJA . . . . .	44
4.9	MANDIOCA . . . . .	45
4.10	MILHO . . . . .	47
4.11	SOJA . . . . .	48
4.12	TOMATE . . . . .	50
4.13	ANÁLISE COMPARATIVA . . . . .	51
<b>5</b>	<b>CONSIDERAÇÕES FINAIS</b> . . . . .	<b>55</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>56</b>
	<b>APÊNDICES</b> . . . . .	<b>59</b>
	<b>APÊNDICE A – FIGURAS</b> . . . . .	<b>60</b>
	<b>APÊNDICE B – CÓDIGOS</b> . . . . .	<b>72</b>

## 1 INTRODUÇÃO

A influência e a importância da agricultura em nossa sociedade podem ser observadas desde o cultivo de produtos destinados à alimentação humana e animal até sua participação no desenvolvimento econômico de países e regiões. Entre outros fatores, as condições climáticas, os tipos de solo e a topografia podem contribuir para a concentração espacial de culturas agrícolas em determinadas regiões.

Em meio a este cenário, a compreensão da dinâmica espacial de culturas agrícolas permite estabelecer padrões entre diferentes culturas, identificar regiões produtoras estratégicas, além de servir como subsídio para políticas públicas do setor. Nesse sentido pode-se destacar o seguro rural, que lida com eventos probabilisticamente dependentes, não sendo possível assim aplicar-se métodos atuariais tradicionais.

Com isso, o objetivo deste trabalho é realizar por meio da Análise Exploratória de Dados Espaciais (AEDE) uma análise comparativa da dependência espacial da produção de culturas agrícolas no Brasil nos anos de 2008 e 2018. O período escolhido para a análise leva em consideração as informações mais recentes presentes na base de dados PAM-IBGE, sendo arbitrária a escolha de uma década para a comparação. Para tanto foram selecionadas as doze culturas que apresentaram os maiores valores totais da produção no ano de 2018, e então identificados seus agrupamentos (*clusters*) e informações espacialmente discrepantes (*outliers* espaciais), de forma a compreender em uma mesma cultura as alterações em sua dinâmica espacial, e entre diferentes culturas semelhanças entre seus padrões de associação espacial.

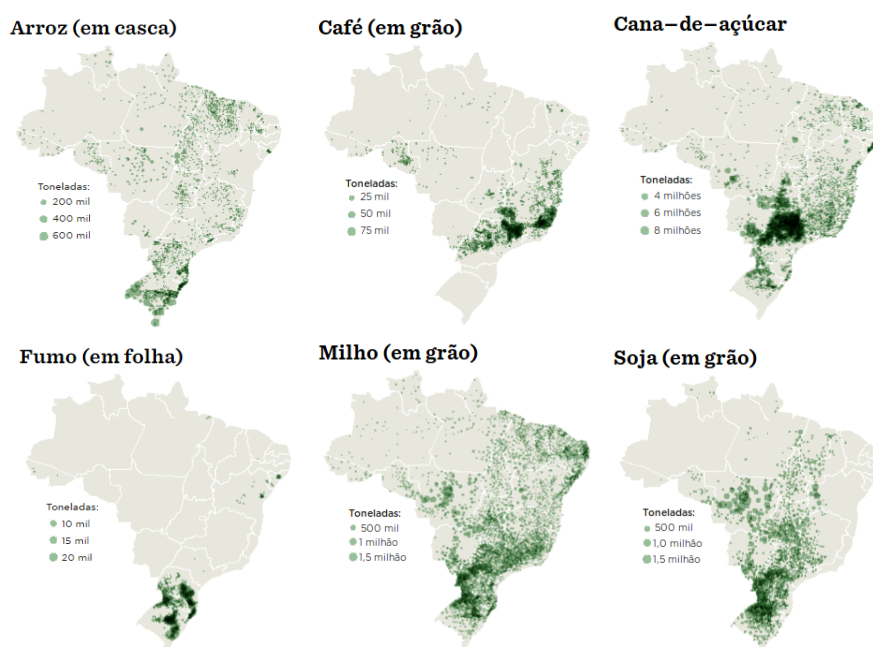
Como justificativa para o trabalho tem-se a relevância da atividade agrícola para o país, além de buscar compreender as relações entre diferentes culturas, seu perfil econômico e a dinâmica espacial das mesmas.

O trabalho encontra-se estruturado em 5 seções, incluindo a Introdução. A Seção 2 apresenta o referencial teórico, abrangendo desde as características do setor agrícola no Brasil, a aspectos e definições referentes à análise espacial. Em seguida, na Seção 3, é apresentado o conjunto de dados utilizado, bem como a aplicação dos métodos apresentados ao mesmo. Na Seção 4 são apresentados e discutidos os resultados da pesquisa. Por fim, na Seção 5 têm-se as considerações finais.

## 2 REFERENCIAL TEÓRICO

A motivação do presente trabalho surgiu em razão da matéria publicada pelo Nexo Jornal no ano de 2018, intitulada “Banana, café, mandioca: onde são cultivados vegetais e grãos no Brasil” (ALMEIDA; ZANLORENSSI, 2018). Tal matéria utiliza dados do ano de 2015 da Produção Agrícola Municipal (PAM) do Instituto Brasileiro de Geografia e Estatística (IBGE) para representar por meio de uma série de mapas as quantidades produzidas nos municípios brasileiros para diferentes culturas agrícolas. Na Figura 1 estão presentes alguns dos mapas contidos na matéria.

Figura 1 – Quantidade produzida, em tonelada, dos municípios brasileiros em 2015 segundo o Nexo Jornal



Fonte: Almeida, Zanlorenssi (2018).

Pela observação dos mapas da Figura 1, nota-se que quanto maiores os círculos sobre as localidades dos municípios, maiores as quantidades produzidas pelos mesmos. Outro ponto a ser levado em consideração são as áreas que apresentam coloração mais intensa devido à sobreposição dos círculos, indicando assim uma maior concentração dos municípios produtores nas respectivas regiões.

Para a cultura arroz, observa-se que os municípios com as maiores quantidades produzidas estão predominantemente no estado do Rio Grande do Sul e que os municípios com menores quantidades produzidas da cultura podem ser observados nos demais estados do país. Em relação às culturas café, cana-de-açúcar e fumo é possível observar áreas que apresentam maior concentração de municípios produtores e maiores quantidades produzidas em regiões específicas do país, para tais culturas têm-se indícios de que fatores

regionais favorecem o desenvolvimento e a produção de tais culturas nessas localidades . Por fim, as culturas milho e soja apresentaram municípios produtores em pontos mais dispersos ao longo do território do país, municípios com maiores quantidades produzidas que podem ser observados principalmente no estado do Mato Grosso, além de áreas com maior concentração de municípios produtores entre o Centro-Oeste e o Sul do país.

Com isso, em razão das especificidades da dinâmica espacial da produção de culturas agrícolas no país, neste trabalho foi empregada a análise exploratória de dados espaciais a fim de identificar e compreender os efeitos da interdependência entre os municípios produtores.

## 2.1 AGRICULTURA

Segundo o IBGE (2014), o termo agricultura compreende o emprego de técnicas desenvolvidas pelo homem para a transformação do meio ambiente com a finalidade de torná-lo mais apto ao desenvolvimento de espécies vegetais. Tal transformação engloba técnicas físicas, químicas e/ou biológicas no cultivo de plantas das quais são obtidos produtos úteis ao interesse humano.

A agricultura é um dos principais agentes do desenvolvimento da economia brasileira, agente esse que, a partir de 1990, passou por uma série de mudanças políticas que incluíram uma maior abertura externa, a desregulamentação dos mercados e as novas políticas públicas do setor. Tais mudanças levaram o mesmo a atuar em uma estrutura mais competitiva, tanto internamente quanto externamente (PEROBELLI *et al.*, 2007).

De acordo com Alvim (2003), a partir da década de 1990, o sistema agroindustrial brasileiro passou a adotar novas formas de organização, a utilizar novos mecanismos impulsionadores de bases de competitividade e rentabilidade, além de alcançar maiores ganhos de produtividade por meio da maior eficiência na coordenação dos recursos produtivos. Com isso, o Brasil aumentou sua participação no mercado internacional, consolidando-se como um dos maiores exportadores de produtos agrícolas do mundo.

O aumento na participação no comércio ocorreu em virtude de diversos fatores, mas principalmente aos investimentos em pesquisa tecnológica e aos altos índices de rentabilidade do setor. Além disso, a disponibilidade de terras, o avanço na pesquisa tecnológica e as técnicas modernas de manejo das lavouras e rebanhos têm sido responsáveis pela expansão das atividades agropecuárias para novas fronteiras (PEROBELLI *et al.*, 2007).

Outro marco importante para o setor no país ocorreu em dezembro de 1973, com a instituição do Programa de Garantia da Atividade Agropecuária (PROAGRO), por meio da Lei nº 5.963. O Programa iniciou sua operação a partir do ano de 1975, tendo como objetivo de sua criação a garantia da atividade dos produtores rurais nos casos em que os

custos investidos em seus empreendimentos eram prejudicados por fenômenos naturais adversos, tendo em vista que a não previsão da variabilidade climática é um dos principais riscos à atividade agrícola (CUNHA; ASSAD, 2001).

Segundo Rossetti (2001), com o início do programa ficou evidente que o PROAGRO, para se manter como um instrumento de política agrícola, deveria passar por sérias mudanças estruturais e operacionais, tendo em vista que ao longo de seus primeiros 22 anos de existência contou com um histórico deficitário. Ainda segundo o autor, a necessidade de tais mudanças ficou ainda mais evidente após a crise econômica e financeira pela qual o país passou no final da década de 1980, tendo com isso iniciadas mudanças já no ano de 1989.

Além disso, a falta de recursos públicos aliada às altas taxas de sinistralidade, às coberturas não condizentes com a realidade das lavouras e às metodologias atuariais inadequadas, faziam com que fosse inviável a permanência do Programa em seu formato inicial. A variabilidade climática não prevista sempre foi uma das principais fontes de risco para a atividade, fato que era comprovado pelas altas taxas de sinistralidade da agricultura no país (CUNHA; ASSAD, 2001).

Foi nesse cenário que, a partir da safra de 1996, o PROAGRO passou por importantes mudanças em sua estrutura, sendo a principal delas a implementação do Zoneamento Agrícola. Com isso, o programa passou a ser orientado por meio de novas regras como a não cobertura da multiplicidade de riscos e o incentivo ao uso de tecnologias, entre elas o zoneamento de riscos climáticos, os cultivares indicados e o plantio direto (CUNHA; ASSAD, 2001).

De acordo com Almeida, Perobelli e Ferreira (2008), o desenvolvimento de culturas agrícolas no espaço se dá de forma heterogênea, por depender de fatores como diferentes técnicas de produção, condições climáticas, tipos de solo e topografia. No entanto, segundo os autores, entre diferentes regiões produtoras o efeito da interdependência se manifesta por meio de diversas formas, entre elas a difusão espacial de fenômenos que influenciam os vizinhos e processos de competição espacial, sejam na expansão da fronteira agrícola ou na formação de cinturões agrícolas.

As culturas agrícolas podem ser classificadas em culturas temporárias e culturas permanentes. O primeiro caso engloba culturas de curta e média duração, com o período compreendido entre o plantio e a colheita inferior a um ano, ademais, após serem colhidas é necessário um novo plantio (IBGE, 2014).

Segundo o IBGE (2014), em virtude das condições de clima e possibilidade de irrigação, no caso das culturas temporárias, é possível o cultivo na mesma área agrícola de lavouras de mesma espécie ou espécies distintas. Em relação às culturas agrícolas temporárias divulgadas pelo IBGE, apenas algumas delas apresentam separação por safras,

sendo tal separação importante para o acompanhamento das variações de preços, da variação dos estoques e da circulação de mercadorias, além de justificar áreas plantadas superiores ao território dos municípios. Ainda segundo o IBGE, as culturas permanentes apresentam longo ciclo de vida produtiva, permitindo a colheita por vários anos sem a necessidade de um novo plantio.

## 2.2 ANÁLISE ESPACIAL

A análise espacial compreende um conjunto de técnicas capazes de mensurar propriedades e relacionamentos de acordo com a localização espacial de determinado fenômeno. De modo geral, tal conjunto de técnicas tem como principal objetivo a incorporação do espaço à análise (CÂMARA *et al.*, 2004b). Ainda segundo os autores, a classificação mais utilizada para caracterizar os problemas de análise espacial possui três categorias:

- eventos ou padrões pontuais: se enquadram nessa categoria os fenômenos identificados como pontos localizados no espaço.
- superfícies contínuas: definidos como dados espaciais estimados por um conjunto de amostras, estando elas regularmente ou irregularmente distribuídas.
- áreas com contagem e taxas agregadas: em geral se referem a indivíduos em pontos específicos do espaço, agregados em unidades de análise comumente delimitadas por polígonos fechados.

Nos três casos listados, a análise espacial tem como finalidade a escolha de um modelo que incorpore à análise os relacionamentos espaciais observados no fenômeno. Por esta razão, antes de partir para a modelagem espacial é comumente realizada a análise exploratória dos dados, buscando identificar os padrões de dependência espacial no fenômeno em questão (CÂMARA *et al.*, 2004b).

Dentre os relacionamentos espaciais incorporados à análise, estão a dependência espacial e a heterogeneidade espacial. Pode-se ter uma ideia do que representa o primeiro destes efeitos pela Primeira Lei da Geografia, comumente chamada Lei de Tobler. Tal lei foi enunciada no ano de 1970 pelo geógrafo suíço Waldo Tobler e diz que tudo depende de tudo, mas coisas próximas estão mais relacionadas entre si do que coisas mais distantes. Sendo assim, a dependência espacial consiste em o valor de uma variável em uma certa região depender do valor desta variável nas regiões próximas (ALMEIDA, 2012).

Ainda segundo Almeida (2012), processos temporais possuem relações diferentes dos processos espaciais. No sentido que, no primeiro deles o valor de uma variável qualquer no tempo  $t$  é influenciado pelo valor da variável no tempo  $t - 1$ , mas o inverso não ocorre. Diferentemente desse tipo de processo, nos processos espaciais têm-se a multidirecionalidade

nas relações entre as regiões, ou seja, o valor da variável na região  $i$  depende do valor na região  $j$ , e a região  $j$  depende da região  $i$  em relação ao valor da mesma variável. O presente trabalho se concentra na análise da dependência espacial.

Segundo Lesage (1998), a heterogenidade espacial refere-se à variação nos relacionamentos entre as variáveis ao longo do espaço, tendo em vista que, em geral, podem-se esperar diferentes relacionamentos em cada uma das unidades espaciais.

Além dessas, Almeida (2012) elenca outras particularidades dos dados espaciais tais como: a falácia ecológica, o problema da unidade de área modificável, o efeito de beirada e a influência de *outliers* espaciais.

A falácia ecológica diz respeito aos erros que têm origem ao deduzir o comportamento do indivíduo pela análise de dados agregados. Algumas razões podem fazer com que seja necessário inferir, ainda que parcialmente, comportamentos individuais por meio de dados agregados. Tais situações acontecem por exemplo quando alguns comportamentos individuais são influenciados pelo comportamento do grupo (ALMEIDA, 2012).

O problema de unidade de área modificável, usualmente denotado pela sigla MAUP, do inglês *modifiable areal unit problem*, diz respeito basicamente aos problemas causados pelas diferentes formas de delimitar as unidades espaciais. A necessidade de agregação de informações espaciais se dá pela ausência de dados individuais, ou então quando as unidades agregadas são o objeto da análise (AVILA; MONASTERIO, 2008).

Segundo Haining (2003), o MAUP apresenta dois efeitos distintos na propriedade dos estimadores. O primeiro deles está relacionado à escala da análise, ou seja, ao número de subáreas em que a região de estudo é particionada, pois tal número de partições determina também o tamanho de cada unidade espacial nas quais os eventos são observados. O segundo efeito diz respeito à partição das unidades, em outras palavras em como tais áreas estão divididas mantendo o número de áreas constante.

O chamado efeito de beirada na inferência estatística de modelos de processos espaciais se deve à possibilidade da dependência espacial ir além das fronteiras da região de estudo, podendo o valor da variável mensurada depender de outras unidades espaciais que não fazem parte da mesma (ANSELIN, 1988). Almeida (2012), acrescenta que por terem um menor número de regiões vizinhas, as regiões da fronteira também fornecem menos informação para a construção de valores médios, como por exemplo as defasagens espaciais.

Por fim, os *outliers* espaciais são definidos por Haining (2003) como valores extremos de acordo com sua posição no mapa, pois a dissimilaridade dos valores leva em consideração o conjunto de regiões vizinhas. Segundo Almeida (2012), a origem em uma base de dados espaciais de *outliers* e pontos de alavancagem pode estar relacionada ao processo de obtenção e armazenamento dos dados, porém não são somente essas suas origens. Tais

valores podem realmente sinalizar valores extremos e necessitam de uma investigação, pois podem representar características reais do fenômeno em estudo.

### 2.2.1 Matriz de Ponderação Espacial

A variabilidade espacial dos dados de uma área tem como ferramenta básica para sua estimação a matriz de ponderação espacial, que representa uma medida de proximidade entre as regiões. Tal matriz é comumente denotada por  $\mathbf{W}$ :

$$\mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{n1} & w_{n2} & \dots & w_{nn} \end{bmatrix},$$

sendo definida para um conjunto com  $n$  áreas por uma matriz quadrada de dimensão  $n \times n$ , em que cada elemento  $w_{ij}$  representa uma medida de proximidade entre as áreas  $i$  e  $j$  (CÂMARA *et al.*, 2004a).

A definição da matriz de ponderação espacial para um conjunto de dados quaisquer deve levar em consideração razões teóricas que a fundamenta. Os modelos mais tradicionais utilizam em sua maioria atributos físicos e geográficos para estabelecer distâncias entre as unidades, como por exemplo a vizinhança, a distância geográfica ou o tempo de deslocamento entre as unidades. Por outro lado, em modelos espaciais aplicados à políticas públicas, as distâncias entre as regiões estão mais relacionadas à aspectos socioeconômicos do que geográficos, sendo então tais fatores utilizados para estabelecer as relações de proximidade (TYSZLER, 2006).

Ao definir uma matriz de ponderação espacial por contiguidade são observadas as fronteiras físicas em comum entre duas regiões. Em sua forma binária, dado que tais regiões apresentam relação de vizinhança, é atribuído ao elemento correspondente na matriz o valor 1, caso contrário é atribuído o valor 0. Formalmente, tem-se:


$$w_{ij} = \begin{cases} 1, & \text{se } i \text{ e } j \text{ são contíguos} \\ 0, & \text{se } i \text{ e } j \text{ não são contíguos.} \end{cases}$$

De acordo com Almeida (2012), por convenção assume-se que cada região não é considerada vizinha de si própria, em outras palavras,  $w_{ij} = 0$  para todo  $i = j$ . Além disso, o conceito de fronteira geográfica pode apresentar diferentes definições na observação de um mapa, para isso, o movimento de peças em um tabuleiro de xadrez é utilizado para denominar algumas das diferentes convenções de contiguidade.

As três diferentes convenções de contiguidade: rainha (*queen*), torre (*rook*) e bispo (*bishop*) são, respectivamente, apresentadas na Figura 2. Na primeira delas, além das

regiões que fazem fronteira com a região  $A$ , os vértices são considerados vizinhos. Na convenção torre apenas as regiões que fazem fronteira com a região são consideradas vizinhas de  $B$ . No último caso, apenas os vértices são considerados vizinhos da região  $C$ .

Figura 2 – Representação gráfica das convenções de contiguidade para a matriz de ponderação espacial



Fonte: Do autor.

Vale ressaltar que a matriz de contiguidade binária é simétrica, no sentido que se duas regiões quaisquer  $i$  e  $j$  compartilham fronteiras físicas, tanto  $w_{ij}$  quanto  $w_{ji}$  serão iguais a 1. Desta forma, a mesma influência exercida pela região  $i$  em  $j$  será observada na relação entre  $j$  e  $i$ . Uma observação importante nesse sentido se deve ao fato de que, após a normalização nas linhas da matriz de ponderação espacial (divisão de cada elemento pela soma da linha), a simetria da matriz não será necessariamente observada, pois tais regiões podem apresentar diferentes números de vizinhos e com isso apresentar valores distintos nos pesos resultantes.

As matrizes que utilizam as distâncias geográficas como critério para a definição dos pesos partem do princípio que duas regiões próximas geograficamente apresentam maior interação espacial. Dentre as matrizes com essa definição, a matriz dos  $k$  vizinhos mais próximos é uma das mais utilizadas. Na definição,  $d_i(k)$  representa a menor distância em relação a região  $i$  para que ela tenha exatamente  $k$  vizinhos (ALMEIDA, 2012).

$$w_{ij} = \begin{cases} 1, & \text{se } d_{ij} < d_i(k) \\ 0, & \text{se } d_{ij} > d_i(k) \end{cases}$$

De acordo com Almeida (2012), a matriz de pesos espaciais gerais de Cliff e Ord (1981) parte do princípio de que duas regiões que compartilham maior extensão de fronteira apresentam uma maior interação entre si, além de considerar o fator de distância entre as regiões. Ambas as informações são utilizadas no cálculo dos pesos da matriz, sendo esses definidos pelo comprimento relativo da fronteira comum entre as regiões, ajustados pela distância inversa entre elas. Formalmente, tem-se:

$$w_{ij} = \frac{f_{ij}^\phi}{d_{ij}^\delta},$$

em que  $f_{ij}$  é a proporção da fronteira comum entre as observações  $i$  e  $j$  no perímetro de  $i$ , e  $\phi$  e  $\delta$  são parâmetros a serem definidos. Tal matriz de pesos espaciais não necessariamente

será simétrica. Ao levar em consideração a proporção do perímetro total da região  $i$  que é comum a região  $j$  em regiões de diferentes perímetros, tal proporção também seria distinta.

### 2.2.2 Análise Exploratória de Dados Espaciais

Segundo Almeida, Perobelli e Ferreira (2008), a Análise Exploratória de Dados Espaciais (AEDE) tem o objetivo de descrever como estão distribuídas espacialmente as observações buscando compreender seus padrões de associação espacial e verificando a existência de *clusters*. Além disso, cabe à metodologia analisar se existem diferentes regimes espaciais ou quaisquer formas de instabilidade, juntamente com a identificação de observações atípicas, ou como são também denominados, *outliers* espaciais.

A necessidade do emprego de tais metodologias se dá pois a identificação de padrões de associação espacial pela percepção humana tende a criar padrões enviesados, encontrando-os até mesmo em dados aleatoriamente distribuídos (MESSNER *et al.*, 1999). Por meio destas metodologias, é possível utilizar indicadores de associação espacial globais ou locais com o objetivo de identificar os diferentes regimes espaciais do conjunto de dados.

Segundo Andrade *et al.* (2007), a análise da estrutura de dependência entre os valores observados nas diversas áreas do estudo se dá pela chamada função de autocorrelação espacial. Autocorrelação, pois leva em consideração a correlação com a própria variável e espacial por considerar o espaço.

### 2.2.3 Autocorrelação Espacial Global

O índice global  $I$  de Moran é um dos principais indicadores de autocorrelação espacial global, expressando-a por meio da medida de autocovariância na forma de produto cruzado. Em tal índice,  $n$  representa o número de regiões,  $z_i$  denota o valor da variável de interesse padronizada na região  $i$  e  $S_0$  representa o somatório de todos os elementos da matriz  $\mathbf{W}$  (ALMEIDA, 2012):

$$I = \frac{n}{S_0} \frac{\sum_i \sum_j w_{ij} z_i z_j}{\sum_{i=1}^n z_i^2}. \quad (1)$$

Matricialmente, tal coeficiente pode ser calculado pela seguinte relação:

$$I = \frac{n}{S_0} \frac{z' \mathbf{W} z}{z' z},$$

em que  $\mathbf{W}z$  representa os valores médios da variável padronizada nos vizinhos de acordo com a matriz  $\mathbf{W}$ .

A equação 1 considera apenas os vizinhos de primeira ordem, no entanto, conforme apresentam Câmara *et al.* (2004a), pode-se estimar a função de autocorrelação para outros

níveis de vizinhança pelos mesmos cálculos utilizando matrizes de pesos espaciais de maior ordem ( $k$ ), ou seja:

$$I^{(k)} = \frac{n \sum_i \sum_j w_{ij}^{(k)} z_i z_j}{\sum_{i=1}^n z_i^2}.$$

Ainda de acordo com os autores, o índice  $I$  de Moran é utilizado, de forma geral, para testar a presença de autocorrelação espacial, sendo a independência espacial a hipótese nula do teste. Valores da estatística entre 0 e 1 indicam autocorrelação espacial positiva, valores entre  $-1$  e 0 indicam autocorrelação espacial negativa e, conseqüentemente, o valor 0 indica independência espacial ao nível global.

A autocorrelação espacial positiva indica que no geral, as regiões que apresentam valores altos na variável de interesse tendem a ter ao seu redor regiões que também apresentam valores altos desta variável e/ou regiões com baixos valores tendem a estar circundadas por regiões que também apresentam baixos valores. Por outro lado, a autocorrelação espacial negativa indica dissimilaridade entre os valores da variável de interesse e a localização dos mesmos. Nesse sentido, geralmente regiões com valores altos da variável estão rodeadas por regiões com baixos valores e/ou regiões com baixos valores têm ao seu redor regiões com valores altos (ALMEIDA, 2012).


Após o cálculo do índice  $I$  de Moran, é necessário verificar se a correlação espacial representada pelos valores é significativa. No entanto, como a distribuição do índice é desconhecida, o valor- $p$  pode ser obtido de duas maneiras: a associação do índice a uma distribuição estatística, geralmente a normal ou pelo teste de pseudo-significância.

A abordagem mais utilizada para tal verificação é o teste de pseudo-significância, e não apresenta pressupostos em relação à distribuição. Em tal abordagem são geradas diferentes permutações dos valores associados às regiões, produzindo assim para cada permutação um novo arranjo espacial com os valores redistribuídos entre as áreas. Dado que a situação observada corresponde somente a apenas um dos arranjos, tem-se uma distribuição empírica do índice (CÂMARA *et al.*, 2004a). Tal abordagem também é conhecida como teste de permutação aleatória.

A autocorrelação espacial pode ser adicionalmente observada por meio dos chamados diagramas de dispersão de Moran. Como exemplo, tem-se na Figura 3 o diagrama para o índice de exclusão/inclusão social de São Paulo, de acordo com o censo de 1991. No eixo horizontal de tal gráfico são representados os valores padronizados da variável de interesse, enquanto que no eixo vertical estão as médias da variável nos vizinhos das respectivas áreas, ou como também é denominada defasagem espacial.

Por meio do diagrama da Figura 3 pode-se perceber que a maior parte dos distritos do município de São Paulo localiza-se nos quadrantes  $Q1$  e  $Q2$ , indicando associação espacial positiva. No quadrante  $Q1$  estão aqueles distritos que possuem o índice de

Figura 3 – Diagrama de dispersão de Moran para o índice de exclusão/inclusão social dos distritos de São Paulo segundo o censo de 1991



Fonte: Câmara *et al.* (2004a).


exclusão/inclusão social acima da média juntamente de seus vizinhos, sendo tal regime espacial denominado alto-alto. Por outro lado, no quadrante  $Q_2$  estão os distritos que possuem o valor do índice abaixo da média juntamente de seus vizinhos, caracterizando o regime espacial baixo-baixo. Os distritos localizados nos quadrantes  $Q_3$  (alto-baixo) e  $Q_4$  (baixo-alto) não seguem o mesmo regime espacial da maioria dos distritos. Na situação em que a dispersão dos pontos no diagrama é observada predominantemente nos quadrantes  $Q_3$  e  $Q_4$  tem-se indícios de associação espacial negativa, ou seja, que as regiões possuem, em sua maioria, valores distintos de seus vizinhos (CÂMARA *et al.*, 2004a).

Vale destacar também que por meio do diagrama de dispersão de Moran é possível identificar a presença de possíveis *outliers* espaciais e pontos de alavancagem. Na Figura 4 tem-se um diagrama de dispersão de Moran hipotético destacando tais informações.

Segundo Carvalho (2008), é possível observar no diagrama da Figura 4 que os *outliers* espaciais são regiões que não apresentam o mesmo processo de dependência espacial da maioria dos dados, influenciando de forma espúria a medida de autocorrelação espacial global. Já os pontos de alavancagem são aquelas regiões que exercem grande influência sobre a reta de regressão.

Assim como o índice global  $I$  de Moran, existem outras estatísticas com esse propósito como o  $c$  de Geary proposto por Geary (1954) e o  $G$  de Getis-Ord proposto por Getis e Ord (1992). Segundo Almeida (2012), a primeira delas é construída de acordo com o quadrado da diferença entre os pares dos valores da variável em questão. Além disso, a hipótese nula, assim como no índice  $I$  de Moran, é a aleatoriedade espacial. Sua fórmula é dada por:

Figura 4 – Diagrama de dispersão de Moran de situação hipotética a fim de evidenciar *outliers* e pontos de alavancagem



Fonte: Carvalho (2008).

$$c = \frac{n-1}{2} \frac{\sum_i \sum_j w_{ij} (y_i - y_j)^2}{\sum_i (y_i - \bar{y})^2}$$

A estatística global de autocorrelação espacial proposta por Getis e Ord (1992) pode ser obtida por:

$$G(d) = \frac{\sum_i \sum_j w_{ij}(d) y_i y_j}{\sum_i \sum_j y_i y_j}, \quad \text{para } j \neq i.$$

As estatísticas anteriormente apresentadas fornecem padrões de associação linear espacial a nível global, no entanto, conforme Almeida (2012), muitas vezes o pesquisador necessita de informações localmente mais detalhadas. Surgem assim os indicadores locais de associação espacial.

#### 2.2.4 Autocorrelação Espacial Local

Indicadores locais de associação espacial ou como são geralmente denominados *local indicator of spatial association* (LISA) são, segundo Anselin (1995), quaisquer estatísticas que satisfazem duas condições:

1. o indicador local de associação espacial dá indícios da extensão de agrupamentos espaciais significativos com valores similares ao redor da observação.
2. a soma dos indicadores de associação espacial de todas as observações é proporcional ao indicador global de autocorrelação espacial.

Formalmente, o índice local de associação espacial  $I$  de Moran para a região  $i$  é dado por:

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

em que analogamente ao índice global os elementos  $z_i$  e  $z_j$  representam os valores padronizados da variável nas regiões  $i$  e  $j$ , respectivamente. Além do indicador local de Moran, existem também indicadores locais para o  $c$  de Geary e o  $G$  de Getis e Ord.

O indicador local da estatística  $c$  de Geary é dado por:

$$c_i = \sum_j w_{ij} (z_i - z_j)^2.$$

Já a estatística local proposta por Getis e Ord, pode ser obtida por:

$$G_i(d) = \frac{\sum_j w_{ij}(d) y_j}{\sum_j y_j}, \quad \text{para } j \neq i.$$

Os índices locais de associação espacial podem então ser calculados para cada uma das regiões e, de posse dos valores das estatísticas e dos respectivos níveis de significância, pode-se avaliar a associação linear espacial. No entanto a quantidade de informações gerada por esse procedimento pode não ser intuitiva se alocada na forma de tabelas, confundindo com isso o pesquisador. Como alternativa têm-se os chamados mapas LISA, que combinam as informações do diagrama de dispersão de Moran e a significância de cada uma das medidas de associação local (ALMEIDA, 2012).

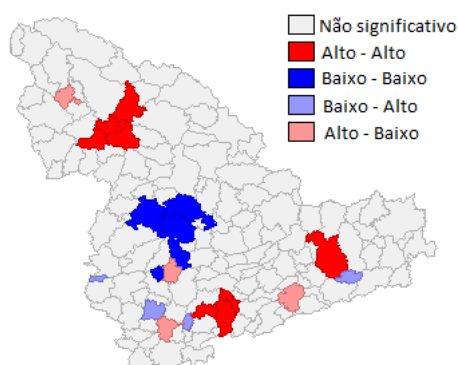
A significância do índice local de associação espacial pode ser obtida de forma similar à significância do índice global de associação espacial, a diferença nesse caso se dá em razão do valor de cada unidade de área  $z_i$  permanecer fixo na área  $i$ . Dessa forma, restam  $n - 1$  valores que são então permutados para se obter a distribuição empírica para cada uma das estatísticas locais (ANSELIN; SYABRI; KHO, 2006).

Como exemplo de mapa LISA, tem-se na Figura 5 um mapa da mesoregião Sul Sudoeste de Minas Gerais tendo como variável de interesse a produtividade do café por município.

De acordo com o mapa da Figura 5, os municípios em cinza não apresentaram o índice local de associação espacial significativo ao nível de significância de 5%, o que segundo Almeida (2012), indica que tais regiões não se encontraram em nenhum agrupamento, pois o valor da variável para a região  $i$  não foi estatisticamente diferente da média de todas as regiões.

Os demais regimes espaciais caracterizam diferenças estatisticamente significativas entre os valores da variável nos municípios e em seus vizinhos. Os municípios com regime

Figura 5 – Mapa LISA da produtividade do café - Sul e Sudoeste de Minas Gerais em 2012



Fonte: Garcia (2018).

espacial alto-alto e baixo-baixo seriam aqueles que em um diagrama de dispersão de Moran, como o exemplificado na Figura 3, estariam nos quadrantes  $Q_1$  ou  $Q_2$  a depender dos valores padronizados dos municípios e da defasagem espacial. Já os municípios com regimes baixo-alto e alto-baixo apresentaram discrepâncias entre os valores da variável nos municípios e nos municípios vizinhos.

No presente trabalho a estatística  $I$  de Moran foi utilizada para a análise da autocorrelação espacial, tanto no nível global quanto no nível local. Segundo Assunção e Reis (1999), o índice  $I$  de Moran é a estatística comumente mais utilizada para analisar o grau de similaridade. Além disso, de acordo com Almeida (2012) para a análise da instabilidade local as diferentes estatísticas apresentam vantagens e desvantagens. Nesse sentido, o autor destaca que em comparação ao  $I$  de Moran local, ainda que a estatística local proposta por Getis e Ord (1992) apresente uma definição mais clara dos agrupamentos espaciais, tal estatística não é capaz de detectar valores espacialmente discrepantes (*outliers* espaciais).

### 3 MATERIAL E MÉTODOS

O presente trabalho utiliza dados da Produção Agrícola Municipal (PAM) do IBGE (2021b) obtidos por meio do Sistema IBGE de Recuperação Automática (SIDRA). Tal base de dados fornece informações como áreas de lavouras, produção obtida, rendimento médio, valor da produção e outras, para 31 culturas agrícolas de lavouras temporárias e 33 culturas de lavouras permanentes, em relação aos municípios, microrregiões, mesorregiões, unidades da federação, grandes regiões e do país como um todo. As pesquisas possuem periodicidade de divulgação anual e encontram-se sob responsabilidade do IBGE desde o ano de 1974.

A fim de selecionar os objetos da pesquisa, as culturas presentes na base de dados PAM-IBGE foram ordenadas em relação ao valor total da produção (em reais) no ano de 2018, conforme Tabela 1. Desta forma, as culturas foram selecionadas segundo sua relevância em relação ao valor total da produção no último ano da análise, utilizando como ponto de corte o valor de R\$ 5 bilhões de reais.

Conforme definições do IBGE (2014) a variável valor da produção é obtida pela média ponderada das informações de quantidade e preço médio corrente pago ao produtor, de acordo com os períodos de colheita e comercialização de cada produto. Além disso, o cálculo da variável não inclui despesas de frete, taxas e impostos ao preço.

Tabela 1 – Quantidades totais produzidas e valores totais da produção das culturas agrícolas ordenadas segundo o valor total da produção no ano de 2018

cultura	quantidade total produzida <sup>1</sup>		valor total da produção <sup>2</sup>
	2008	2018	2018
soja (em grão)	59.833.105	117.887.672	127.549.867
cana-de-açúcar	645.300.182	746.828.157	52.238.542
milho (em grão)	58.933.347	82.288.298	37.644.731
café (em grão total)	2.796.927	3.556.638	22.623.368
algodão (herbáceo em caroço)	3.983.181	4.956.044	12.790.580
mandioca	26.703.039	17.644.733	9.718.965
laranja	18.538.084	16.713.534	9.450.570
arroz (em casca)	12.061.465	11.749.192	8.650.626
banana (cacho)	6.998.150	6.752.171	6.975.536
fumo (em folha)	851.058	762.266	6.510.625
feijão (em grão)	3.461.194	2.915.030	5.693.442
tomate	3.867.655	4.110.242	5.088.543

Fonte: Do autor.

Nota:

<sup>1</sup> quantidade total produzida, em toneladas.

<sup>2</sup> valor total da produção, em reais, no ano de 2018.

Após a seleção das culturas, foi utilizada para a análise espacial a variável quantidade produzida (em toneladas). Segundo o IBGE (2014), tal variável é definida como a quantidade de produto obtida na área colhida no ano base do levantamento, em toneladas,

com exceção do abacaxi e do coco-da-baía. Destaca-se também que a Tabela 1 apresenta as quantidades totais das culturas nos anos de 2008 e 2018, tendo em vista que a participação de cada uma das regiões em termos percentuais na produção total do país nos respectivos anos também foi empregada no trabalho.

Para a delimitação das unidades geográficas foi utilizada a divisão em municípios, por meio dos arquivos de malhas geográficas obtidos do Portal de Mapas do IBGE (2021a). Tal divisão foi de encontro ao menor nível de agregação da base de dados, fornecendo assim uma análise mais detalhada conforme os dados disponíveis. Por meio das malhas foram obtidas as relações de vizinhança entre os municípios e elaborados os mapas temáticos e os mapas LISA.

A linguagem de programação *Python* foi utilizada para a aplicação dos métodos e elaboração dos gráficos, por meio do ambiente de desenvolvimento *Google Colaboratory* (Colab). Os códigos utilizados encontram-se no Apêndice. Para o tratamento dos dados e obtenção dos resultados foram utilizadas bibliotecas da linguagem tais como *numpy*, *pandas*, *geopandas*, *mapclassify*, *plot*, *libpysal* e *matplotlib*.

Após tais definições partiu-se para a análise descritiva do conjunto de dados. Em tal etapa foram elaborados gráficos e tabelas de forma a compreender a distribuição dos valores para os diferentes tipos de culturas. Como medidas resumo, foram calculadas a média amostral ( $\bar{x}$ ), o coeficiente de variação (CV) e os quartis para a quantidade produzida de cada uma das culturas.

Para a comparação das quantidades produzidas dos municípios nos anos de 2008 e 2018 utilizou-se de mapas temáticos, construídos de acordo com intervalos de valores obtidos por meio do método de classificação Fisher-Jenks. Tal método, segundo Rey *et al.* (2013), é frequentemente recomendado por cartógrafos, sendo apresentado por Jenks (1977) e originalmente proposto por Fisher (1958), a abordagem baseia-se no particionamento ideal de dados univariados.

O método foi aplicado aos dados de cada uma das culturas em 2018, com o objetivo de estabelecer quatro intervalos de valores, sendo posteriormente tais intervalos aplicados aos dados de 2008. Assim, foi possível estabelecer uma comparação direta entre ambos os mapas. Vale destacar que em tal classificação foram desconsiderados os municípios que não apresentaram quantidade produzida no ano em questão.

A definição da matriz de ponderação espacial adotada foi a convenção rainha (*queen*), normalizada em relação às linhas. Tal normalização consistiu na divisão de cada um dos valores da matriz em sua forma binária pela soma das respectivas linhas. Com isso, garante-se a conectividade balanceada entre as regiões, de forma que, como apontado por Almeida (2012), podem existir regiões com um grande número de vizinhos e outras com poucos.


As significâncias das estatísticas globais de autocorrelação espacial foram verificadas por meio do teste de permutação aleatória, ou como também é conhecido teste de pseudo-significância. O mesmo consistiu na geração de 999 diferentes permutações dos valores associados a cada uma das regiões, mantendo a matriz de ponderação espacial fixa. Como a situação observada corresponde a apenas um dos arranjos, obteve-se então uma distribuição empírica da estatística e assim foram estimados os pseudo valores- $p$ .

Na situação em que não há dependência espacial o valor da variável em uma região poderia estar em qualquer outra região, estando com isso o valor observado da estatística próximo ao centro da distribuição. Tal situação consiste na hipótese nula do teste ( $H_0$ ), que seria a aleatoriedade espacial. Por outro lado, haveriam indícios de autocorrelação espacial se o valor observado estivesse próximo aos extremos da distribuição, dependendo sua significância do nível  $\alpha$  fixado. Os níveis de significância adotados para os testes globais e locais da autocorrelação espacial foram ambos iguais a 5%.

#### 4 RESULTADOS E DISCUSSÃO

Inicialmente, buscou-se indícios da participação de cada uma das cinco regiões do país na produção das culturas selecionadas na análise. Tal etapa consistiu na visualização do percentual das quantidades produzidas por meio do gráfico de colunas empilhadas para ambos os anos, conforme Figura 6.

Figura 6 – Porcentagem da quantidade produzida, em toneladas, das culturas em cada região do país nos anos de 2008 e 2018



Fonte: Do autor.

No ano de 2008, a região Centro-Oeste foi responsável por cerca de 64% de toda a produção de algodão do país, aumentando sua participação para 70% em 2018. Além disso, pode-se destacar a participação dessa região na produção de soja e milho. O arroz foi predominantemente produzido na região Sul, contando com cerca de 70% do total em 2008 e 81% no ano de 2018. Nesse sentido, vale destacar também a predominância das produções de café, cana-de-açúcar e laranja no Sudeste e da cultura agrícola fumo no Sul do país.

Entre os anos de 2008 e 2018, pode-se destacar as alterações nos percentuais de produção em cada uma das regiões. Na região Centro-Oeste houve redução da participação na produção do arroz, passando de cerca de 9% para 6% do total produzido no país. Ainda em relação ao arroz, destaca-se a redução da participação das regiões Nordeste e Sudeste, e o aumento da participação da região Sul do país. Em relação à participação das regiões na produção de café, houve redução na região Sul e aumento na região Sudeste.

Posteriormente, foram obtidas as medidas resumo sobre a quantidade produzida (em toneladas) dos municípios brasileiros. Em tal análise foram desconsiderados, para cada cultura agrícola, os municípios que não tiveram produção nos respectivos anos. Assim, foram observados os números de municípios produtores e calculadas as médias amostrais ( $\bar{x}$ ), os coeficientes de variação ( $CV$ ), os valores máximos, os valores mínimos e os quartis.

Na Tabela 2 estão apresentadas as estatísticas calculadas para as culturas selecionadas no ano de 2008.

Tabela 2 – Medidas resumo da quantidade produzida (em toneladas) das culturas agrícolas em 2008

cultura	$n$	$\bar{x}$	$CV$	mín.	25% ( $Q_1$ )	50% ( $Q_2$ )	75% ( $Q_3$ )	máx.
algodão	722	5.516,87	525	1,00	12,00	54,00	360,00	534.342,00
arroz	3.417	3.529,84	649	1,00	28,00	148,00	945,00	650.642,00
banana	3.494	2.002,90	414	2,00	80,00	220,00	834,50	158.400,00
café	1.838	1.521,72	251	1,00	22,00	124,00	913,75	40.315,00
cana-de-açúcar	3.727	173.141,99	300	2,00	834,00	3.600,00	44.730,00	10.260.000,00
feijão	4.741	730,06	425	1,00	44,00	136,00	450,00	123.840,00
fumo	925	920,06	254	1,00	19,00	104,00	612,00	23.650,00
laranja	3.028	6.122,22	521	1,00	52,00	165,00	700,00	556.160,00
mandioca	4.726	5.650,24	296	6,00	400,00	1.362,50	4.477,50	592.000,00
milho	5.322	11.073,53	328	1,00	349,25	1.536,00	7.732,50	997.440,00
soja	1.830	32.695,69	289	1,00	1.024,50	6.240,00	26.415,00	1.794.000,00
tomate	1.903	2.032,40	463	3,00	60,00	200,00	800,00	239.400,00

Fonte: Do autor.

Pode-se observar na Tabela 2 que o algodão, por exemplo, contou em tal ano com 722 municípios produtores, quantidade produzida média de 5.516,87 toneladas e coeficiente de variação igual a 525%. Além disso, os valores mínimos e máximos observados para os municípios produtores da cultura foram de 1 tonelada e 534.342 toneladas, respectivamente. Quanto à distribuição dos valores, vale destacar que 50% dos municípios produtores de algodão contaram com quantidades produzidas entre 12 e 360 toneladas.

Em relação aos números de municípios produtores pode-se destacar as culturas milho, feijão e mandioca com os maiores números de produtores, respectivamente, 5.322, 4.741 e 4.726 municípios. Já os menores números de municípios produtores foram observados para o algodão, com 722 municípios, e para o fumo, com 925 municípios. No que diz respeito aos coeficientes de variação os maiores valores foram observados para o arroz, o algodão e a laranja, sendo respectivamente iguais à 649%, 525% e 521%. Por outro lado,

as culturas café e fumo contaram com os menores coeficientes de variação sendo iguais à 251% e 254%.

Por se trataram de culturas com diferentes características, tal comparação entre as culturas não se estendeu às quantidades produzidas médias, aos quartis e aos valores extremos. No entanto, destaca-se em todas as culturas as diferenças observadas entre as quantidades produzidas médias e a mediana da quantidade produzida, representada pelo segundo quartil das distribuições dos valores. Tal diferença evidencia a presença de municípios com altas quantidades produzidas, sendo tais valores discrepantes se comparados aos demais.

Na Tabela 3 estão apresentadas as estatísticas calculadas para as culturas no ano de 2018.

Tabela 3 – Medidas resumo da quantidade produzida (em toneladas) das culturas agrícolas em 2018

cultura	$n$	$\bar{x}$	CV	mín.	25% ( $Q_1$ )	50% ( $Q_2$ )	75% ( $Q_3$ )	máx.
algodão	223	22.224,41	338	1,00	14,00	390,00	10.482,50	756.891,00
arroz	1.925	6.103,48	608	1,00	10,00	78,00	720,00	755.486,00
banana	3.399	1.986,52	459	1,00	51,00	160,00	748,00	210.975,00
café	1.448	2.456,24	244	1,00	16,00	135,00	1.616,25	82.830,00
cana-de-açúcar	3.345	223.267,01	280	2,00	420,00	1.800,00	75.000,00	8.118.000,00
feijão	4.330	673,22	429	1,00	24,00	84,00	298,00	63.870,00
fumo	651	1.170,92	248	1,00	20,00	110,00	690,50	26.790,00
laranja	2.420	6.906,42	444	1,00	40,00	155,00	902,50	510.000,00
mandioca	4.730	3.730,39	350	1,00	170,00	607,50	2.280,00	373.809,00
milho	5.069	16.233,64	500	1,00	185,00	1.108,00	6.840,00	2.851.200,00
soja	2.318	50.857,49	267	2,00	1.800,00	10.800,00	43.557,50	2.232.000,00
tomate	1.788	2.298,79	567	4,00	58,00	172,50	800,00	356.000,00

Fonte: Do autor.

Conforme a Tabela 3, destaca-se, respectivamente, com os maiores números de municípios produtores em 2018 as culturas milho, mandioca e feijão. Por outro lado, os menores valores foram observados para as culturas algodão e fumo, que contaram com 223 e 651 municípios produtores. Em relação aos coeficientes de variação os maiores valores foram observados no ano de 2018 para as culturas arroz, tomate e milho, enquanto que as culturas café, fumo e soja apresentaram os menores valores do coeficiente.

Tal como destacado no ano de 2008, destaca-se também no ano de 2018 as diferenças observadas entre a quantidade produzida média e a mediana da quantidade produzida.

Comparando as estatísticas entre os anos de 2008 e 2018, pode-se destacar que entre os anos as cinco culturas com os maiores números de municípios produtores em 2008 também contaram com os maiores valores no ano de 2018. No entanto, com exceção da cultura milho, houveram alterações no ordenamento dos números de municípios produtores das culturas desse grupo. Já em relação aos menores números de produtores, além do fato de que as culturas algodão e fumo também apresentaram os menores valores em 2018,

destaca-se que tais números foram ainda menores do que no início da comparação.

De modo geral, nota-se que entre 2008 e 2018 as culturas algodão, arroz, café, cana-de-açúcar, fumo e laranja, tiveram redução no número de municípios produtores e no coeficiente de variação, enquanto que suas quantidades médias produzidas aumentaram. Por outro lado, a cultura mandioca contou com um maior número de municípios produtores e maior dispersão dos valores em relação à média, além de redução na quantidade produzida média em 2018. As culturas milho e tomate contaram com maiores médias e coeficientes de variação no último ano e redução de municípios produtores. As culturas banana e feijão apresentaram em 2018 menores números de municípios produtores e de quantidade produzida média, além de maior coeficiente de variação, enquanto a cultura soja apresentou comportamento distinto das duas últimas culturas.

Para identificar a existência ou não de autocorrelação espacial nas culturas utilizou-se primeiramente a estatística  $I$  de Moran global, por meio da matriz de ponderação espacial rainha. A significância de tais valores foi verificada por meio do teste de permutação aleatória, estando seus respectivos pseudo-valores de probabilidade presentes nas colunas valor- $p$  da Tabela 4. As culturas foram ordenadas de forma decrescente, segundo os valores da estatística em 2008.

Tabela 4 –  $I$  de Moran global para as culturas nos anos de 2008 e 2018 e pseudo-valores- $p$

cultura	2008		2018	
	$I$ de Moran	valor- $p$	$I$ de Moran	valor- $p$
fumo	0,614	0,001	0,511	0,001
café	0,599	0,001	0,601	0,001
cana-de-açúcar	0,599	0,001	0,621	0,001
soja	0,546	0,001	0,540	0,001
arroz	0,536	0,001	0,498	0,001
laranja	0,501	0,001	0,418	0,001
milho	0,489	0,001	0,545	0,001
banana	0,341	0,001	0,281	0,001
mandioca	0,337	0,001	0,413	0,001
feijão	0,305	0,001	0,429	0,001
algodão	0,266	0,001	0,252	0,001
tomate	0,150	0,001	0,088	0,002

Fonte: Do autor.

Ao nível de significância de 5%, todas as culturas apresentaram autocorrelação espacial em ambos os anos, o que dá indícios de que a quantidade total produzida está autocorrelacionada espacialmente nos municípios brasileiros. Mais que isso, pelos sinais positivos das estatísticas há evidências de que municípios com quantidades totais produzidas acima da média, em geral, também são vizinhos de municípios com quantidades totais produzidas acima da média. Além disso, quanto mais próximos de 1 estiverem os valores da estatística, mais forte a concentração espacial destes. Nesse sentido, vale destacar que a cultura tomate apresentou a menor autocorrelação espacial nos dois anos avaliados.

Ainda sobre a autocorrelação espacial global, destaca-se o aumento no valor da estatística no ano de 2018 para as culturas café, cana-de-açúcar, feijão, mandioca e milho, e redução em tal valor para as culturas algodão, arroz, banana, fumo, laranja, soja e tomate.

De posse de tais resultados partiu-se para uma análise mais detalhada da localização dos regimes espaciais encontrados. Para cada uma das culturas foram elaborados mapas temáticos, diagramas de dispersão de Moran e os mapas LISA em relação aos dois anos. Dessa forma, foi possível identificar a localização de agrupamentos e valores discrepantes segundo sua localização no espaço.

A apresentação e a discussão dos resultados da análise exploratória de dados espaciais foi dividida em subseções, contendo cada uma delas uma cultura do estudo. Para cada cultura, são apresentados os mapas temáticos de 2008 e 2018, além dos diagramas de dispersão de Moran e dos mapas LISA que são apresentados no Apêndice. Ao final da análise de cada uma das culturas selecionadas, apresenta-se uma análise comparativa das alterações ocorridas entre as culturas, de forma a destacar indícios dos processos de competição espacial entre as mesmas.

#### 4.1 ALGODÃO

Conforme as quantidades produzidas percentuais da cultura algodão, apresentadas na Figura 6, a região Centro-Oeste foi responsável por cerca de 64% de toda produção da cultura do país no ano de 2008, alcançando 70% da produção em 2018. A região Nordeste, por sua vez, foi responsável por aproximadamente 32% e 28% da produção do país, nos anos de 2008 e 2018, respectivamente.

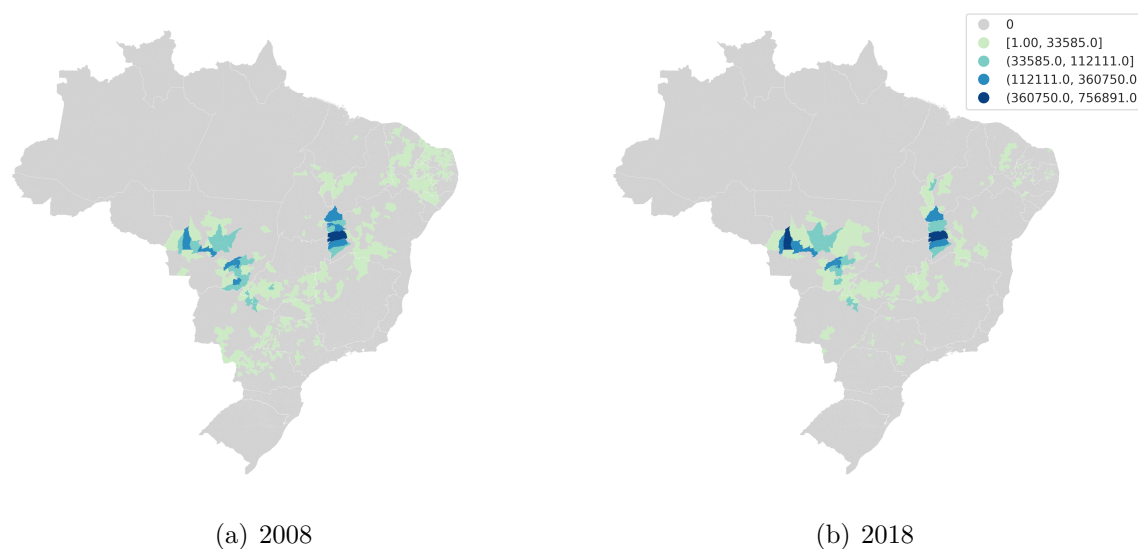
Os mapas temáticos da quantidade produzida de algodão, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 7.

Observa-se nos mapas temáticos os municípios com as maiores quantidades produzidas nas regiões Centro-Oeste e Nordeste, em especial nos estados do Mato Grosso e da Bahia. Entre as alterações observadas nos anos 2008 e 2018, pode-se destacar o aumento da produtividade em algumas áreas do estado do Mato Grosso, que passaram do terceiro para o quarto intervalo de valores de quantidade produzida. Na vizinhança dessas áreas, destaca-se também municípios que passaram do segundo para o terceiro intervalo. Por outro lado, algumas localidades tiveram redução da quantidade produzida, migrando com isso para menores faixas de valores, como é o caso dos municípios localizados no sul do estado do Mato Grosso, e também, daqueles localizados ao norte da área com a maior produtividade no estado da Bahia.

Os diagramas de dispersão de Moran e os mapas LISA para a cultura algodão estão apresentados na Figura 19 do Apêndice.

Os diagramas de dispersão de Moran da cultura evidenciam que, conforme ob-

Figura 7 – Mapas temáticos para a quantidade de algodão produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

servado nas estatísticas globais de autocorrelação espacial, houve em 2018 o aumento da concentração espacial. Além disso, os pontos mais dispersos abaixo da reta de ajuste evidenciam municípios com altos valores padronizados de quantidades produzidas e baixa defasagem espacial, nos dois anos analisados.

Em relação aos mapas indicadores de autocorrelação espacial local, destaca-se, além das regiões mencionadas nos mapas temáticos, municípios em seus arredores. Tal situação se deve ao fato de que, a referência a alto e baixo está relacionada à média da variável, e não ao seu valor absoluto. Ou seja, os municípios com regime espacial alto-alto possuem quantidades produzidas acima da média juntamente a seus vizinhos e não os maiores valores de quantidades produzidas.

Entre os anos de 2008 e 2018, observa-se que os agrupamentos alto-alto, predominantemente localizados no estado do Mato Grosso, se tornaram um único agrupamento em razão da mudança ou significância dos regimes espaciais dos municípios localizados ao leste, na parte superior do agrupamento. Por outro lado, os municípios localizados na parte inferior do agrupamento, em sua maioria não apresentaram regime espacial significativo. Já em relação ao agrupamento alto-alto localizado na região Nordeste, observou-se a mudança no regime espacial de municípios localizados ao norte do agrupamento, e com isso, o aumento em sua extensão.


No que diz respeito aos municípios com quantidades produzidas espacialmente discrepantes (*outliers* espaciais), destaca-se aqueles com regime espacial baixo-alto nas fronteiras dos agrupamentos alto-alto. Estes, delimitam municípios que, juntamente de seus

vizinhos, tiveram quantidades produzidas de algodão acima da média. Por fim, municípios com regime espacial alto-baixo foram identificados nos anos de 2008 e 2018 nas regiões Centro-Oeste, Sudeste e Nordeste do país.

## 4.2 ARROZ

Os mapas temáticos da quantidade produzida de arroz, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 8.

Figura 8 – Mapas temáticos para a quantidade de arroz produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

Ao analisar os mapas temáticos, observa-se que a cultura arroz apresentou o maior número de municípios com quantidades produzidas acima do primeiro intervalo de valores na região Sul do país, em especial no estado do Rio Grande do Sul. Conforme apresentado na Figura 6, a região Sul foi responsável por cerca de 70% da quantidade produzida no país em 2008 e aproximadamente 82% em 2018. No entanto, outras áreas também se destacaram nos mapas temáticos da cultura nas regiões Centro-Oeste e Norte do país, que foram responsáveis, respectivamente, por cerca de 9% e 8,5% em 2008, e 6% e 9% em 2018, do total produzido no país. A região Nordeste, ainda que não tenha apresentado municípios com grandes quantidades produzidas em tais mapas, foi responsável por aproximadamente 10% da produção do país em 2008, reduzindo sua participação para cerca de 3% em 2018.

Pela comparação dos mapas temáticos da cultura em 2008 e 2018, pode-se perceber o aumento da produtividade em uma área localizada no oeste do estado do Rio Grande do Sul, migrando para o quarto intervalo de valores, além de uma região no sul do estado que migrou do primeiro para o segundo intervalo. Nas demais regiões, destaca-se a redução da

quantidade produzida em municípios no Centro-Oeste e no Norte, além do aumento da produção de áreas mais ao centro do país.

Os diagramas de dispersão de Moran e os mapas *LISA* para a cultura arroz estão apresentados na Figura 20 do Apêndice.

Os diagramas de dispersão de Moran da cultura apresentam redução na inclinação da reta de ajuste em 2018, dado que a estatística global de autorrelação espacial passou de 0,536 para 0,498 em 2018, conforme apresentado na Tabela 4. Além disso, pontos mais distantes dos demais foram observados acima e abaixo da reta. No primeiro caso, indicam municípios que tiveram menor valor padronizado da quantidade produzida e alta defasagem espacial, enquanto que, no segundo caso, estão municípios com maior valor padronizado da quantidade produzida e baixa defasagem espacial, segundo a reta de ajuste.

Os agrupamentos espaciais presentes nos mapas *LISA*, evidenciam na região Sul do país, a permanência do regime espacial dos municípios pertencentes ao principal agrupamento alto-alto, localizado no estado do Rio Grande do Sul. Além disso, destaca-se no interior de tal agrupamento, municípios que tiveram regime espacial baixo-alto. Estes, ainda que cercados por municípios com quantidades produzidas acima da média, tiveram baixa produção em relação a média.

Nas demais regiões do país, destaca-se de 2008 para 2018, a mudança ou a não significância do regime espacial dos municípios localizados no centro do agrupamento alto-alto próximo à região Centro-Oeste. Além disso, observou-se, em 2018, na região Norte a não significância do regime espacial de grande parte dos municípios do agrupamento alto-alto no estado de Roraima.


### 4.3 BANANA

Os mapas temáticos da quantidade produzida de banana, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 9.

Tais mapas, apresentam municípios em destaque nas regiões Norte, Nordeste, Sudeste e Sul. Em 2008, as regiões Norte e Nordeste foram responsáveis por aproximadamente 12% e 41% do total de banana produzido no país, passando, respectivamente, para 13% e 33% do total em 2018. As regiões Sul e Sudeste representaram cerca de 13% e 30% da quantidade produzida em 2008, aumentando sua participação no ano de 2018 para 15% e 34%.

Ainda em relação aos mapas temáticos, pode-se destacar que na região Norte, houve o aumento da produção em municípios que antes estavam compreendidos no segundo intervalo de valores e passaram a pertencer ao terceiro intervalo em 2018. Em suas proximidades, destaca-se, no oeste o aumento da produção de municípios que em 2008 se encontravam no primeiro intervalo, e ao leste a redução da quantidade produzida de

Figura 9 – Mapas temáticos para a quantidade de banana produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

alguns municípios. Além disso, houve redução da quantidade produzida em municípios do estado do Acre.

Na região Nordeste, observou-se um maior número de áreas em destaque, com menores extensões e mais distantes entre si. Os municípios com as maiores quantidades produzidas se localizaram no estado da Bahia, sendo observada a permanência de alguns desses em 2008 e 2018, e o aumento da produção da área mais ao sul apenas em 2018. Ainda sobre o estado da Bahia, vale destacar a redução da quantidade produzida em alguns municípios localizados próximos ao litoral do estado.

As demais áreas em destaque nos mapas temáticos se concentraram principalmente nos estados de São Paulo e Paraná, em municípios próximos ao litoral. Em tais localidades, destaca-se a redução da quantidade produzida entre 2008 e 2018, em alguns municípios do estado de São Paulo, e aumento em municípios do Paraná. Destaca-se também que, alguns desses municípios apresentaram quantidade produzida na faixa de valores do último intervalo.

Os diagramas de dispersão de Moran e os mapas LISA para a cultura banana estão apresentados na Figura 21 do Apêndice.

O diagrama de dispersão de Moran da cultura no ano de 2018 apresenta menor inclinação da reta de ajuste, indicando uma menor concentração espacial do que a observada em 2008, o que é comprovado pelos valores das estatísticas globais. Além disso, em ambos os anos, foram observados valores mais distantes dos demais, abaixo da reta.

Os agrupamentos espaciais, obtidos por meio dos mapas LISA, indicam a presença

de agrupamentos alto-alto nas proximidades daqueles municípios destacados nos mapas temáticos. As principais modificações ocorridas entre 2008 e 2018 foram, a mudança do regime espacial de municípios próximos ao agrupamento de maior extensão na região Norte, o maior número de municípios com regime espacial alto-alto próximos aos estados de Roraima e Rondônia, e as mudanças de regimes espaciais de municípios no Acre.

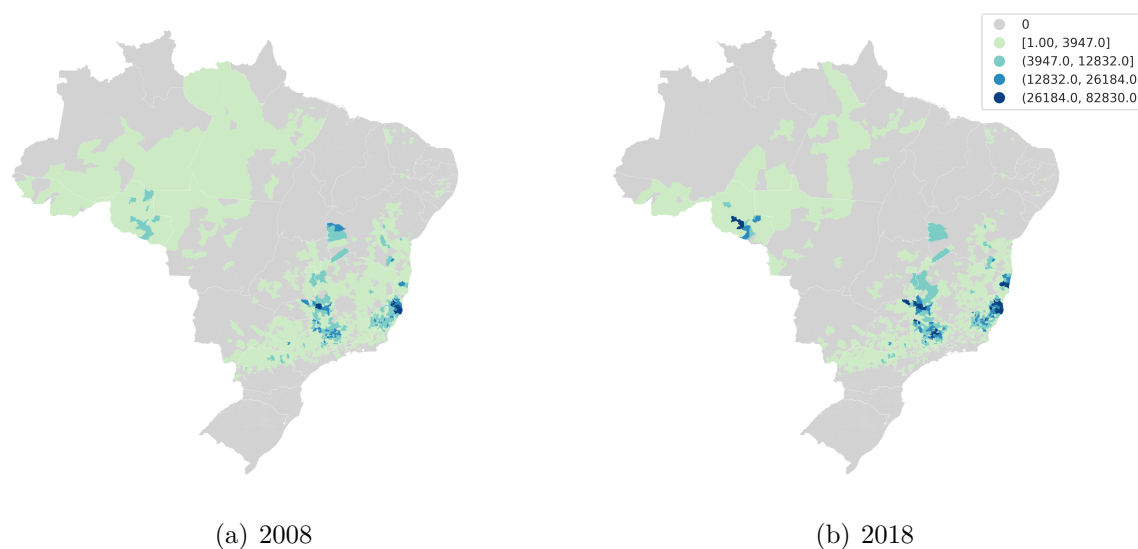
Em 2018, observa-se que na região Nordeste os agrupamentos alto-alto tiveram menores extensões e estiveram mais distantes entre si, podendo destacar também a diminuição no número de agrupamentos no estado da Bahia. No Sudeste, observou-se o aumento do número de municípios pertencentes ao agrupamento alto-alto no estado do Espírito Santo. Por fim, destaca-se no ano de 2008 a presença de municípios com regime espacial alto-baixo nos estados Minas Gerais e São Paulo, mas no ano de 2018 tal regime espacial foi observado somente no estado de São Paulo.

#### 4.4 CAFÉ

A cultura café contou com a predominância de sua produção no Sudeste do país, em ambos os anos analisados. Em 2008, tal região foi responsável por aproximadamente 82% do total de café produzido no país, aumentando sua participação para 86% em 2018.

Os mapas temáticos da quantidade produzida de café, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 10.

Figura 10 – Mapas temáticos para a quantidade de café produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

Como observa-se nos mapas temáticos, a cultura apresentou a maior concentração de municípios com quantidades produzidas acima do primeiro intervalo de valores nos

estados de Minas Gerais e do Espírito Santo. Além desses, pode-se destacar municípios no sul do estado da Bahia e no estado de Rondônia.

Entre os anos de 2008 e 2018, observou-se o aumento da quantidade produzida em municípios dos estados de Minas Gerais, Espírito Santo, Bahia e Rondônia, que alcançaram a maior faixa de valores de quantidades produzidas. Além desses, alguns municípios localizados ao norte dos municípios em destaque no estado de Minas Gerais, tiveram produção acima de 3.654 toneladas no ano de 2018.

Os diagramas de dispersão de Moran e os mapas LISA para a cultura café estão apresentados na Figura 22 do Apêndice.

No que diz respeito à dispersão dos pontos nos diagramas de dispersão de Moran, observou-se em ambos os anos maior concentração dos pontos em torno da reta de ajuste. As principais exceções foram dois municípios em 2008 e apenas um com o distanciamento dos demais ainda maior em 2018. O último município se destacou principalmente pelo alto valor padronizado da quantidade produzida. Além desses, vale destacar a concentração de alguns pontos abaixo da reta de ajuste, entre os valores padronizados de quantidade produzida de 5 e 12.

Em relação aos mapas *LISA*, os principais agrupamentos alto-alto observados se localizaram nos estados de Minas Gerais, Espírito Santo, Bahia e Rondônia. Desses, pode-se destacar algumas alterações nos agrupamentos nos dois primeiros estados. No agrupamento em Minas Gerais, tais alterações foram a significância do regime espacial do município no norte do primeiro agrupamento e a mudança de regime espacial de baixo-alto para alto-alto de um município a oeste. No Espírito Santo as alterações foram a significância ou não dos regimes dos municípios localizados nas extremidades do agrupamento.

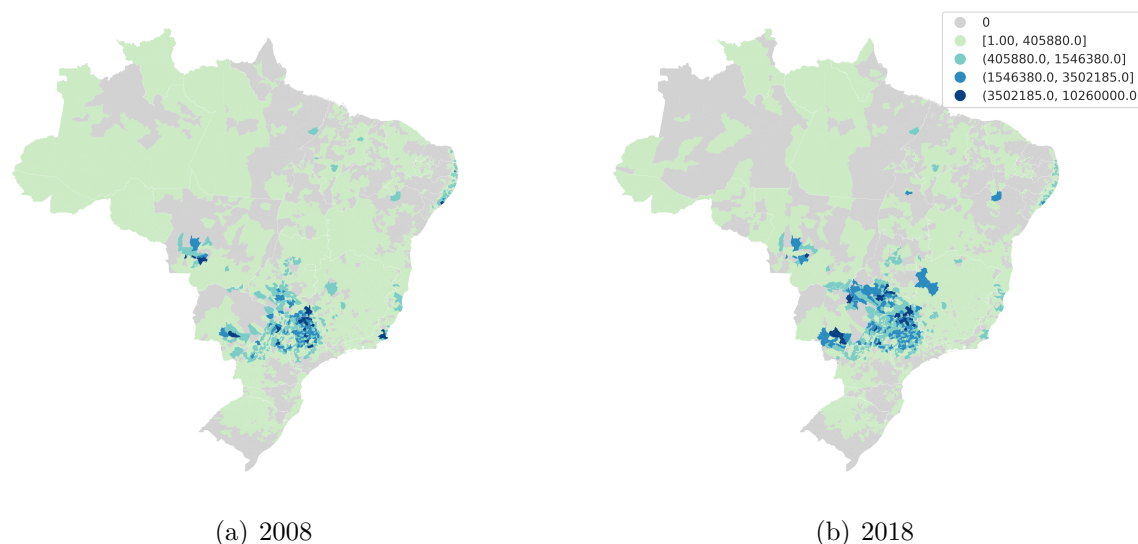
Nos agrupamentos alto-alto dos demais estados, destaca-se, na Bahia o aumento do número de municípios pertencentes ao agrupamento próximo ao litoral e a não significância do regime espacial de dois municípios que em 2008 tinham regime alto-alto. Já no estado de Rondônia, observou-se a mudança do regime espacial de um município de baixo-alto para alto-alto e a significância do regime de um município vizinho ao mesmo, além da não significância em 2018 dos municípios ao norte de tal agrupamento.

#### 4.5 CANA-DE-AÇÚCAR

A cana-de-açúcar apresentou a maior concentração de sua quantidade produzida na região Sudeste do país, representando 69% em 2008 e 68% do total produzido em 2018. Os percentuais das demais regiões em 2018 foram: a região Centro-Oeste com 19%, a região Nordeste com 7% e o Sul com 5% da quantidade produzida total. Tais regiões, representaram no ano de 2008, 8% na região Sul e aproximadamente 11% nas demais. A região Norte representou menos de 1% da produção de cana-de-açúcar em ambos os anos.

Os mapas temáticos da quantidade de cana-de-açúcar produzida, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 11.

Figura 11 – Mapas temáticos para a quantidade de cana-de-açúcar produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

Segundo os mapas temáticos, a maior concentração de municípios acima do primeiro intervalo de valores foi observada entre as regiões Sudeste e Centro-Oeste do país. Tal localidade contou com o aumento da produtividade em diversos municípios entre os anos de 2008 e 2018, mas principalmente daqueles localizados na região Centro-Oeste. Além disso, observa-se que os municípios pertencentes ao último intervalo de valores de quantidade produzida estão nos estados de Minas Gerais, São Paulo, Goiás, Mato Grosso do Sul e Mato Grosso. No ano de 2008, municípios no estado do Rio de Janeiro e no Nordeste também apresentaram quantidades produzidas nessa faixa de valores, porém suas produtividades foram menores em 2018.

Os diagramas de dispersão de Moran e os mapas LISA para a cultura cana-de-açúcar estão apresentados na Figura 23 do Apêndice.

Os diagramas de dispersão de Moran da cultura apresentaram maior inclinação da reta de ajuste, tendo em vista que a estatística global de Moran passou de 0,599 em 2008 para 0,621 em 2018. Além disso, um município se distanciou dos demais em 2008, destacando também grupos de municípios que ficaram acima ou abaixo da reta em tal ano. Em 2018, tais grupos se destacaram principalmente abaixo da reta.

Os mapas *LISA* da cultura evidenciam o maior agrupamento em número de municípios de regime espacial alto-alto entre o Sudeste e o Centro-Oeste do país. Tal agrupamento contou com a mudança de municípios de regime baixo-alto em 2008 e

municípios com regimes espaciais não significativos, para o regime alto-alto, principalmente no sentido da região Centro-Oeste.

Os agrupamentos nos estados do Mato Grosso e do Mato Grosso do Sul também contaram com um número maior de municípios em 2018, podendo destacar além disso em tal ano, a então significância de um agrupamento alto-alto próximo ao Norte do estado de Minas Gerais. Já os agrupamentos localizados no Nordeste e no Rio de Janeiro não apresentaram regimes espaciais significativos em 2018.

Por fim, em relação aos municípios com quantidades produzidas espacialmente discrepantes, observou-se em 2008 municípios com regime alto-baixo nos estados do Amazonas, do Pará, do Mato Grosso, Tocantins e Bahia. Tais municípios, apesar de não terem como vizinhos municípios com quantidades produzidas acima da média, apresentam produtividade acima dessa, se destacando nas localidades. Por outro lado, municípios com regime espacial baixo-alto foram observados principalmente nas proximidades dos agrupamentos alto-alto, migrando em alguns casos para o regime alto-alto em 2018.

#### 4.6 FEIJÃO

O feijão apresentou maior distribuição de suas quantidades produzidas entre as regiões, porém com menor participação da região Norte. No ano de 2018, os percentuais de quantidade produzida em cada região do país foram de aproximadamente 29% na região Sul, 26% na Sudeste, 25% na Centro-Oeste e 18% na região Nordeste. Tais valores, no ano de 2008, foram de aproximadamente 30%, 26%, 11% e 29% da quantidade total produzida no país, respectivamente.

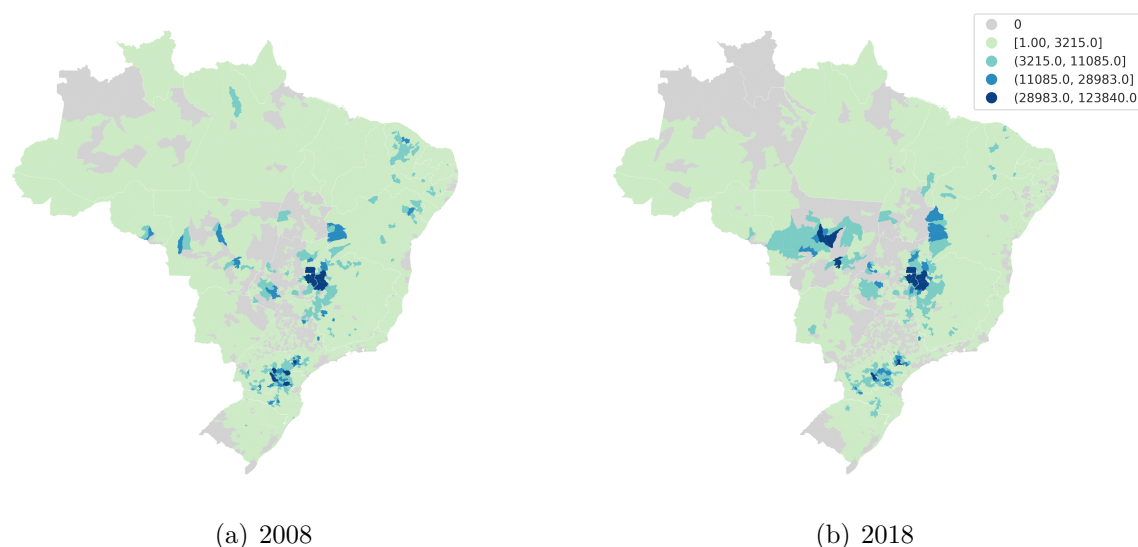
Os mapas temáticos da quantidade de feijão produzida, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 12.

Os mapas da cultura evidenciam a redução da participação da região Nordeste pela diminuição do número de municípios em destaque, que passaram para a primeira faixa de valores de quantidades produzidas. Por outro lado, o aumento da participação na região Centro-Oeste também pode ser observado em tais mapas, dado que grande parte dos municípios passaram do primeiro para o segundo intervalo de valores, enquanto que outros tiveram suas quantidades produzidas no terceiro ou quarto intervalos de valores. Destaca-se ainda o aumento da quantidade produzida na vizinhança dos municípios com maiores quantidades produzidas no estado de Minas Gerais.

Os diagramas de dispersão de Moran e os mapas LISA para a cultura feijão estão apresentados na Figura 24 do Apêndice.

Os diagramas de dispersão de Moran da cultura evidenciam o aumento da concentração espacial para a quantidade produzida de feijão no país que, conforme observado pelo  $I$  de Moran global, aumentou de 0,305 para 0,429 em 2018. Além disso, em 2008

Figura 12 – Mapas temáticos para a quantidade de feijão produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

observa-se um município isolado dos demais, em razão do alto valor padronizado de sua quantidade produzida. Já no ano de 2018, tal distanciamento de um único município não foi observado, embora um grupo desses tenha se distanciados dos demais em menor magnitude.

Em relação aos agrupamentos espaciais, obtidos pelos mapas LISA, nota-se a não significância em 2018 do regime espacial de praticamente todos os municípios do agrupamento alto-alto observado no estado do Ceará em 2008, além de outros agrupamentos do regime espacial no Nordeste. Por outro lado, observou-se um maior número de municípios pertencentes aos agrupamentos nos estados do Mato Grosso, Minas Gerais, Goiás, Bahia, Paraná e São Paulo.

Os municípios que tiveram quantidades produzidas espacialmente discrepantes em 2008, em sua grande parte, não permaneceram no mesmo regime em 2018. Dois daqueles pertencentes ao regime alto-baixo na região Centro-Oeste, migraram para o regime alto-alto em razão da produção de seus vizinhos ter superado a média da quantidade produzida. Os demais municípios em tal regime na região, passaram a apresentar regime baixo-baixo em 2018, juntamente com os municípios localizados nos estados do Rio de Janeiro e do Rio Grande do Sul.


#### 4.7 FUMO

A produção da cultura agrícola fumo esteve quase que em sua totalidade concentrada na região Sul, em ambos os anos analisados. Em 2008, a participação da região foi de

cerca de 97%, aumentando para cerca de 98% em 2018. O restante da produção da cultura esteve principalmente na região Nordeste sendo aproximadamente 3% em 2008 e 2% em 2018.

Os mapas temáticos da quantidade de fumo produzida, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 13.

Figura 13 – Mapas temáticos para a quantidade de fumo produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

Nos mapas temáticos da cultura, pode-se perceber o aumento da quantidade produzida em alguns municípios da região Sul do país, em especial no estado do Paraná. No estado do Rio Grande do Sul, grande parte dos municípios na maior faixa de valores em 2008 se mantiveram em tal intervalo em 2018. No entanto, alguns municípios do estado passaram a pertencer a faixas de menores valores de quantidade produzida.

Os diagramas de dispersão de Moran e os mapas LISA para a cultura fumo estão apresentados na Figura 25 do Apêndice.

Nos diagramas de dispersão de Moran, pode-se destacar alterações nos padrões de dispersão dos pontos entre 2008 e 2018. No ano de 2008 os pontos apresentaram certa dispersão ao redor da reta de ajuste, principalmente abaixo dela. Já no ano de 2018, nota-se um grupo de municípios dispersos abaixo da reta, paralelamente ao eixo horizontal. Nesse sentido, vale destacar o menor valor da estatística global no ano de 2018.

Os mapas *LISA* da cultura destacam dois agrupamentos de municípios com regime espacial alto-alto na região Sul do país. Estes, apresentaram entre 2008 e 2018 alterações nos municípios nas fronteiras dos mesmos. Entre tais alterações, pode-se destacar a mudança de alto-alto para baixo-alto de municípios ao sul do agrupamento que se estende de Santa


Catarina até o Paraná, além de mudança de regime na parte norte do agrupamento. No agrupamento mais ao sul, destaca-se a mudança de regime espacial para baixo-alto em municípios de sua fronteira ao norte e também de alguns municípios próximos ao litoral. Em ambos os agrupamentos vale destacar a presença de municípios com tal regime espacial, delimitando os principais agrupamentos de regiões produtoras.

#### 4.8 LARANJA

A cultura laranja apresentou nos dois anos sua produção concentrada principalmente na região Sudeste do país. Esta foi responsável por cerca de 82% no ano de 2008, atingindo aproximadamente 83% do total produzido no país em 2018. As demais regiões e suas participações na quantidade total produzida no país em 2008 foram, aproximadamente, 1% na região Norte, 11% na Nordeste, 1% na Centro-Oeste e 5% na Sul. No ano de 2018 tais valores foram, respectivamente, cerca de 2%, 7%, 1% e 7% do total produzido no país no ano.

Os mapas temáticos da quantidade de laranja produzida, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 14.

Figura 14 – Mapas temáticos para a quantidade de laranja produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

Por meio dos mapas temáticos, nota-se que os municípios com as maiores quantidades produzidas na região Sudeste se destacaram entre os estados de São Paulo e Minas Gerais. Entre tais municípios observou-se alterações entre os dois anos, que foram a redução ou o aumento da quantidade produzida em municípios da localidade, enquanto que alguns dos municípios na maior faixa de valores em 2008, permaneceram em tal faixa

de valores em 2018. Além desses, observou-se a redução da quantidade produzida de alguns municípios localizados na região Nordeste, no estado de Sergipe.

Os diagramas de dispersão de Moran e os mapas LISA para a cultura laranja estão apresentados na Figura 26 do Apêndice.

Os diagramas de dispersão de Moran em ambos os anos apresentam municípios mais dispersos abaixo das retas de ajustes. Tais retas, como apresentado pelas estatísticas globais de autocorrelação, indicaram menor concentração espacial da quantidade produzida em 2018, dado que em tal ano a reta de ajuste apresentou menor inclinação. Destaca-se também em 2018, que a dispersão desses municípios se concentrou em faixas de valores mais próximos de defasagem espacial, ou seja, municípios com as médias dos vizinhos mais próximas entre si.

Os mapas *LISA* da cultura laranja, destacam o principal agrupamento alto-alto, em relação ao número de municípios, nos estados de São Paulo e Minas Gerais. Entre 2008 e 2018, destacam-se alterações como o aumento no número de municípios ao norte, ao sul e ao leste do agrupamento. Nas demais localidades, têm-se o aumento no número de municípios do agrupamento localizado no norte do estado do Paraná e alterações no agrupamento entre Sergipe e Bahia.

Vale destacar também, um número maior de municípios com regime espacial alto-baixo em 2018 nos estados de São Paulo, Minas Gerais e Goiás. Estes, passaram a produzir quantidades acima da média, enquanto seus vizinhos continuaram abaixo dela.

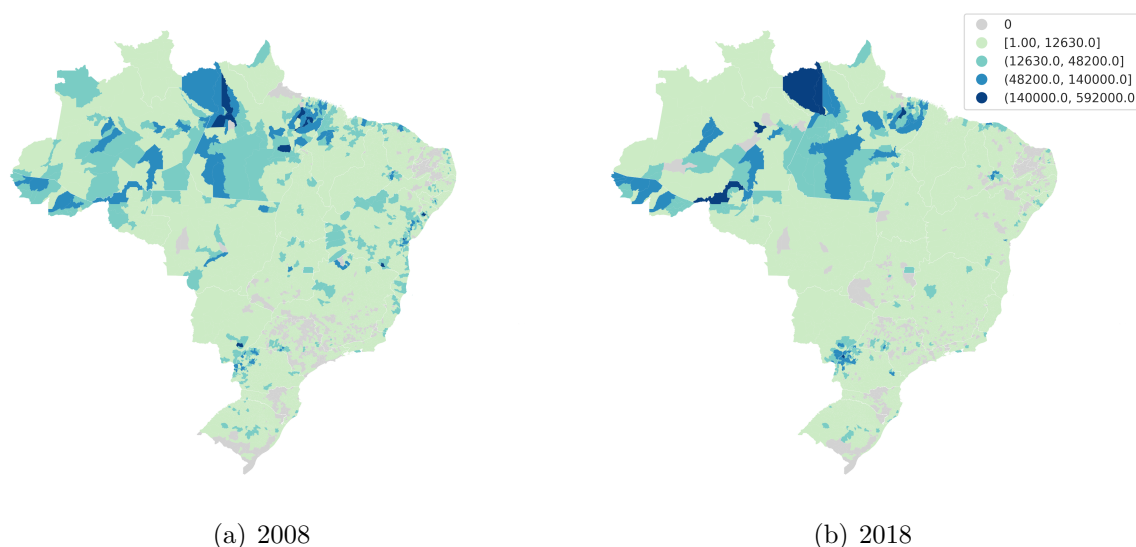
#### 4.9 MANDIOCA

A cultura mandioca, entre os anos de 2008 e 2018, contou com alterações nas participações das regiões em relação à quantidade produzida da cultura no país. Nas regiões Norte e Sul, foram observados os maiores aumentos de participação, dado que passaram de 29% para 36%, e 20% para 27% dos totais produzidos no país em cada um dos anos. As regiões Sudeste e Centro-Oeste também apresentaram aumento em tal participação. O Sudeste passou de 9% para 11% do total produzido, enquanto que o Centro-Oeste aumentou sua participação de 6% para 7% em 2018. No entanto, a região Nordeste apresentou redução em tal valor, reduzindo de 37% para 20% do total produzido no país.

Os mapas temáticos da quantidade de mandioca produzida, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 15.

De acordo com os mapas temáticos da cultura, fica evidente a redução da participação da região Nordeste, pela diminuição do número de municípios com produtividade acima do primeiro intervalo de valores. Observou-se também a redução da produtividade em municípios que em 2008 se encontravam no segundo intervalo de quantidade produzida

Figura 15 – Mapas temáticos para a quantidade de mandioca produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

na região Norte, no entanto, simultaneamente, houve o aumento de produtividade em outros municípios da região.

Entre os estados do Paraná e do Mato Grosso do Sul, observou-se que entre 2008 e 2018 houve o aumento da concentração dos municípios nos maiores intervalos de quantidade produzida. Em tal localidade nota-se que municípios que em 2008 apresentavam quantidades produzidas no primeiro ou segundo intervalos de valores, passaram a pertencer ao terceiro intervalo. Tais municípios se concentraram, principalmente, ao redor de um município com quantidade produzida na maior faixa de valores em 2018.

Os diagramas de dispersão de Moran e os mapas LISA para a cultura mandioca estão apresentados na Figura 27 do Apêndice.

Os diagramas de dispersão de Moran da mandioca, ressaltam o aumento da concentração espacial da cultura em 2018, ano que apresentou segundo tal diagrama maior inclinação da reta de ajuste e, conseqüentemente, maior  $I$  de Moran global. Municípios distantes dos demais foram observados acima da reta de ajuste, mas principalmente abaixo dela, em razão de maior variabilidade desses municípios em relação ao valor padronizado da quantidade produzida, do que da defasagem espacial.

Em relação aos regimes espaciais dos municípios, destaca-se as alterações observadas na região Norte do país, em especial a mudança ou a não significância dos regimes dos municípios que em 2008 estavam no regime alto-alto. Em alguns casos, tais municípios passaram a apresentar regime baixo-alto, indicando a redução em suas quantidades produzidas. Nas proximidades dos estados do Pará e do Maranhão, alguns municípios

pertencentes ao agrupamento alto-alto em 2018 também não apresentaram regime espacial significativo no último ano.

Na região Nordeste, observou-se a diminuição dos agrupamentos espaciais de municípios com regime alto-alto, principalmente no estado da Bahia. Já entre as regiões Sul e Centro-Oeste, nota-se que o agrupamento alto-alto observado em 2008, apresentou maior concentração dos municípios em tal regime espacial, em razão da então significância ou mudança do regime dos mesmos.


Por fim, em relação aos regimes espaciais alto-baixo e baixo-alto dos municípios em ambos os anos, observou-se que a permanência de municípios no regime baixo-alto ao redor dos agrupamentos alto-alto, fornecem indícios dos limites da extensão dos agrupamentos com produtividade dos municípios acima das médias. Por outro lado, os municípios com regime alto-baixo, destacaram regiões com quantidades produzidas acima da média, porém não foi observada a permanência dos municípios com esse regime nos dois anos analisados.

#### 4.10 MILHO

A cultura milho contou com o aumento expressivo da participação percentual da região Centro-Oeste em sua quantidade produzida, passando de 29% em 2008 para 52% em 2018. Tal aumento, em contrapartida, significou a diminuição das participações das regiões Sudeste de 19% em 2008 para 14% em 2018, e Sul que passou de 42% para 24%.

Os mapas temáticos da quantidade de milho produzida, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 16.

Figura 16 – Mapas temáticos para a quantidade de milho produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

A comparação dos mapas temáticos da cultura em 2008 e 2018 evidencia o aumento da participação da região Centro-Oeste na produção de milho por meio do aumento das quantidades produzidas nos municípios. Tal região em 2008 apresentava em destaque apenas municípios com quantidades produzidas no segundo intervalo de valores e um município no terceiro intervalo. Já em 2018, apresentou um maior número de municípios no segundo e no terceiro intervalos de valores, além do aumento da produção no município que em 2008 estava no terceiro intervalo, para o quarto intervalo de quantidade produzida.

Os diagramas de dispersão de Moran e os mapas LISA para a cultura milho estão apresentados na Figura 28 do Apêndice.

Como indicado pelo  $I$  de Moran global, os diagramas de dispersão da cultura, apresentam no ano de 2018 uma maior dispersão dos municípios com valores padronizados de quantidades produzidas e defasagens espacial acima dos demais.

Os mapas *LISA* da cultura evidenciam a redução dos agrupamentos alto-alto localizados nas regiões Sul e Sudeste do país, em especial nos estados do Paraná e de Minas Gerais. Por outro lado, na região Centro-Oeste observou-se um maior número de municípios nos agrupamentos alto-alto, tanto no agrupamento de maior extensão, quanto no agrupamento no estado do Mato Grosso do Sul. Na região Nordeste, em 2018 os municípios localizados entre os estados do Maranhão e do Piauí apresentaram regime espacial significativo, e com isso um novo agrupamento alto-alto na região.

No que diz respeito às discrepâncias espaciais das quantidades produzidas, observa-se em 2008 municípios com regime baixo-alto nas fronteiras dos agrupamentos alto-alto, que em parte, mantiveram o regime em 2018. Por outro lado, o regime alto-baixo foi observado apenas em 2018 no estado de Rondônia.

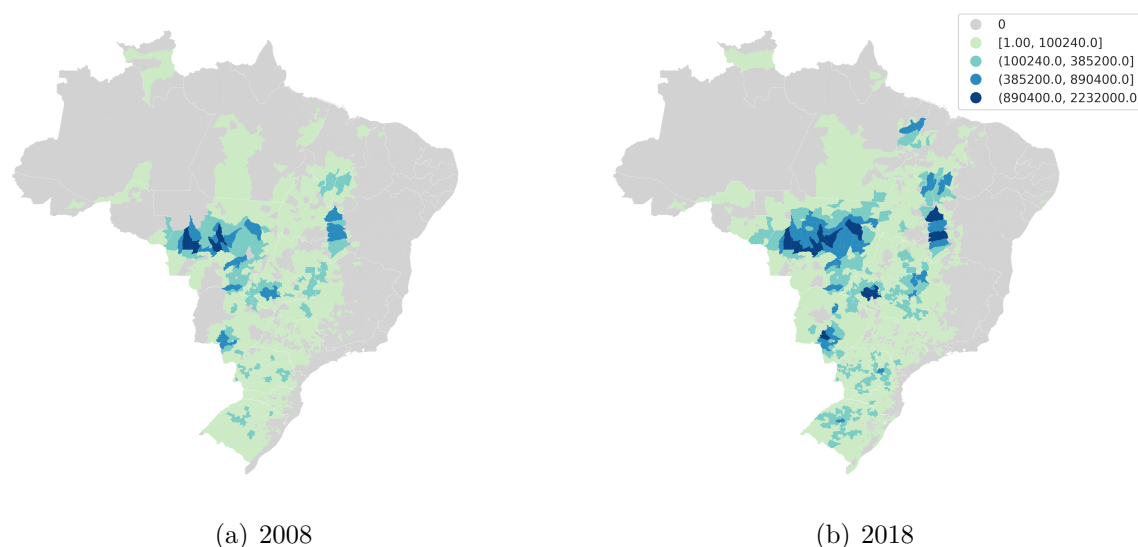
#### 4.11 SOJA

A cultura soja não apresentou grandes alterações nas quantidades percentuais produzidas em cada região. Os valores observados em relação aos anos de 2008 e 2018, foram de aproximadamente 2% e 5% na região Norte, 8% e 10% na Nordeste, 49% e 45% na Centro-Oeste e 34% e 33% na região Sul. Na região Sudeste, o percentual da quantidade produzida nos dois anos foi de aproximadamente 7%.

Os mapas temáticos da quantidade de soja produzida, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 17.

Nos mapas temáticos da cultura, observa-se o aumento da quantidade produzida nos municípios no país como um todo. Aqueles que se destacaram em 2008 com valores acima do primeiro intervalo, em sua maioria, aumentaram suas quantidades produzidas, sendo observados também o aumento nos municípios vizinhos a tais regiões. Os municípios na maior faixa de valores de quantidade produzida, que em 2008 foram observados apenas

Figura 17 – Mapas temáticos para a quantidade de soja produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

no estado do Mato Grosso, em 2018 estiveram presentes também no Mato Grosso do Sul, em Goiás e na Bahia.

Os diagramas de dispersão de Moran e os mapas *LISA* para a cultura soja estão apresentados na Figura 29 do Apêndice.

Por meio dos diagramas de dispersão de Moran, nota-se que em 2018 os municípios apresentaram menor variabilidade em relação ao valor padronizado da quantidade produzida e à defasagem espacial, dado que os pontos estiveram mais concentrados. No entanto, as retas de ajustes não apresentaram alterações no que diz respeito às suas inclinações, tendo em vista que, como indicado pelo *I* de Moran global, o valor da estatística para a cultura foi de 0,546 em 2008 e 0,540 em 2018.

Segundo os mapas *LISA* da cultura, pode-se perceber um maior número de municípios com regime espacial alto-alto em 2018, nas redondezas dos agrupamentos de tal regime observados em 2008. Tais municípios, como destacado em relação aos mapas temáticos, passaram a produzir maiores quantidades de soja e com isso, quantidades produzidas acima da média.


Já em relação aos municípios que tiveram quantidades produzidas espacialmente discrepantes, destaca-se os municípios nas vizinhanças dos agrupamentos alto-alto que, em ambos os anos, apresentaram regime espacial baixo-alto. Tais municípios, ainda com o aumento da produtividade nos arredores dos principais agrupamentos, permaneceram com quantidades produzidas abaixo da média. Por outro lado, apenas um município com regime alto-baixo foi observado em 2018, na região Nordeste do país.

#### 4.12 TOMATE

A cultura tomate contou com a maior parte de sua produção nos anos de 2008 e 2018 concentrada nas regiões Centro-Oeste e Sudeste do país. A região Centro-Oeste, no ano de 2008 produziu cerca de 30% do total do país, aumentando sua participação para 33% em 2018. Já a região Sudeste, que no primeiro ano representava 40% da produção, em 2018 aumentou sua participação para 42%. As demais regiões, em 2008 e 2018 foram responsáveis, respectivamente, por 0,7% e 0,4% na região Norte, 15% e 12% na Nordeste e 13% e 14% na região Sul do país.

Os mapas temáticos da quantidade de tomate produzida, em toneladas, nos anos de 2008 e 2018 estão apresentados na Figura 18.

Figura 18 – Mapas temáticos para a quantidade de tomate produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

Observa-se nos mapas temáticos, que a cultura apresentou, em ambos os anos, o maior número de municípios acima do primeiro intervalo de valores no estado de Goiás. No entanto, municípios com quantidades produzidas acima de tais valores também foram observados em áreas das regiões Sul, Sudeste e Nordeste do país, com menores concentrações.

Entre os anos de 2008 e 2018, pode-se destacar a queda da produtividade de alguns municípios do estado de Goiás, e o aumento em outros municípios. No estado da Bahia, o número de municípios com quantidades produzidas entre 40 e 162 mil toneladas foi maior em 2018 em torno do município que apresentou quantidade produzida em tal faixa de valores em 2008.

Os diagramas de dispersão de Moran e os mapas LISA para a cultura tomate estão apresentados na Figura 30 do Apêndice.

Os diagramas de dispersão de Moran, como indicado pelas estatísticas  $I$  de Moran globais em 2008 e 2018, apresentaram baixa inclinação da reta de ajuste aos pontos, principalmente no último ano. Além disso, nota-se maior dispersão dos valores em relação ao valor padronizado da quantidade produzida nos dois anos em questão.

Os agrupamentos espaciais observados nos mapas LISA da cultura, indicam a presença de agrupamentos de municípios com regime alto-alto com menores extensões e localizados em diferentes áreas das regiões Sul, Sudeste, Centro-Oeste e Nordeste. A principal alteração nesses agrupamentos ocorreu entre os estados de Minas Gerais e Goiás, pela redução do agrupamento no sentido do Distrito Federal (área com regime alto-baixo em 2008) e significância do regime espacial dos municípios do estado da região Sudeste.

Em tal cultura, destaca-se também maior número de municípios com regime espacial alto-baixo em 2018, indicando municípios que se destacam na produção do tomate em relação a seus vizinhos. Já os municípios com regime baixo-alto estiveram localizados principalmente ao redor dos agrupamentos entre as regiões Sudeste e Centro-Oeste do país, destacando a permanência do regime de alguns desses em 2018.

#### 4.13 ANÁLISE COMPARATIVA

Inicialmente é importante destacar as principais alterações que foram observadas em relação à participação das regiões no total produzido no país, com base na Figura 6, além de apresentar sob a ótica de alguns autores teorias que possam explicar, ainda que parcialmente, tais alterações.

Para o arroz observa-se que, entre os anos de 2008 e 2018, houve o aumento da participação da região Sul e redução das regiões Centro-Oeste e Nordeste, sendo necessário o conhecimento do processo de cultivo do arroz no país para compreender tais alterações.

O cultivo de arroz no Brasil se dá por meio de dois tipos de sistemas de produção: o irrigado por inundação e o de terras altas. O primeiro deles se concentra no Sul e em várzeas tropicais, em especial nos estados do Rio Grande do Sul, Santa Catarina, Maranhão, Tocantins e Mato Grosso do Sul. Tais estados foram juntos responsáveis por cerca de 85% da produção de arroz no país no ano de 2014. Já o sistema de terras altas representa cerca de 50% da área nacional ocupada com o cultivo de arroz e se dissemina por todo o território nacional (WANDER; SILVA, 2014).

Segundo Wander e Silva (2014), a participação na oferta total do sistema de terras altas tem diminuído nos últimos anos, especialmente, pois as áreas ocupadas pela cultura, em sua grande maioria envolvendo os estados de Goiás, Distrito Federal, Mato Grosso e Tocantins têm cedido espaço para culturas como a soja, o milho e a cana-de-açúcar.

Em relação ao feijão, que contou com o aumento da participação da região Centro-Oeste na produção total do Brasil, é importante destacar que o mesmo é considerado uma cultura atípica, por permitir a obtenção de três safras ao longo do ano agrícola, sendo elas: primeira safra (safra das “águas”), segunda safra (safra da “seca”) e terceira safra (safra irrigada). A cultura feijão utilizada no presente trabalho abrange a produção total das três safras.

De acordo com Silva e Wander (2013), na primeira safra o Sul é tradicional no cultivo da cultura, ocupando, no período entre 2006 e 2011, o primeiro lugar em relação à área e produção. Em seguida encontram-se Sudeste, Centro-Oeste, Nordeste e Norte. Em tal safra destaca-se também a região Centro-Oeste que obteve a maior produtividade nacional das regiões, com evidências de que os produtores possuem variedades melhoradas de feijão comum, além de alta tecnologia e destaque nacional no cenário agrícola.

Em relação à segunda safra, no mesmo período 2006 – 2011, ocorreu a redução da área plantada e, com isso, a redução na produção. No entanto, percebe-se a evolução dos níveis de rendimento pela adoção de tecnologias que viabilizam maiores produtividades, em especial nos estados do Paraná, São Paulo, Minas Gerais e Goiás. O destaque da produção na segunda safra também é da região Sul (SILVA; WANDER, 2013).

Por fim, a terceira safra decorre da possibilidade do uso de irrigação em épocas de precipitação desfavorável, além das altitudes favoráveis de regiões, em especial na região dos cerrados. A obtenção de tal safra ocorre principalmente nos estados de Goiás, Mato Grosso, Tocantins, noroeste de Minas Gerais, Espírito Santo, São Paulo e parte da Bahia. No período 2006 – 2011, expressivos incrementos em relação ao nível de rendimento da cultura podem ser observados em âmbito nacional, tendo como principal causa os rendimentos nas regiões Sudeste e Centro-Oeste (SILVA; WANDER, 2013).

Sendo assim, pode-se destacar a presença e importância das regiões Sudeste e Centro-Oeste para a cultura feijão nas três safras da cultura, mas principalmente na terceira safra, o que aliado à alta produtividade da região, poderia ser um dos motivos capazes de explicar o aumento de sua participação na produção do feijão no país entre 2008 e 2018.

Para o milho, que contou com o aumento da participação da região Centro-Oeste e redução no Sul e no Sudeste do país, uma das possíveis justificativas é apresentada por Souza *et al.* (2018), segundo os quais o deslocamento ao longo das últimas quatro décadas da produção de milho do Sul para o norte do país, especialmente para o Centro-Oeste, foi propiciado pelo aumento da demanda pelo grão e pela disponibilidade de terras mais baratas. Além disso, segundo os autores, um maior crescimento em termos de produção tem sido observado no Centro-Oeste, mas a região Sul se destaca em termos de eficiência em produtividade.

Analisando as peculiaridades dos agrupamentos de cada uma das culturas, pode-se notar que, enquanto culturas como o tomate e banana apresentaram a formação de pequenos agrupamentos espaciais com alta produtividade e distantes entre si, outras culturas como o milho e a soja, apresentaram agrupamentos de maior extensão e próximos aos demais.

Vale destacar que apesar das pequenas extensões das áreas em destaque da cultura banana no Nordeste, tal região foi responsável por 41% da produção da cultura em 2008 e 33% em 2018. Além disso, destaca-se que a região Centro-Oeste praticamente dobrou sua participação na produção de cana-de-açúcar no país entre os dois anos. A cultura feijão também apresentou alterações nesse sentido, tendo em vista que sua quantidade produzida passou de 11% para 25% em 2018.

No que diz respeito aos agrupamentos espaciais observados em ambos os anos, destacam-se culturas que não sofreram grandes alterações em determinadas regiões como é o caso do arroz no Rio Grande do Sul, o café na região Sudeste, o fumo na região Sul e a laranja no estado de São de Paulo. Por outro lado, a produção de certas culturas, ainda que tenham permanecido concentradas em determinadas localidades, expandiram a extensão de seus agrupamentos em 2018, como ocorreu com o algodão na região Centro-Oeste, a cana-de-açúcar entre o Sudeste e o Centro-Oeste do país, o feijão no estado do Mato Grosso e em Minas Gerais, a mandioca no Mato Grosso do Sul e o milho e a soja na região Centro-Oeste.

Outro ponto a ser destacado, é a presença em algumas culturas de regiões com regime espacial baixo-alto nas imediações dos agrupamentos alto-alto observados. A identificação dessas regiões e a permanência de seu regime espacial em ambos os anos fornecem indícios dos limites geográficos de tais regiões produtoras bem como da expansão do agrupamento em determinadas direções.

De modo geral, pode-se considerar a existência de três grupos de culturas. No primeiro deles estão aquelas que tendem a se concentrar em poucas áreas, sendo tal grupo composto pelas culturas: algodão, arroz, café, cana-de-açúcar, laranja e fumo. Tais culturas foram identificadas em um primeiro momento pela participação predominante de certas regiões do país nas produções totais. Em seguida, tal característica foi observada também nos mapas temáticos e mapas *LISA* dessas culturas. Vale lembrar também que tais culturas se comportaram de maneira semelhante na comparação dos resultados das Tabelas 2 e 3, ou seja, menores números de municípios produtores e coeficientes de variação e maiores quantidades produzidas médias.

Para a cultura fumo, foram identificadas duas áreas em destaque na região Sul, enquanto que para o arroz apenas uma área se destacou em tal região. As culturas café, cana-de-açúcar e laranja, foram predominantemente produzidas na região Sudeste, contendo tal região as principais áreas em destaque das culturas. Já o algodão, apresentou uma maior

área em destaque no Centro-Oeste e além dela, outra área na região Nordeste. Não foram identificadas grandes alterações nos agrupamentos de tais culturas, com exceção do arroz, que em 2018 não apresentou regime espacial significativo para municípios alto-alto em 2008 na região Norte. Em relação aos valores do  $I$  de Moran das culturas do primeiro grupo, destaca-se que as maiores reduções nos valores da estatística entre 2008 e 2018 foram observadas para as culturas fumo e laranja. Já as culturas arroz e algodão apresentaram menores reduções nesse sentido. Por outro lado, para a cultura cana-de-açúcar observou-se o aumento no valor da estatística, enquanto que o valor da estatística para o café aumentou em menor magnitude.

Um segundo grupo teria como culturas aquelas que apresentaram áreas em destaque em 2008, expandindo-as em 2018 pelo aumento da produtividade de seus vizinhos e, conseqüentemente, a mudança ou a significância de seus regimes espaciais. Tais culturas foram: o feijão, o milho e a soja. No que diz respeito ao  $I$  de Moran de cada uma delas, destaca-se o maior valor da estatística para o milho e o feijão, indicando uma maior concentração espacial em 2018. Já para a cultura soja, as estatísticas de 2008 e 2018 foram aproximadamente iguais.

As culturas banana e tomate estariam em um terceiro grupo de culturas, as quais apresentaram em sua maioria agrupamentos com menores extensões e mais espaçados entre si. Tais culturas apresentaram redução da estatística  $I$  de Moran entre 2008 e 2018, indicando menores concentrações espaciais. A cultura mandioca apresentou características distintas das demais culturas, entre elas a redução dos agrupamentos nas regiões Norte e Nordeste do país, e o maior número de municípios no agrupamento entre o Sul e o Centro-Oeste.

## 5 CONSIDERAÇÕES FINAIS

A análise de culturas agrícolas por todo o território nacional possibilitou compreender determinados padrões de associação espacial entre diferentes perfis de culturas nos anos analisados. Dessa forma, foram identificadas tanto aquelas regiões que não apresentaram grandes alterações na produção de seus municípios, quanto aquelas que foram influenciadas ou influenciaram seus vizinhos. A análise conjunta dos mapas temáticos e dos mapas *LISA*, possibilitou além da identificação dos municípios com as maiores quantidades produzidas, a identificação dos agrupamentos de municípios, evidenciando assim o potencial produtivo de tais conjuntos de municípios.

A análise comparativa estabelecida entre diferentes culturas permitiu a identificação de grupos com características similares, seja pela concentração dos agrupamentos de municípios em determinadas regiões, pela expansão dos agrupamentos observados em 2008 no ano de 2018, ou mesmo pela extensão e proximidade entre os agrupamentos. Ademais, ao analisar conjuntamente tais culturas foi possível compreender além dos efeitos da interdependência entre as regiões produtoras em uma mesma cultura, os processos de competição espacial entre culturas distintas, como é o caso do arroz produzido por meio do sistema de terras altas.

Por fim, ressalta-se que o trabalho se limitou à comparação das alterações relacionadas à quantidade produzida pelos municípios brasileiros nos anos de 2008 e 2018, tendo em vista a matéria que o motivou. Em outros cenários poderiam ser utilizadas variáveis relacionadas à produtividade ou outras características das culturas, de forma a possibilitar a análise das peculiaridades do setor agrícola no país sob diferentes pontos de vista.

## REFERÊNCIAS

- ALMEIDA, E. **Econometria espacial aplicada**. Campinas, SP: Alínea, 2012.
- ALMEIDA, E.; PEROBELLI, F.; FERREIRA, P. Existe convergência espacial da produtividade agrícola no Brasil? **Revista de Economia e Sociologia Rural**, SciELO Brasil, Rio de Janeiro, v. 46, n. 1, p. 31–52, 2008.
- ALMEIDA, R.; ZANLORENSSI, G. Banana, café, mandioca: onde são cultivados vegetais e grãos no Brasil. **Nexo Jornal**, São Paulo, 2018. Disponível em: <https://www.nexojornal.com.br/grafico/2018/02/07/Banana-café-mandioca-onde-são-cultivados-vegetais-e-grãos-no-Brasil>. Acesso em: 04 abr. 2019.
- ALVIM, M. **Análise da competitividade da produção de soja no sistema de plantio direto no estado de Mato Grosso do Sul**. 2003. 147 p. Tese (Doutorado em Economia Aplicada) — Universidade Federal de Viçosa, Viçosa, 2003.
- ANDRADE, A. *et al.* **Introdução à estatística espacial para a saúde pública**. Brasília: Ministério da Saúde, 2007.
- ANSELIN, L. **Spatial econometrics: methods and models**. Dordrecht: Kluwer Academic, 1988. v. 2.
- ANSELIN, L. Local indicators of spatial association. **Geographical analysis**, Wiley Online Library, v. 27, n. 2, p. 93–115, 1995.
- ANSELIN, L.; SYABRI, I.; KHO, Y. Geoda: an introduction to spatial data analysis. **Geographical analysis**, The Ohio State University, v. 38, n. 2, p. 5–22, 2006.
- ASSUNÇÃO, R.; REIS, E. A new proposal to adjust Moran's I for population density. **Statistics in medicine**, Wiley Online Library, v. 18, n. 16, p. 2147–2162, 1999.
- AVILA, R.; MONASTERIO, L. O MAUP e a análise espacial: um estudo de caso para o Rio Grande do Sul (1991-2000). **Revista Análise Econômica**, Porto Alegre, n. 49, p. 233–259, 2008.
- CÂMARA, G. *et al.* Análise espacial de áreas. In: DRUCK, S. *et al.* (Ed.). **Análise espacial de dados geográficos**. 2. ed. Brasília: Embrapa, 2004. cap. 5, p. 157–206.
- CÂMARA, G. *et al.* Análise espacial e geoprocessamento. In: DRUCK, S. *et al.* (Ed.). **Análise espacial de dados geográficos**. 2. ed. Brasília: Embrapa, 2004. cap. 1, p. 21–52.
- CARVALHO, T. **A hipótese da curva de Kuznets ambiental global e o Protocolo de Quioto**. 2008. 131 p. Dissertação (Mestrado em Economia Aplicada) — Universidade Federal de Juiz de Fora, Juiz de Fora, 2008.
- CLIFF, A.; ORD, K. **Spatial processes, models and applications**. Londres: Pion, 1981.

CUNHA, G.; ASSAD, E. Uma visão geral do número especial da RBA sobre zoneamento agrícola no Brasil. **Revista Brasileira de Agrometeorologia**, v. 9, n. 3, p. 377–385, 2001.

FISHER, W. On grouping for maximum homogeneity. **Journal of the American statistical Association**, Taylor & Francis, v. 53, n. 284, p. 789–798, 1958.

GARCIA, J. **Análise de dados de área aplicada a indicadores de seguridade rural para a cultura do café**. 2018. 85 p. Dissertação (Mestrado em Estatística Aplicada e Experimentação Agropecuária) — Universidade Federal de Lavras, Lavras, 2018.

GEARY, R. C. The contiguity ratio and statistical mapping. **The incorporated statistician**, v. 5, n. 3, p. 115–146, 1954.

GETIS, A.; ORD, K. The analysis of spatial association by use of distance statistics. **Geographical analysis**, Ohio State University Press, v. 24, n. 3, p. 189–206, 1992.

HAINING, R. **Spatial data analysis: theory and practice**. Cambridge: Cambridge University Press, 2003.

IBGE. **Manual técnico das pesquisas agropecuárias municipais**. Rio de Janeiro, 2014. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/instrumentosdecoleta>. Acesso em: 04 mar. 2021.

IBGE. **Portal de mapas**. Rio de Janeiro, 2021. Disponível em: <https://portaldemapas.ibge.gov.br/>. Acesso em: 04 mar. 2021.

IBGE. **Produção agrícola municipal**. Rio de Janeiro, 2021. Disponível em: <https://sidra.ibge.gov.br/tabela/5457>. Acesso em: 04 mar. 2021.

JENKS, G. Optimal data classification for choropleth maps. **Department of Geography, University of Kansas Occasional Paper**, 1977.

LESAGE, J. **Spatial econometrics**. Toledo: Univesidade de Toledo, 1998.

MESSNER, S. *et al.* The spatial patterning of county homicide rates: An application of exploratory spatial data analysis. **Journal of Quantitative Criminology**, Springer, v. 15, n. 4, p. 423–450, 1999.

PEROBELLI, F. *et al.* Produtividade do setor agrícola brasileiro (1991-2003): uma análise espacial. **Nova economia**, SciELO Brasil, v. 17, n. 1, p. 65–91, 2007.

REY, S. *et al.* Parallel optimal choropleth map classification in pysal. **International Journal of Geographical Information Science**, Taylor & Francis, v. 27, n. 5, p. 1023–1039, 2013.

ROSSETTI, L. Zoneamento agrícola em aplicações de crédito e seguridade rural no Brasil: aspectos atuariais e de política agrícola. **Revista Brasileira de Agrometeorologia**, v. 9, n. 3, p. 386–399, 2001.

SILVA, O.; WANDER, A. **O feijão-comum no Brasil: passado, presente e futuro**. Santo Antônio de Goiás: Embrapa, 2013.

SOUZA, A. *et al.* Estudo da produção do milho no Brasil. **South American Development Society Journal**, v. 4, n. 11, p. 182–194, 2018.

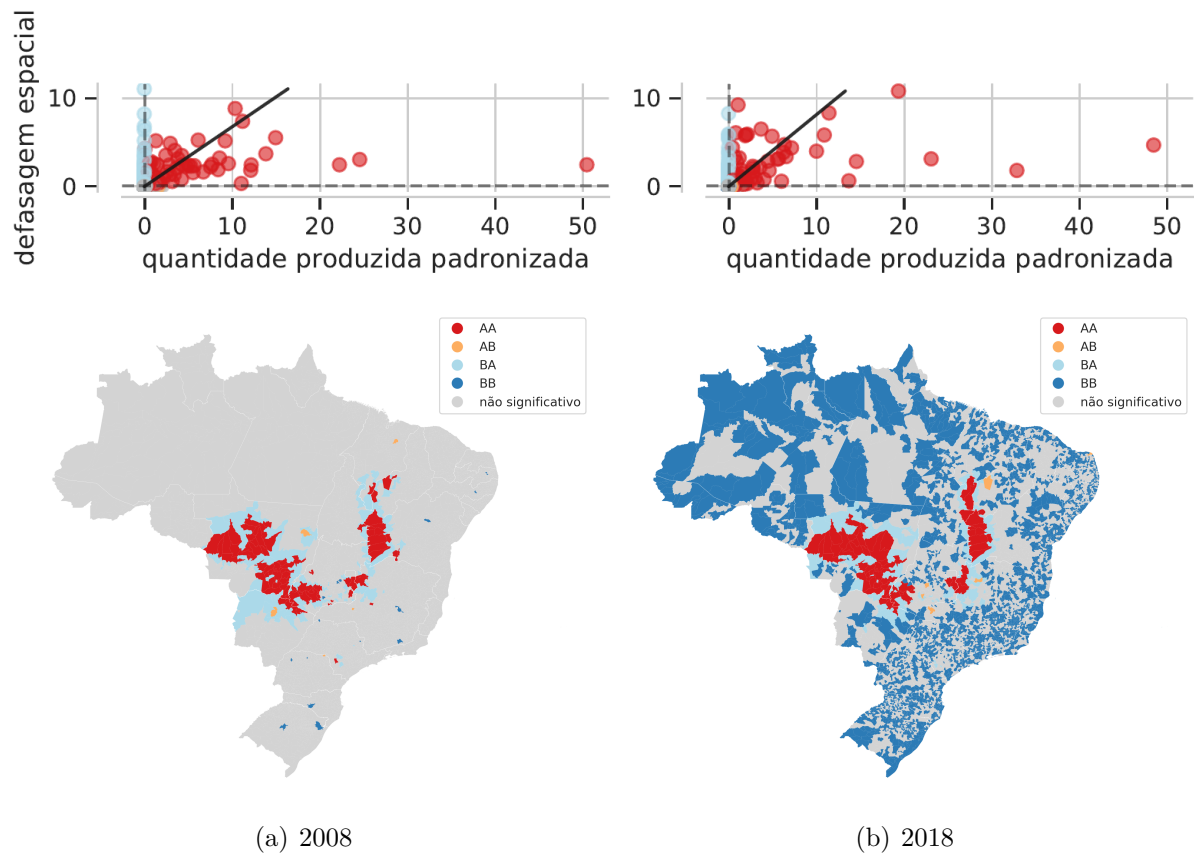
TYSZLER, M. **Econometria espacial: discutindo medidas para a matriz de ponderação espacial**. 2006. 155 p. Dissertação (Mestrado em Administração Pública e Governo) — Fundação Getúlio Vargas, São Paulo, 2006.

WANDER, A.; SILVA, O. Rentabilidade da produção de arroz no Brasil. In: CAMPOS, S. *et al.* (Ed.). **Sustentabilidade e sustentação da produção de alimentos: o desafio da rentabilidade na produção**. Brasília: Embrapa, 2014. v. 2, cap. 5, p. 117–133.

## Apêndices

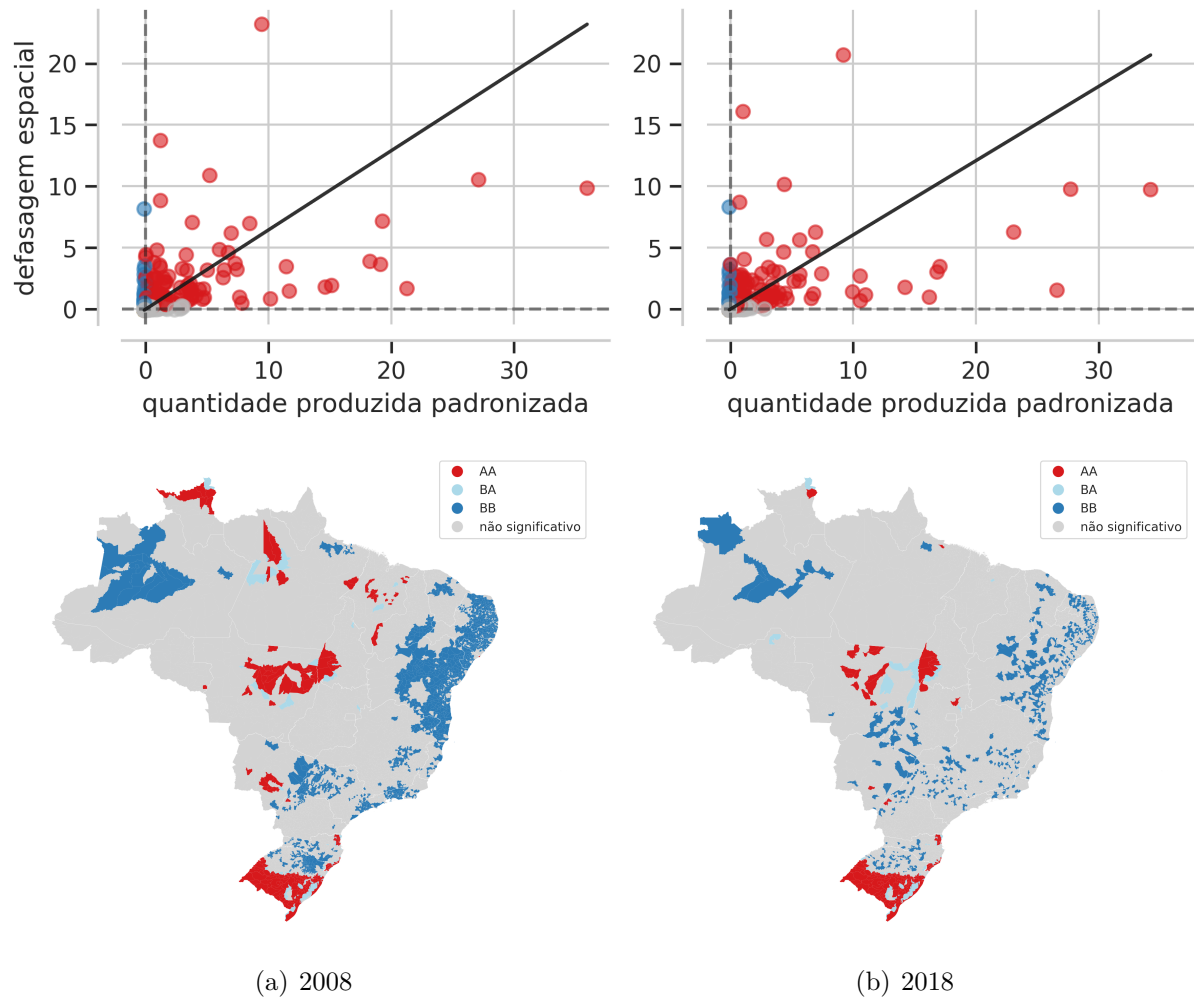
## APÊNDICE A – FIGURAS

Figura 19 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de algodão produzida, em toneladas, nos anos de 2008 e 2018



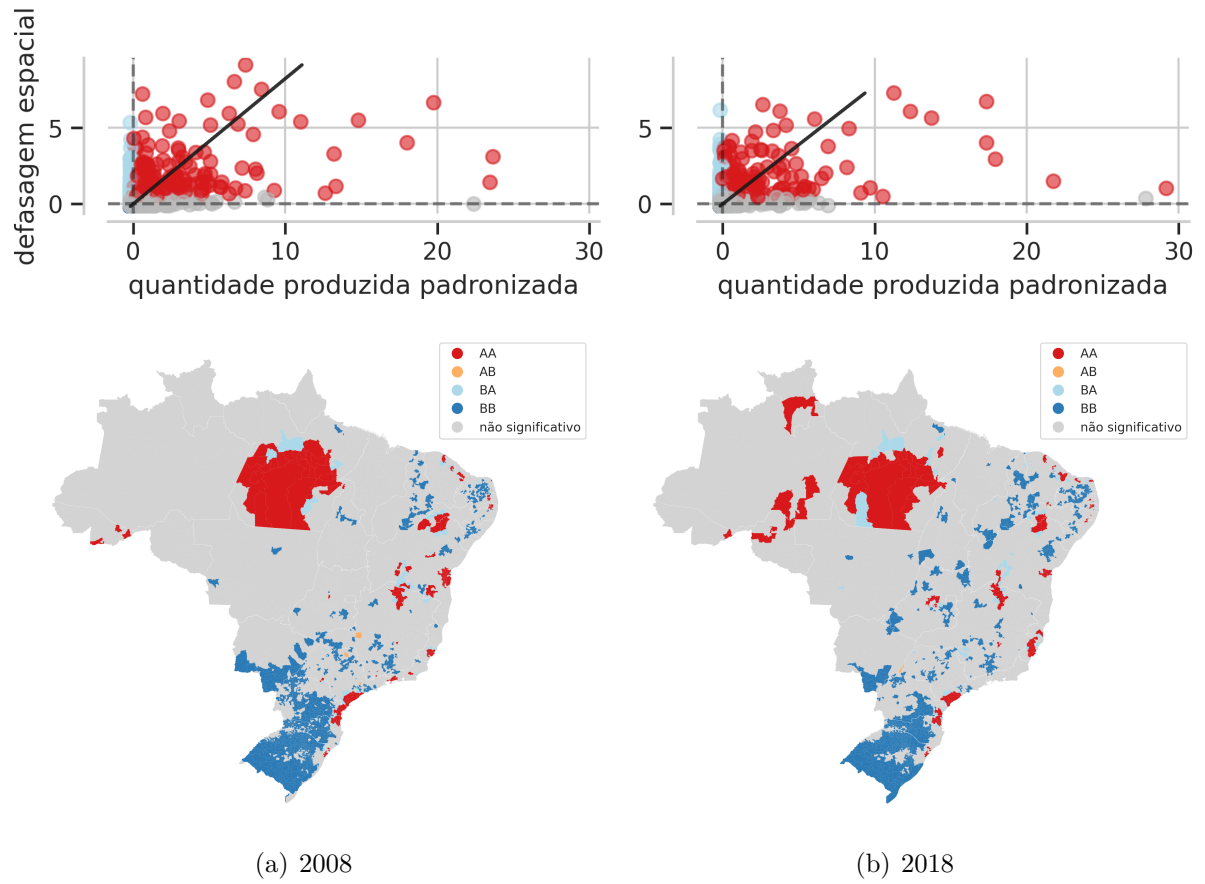
Fonte: Do autor.

Figura 20 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de arroz produzida, em toneladas, nos anos de 2008 e 2018



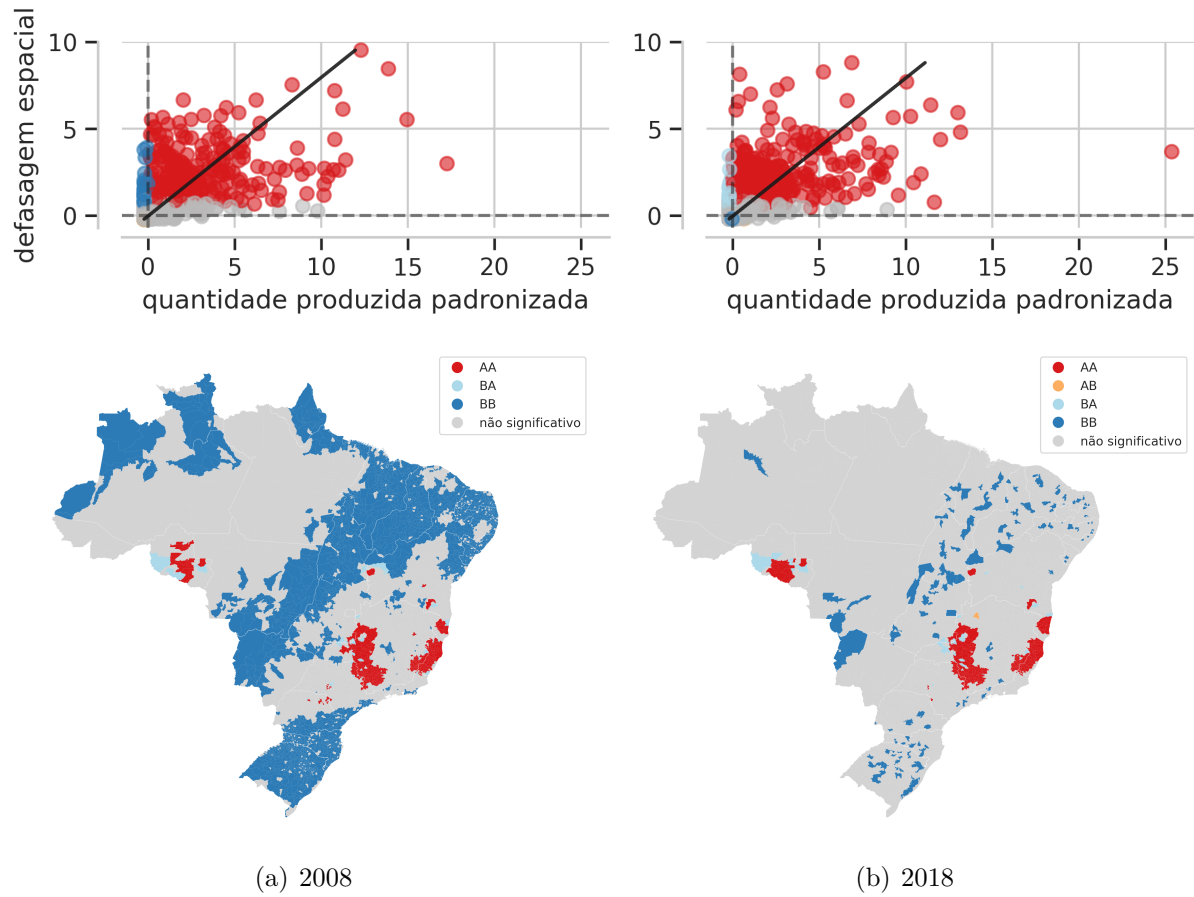
Fonte: Do autor.

Figura 21 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de banana produzida, em toneladas, nos anos de 2008 e 2018



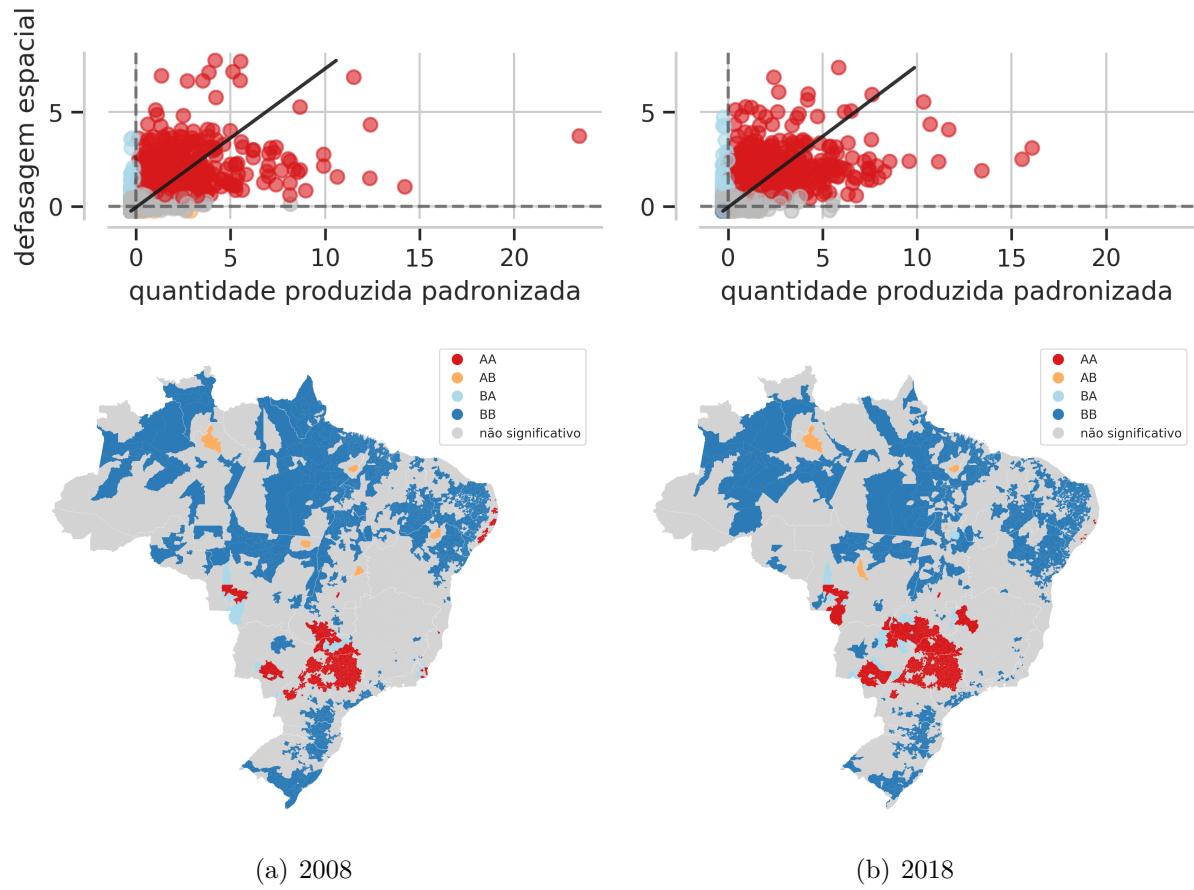
Fonte: Do autor.

Figura 22 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de café produzida, em toneladas, nos anos de 2008 e 2018



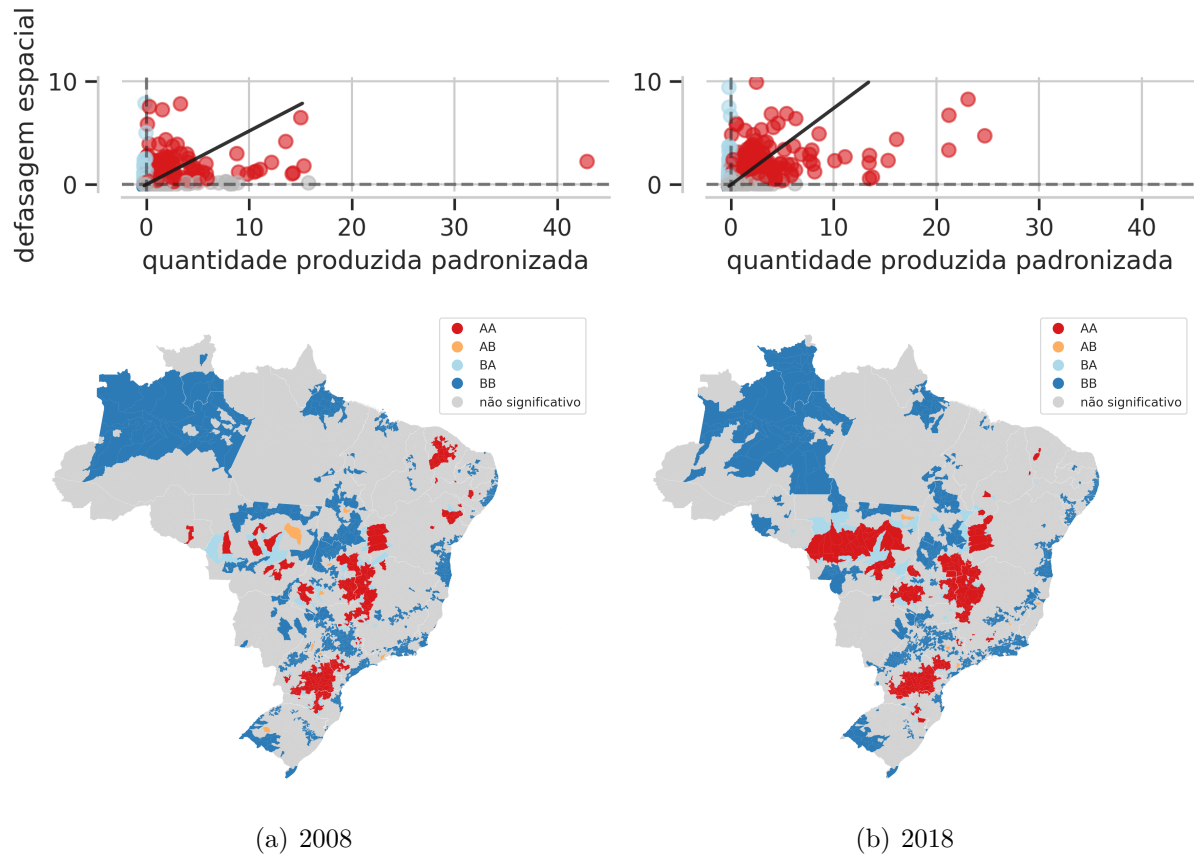
Fonte: Do autor.

Figura 23 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de cana-de-açúcar produzida, em toneladas, nos anos de 2008 e 2018



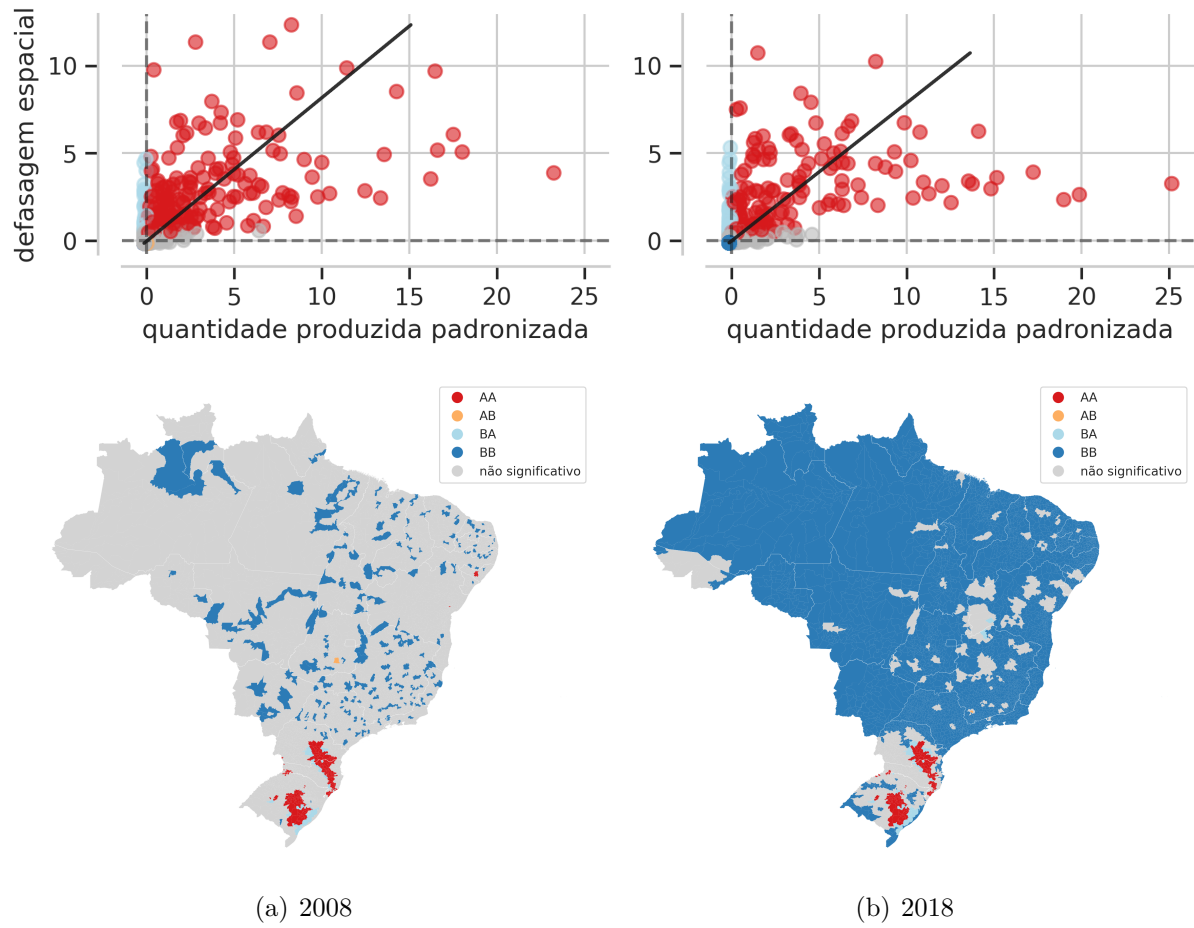
Fonte: Do autor.

Figura 24 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de feijão produzida, em toneladas, nos anos de 2008 e 2018



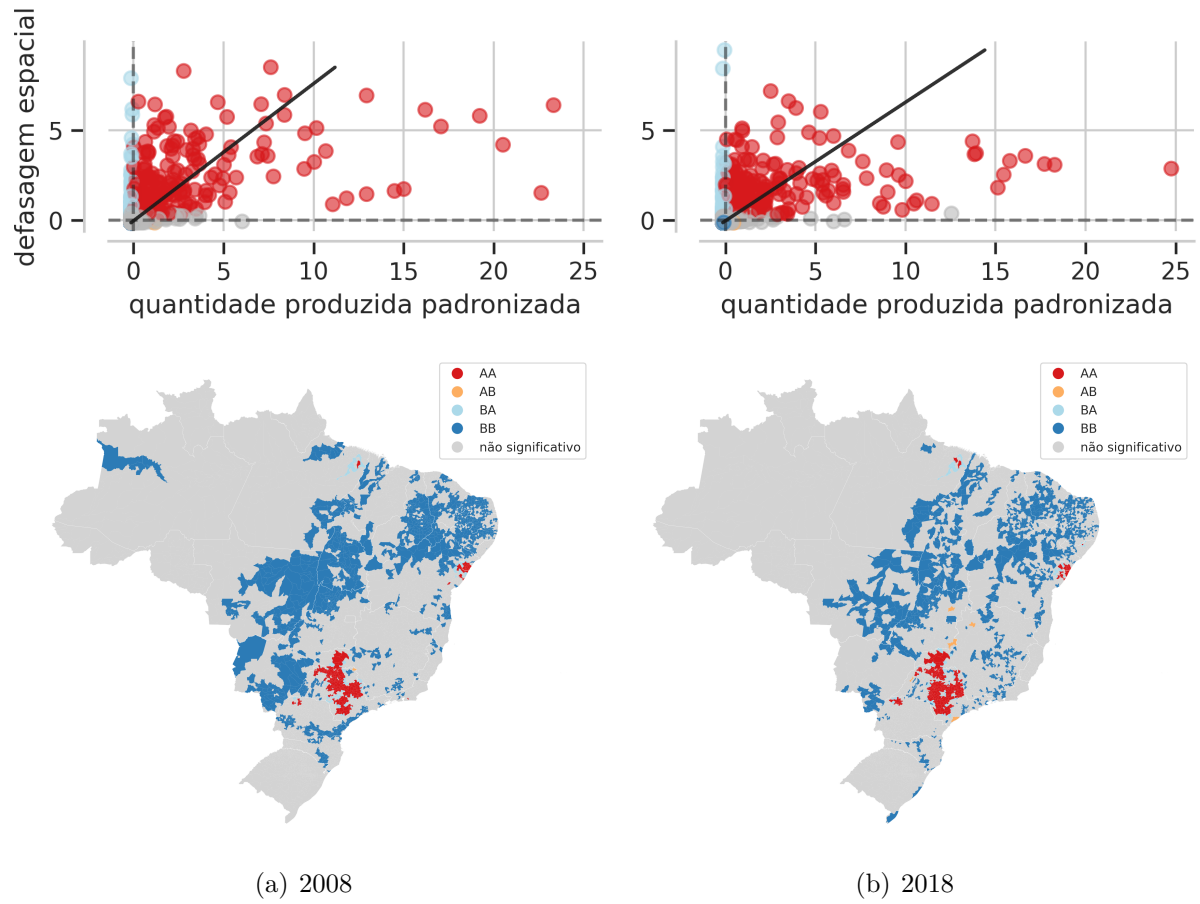
Fonte: Do autor.

Figura 25 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de fumo produzida, em toneladas, nos anos de 2008 e 2018



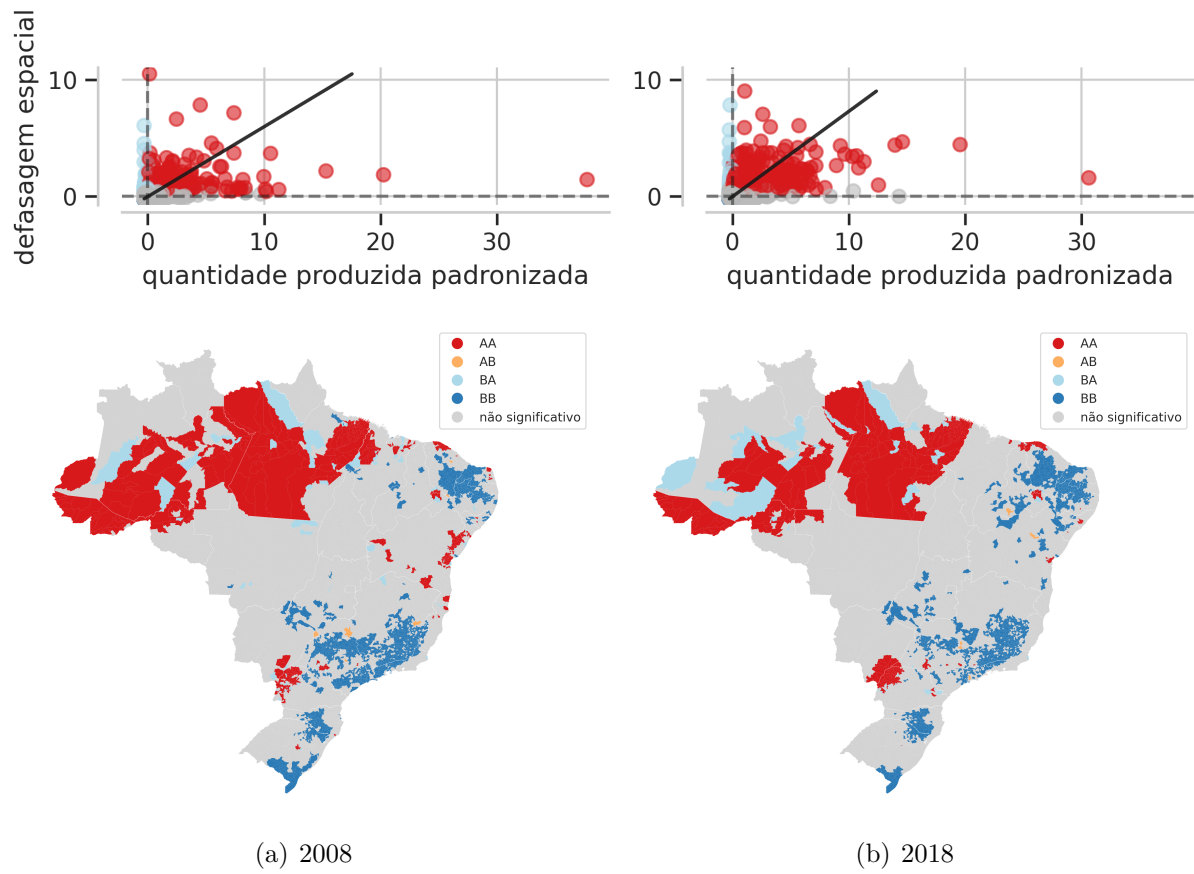
Fonte: Do autor.

Figura 26 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de laranja produzida, em toneladas, nos anos de 2008 e 2018



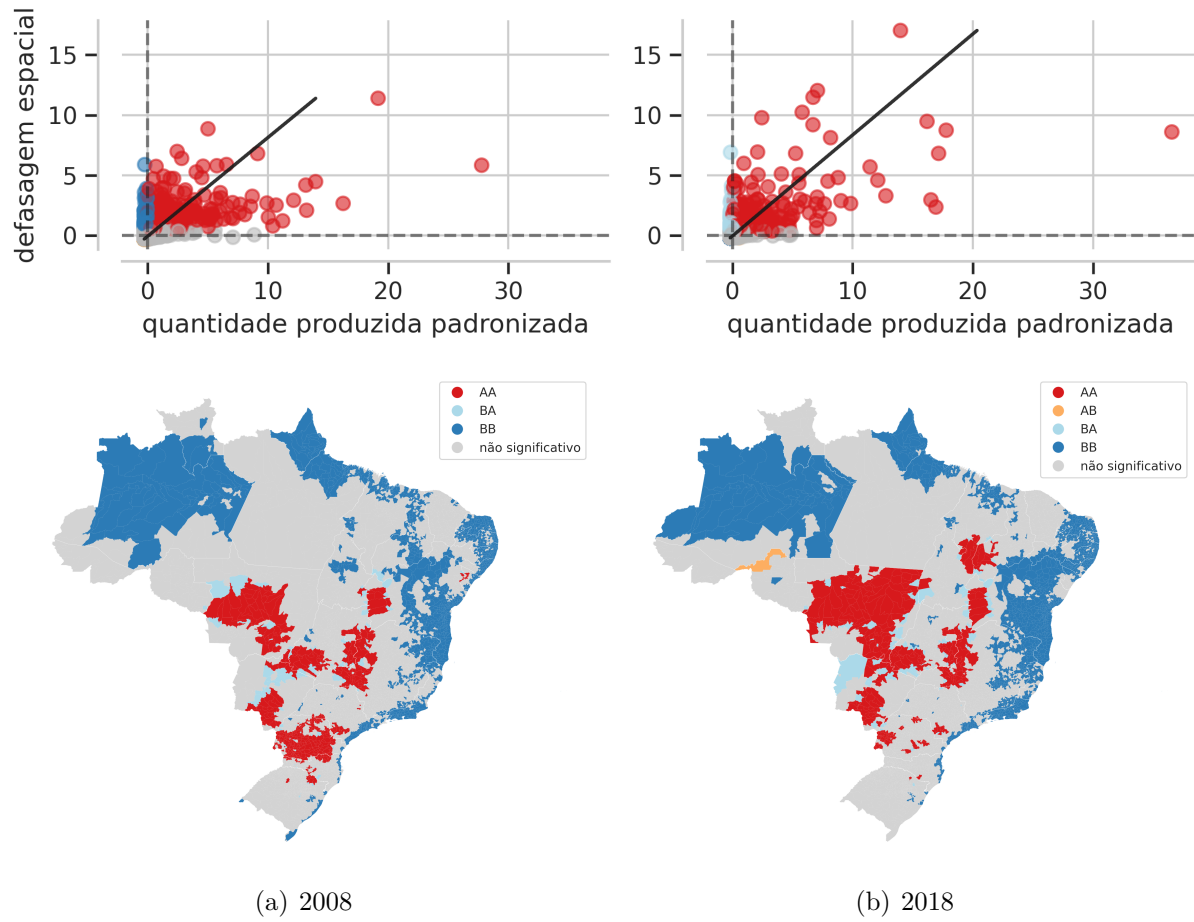
Fonte: Do autor.

Figura 27 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de mandioca produzida, em toneladas, nos anos de 2008 e 2018



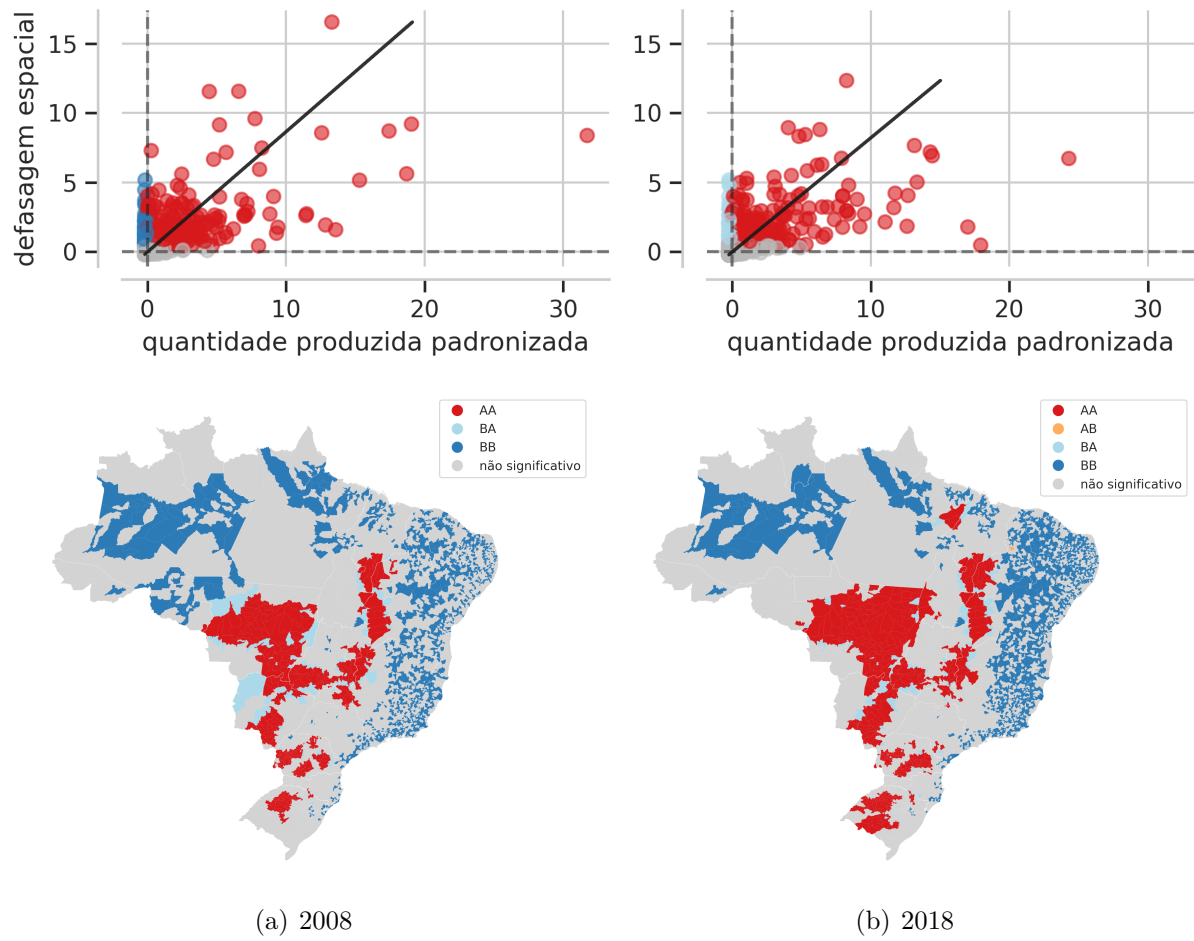
Fonte: Do autor.

Figura 28 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de milho produzida, em toneladas, nos anos de 2008 e 2018



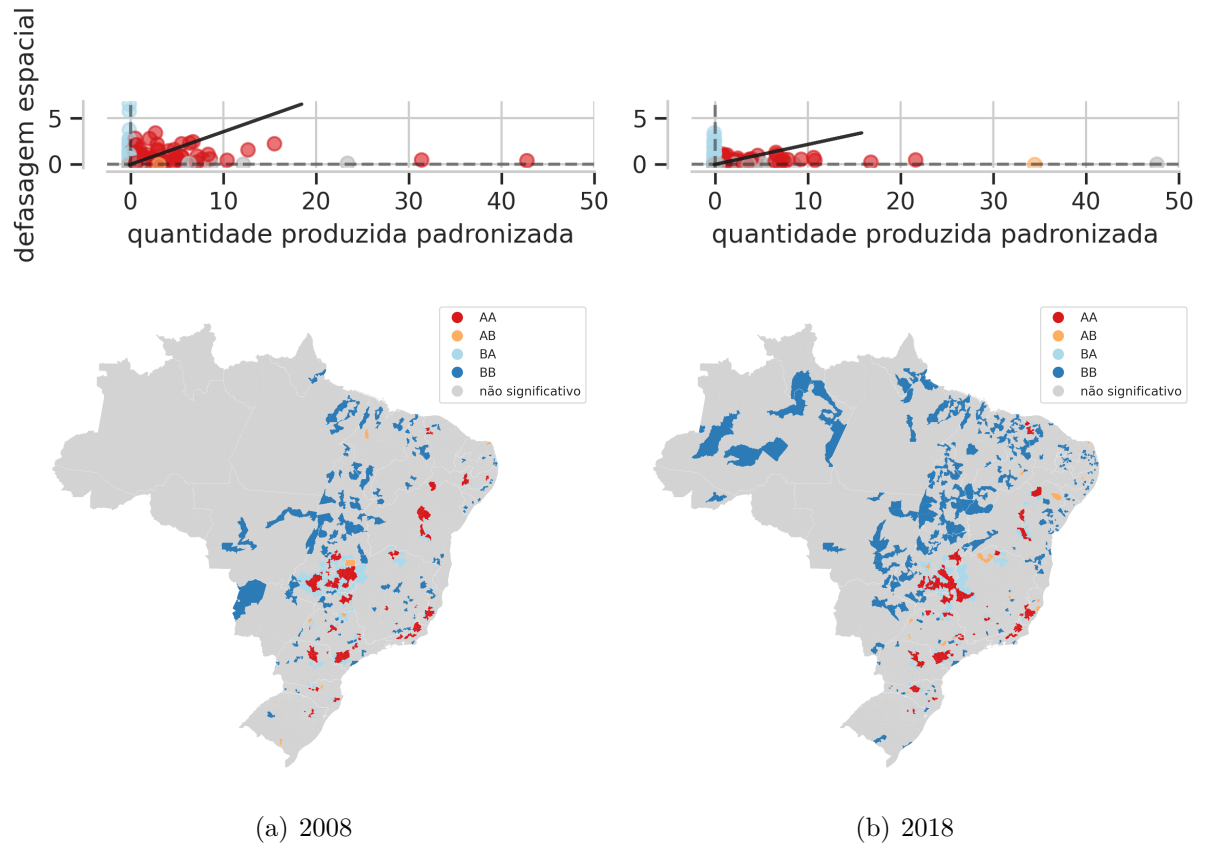
Fonte: Do autor.

Figura 29 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de soja produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

Figura 30 – Diagramas de dispersão de Moran e mapas LISA para a quantidade de tomate produzida, em toneladas, nos anos de 2008 e 2018



Fonte: Do autor.

## APÊNDICE B – CÓDIGOS

```

import pandas as pd
import numpy as np
import os

"""\#Dados"""\

from google.colab import drive
drive.mount("/content/drive")

os.getcwd()

os.chdir("/content/drive/My_Drive/2019-marcio/")

"""\# Escolha das culturas"""\

escolha_culturas = pd.read_csv("Dados/escolha_culturas.csv",encoding="
    ↪ latin-1",sep = ";")
escolha_culturas

escolha_culturas.sort_values("Valor",ascending=False).head(15).to_latex(
    ↪ index = False)

"""\# Novo conjunto de dados"""\

os.getcwd()

"""\## Quantidade produzida"""\

quantidade_produzida = pd.read_csv("Dados/quantidade_produzida.csv",
    ↪ encoding = "latin-1",sep = ";")
quantidade_produzida = quantidade_produzida.replace(["...", "-"], np.nan).
    ↪ fillna(0)
quantidade_produzida

#selecao das culturas

```

```

culturas_selecionadas = quantidade_produzida[["Cod.,"Município","Ano","
    ↪ Algodão(herbáceo(em_carroço)","Arroz(em_casca)","Banana(cacho)","
    ↪ Café(em_grão)_Total","Cana-de-acúcar","Feijão(em_grão)","Fumo(em
    ↪ _folha)","Laranja","Mandioca","Milho(em_grão)","Soja(em_grão)","
    ↪ Tomate"]]
culturas_selecionadas.columns = ["mun","município","ano","algodão","arroz
    ↪ ","banana","café","cana","feijão","fumo","laranja","mandioca","
    ↪ milho","soja","tomate"]
culturas_selecionadas

culturas_selecionadas.info()

culturas = culturas_selecionadas.iloc[:, 3:].astype(int)
culturas.info()

#unindo novamente as culturas aos identificadores do município e ao ano
dados_selecionados = culturas_selecionadas[["mun","município","ano"]]
dados = pd.concat([dados_selecionados,culturas],axis =1)
dados

#Salvando dados das culturas selecionadas
dados.to_csv("Dados/culturas_selecionadas.csv",index=False,sep=";",
    ↪ encoding="latin-1")

# Pacotes

!pip install geopandas==0.8.1
!pip install --upgrade pyshp
!pip install shapely==1.7.0
!pip install --upgrade descartes
!pip install mapclassify==2.3.0 libpysal==4.3.0 splot==1.1.3

# Commented out IPython magic to ensure Python compatibility.
# Carregando os pacotes
import pandas as pd
import numpy as np
import scipy.stats as stats
# %matplotlib inline
import matplotlib.pyplot as plt

```

```

import seaborn as sns
sns.set(style="whitegrid", palette="pastel")
from sklearn.decomposition import PCA
from sklearn.preprocessing import scale
from sklearn.cluster import KMeans
pd.set_option("mode.chained_assignment", None)
import os

# espacial
import geopandas as gp
import splot
import mapclassify as mc
from libpysal.weights.contiguity import Queen
from esda import Moran, Moran_Local
from splot.esda import plot_moran, moran_scatterplot, lisa_cluster,
    ↪ plot_local_autocorrelation

"""# Dados

"""

# links para arquivos
link = "https://raw.githubusercontent.com/lincolnfrias/dados/master/"
link_p = "https://raw.githubusercontent.com/patriciasiqueira/
    ↪ patriciasiqueira.github.io/master/arquivos/"

from google.colab import drive
drive.mount("/content/drive")

os.getcwd()

os.chdir("/content/drive/My_Drive/2019-marcio/")

# lendo os dados sobre as culturas com valores acima de 5bi para 2008 e
    ↪ 2018
#dados = pd.read_csv(link_p+"culturas-08-18.csv")
dados = pd.read_csv("Dados/culturas_selecionadas.csv", sep = ";", encoding=
    ↪ "latin-1")

```

```

# shapefile
br = gp.read_file(link+"br.json")
# br.geometry = br.geometry.simplify(0.0001) # para melhorar a
    ↪ visualizacao do mapa
br = br.rename(columns={"CD_GEOCMU": "mun"})
br.mun = br.mun.astype(int)
br2 = br.drop("NM_MUNICIP", axis=1)

""""## Dados 2008""""

dados08_0 = dados.query("ano_==2008")
dados08_0.head()

# Unir dados e shapefile e retirar ilhas
dados08 = dados08_0.merge(br2,how="right")
dados08 = gp.GeoDataFrame(dados08)
dados08.iloc[:,0:15] = dados08.iloc[:,0:15].fillna(0)
#Conferindo ilhas
dados08.iloc[[1525,3499]]

dados08 = dados08[dados08.mun != 2605459] # retirar Fernando de Noronha
dados08 = dados08[dados08.mun != 3520400] # retirar Ilhabela

# matriz de vizinhanca queen
w08 = Queen.from_dataframe(dados08)
w08.transform = "r"

""""## Dados 2018""""

""""

dados18_0 = dados.query("ano_==2018")
dados18_0.head()

# Unir dados e shapefile
dados18 = dados18_0.merge(br2, how="right")
dados18 = gp.GeoDataFrame(dados18)
dados18.iloc[:, 0:15] = dados18.iloc[:, 0:15].fillna(0)
dados18.iloc[[1525,3499]]

```

```

dados18 = dados18[dados18.mun != 2605459] # retirar Fernando de Noronha
dados18 = dados18[dados18.mun != 3520400] # retirar Ilhabela

# matriz de vizinhanca queen
w18 = Queen.from_dataframe(dados18)
w18.transform = "r"

"""># Estatistica descritiva com todos os municipios

Ignorar por enquanto
"""

culturas = ["algodao", "arroz", "banana", "cafe", "cana","feijao","fumo",
    ↪ "laranja", "mandioca", "milho", "soja", "tomate"]

#2008
dados08[culturas].T.apply(pd.DataFrame.describe,axis=1)

#2018
dados18[culturas].T.apply(pd.DataFrame.describe,axis=1)

"""># Estatistica descritiva apenas com os municipios produtores"""

culturas = ["algodao", "arroz", "banana", "cafe", "cana","feijao","fumo",
    ↪ "laranja", "mandioca", "milho", "soja", "tomate"]

#2008
dados = dados08
dados = dados.replace(0,np.NaN)
est = dados[culturas].T.apply(pd.DataFrame.describe,axis=1)
est["std"] = est["std"]/est["mean"]; est = est.rename(columns={"std":"cv"
    ↪ }) #Substituindo o s pelo cv
est#.to_latex(float_format=lambda x: format(x,".2f"), index=True)

#2018
dados = dados18
dados = dados.replace(0,np.NaN)
est = dados[culturas].T.apply(pd.DataFrame.describe,axis=1)

```

```
est["std"] = est["std"]/est["mean"]; est = est.rename(columns={"std":"cv"
    ↪ }) #Substituindo o s pelo cv
est#.to_latex(float_format=lambda x: format(x,".2f"), index=True)
```

```
""""# I de Moran Global para Tabelas
```

Calculo do I de Moran Global para todas as culturas, bem como os valores  
 ↪ de significancia dos testes de permutacao aleatoria.

```
## 2008
```

```
"""
```

```
nomes = ["algodao", "arroz", "banana", "cafe", "cana","feijao","fumo","
    ↪ laranja", "mandioca", "milho", "soja", "tomate"]
```

```
moran08 = []
```

```
p_sim08 = []
```

```
for i in nomes:
```

```
    temp = Moran(dados08[i].values, w08,)
```

```
    moran08 = np.append(moran08,temp.I)
```

```
    p_sim08 = np.append(p_sim08,temp.p_sim)
```

```
data = {
```

```
    "cultura": nomes,
```

```
    "IMoran": moran08,
```

```
    "p_sim": p_sim08
```

```
}
```

```
tab = pd.DataFrame(data,columns= ["cultura","IMoran","p_sim"])
```

```
tab#.to_latex(decimal = ",",index= False)
```

```
""""## 2018
```

```
"""
```

```
nomes = ["algodao", "arroz", "banana", "cafe", "cana","feijao","fumo","
    ↪ laranja", "mandioca", "milho", "soja", "tomate"]
```

```
moran18 = []
```

```

p_sim18 = []
for i in nomes:
    temp = Moran(dados18[i].values, w18)
    moran18 = np.append(moran18,temp.I)
    p_sim18 = np.append(p_sim18,temp.p_sim)

data = {
    "cultura": nomes,
    "IMoran": moran18,
    "p_sim": p_sim18
}

tab = pd.DataFrame(data,columns= ["cultura","IMoran","p_sim"])
tab#.to_latex(decimal = ",",index= False)

#Unindo anos
data = {
    "cultura": nomes,
    "IMoran08": moran08,
    "p_sim08": p_sim08,
    "IMoran18": moran18,
    "p_sim18": p_sim18
}

data
tab = pd.DataFrame(data,columns= ["cultura","IMoran08","p_sim08","
↔ IMoran18","p_sim18"])
tab#.to_latex(decimal = ",",index= False,float_format="%.3f")

# Pacotes

!pip install geopandas==0.8.1
!pip install --upgrade pyshp
!pip install --upgrade descartes
!pip install mapclassify==2.3.0 libpysal==4.3.0 splot==1.1.3
!pip install shapely==1.7.0
!pip install jenkspy==0.2.0

```

```
# Commented out IPython magic to ensure Python compatibility.
# Carregando os pacotes
import os
import pandas as pd
import numpy as np
import scipy.stats as stats
# %matplotlib inline
import matplotlib.pyplot as plt
import matplotlib.cm as cm
import seaborn as sns
sns.set(style='whitegrid', palette='pastel')
from sklearn.decomposition import PCA
from sklearn.preprocessing import scale
from sklearn.cluster import KMeans
pd.set_option('mode.chained_assignment', None)

# espacial
import geopandas as gp
import splot
import mapclassify as mc
from libpysal.weights.contiguity import Queen
from esda import Moran, Moran_Local
from splot.esda import plot_moran, moran_scatterplot, lisa_cluster,
    ↪ plot_local_autocorrelation

#Novos
import matplotlib as mpl
from libpysal.weights.spatial_lag import lag_spatial
import seaborn as sbn
from esda.moran import (Moran_Local, Moran_Local_BV,
                        Moran, Moran_BV)

from matplotlib import patches, colors
from matplotlib.collections import PatchCollection
from matplotlib.colors import ListedColormap, LinearSegmentedColormap

#Cruzar divisao UF com municipios
```

```

import shapefile
from matplotlib.patches import Polygon

#Fisher Jenks
from spreg import OLS
import jenkspy

""""# Funcoes """"

# modificando codigo fonte de funcoes
def moran_hot_cold_spots(moran_loc, p=0.05):
    sig = 1 * (moran_loc.p_sim < p)
    HH = 1 * (sig * moran_loc.q == 1)
    LL = 3 * (sig * moran_loc.q == 3)
    LH = 2 * (sig * moran_loc.q == 2)
    HL = 4 * (sig * moran_loc.q == 4)
    cluster = HH + LL + LH + HL
    return cluster

def mask_local_auto(moran_loc, p=0.5):
    '''
    Create Mask for coloration and labeling of local spatial
    ↪ autocorrelation
    Parameters
    -----
    moran_loc : esda.moran.Moran_Local instance
        values of Moran's I Global Autocorrelation Statistic
    p : float
        The p-value threshold for significance. Points will
        be colored by significance.
    Returns
    -----
    cluster_labels : list of str
        List of labels - ['ns', 'HH', 'LH', 'LL', 'HL']
    colors5 : list of str
        List of colours - ['#d7191c', '#fdae61', '#abd9e9',
        '#2c7bb6', 'lightgrey']
    colors : array of str
        Array containing coloration for each input value/ shape.

```

```

labels : list of str
    List of label for each attribute value/ polygon.
'''
# create a mask for local spatial autocorrelation
cluster = moran_hot_cold_spots(moran_loc, p)

cluster_labels = ['nao_significativo', 'AA', 'BA', 'BB', 'AB'] #
    ↪ Traduzindo a legenda dos mapas LISA
labels = [cluster_labels[i] for i in cluster]

colors5 = {0: 'lightgrey',
           1: '#d7191c',
           2: '#abd9e9',
           3: '#2c7bb6',
           4: '#fdae61'}
colors = [colors5[i] for i in cluster] # for Bokeh
# for MPL, keeps colors even if clusters are missing:
x = np.array(labels)
y = np.unique(x)
colors5_mpl = {'AA': '#d7191c', #Traduzindo a legenda dos mapas LISA
              'BA': '#abd9e9',
              'BB': '#2c7bb6',
              'AB': '#fdae61',
              'nao_significativo': 'lightgrey'}
colors5 = [colors5_mpl[i] for i in y] # for mpl

# HACK need this, because MPL sorts these labels while Bokeh does not
cluster_labels.sort()
return cluster_labels, colors5, colors, labels

def lisa_cluster2(moran_loc, gdf, p=0.05, ax=None,
                 legend=True, legend_kwds=None, **kwargs):
    """
    Create a LISA Cluster map
    Parameters
    -----
    moran_loc : esda.moran.Moran_Local or Moran_Local_BV instance
        Values of Moran's Local Autocorrelation Statistic
    gdf : geopandas dataframe instance

```

The Dataframe containing information to plot. Note that 'gdf' will  
 ↪ be  
 modified, so calling functions should use a copy of the user  
 provided 'gdf'. (either using `gdf.assign()` or `gdf.copy()`)

`p` : float, optional  
 The p-value threshold for significance. Points will  
 be colored by significance.

`ax` : matplotlib Axes instance, optional  
 Axes in which to plot the figure in multiple Axes layout.  
 Default = None

`legend` : boolean, optional  
 If True, legend for maps will be depicted. Default = True

`legend_kwds` : dict, optional  
 Dictionary to control legend formatting options. Example:  
 ‘‘`legend_kwds={'loc': 'upper left', 'bbox_to_anchor': (0.92, 1.05)`  
 ↪ `}`‘‘  
 Default = None

`**kwargs` : keyword arguments, optional  
 Keywords designing and passed to `geopandas.GeoDataFrame.plot()`.

Returns  
 -----

`fig` : matplotlib Figure instance  
 Figure of LISA cluster map

`ax` : matplotlib Axes instance  
 Axes in which the figure is plotted

Examples  
 -----

Imports

```
>>> import matplotlib.pyplot as plt
>>> from libpysal.weights.contiguity import Queen
>>> from libpysal import examples
>>> import geopandas as gpd
>>> from esda.moran import Moran_Local
>>> from splot.esda import lisa_cluster
```

Data preparation and statistical analysis

```
>>> link = examples.get_path('Guerry.shp')
>>> gdf = gpd.read_file(link)
```

```

>>> y = gdf['Donatns'].values
>>> w = Queen.from_dataframe(gdf)
>>> w.transform = 'r'
>>> moran_loc = Moran_Local(y, w)
Plotting

>>> fig = lisa_cluster(moran_loc, gdf)
>>> plt.show()

"""
# retrieve colors5 and labels from mask_local_auto
_, colors5, _, labels = mask_local_auto(moran_loc, p=p)

# define ListedColormap
hmap = colors.ListedColormap(colors5)

if ax is None:
    figsize = kwargs.pop('figsize', None)
    fig, ax = plt.subplots(1, figsize=figsize)
else:
    fig = ax.get_figure()

gdf.assign(cl=labels).plot(column='cl', categorical=True,
                           k=2, cmap=hmap, linewidth=0, ax=ax,
                           edgecolor='white', legend=legend,
                           legend_kwds=legend_kwds, **kwargs)

ax.add_collection(PatchCollection(ptchs_uf,color='none', edgecolor='w'
    ↪ , linewidths=0.01)) #adicionar linhas dos estados ao mapa
ax.set_axis_off()
ax.set_aspect('equal')
return fig, ax

"""# Dados"""

# links para arquivos
link = 'https://raw.githubusercontent.com/marcioaloisiojr/dados/master/'

# shapefile

```

```

br = gp.read_file(link+'br.json')
br = br.rename(columns={'CD_GEOCMU': 'mun'})
br.mun = br.mun.astype(int)
br2 = br.drop('NM_MUNICIP', axis=1)

br2.info()

"""### Montar Drive"""

#Para salvar os graficos no Google Drive
from google.colab import drive
drive.mount('/content/drive')

os.chdir('/content/drive/My_Drive/2019-marcio')

os.getcwd()

# lendo os dados sobre as culturas com valores acima de 5bi para 2008 e
    ↪ 2018
dados = pd.read_csv(link+'/culturas_selecionadas.csv',sep = ';',encoding='
    ↪ latin-1')

dados.head()

"""### Dados 2008"""

dados08_0 = dados.query('ano==2008')
dados08_0.head()

dados08_0.info()

# Unir dados e shapefile e retirar ilhas
dados08 = dados08_0.merge(br2,how='right')
dados08 = gp.GeoDataFrame(dados08)
dados08.iloc[:,0:15] = dados08.iloc[:,0:15].fillna(0)
#Conferindo ilhas
dados08.iloc[[1525,3499]] #Fernando de Noronha e Ilhabela

dados08.info()

```

```

dados08 = dados08[dados08.mun != 2605459] # retirar Fernando de Noronha
dados08 = dados08[dados08.mun != 3520400] # retirar Ilhabela

dados08.info()

# matriz de vizinhanca queen
w08 = Queen.from_dataframe(dados08)
w08.transform = 'r'

"""## Dados 2018

"""

dados18_0 = dados.query('ano==2018')
dados18_0.head()

# Unir dados e shapefile
dados18 = dados18_0.merge(br2, how='right')
dados18 = gp.GeoDataFrame(dados18)
dados18.iloc[:, 0:15] = dados18.iloc[:, 0:15].fillna(0)
#Conferindo ilhas
dados18.iloc[[1525,3499]] #Fernando de Noronha e Ilhabela

dados18.info()

dados18 = dados18[dados18.mun != 2605459] # retirar Fernando de Noronha
dados18 = dados18[dados18.mun != 3520400] # retirar Ilhabela

dados18.info()

# matriz de vizinhanca queen
w18 = Queen.from_dataframe(dados18)
w18.transform = 'r'

"""# Divisao do pais por UF"""

#Grafico com divisao por UF
sf_uf = gp.read_file(link+"br_divisao_uf.json")

```

```

sf_uf.plot(figsize = (9,9),linewidth = 0.1)
plt.axis('off')
plt.show()

sf_rg = br
sf_rg.plot(figsize = (9,9),linewidth = 0.1)
plt.axis('off')
plt.show()

#Regioes geograficas
sf = shapefile.Reader('br_regioes_geograficas/
    ↪ RG2017_regioesgeograficas2017.shp')
#sf = shapefile.Reader(link+'br.json')
shapes = sf.shapes()
Nshp = len(shapes)

ptchs = []
for nshp in range(Nshp):
    pts = np.array(shapes[nshp].points)
    prt = shapes[nshp].parts
    par = list(prt) + [pts.shape[0]]

    for pij in range(len(prt)):
        ptchs.append(Polygon(pts[par[pij]:par[pij+1]]))

#UF
sf_uf = shapefile.Reader('br_unidades_da_federacao/BRUFE250GC_SIR.shp')
shapes_uf = sf_uf.shapes()
Nshp_uf = len(shapes_uf)

ptchs_uf = []
for nshp_uf in range(Nshp_uf):
    pts_uf = np.array(shapes_uf[nshp_uf].points)
    prt_uf = shapes_uf[nshp_uf].parts
    par_uf = list(prt_uf) + [pts_uf.shape[0]]

    for pij_uf in range(len(prt_uf)):
        ptchs_uf.append(Polygon(pts_uf[par_uf[pij_uf]:par_uf[pij_uf+1]]))

```

```

fig = plt.figure(figsize = (9,9))
ax = fig.add_subplot(111)

ax.add_collection(PatchCollection(ptchs,facecolor='0.75', edgecolor='w',
    ↪ linewidths=0))
ax.add_collection(PatchCollection(ptchs_uf,color='none', edgecolor='w',
    ↪ linewidths=0.5))
ax.axis('auto'); ax.axis('off')
plt.show()
# Fonte: http://www.phme.it/wilt/2017/05/06/dynamic-mapping-with-
    ↪ shapefiles-and-python/

"""# Dados por regioao"""

#Unindo os dois graficos com as culturas nas linhas
por_regiao = pd.read_csv(link+'por_regiao.csv',sep = ';',encoding='latin
    ↪ -1')
por_regiao

#Grafico
order = ['Norte', 'Nordeste', 'Centro-Oeste', 'Sudeste', 'Sul']
por_regiao_pct = por_regiao.groupby(['rotulo_cultura', 'regiao',])['
    ↪ quantidade'].sum().rename('count')
c = por_regiao_pct / por_regiao_pct.groupby(level=0).sum()*100
c.unstack()[order].plot.barh(stacked = True,figsize = (10,10),cmap='
    ↪ RdYlBu')
plt.gca().invert_yaxis()
plt.ylabel('')
plt.xlabel('')
plt.legend(loc='upper_right', ncol = 5,mode = 'expand',borderaxespad = 0.,
    ↪ bbox_to_anchor=(0, -0.15, 1., .102))
plt.savefig('por_regiao.pdf',bbox_inches="tight")
plt.show()

#Tabela
order = ['Norte', 'Nordeste', 'Centro-Oeste', 'Sudeste', 'Sul']
por_regiao_pct = por_regiao.groupby(['rotulo_cultura', 'regiao',])['
    ↪ quantidade'].sum().rename('count')

```

```

c = por_regiao_pct / por_regiao_pct.groupby(level=0).sum()*100
c.unstack()[order]

"""# Mapas tematicos

"""

#Exportar ou nao para o google drive os graficos?
salvar = False

#Funcao para mapas tematicos
def mapas_tematicos_fj(cultura,ano,salvar = True,dados08 = dados08,
    ↪ dados18 = dados18,**kwargs):
    #Paleta de cores
    GnBu = cm.get_cmap('GnBu', 256)
    newcolors = GnBu(np.linspace(0, 1, 256))
    cinza = np.array([211/256, 211/256, 211/256, 1]) #definindo manualmente
    ↪ a cor do regime nao significativo
    newcolors[:25, :] = cinza
    newcmp = ListedColormap(newcolors)
    #Funcao
    referencia = jenkspy.jenks_breaks(dados18[cultura][dados18[cultura] !=
    ↪ 0], nb_class=4) #Fisher Jenks a partir dos dados de 2018
    referencia[0] = 0 #Alterando para os municipios nao produtores
    if max(dados08[cultura]) > max(dados18[cultura]): #Se max 2008 for
    ↪ maior do que o max em 2018...
        print('Maximo de 2008 maior do que o maximo de 2018')
        referencia[-1] = max(dados08[cultura])
    labels = ['0', '[1.00, '+str(referencia[1]) +']' , '('+ str(referencia
    ↪ [1]) + ', '+ str(referencia[2]) +']' , '('+ str(referencia[2]) +
    ↪ ', '+ str(referencia[3]) +']' , '('+ str(referencia[3]) + ', '+ str
    ↪ (referencia[4]) +']'] #rotulos da legenda
    print(labels)
    if ano == 2008:
        dados_mt = dados08
    else:
        dados_mt = dados18
    classif = mc.UserDefined(dados_mt[cultura].values,referencia)

```

```

cl = [labels[i] for i in classific.yb]
df = dados_mt.assign(cl = cl)
df.cl = pd.Categorical(df.cl,ordered=True,categories=labels)
legenda = (ano == 2018) #Exibir legenda apenas para 2018
figsize = kwargs.pop('figsize', None)
fig, ax = plt.subplots(1, figsize=figsize)
df.plot(column='cl', categorical=True,cmap= newcmp, linewidth=0, ax=ax,
        legend=legenda)
ax.add_collection(PatchCollection(ptchs_uf,color='none', edgecolor='w',
    ↪ linewidths=0.01)) #Adicionando a divisao por uf ao mapa
ax.set_axis_off()
ax.set_aspect('equal')
if salvar:
    nome_figura = 'mapas_tematicos/mt_' + cultura + str(ano)[2] + str(ano)
    ↪ [3] + '.pdf'
    plt.savefig(nome_figura,bbox_inches="tight")
return fig, ax

"""### Algodao"""

#2008
mapas_tematicos_fj('algodao',ano = 2008,figsize = (9,9))
plt.show()

#2018
mapas_tematicos_fj('algodao',ano = 2018,figsize = (9,9))
plt.show()

"""### Arroz"""

#2008
mapas_tematicos_fj('arroz',ano = 2008,figsize = (9,9))
plt.show()

#2018
mapas_tematicos_fj('arroz',ano = 2018,figsize = (9,9))
plt.show()

"""### Banana"""

```

```
#2008
mapas_tematicos_fj('banana',ano = 2008,figsize = (9,9))
plt.show()
```

```
#2018
mapas_tematicos_fj('banana',ano = 2018,figsize = (9,9))
plt.show()
```

```
""""### Cafe""""
```

```
#2008
mapas_tematicos_fj('cafe',ano = 2008,figsize = (9,9))
plt.show()
```

```
#2018
mapas_tematicos_fj('cafe',ano = 2018,figsize = (9,9))
plt.show()
```

```
""""### Cana-de-acucar""""
```

```
#2008
mapas_tematicos_fj('cana',ano = 2008,figsize = (9,9))
plt.show()
```

```
#2018
mapas_tematicos_fj('cana',ano = 2018,figsize = (9,9))
plt.show()
```

```
""""### Feijao""""
```

```
#2008
mapas_tematicos_fj('feijao',ano = 2008,figsize = (9,9))
plt.show()
```

```
#2018
mapas_tematicos_fj('feijao',ano = 2018,figsize = (9,9))
plt.show()
```

```
"""### Fumo"""

#2008
mapas_tematicos_fj('fumo',ano = 2008,figsize = (9,9))
plt.show()

#2018
mapas_tematicos_fj('fumo',ano = 2018,figsize = (9,9))
plt.show()

"""### Laranja"""

#2008
mapas_tematicos_fj('laranja',ano = 2008,figsize = (9,9))
plt.show()

#2018
mapas_tematicos_fj('laranja',ano = 2018,figsize = (9,9))
plt.show()

"""### Mandioca"""

#2008
mapas_tematicos_fj('mandioca',ano = 2008,figsize = (9,9))
plt.show()

#2018
mapas_tematicos_fj('mandioca',ano = 2018,figsize = (9,9))
plt.show()

"""### Milho"""

#2008
mapas_tematicos_fj('milho',ano = 2008,figsize = (9,9))
plt.show()

#2018
mapas_tematicos_fj('milho',ano = 2018,figsize = (9,9))
plt.show()
```

```

"""### Soja"""

#2008
mapas_tematicos_fj('soja',ano = 2008,figsize = (9,9))
plt.show()

#2018
mapas_tematicos_fj('soja',ano = 2018,figsize = (9,9))
plt.show()

"""### Tomate"""

#2008
mapas_tematicos_fj('tomate',ano = 2008,figsize = (9,9))
plt.show()

#2018
mapas_tematicos_fj('tomate',ano = 2018,figsize = (9,9))
plt.show()

"""# Diagramas de Dispersao de Moran e Mapas LISA 2008 e 2018

"""

#Alterar salvamento?
salvar = False

def dispersao_moran(moran_loc08,moran_loc18):
    fig, (ax1,ax2) = plt.subplots(1,2, figsize = (9,3.3), sharey= 'row',
        ↪ sharex= True)

    moran_scatterplot(moran_loc08, p=0.05, ax= ax1)
    moran_scatterplot(moran_loc18, p=0.05,ax = ax2)
    ax1.set_xlabel('quantidade_produzida_padronizada')
    ax1.set_title('')
    ax1.set_ylabel('defasagem_espacial')
    ax2.set_xlabel('quantidade_produzida_padronizada')
    ax2.set_title('')

```

```

    ax2.set_ylabel('')
    return fig

"""### Algodao"""

#2008
y08 = dados08['algodao'].values
moran_loc08_algodao = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['algodao'].values
moran_loc18_algodao = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_algodao,moran_loc18_algodao)
if salvar: plt.savefig('dispersao_moran/dalgodao.pdf',bbox_inches="tight"
    ↪ )
plt.show()

lisa_cluster2(moran_loc08_algodao, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/algodao08.pdf',bbox_inches="tight")

lisa_cluster2(moran_loc18_algodao, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/algodao18.pdf',bbox_inches="tight")

"""### Arroz"""

#2008
y08 = dados08['arroz'].values
moran_loc08_arroz = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['arroz'].values
moran_loc18_arroz = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_arroz,moran_loc18_arroz)
if salvar: plt.savefig('dispersao_moran/darroz.pdf',bbox_inches="tight")
plt.show()

```

```

lisa_cluster2(moran_loc08_arroz, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/arroz08.pdf',bbox_inches="tight")

lisa_cluster2(moran_loc18_arroz, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/arroz18.pdf',bbox_inches="tight")

"""### Banana

"""

#2008
y08 = dados08['banana'].values
moran_loc08_banana = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['banana'].values
moran_loc18_banana = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_banana,moran_loc18_banana)
if salvar: plt.savefig('dispersao_moran/dbanana.pdf',bbox_inches="tight")
plt.show()

lisa_cluster2(moran_loc08_banana, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/banana08.pdf',bbox_inches="tight")

lisa_cluster2(moran_loc18_banana, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/banana18.pdf',bbox_inches="tight")

"""### Cafe

"""

#2008
y08 = dados08['cafe'].values
moran_loc08_cafe = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['cafe'].values

```

```
moran_loc18_cafe = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_cafe,moran_loc18_cafe)
if salvar: plt.savefig('dispersao_moran/dcafe.pdf',bbox_inches="tight")
plt.show()

lisa_cluster2(moran_loc08_cafe, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig("mapas_lisa/cafe08.pdf",bbox_inches="tight")

lisa_cluster2(moran_loc18_cafe, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig("mapas_lisa/cafe18.pdf",bbox_inches="tight")

"""### Cana-de-acucar

"""

#2008
y08 = dados08['cana'].values
moran_loc08_cana = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['cana'].values
moran_loc18_cana = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_cana,moran_loc18_cana)
if salvar: plt.savefig('dispersao_moran/dcana.pdf',bbox_inches="tight")
plt.show()

lisa_cluster2(moran_loc08_cana, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig("mapas_lisa/cana08.pdf",bbox_inches="tight")

lisa_cluster2(moran_loc18_cana, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig("mapas_lisa/cana18.pdf",bbox_inches="tight")

"""### Feijao"""

#2008
y08 = dados08['feijao'].values
moran_loc08_feijao = Moran_Local(y08,w08,seed=55555)
```

```

#2018
y18 = dados18['feijao'].values
moran_loc18_feijao = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_feijao,moran_loc18_feijao)
if salvar: plt.savefig('dispersao_moran/dfeijao.pdf',bbox_inches="tight")
plt.show()

lisa_cluster2(moran_loc08_feijao, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/feijao08.pdf',bbox_inches="tight")

lisa_cluster2(moran_loc18_feijao, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/feijao18.pdf',bbox_inches="tight")

""### Fumo""

#2008
y08 = dados08['fumo'].values
moran_loc08_fumo = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['fumo'].values
moran_loc18_fumo = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_fumo,moran_loc18_fumo)
if salvar: plt.savefig('dispersao_moran/dfumo.pdf',bbox_inches="tight")
plt.show()

lisa_cluster2(moran_loc08_fumo, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/fumo08.pdf',bbox_inches="tight")

lisa_cluster2(moran_loc18_fumo, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/fumo18.pdf',bbox_inches="tight")

""### Laranja""

#2008
y08 = dados08['laranja'].values

```

```

moran_loc08_laranja = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['laranja'].values
moran_loc18_laranja = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_laranja,moran_loc18_laranja)
if salvar: plt.savefig('dispersao_moran/dlaranja.pdf',bbox_inches="tight"
    ↪ )
plt.show()

lisa_cluster2(moran_loc08_laranja, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/laranja08.pdf',bbox_inches="tight")

lisa_cluster2(moran_loc18_laranja, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/laranja18.pdf',bbox_inches="tight")

"""### Mandioca"""

#2008
y08 = dados08['mandioca'].values
moran_loc08_mandioca = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['mandioca'].values
moran_loc18_mandioca = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_mandioca,moran_loc18_mandioca)
if salvar: plt.savefig('dispersao_moran/dmandioca.pdf',bbox_inches="tight"
    ↪ ")
plt.show()

lisa_cluster2(moran_loc08_mandioca, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/mandioca08.pdf',bbox_inches="tight")

lisa_cluster2(moran_loc18_mandioca, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig('mapas_lisa/mandioca18.pdf',bbox_inches="tight")

"""### Milho"""

```

```
#2008
y08 = dados08['milho'].values
moran_loc08_milho = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['milho'].values
moran_loc18_milho = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_milho,moran_loc18_milho)
if salvar: plt.savefig('dispersao_moran/dmilho.pdf',bbox_inches="tight")
plt.show()

lisa_cluster2(moran_loc08_milho, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig("mapas_lisa/milho08.pdf",bbox_inches="tight")

lisa_cluster2(moran_loc18_milho, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig("mapas_lisa/milho18.pdf",bbox_inches="tight")

""### Soja""

#2008
y08 = dados08['soja'].values
moran_loc08_soja = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['soja'].values
moran_loc18_soja = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_soja,moran_loc18_soja)
if salvar: plt.savefig('dispersao_moran/dsoja.pdf',bbox_inches="tight")
plt.show()

lisa_cluster2(moran_loc08_soja, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig("mapas_lisa/soja08.pdf",bbox_inches="tight")

lisa_cluster2(moran_loc18_soja, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig("mapas_lisa/soja18.pdf",bbox_inches="tight")
```

```
"""### Tomate"""

#2008
y08 = dados08['tomate'].fillna(0)
y08 = y08.values
moran_loc08_tomate = Moran_Local(y08,w08,seed=55555)

#2018
y18 = dados18['tomate'].fillna(0)
y18 = y18.values
moran_loc18_tomate = Moran_Local(y18, w18,seed=55555)

dispersao_moran(moran_loc08_tomate,moran_loc18_tomate)
if salvar: plt.savefig('dispersao_moran/dtomate.pdf',bbox_inches="tight")
plt.show()

lisa_cluster2(moran_loc08_tomate, dados08, p=0.05, figsize = (9,9))
if salvar: plt.savefig("mapas_lisa/tomate08.pdf",bbox_inches="tight")

lisa_cluster2(moran_loc18_tomate, dados18, p=0.05, figsize = (9,9))
if salvar: plt.savefig("mapas_lisa/tomate18.pdf",bbox_inches="tight")
```