

UNIVERSIDADE FEDERAL DE ALFENAS  
INSTITUTO DE CIÊNCIAS SOCIAIS APLICADAS  
BACHARELADO INTERDISCIPLINAR EM CIÊNCIA E ECONOMIA

GUILHERME DA COSTA FEDELE

ANÁLISE ESPACIAL DO PIB E ISS PARA MUNICÍPIOS DO ESTADO DE SÃO  
PAULO

VARGINHA - MG  
2021

GUILHERME DA COSTA FEDELE

ANÁLISE ESPACIAL DO PIB E ISS PARA MUNICÍPIOS DO ESTADO DE SÃO  
PAULO

Trabalho de conclusão de Piepex como parte dos requisitos para obtenção do grau de Bacharel Interdisciplinar em Ciência e Economia.

Orientador: Deive Ciro de Oliveira

VARGINHA - MG

2021



Ministério da Educação  
Universidade Federal de Alfenas  
Avenida Celina Ferreira Ottoni, 4000 - Bairro Padre Vitor, Varginha/MG - CEP 37048-395  
Telefone: (35) 3219-8640 - <http://www.unifal-mg.edu.br>

CURSO BACHARELADO INTERDISCIPLINAR EM CIÊNCIA E ECONOMIA  
ATA de defesa de Trabalho de Conclusão de Curso

As 19:00 horas do dia 13 do mês de SETEMBRO do ano de 2021, na Universidade Federal de Alfenas – Unifal-MG, Campus Varginha, compareceram para defesa de trabalho de conclusão de curso - TCP do(a) discente GUILHERME DA COSTA FEDELE tendo como título do trabalho: ANÁLISE ESPACIAL DO PIB E ISS PARA MUNICÍPIOS DO ESTADO DE SÃO PAULO, e a Banca Examinadora composta pelos examinadores: DEIVE CIRO DE OLIVEIRA (orientador), LUCIENE RESENDE GONÇALVES (examinadora)), e JORGE GARCIA FILHO (examinador). Após a apresentação e as observações dos membros da banca avaliadora, ficou definido que o trabalho foi considerado APROVADO COM RESTRIÇÕES (Observações sugeridas pelos avaliadores).

Eu, DEIVE CIRO DE OLIVEIRA (orientador), lavrei a presente ata que segue assinada por mim e pelos demais membros da Banca Examinadora.

Observações:

Discente:

NOME: GUILHERME DA COSTA FEDELE

Membros da Banca Examinadora:

NOME: DEIVE CIRO DE OLIVEIRA

NOME: LUCIENE RESENDE GONÇALVES

NOME: JORGE GARCIA FILHO



Documento assinado eletronicamente por **Deive Ciroliveira, Professor do Magistério Superior**, em 13/09/2021, às 20:40, 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 **Luciene Resende Gonçalves, Professor do Magistério Superior**, em 17/09/2021, às 09:51, 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 **Guilherme da Costa Fedele, Usuário Externo**, em 20/09/2021, às 18:33, 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 **Jorge Garcia Filho, Usuário Externo**, em 20/09/2021, às 18:46, 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 **0592846** e o código CRC **EFC7FDC7**.

---

Referência: Processo nº 23087.010598/2021-71

SEI nº 0592846

GUILHERME DA COSTA FEDELE

ANÁLISE ESPACIAL DO PIB E ISS PARA MUNICÍPIOS DO ESTADO DE SÃO  
PAULO

Trabalho de conclusão de Piepex como parte dos requisitos para obtenção do grau de Bacharel Interdisciplinar em Ciência e Economia.

Aprovado em \_\_\_\_ de \_\_\_\_\_ de \_\_\_\_\_

BANCA EXAMINADORA:

---

Prof Dr. Deive Ciro de Oliveira

---

Prof Dr. Luciene Resende Gonçalves

---

Ms. Jorge Garcia Filho

## RESUMO

O PIB é o principal indicador que mede o nível de atividade econômica de uma determinada região, ou seja, a nível municipal é o principal termômetro econômico. Já o ISS é um imposto municipal que incide sobre os serviços, diferentemente de outros impostos que incidem sobre propriedades, o ISS ajuda a entender de uma maneira um pouco mais clara o nível de atividade econômica dos municípios. Além disso os municípios se interligam, existe uma relação entre os municípios que afeta diretamente a economia local. Com isto este trabalho tem como objetivo fazer uma análise descritiva espacial, para entender melhor essa relação entre municípios vizinhos para o PIB e para o ISS. Para isto serão analisados 644 municípios do estado de São Paulo nos anos de 2003 a 2018. Os métodos remetem a utilização de técnicas de Análise Exploratória de Dados Espaciais, utilizando os Índices de Moran Global e Local para medir a autocorrelação espacial e para verificar a existência de aglomerados espaciais. A partir dos resultados foi possível observar uma autocorrelação positiva, para todos os anos analisados e para as duas variáveis. Além disso a partir do Índice de Moran Local, foi possível analisar a formação de aglomerados espaciais do tipo Alto-Alto e do tipo Baixo-Alto em diferentes pontos do estado para anos diferentes. Com isso o estudo revela que para estas variáveis há um indicativo de sinergia entre os municípios estudados.

**Palavras-chave:** Estatística espacial; Dados de área; I de Moran; ISS; PIB.

## ABSTRACT

GDP is the main indicator that measures the level of economic activity in a given region, that is, at the municipal level it is the main economic thermometer. The ISS is a municipal tax levied on services, unlike other taxes levied on properties, the ISS helps to understand the level of economic activity in municipalities a little more clearly. In addition, the municipalities are interconnected, there is a relationship between the municipalities that directly affects the local economy. With this, this work aims to make a spatial descriptive analysis, to better understand this relationship between neighboring cities for the GDP and for the ISS. For this, 644 municipalities in the state of São Paulo will take place in the years 2003 to 2018. The methods refer to the use of the Exploratory Spatial Data Analysis technique, using the Global and Local Moran Index to assess the spatial autocorrelation and to verify the existence of spatial clusters. From the results, it was possible to observe a positive autocorrelation for all driven years and for the two variables. Furthermore, from the Local Moran Index, it was possible to analyze the formation of High-High and Low-High spatial clusters in different points of the state for different years. With this, the study reveals that for these variables there is an indication of synergy between the studied municipalities.

**Keywords:** spatial statistics; area data; I of Moran; ISS; GDP.

## SUMÁRIO

1	INTRODUÇÃO . . . . .	7
2	REFERENCIAL TEÓRICO . . . . .	9
3	MÉTODOS E MATERIAL . . . . .	11
3.1	MÉTODOS . . . . .	11
3.1.1	Estatística Espacial . . . . .	11
3.1.2	Dados Espaciais . . . . .	11
3.1.3	Autocorrelação espacial . . . . .	11
3.1.4	Matriz de ponderação espacial . . . . .	12
3.1.5	Modelagem de Tendência . . . . .	13
3.1.6	I de Moran Global . . . . .	14
3.1.7	I de Moran Local . . . . .	15
3.1.8	Inferência Sobre o I de Moran . . . . .	16
3.1.9	Diagrama de dispersão de Moran . . . . .	16
3.1.10	Mapas LISA . . . . .	17
3.2	MATERIAL . . . . .	17
3.3	FERRAMENTAS COMPUTACIONAIS . . . . .	19
4	RESULTADOS E DISCUSSÃO . . . . .	20
5	CONSIDERAÇÕES FINAIS . . . . .	29
	REFERÊNCIAS . . . . .	30

## 1 INTRODUÇÃO

O estado de São Paulo está localizado na região Sudeste do Brasil, é composto por 645 municípios que estão divididos em 15 mesorregiões e 63 microrregiões. É o estado mais populoso do Brasil, além de ter o segundo maior IDH (Índice de Desenvolvimento Humano), com 0,783, atrás apenas do Distrito Federal com 0,824, isto para o ano de 2010 (IBGE, 2017). Também é o estado com o maior PIB (Produto Interno Bruto), no ano de 2018 correspondeu a aproximadamente R\$ 2,210 trilhões (IBGE, 2021).

Dentre as cinco regiões do Brasil, a que mais se destaca em relação ao PIB é a região Sudeste, com destaque para o Estado de São Paulo. No ano de 2018 o PIB do Brasil foi de R\$ 7,004 trilhões, sendo que 53,1% está concentrada na região Sudeste. Além disso, o estado de São Paulo sozinho representa 31,6% do PIB brasileiro (IBGE, 2021).

Produto Interno Bruto (PIB) corresponde a toda produção da economia de um país ou região, em um dado período de tempo, geralmente anualmente ou trimestralmente, sempre calculado a preços de mercado, ou seja, preços correntes. Quando se trata de estudos estatísticos econômicos o PIB é o indicador mais usado dentro do Sistema de Contas Nacionais (SCN) que é a principal fonte de dados para estudos estatísticos (FEIJÓ; LIMA; FILHO, 2001).

Assim tem-se que o crescimento econômico está intrinsecamente ligada ao aumento da produção, ou seja, ao aumento do PIB. Porém crescimento não pode ser confundido com desenvolvimento econômico, nem sempre o crescimento reflete um aumento na qualidade de vida dos residentes de determinada região (NEGRI et al., 2006).

Outro importante termômetro da economia é o orçamento público, uma vez que geralmente quando há um aumento do investimento do governo a tendência é que haja um aumento de empregos, conseqüentemente aumentando a renda, aquecendo então a economia. O inverso também pode ocorrer, uma diminuição no investimento do governo, ou seja, uma restrição orçamentária, tende a desaquecer a economia de um modo geral, diminuindo o PIB no período subsequente. A tributação é a principal fonte de receitas do setor público, compondo parte importante do orçamento do Estado (TONI, 2010).

O governo também tem a função de regular a economia, arrecadando recursos através de impostos e alocando estes recursos principalmente em saúde, educação e assistência social (GIAMBIAGI; ALEM; PINTO, 2017).

Os impostos se dividem em Federais, Estaduais e Distrito Federal além dos municipais (PÊGAS, 2017). Dentro do governo municipal, o Imposto sobre Serviços de Qualquer Natureza (ISS) se mostra uma importante fonte de receita própria, no ano de 2018 o ISS representou 47,94% da receita tributária municipal. Além disso, o ISS foi responsável por 0,94% da carga tributária brasileira no ano de 2019, o maior valor entre os governos municipais (BREMAEKER, 2018).

O ISS foi criado no Brasil no ano de 1965, substituindo três impostos vigentes desde a Constituição de 1946, eram eles: o Imposto sobre Transações (estadual), o Imposto de Indústrias e Profissões (municipal) e o Imposto sobre Diversões Públicas (municipal) (PÊGAS, 2017). O ISS é um imposto municipal, ou seja, que compete aos municípios sua cobrança. Além disso, tem como fato gerador a prestação de serviços, sendo o valor da prestação de serviços a base de cálculo do imposto e incidindo sobre os prestadores de serviços do município. (PÊGAS, 2017).

No que se diz respeito à arrecadação tributária, a região Sudeste é responsável por 64,51% da arrecadação total do país, também é a que mais arrecada ISS, seguida da região Sul e da Região Centro-Oeste. Isso se deve pela maior urbanização destas três regiões em relação as regiões Norte e Nordeste (BREMAEKER, 2018). Sendo que só o estado de São Paulo arrecadou R\$ 22.089.145.065,76 de ISS no ano de 2018, há uma discrepância em relação ao segundo estado que mais arrecadou, o Rio de Janeiro, que arrecadou R\$ 4.845.997.561,19 (IPEADATA, 2021).

Com isso, o objetivo deste trabalho é analisar se há autocorrelação espacial tanto do PIB quanto do ISS para os municípios do estado de São Paulo. O trabalho busca analisar se há uma relação predatória para as variáveis estudadas, ou seja, uma relação entre os municípios onde o aumento de determinado município atrapalha o aumento dos municípios ao seu redor. Ou se existe uma relação sinérgica entre os municípios, demonstrando um crescimento conjunto entre os municípios para as variáveis estudadas.

Os métodos utilizados serão os Índices de Moran global e local, para a comprovação da significância estatística serão utilizados o teste de normalidade assintótica e a permutação aleatória. Além da elaboração do Diagrama de dispersão de Moran, e os mapas LISA, tanto de significância, quanto de *clusters*.

O trabalho se divide em cinco seções, incluindo esta introdução. Na seção a seguir será apresentado o referencial teórico, seguida da terceira seção que trabalhará os métodos, materiais e ferramentas computacionais utilizados para a análise. Na quarta seção serão apresentados os resultados e suas discussões, já na quinta seção serão expostas as considerações finais, e por fim, na sexta seção serão apresentadas as referências.

## 2 REFERENCIAL TEÓRICO

A análise espacial pode ser usada em diversas áreas do conhecimento, sendo usada para mapear doenças, realizar estudos ecológicos, além de ser muito usado também para monitorar problemas ambientais (ANDRADE et al., 2007). Porém isso não limita seu uso em outros estudos, a principal característica da análise espacial é estudar relacionamentos levando em consideração a localização espacial do fenômeno estudado de forma explícita. Resumidamente, adicionar o elemento espacial na análise proposta. (MONTEIRO et al., 2004). A seguir serão expostos alguns trabalhos que utilizam a estatística espacial para estudar as mais diversas áreas do conhecimentos.

Cardozo, Schaab e Parré (2019) fizeram uma análise espacial da produtividade de café na região sudeste de 1990 a 2015, utilizando Análise Exploratória de Dados Espacial (AEDE) e demonstrando que houve autocorrelação espacial negativa em todos os períodos do estudo, demonstrando que onde a produção era menor houve crescimento nas produções vizinhas diferente das regiões onde a produção já era mais alta. Já Seffrin, Araújo e Bazzi (2018) utilizou a estatística espacial para estudar a produção de soja na região oeste do estado do Paraná, nos anos de 2007 e 2008, utilizou tanto o Índice de Moran, quanto o Índice de Geary para estudar a autocorrelação espacial, ambos se mostraram positivas no período da análise, demonstrando que havia autocorrelação espacial.

Além da análise de produção rural, Friestino et al. (2016) utilizou a estatística espacial para estudar a incidência de câncer para o município de Campinas, localizado no interior do estado de São Paulo. Mapeando os casos de câncer para a cidade, auxiliando as unidades de saúde e o hospital de referência a terem um panorama mais detalhado da realidade local.

Trabalhos que estudam variáveis econômicas utilizando a estatística espacial, tem-se como exemplo Höher, Souza e Fochezatto (2020) que analisaram a distribuição espacial das cooperativas de crédito e concessão de crédito rural, testando também se essas variáveis teriam influência sobre o PIB, para os municípios do estado do Rio Grande do Sul. O que foi confirmado com os resultados do estudo, onde o aspecto geográfico mostrou ter um papel muito relevante, uma vez que tanto as cooperativas de crédito quanto a concessão de crédito rural tiveram uma alta correlação espacial, quanto essas variáveis somadas, influenciaram o crescimento do PIB.

Höher et al. (2018) também testou a hipótese de que o PIB influenciaria o IDHM para os municípios do Tocantins no ano de 2015, utilizou AEDE para testar essa hipótese e para testar também a autocorrelação para as duas variáveis de forma independente. Os resultados também demonstraram uma autocorrelação significativa, um município com um PIB alto, estava cercado de municípios com o PIB alto também. O IDHM seguiu a mesma tendência, além de demonstrar que havia também influência do PIB no IDHM.

Pinto e Parré (2019) trazem outro estudo que utiliza a variável PIB em sua análise, porém desta vez relacionando os gastos públicos dos municípios do Paraná com o aumento do PIB per capita, para o ano de 2010. Demonstrando que há correlação espacial, ou seja, que o aumento de despesas dos governos municipais aumentam o PIB per capita municipal e pode ser benéfico para toda a região envolvida.

Na área contábil, que também é abordada no trabalho, a estatística espacial também pode ser utilizada, como Santos e Nascimento (2014) que estudaram a arrecadação do Imposto Predial e Territorial Urbano (IPTU) no estado do Paraná de 1997 a 2011, dividindo sua análise em dois períodos, antes e depois da Lei de Responsabilidade Fiscal (LRF). Para os dois períodos houve autocorrelação espacial positiva, mostrando que a espacialidade influencia na arrecadação do imposto.

Já Gomes et al. (2019) estudaram a arrecadação de ISS para o estado de Minas Gerais, no período de 2013 a 2016, tendo como resultado, municípios com alta arrecadação geralmente cercados por municípios também com alta arrecadação e municípios com baixa arrecadação com vizinhos também com baixa arrecadação. Santos, Nascimento e Felema (2013) também estudaram o ISS, porém para o estado do Paraná, para os anos de 1997 a 2011, assim como Santos e Nascimento (2014) também utilizaram a LRF como divisão do período estudado e obteve resultados parecidos, nos dois períodos a autocorrelação espacial foi positiva.

## 3 MÉTODOS E MATERIAL

### 3.1 MÉTODOS

#### 3.1.1 Estatística Espacial

Estatística espacial é o ramo da estatística que tem como principal característica a análise dos eventos de acordo com sua localização no espaço. Podendo assim modelar a ocorrência desses fenômenos tanto estrutural em sua distribuição espacial como para identificar padrões (ANDRADE et al., 2007).

Esses tipos de estudos tornaram-se comuns em função da maior disponibilidade e facilidade de se utilizar os Sistemas de Informação Geográfica (SIG). O SIG é capaz de mostrar uma grande quantidade de dados, das mais variadas fontes em um mapa com cores, melhorando a visualização de padrões espaciais (MONTEIRO et al., 2004).

#### 3.1.2 Dados Espaciais

Para estudar estatística espacial, não apenas os métodos são diferentes, os tipos de dados também se diferenciam. Os dados não espaciais tem a função de determinar quanto um fenômeno varia, já os dados espaciais além de determinar quanto um fenômeno varia, se preocupa também em determinar aonde esse fenômeno ocorre no espaço (ALMEIDA, 2012).

Os três tipos de dados espaciais são: Eventos ou Padrões Pontuais, Superfícies Contínuas e Áreas com Contagens e Taxas agregadas. A primeira trata de pontos definidos no espaço onde os fenômenos ocorreram, como disseminação de doenças ou incidência de crimes, por exemplo. Já o segundo é obtido através de amostras de campo que podem ser regularmente distribuída ou não. Normalmente este tipo de dado é obtido através de levantamento de recursos naturais. Já o terceiro tipo trata de dados obtidos de levantamentos populacionais, como o censo por exemplo. Por esses dados ter confidencialidade, apesar de serem dados pontuais, eles acabam sendo expressos por polígonos fechados, esses polígonos podem ser setores censitários, municípios, por exemplo (MONTEIRO et al., 2004). A partir do tipo de dado, é possível determinar a autocorrelação espacial.

#### 3.1.3 Autocorrelação espacial

Autocorrelação espacial é um indicador que avalia para uma variável de interesse se existe uma relação entre um local de referência e seus determinados vizinhos. Em análises de área, nem sempre é possível determinar exatamente o ponto onde o fenômeno ocorreu, com isso é necessário utilizar ferramentas para a captação e mensuração da espacialidade

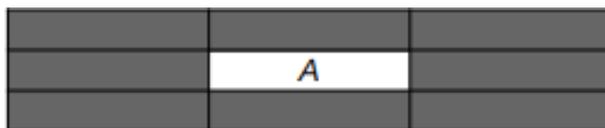
entre as áreas. Com isso é preciso determinar a matriz de ponderação espacial (W) (ALMEIDA, 2012).

### 3.1.4 Matriz de ponderação espacial

Uma matriz de ponderação espacial (W), tem como característica ser uma matriz quadrada, de dimensão  $n \times n$ . Os pesos espaciais  $w_{ij}$  representam o grau de conexão entre a região  $i$  e a região  $j$  (ALMEIDA, 2012).

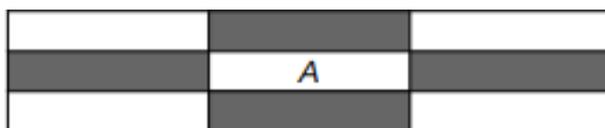
Existem três meios de determinar a contiguidade entre as regiões. O primeiro é a convenção *rainha* (*queen*) de contiguidade, que abrange todos os vizinhos que fazem divisa em todas as direções. Em seguida temos *torre* (*rock*) e *bispo* (*bishop*), a primeira convenção leva em consideração vizinhos na horizontal e vertical, e a segunda considera os vizinhos nas diagonais. As figuras a seguir representam as três principais convenções (ALMEIDA, 2012).

Figura 1 – Convenção *rainha* de contiguidade



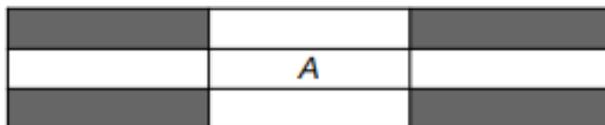
Fonte: Elaboração Própria

Figura 2 – Convenção *torre* de contiguidade



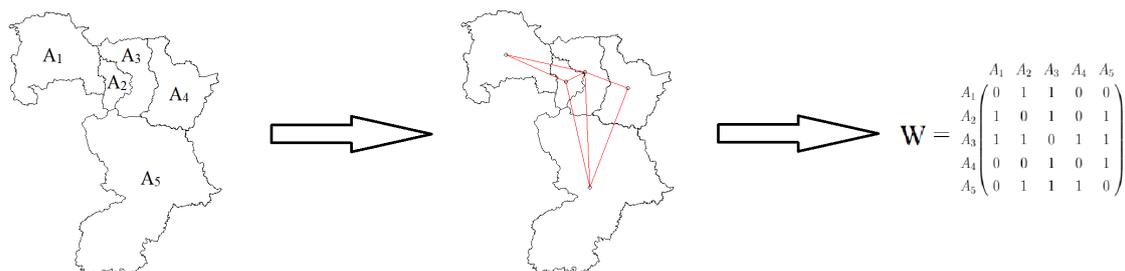
Fonte: Elaboração Própria

Figura 3 – Convenção *bispo* de contiguidade



Fonte: Elaboração Própria

Para este trabalho será utilizada a Matriz de Contiguidade do tipo *rainha*, pois esta é a mais abrangente. Um exemplo de aplicação reduzido, utilizando cinco municípios contíguos do estado de São Paulo, sendo eles Sorocaba ( $A_1$ ), Alumínio ( $A_2$ ), Mairinque ( $A_3$ ), São Roque ( $A_4$ ) e Ibiúna ( $A_5$ ). Apresentado na Figura 4.

Figura 4 – Exemplo matriz *rainha* de contiguidade

Fonte: Elaboração Própria

A partir da construção da matriz binária, é necessário normalizá-la em suas linhas, para que a matriz seja suavizada, auxiliando futuramente na análise. A soma de cada linha da matriz deve ser igual a um. Ou seja, é o resultado da divisão de cada  $w_{ij}$  pelo número total de cada linha (ALMEIDA, 2012). Demonstrada na Matriz  $W'$  a seguir:

$$W' = \begin{matrix} & A_1 & A_2 & A_3 & A_4 & A_5 \\ \begin{matrix} A_1 \\ A_2 \\ A_3 \\ A_4 \\ A_5 \end{matrix} & \begin{pmatrix} 0 & 0,5 & 0,5 & 0 & 0 \\ 0,333 & 0 & 0,333 & 0 & 0,333 \\ 0,25 & 0,25 & 0 & 0,25 & 0,25 \\ 0 & 0 & 0,5 & 0 & 0,5 \\ 0 & 0,333 & 0,333 & 0,333 & 0 \end{pmatrix} \end{matrix}$$

### 3.1.5 Modelagem de Tendência

Dados tendenciosos são um problema na análise espacial, uma vez que a tendência pode causar análises equivocadas da realidade e comprometer toda a análise (FILHO, 2018).

Uma forma de contornar esse problema é utilizar a média móvel espacial para modelar a tendência, reduzindo a variabilidade espacial, ou seja, gera uma superfície com menor flutuação dos dados (MONTEIRO et al., 2004).

A média móvel espacial é dada pela fórmula:

$$\hat{\mu}_i = \sum_{j=1}^n w_{ij} z_i. \quad (3.1)$$

Onde,  $z_i$  é a variável padronizada e  $w_{ij}$  são os elementos da matriz. Com isso temos que a média móvel espacial de modo simplificado é a média dos vizinhos.

Seguindo o exemplo de aplicação reduzido, foram atribuídos valores aleatórios para uma determinada variável, denominada Gama e calculado a Média Móvel Espacial para os valores aleatórios, conforme a Tabela 1 a seguir:

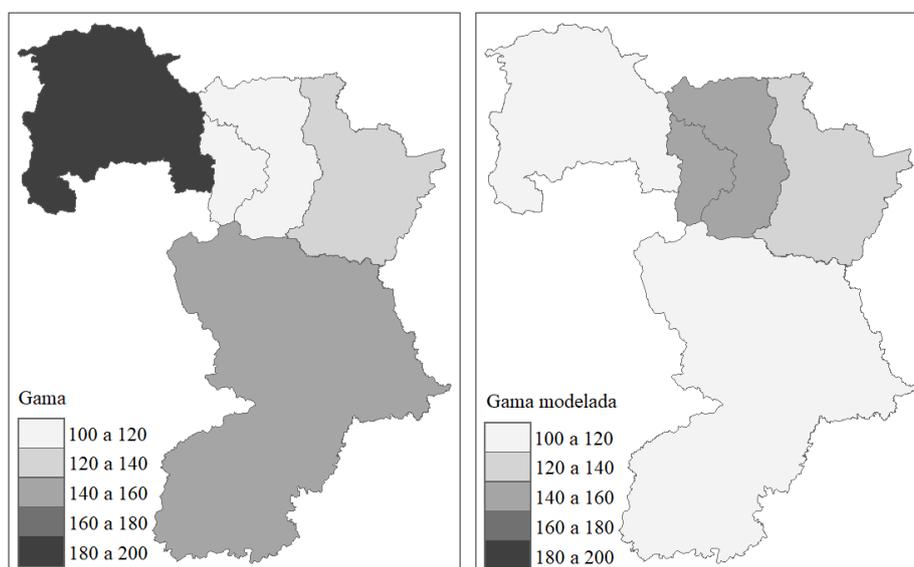
Tabela 1 – Valores aleatórios para a variável Gama

Municípios	Gama	Gama Normalizada
Sorocaba (A <sub>1</sub> )	200	105
Alumínio (A <sub>2</sub> )	110	151,33
Mairinque (A <sub>3</sub> )	100	146,75
São Roque (A <sub>4</sub> )	123	127
Ibiúna (A <sub>5</sub> )	154	111

Fonte: Elaboração Própria

Na tabela é possível notar que os valores tiveram uma menor variação, tornando-se mais homogêneos. Na Figura 5 a seguir demonstra uma superfície com menor flutuação a partir do cálculo da Média Móvel Espacial em relação à variável Gama.

Figura 5 – Gama e Gama aplicada Média Móvel Espacial



Fonte: Elaboração Própria

Feita a modelagem de tendência, pode-se partir para a análise de dependência espacial.

### 3.1.6 I de Moran Global

Moran propôs o primeiro coeficiente de autocorrelação espacial, para isso ele utilizou a medida da autocovariância na forma de produto cruzado, que foi denominada I de Moran (ALMEIDA, 2012).

O I de Moran é dado algebricamente por:

$$I = \frac{n}{S_0} \frac{\sum_i \sum_j w_{ij} z_i z_j}{\sum_{i=1}^n z_i^2}. \quad (3.2)$$

E matricialmente por:

$$I = \frac{n}{S_0} \frac{z'Wz}{z'z}. \quad (3.3)$$

Em (3.2) e (3.3),  $n$  é o número de regiões, já  $z$  representa a variável de interesse padronizada, ou seja os desvios divididos pela média, isto algebricamente pode ser representado por:  $z_i = (y_i - \bar{Y})$ ,  $w_{ij}$  é o elemento da matriz normalizada de proximidade espacial e  $S_0$  é dado pela equação:

$$S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{ij}. \quad (3.4)$$

Caso a matriz de proximidade seja normalizada,  $S_0$  passa a ser igual à  $n$ , com isso, pode-se reescrever a equação (3.3) da seguinte forma:

$$I = \frac{z'Wz}{z'z}. \quad (3.5)$$

O Índice de Moran não é centrado em zero, é centrado em seu valor esperado, caso  $I$  seja maior que o valor esperado indica uma autocorrelação espacial positiva, caso o valor de  $I$  seja menor do que o valor esperado isto indica uma autocorrelação espacial negativa e por último, caso o valor de  $I$  seja igual ao valor esperado não existe indicio de autocorrelação espacial, ou seja a variável é independente (ALMEIDA, 2012).

Este valor esperado é dado por:

$$E(I) = -\frac{1}{(n-1)}. \quad (3.6)$$

Para o exemplo da variável Gama trabalhado, tem-se  $I = -0.48031565$  e o  $E(I) = -0.25$ , portanto,  $I$  menor do que o  $E(I)$  demonstra uma autocorrelação negativa para os cinco municípios do exemplo.

Um indicio de autocorrelação positiva, demonstra uma similaridade entre os vizinhos, ou seja, se  $i$  tem valores altos da variável em análise, existe a propensão de que seus vizinhos tenham valores altos também. Já uma autocorrelação negativa, indica o inverso, que há dissimilaridade, com isso são inversos, se  $i$  tem valores altos, seus vizinhos tem valores baixos (ALMEIDA, 2012).

### 3.1.7 I de Moran Local

A estatística  $I$  de Moran local, foi sugerida por Anselin (1995), como um meio estatístico para calcular a autocorrelação local. Para Anselin (1995) um "*Local Indicator of Spatial association* (LISA)" poderá ser qualquer estatística que tenha a capacidade de indicar *clusters* espaciais, que sejam significativos estatisticamente para cada observação.

Além disso, também é necessário que o somatório dos indicadores locais sejam proporcionais ao indicador de autocorrelação espacial global utilizada, isto para todas as regiões em análise.

o I de Moran local para  $y$  seja padronizada, em uma determinada região  $i$ ,  $z_j$  pode ser dado algebricamente por:

$$I_i = z_i \sum_{j=1}^j w_{ij} z_j. \quad (3.7)$$

Já o seu valor esperado é dado por Anselin (1995):

$$E[I_i] = \frac{-w_i}{(n - 1)}. \quad (3.8)$$

Onde o elemento  $w_i$  corresponde a soma dos elementos da linha  $i$  da matriz  $W$ .

### 3.1.8 Inferência Sobre o I de Moran

Existem duas formas de se testar a significância do I de Moran por meio da inferência. A primeira forma é o teste de normalidade, onde se assume uma variável padronizada, representada por  $Z(I)$ , onde está tem uma distribuição amostral normal, com média zero e variância unitária (ALMEIDA, 2012). Dada por:

$$Z(I) = \frac{[I - E(I)]}{DP(I)}. \quad (3.9)$$

Onde  $E(I)$  representa o valor esperado para o Índice de Moran e  $DP(I)$  representa o desvio padrão.

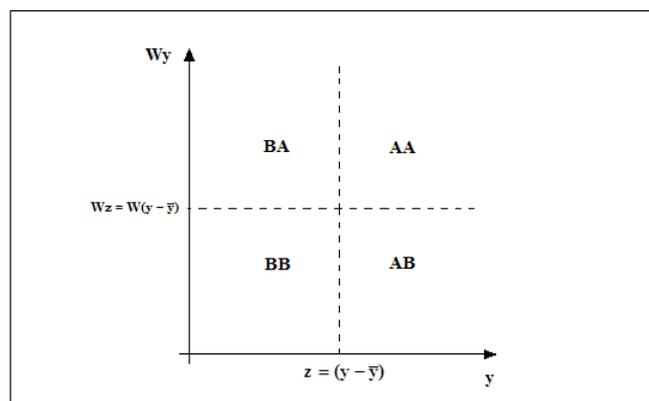
O segundo meio de testar a significância é a permutação aleatória, onde o primeiro passo é obter todos os valores observados e permuta-los aleatoriamente. O segundo passo se calcula a estatística para cada permutação, com isso se obtém uma distribuição de referência empírica para todas as realocações aleatórias (ALMEIDA, 2012).

### 3.1.9 Diagrama de dispersão de Moran

Outro modo de visualizar a autocorrelação espacial, é por meio do diagrama de dispersão de Moran, que nada mais é do que um gráfico da dispersão dos pontos que representam as regiões estudadas. Seu eixo vertical representa a defasagem espacial da variável de interesse e seu eixo horizontal representa a própria variável. Porém os eixos devem ser padronizados, para que ambos tenham média zero e a variância unitária, com isso temos  $z$  e  $Wz$  (ALMEIDA, 2012).

O diagrama de dispersão de Moran é representado na Figura 6 a seguir:

Figura 6 – Exemplo diagrama de dispersão de Moran



Fonte: Lima, Caldarelli e Camara (2014)

O diagrama, como observado na figura anterior é dividido em quatro quadrantes, Alto-Alto (AA), onde a variável estudada é alta e a média dos vizinhos também é alta. Baixo-Baixo (BB) que é o inverso onde tanto a variável quanto a média dos vizinhos são baixas. Também tem-se Alto-Baixo (AB) que demonstra que a variável tem valores alto, porém a média de seus vizinhos é baixa e por último Baixo-Alto (BA) que é o contrário da Alto-Baixo, onde a variável tem valor baixo porém a média de seus vizinhos é alta (FILHO, 2018).

### 3.1.10 Mapas LISA

Para melhor visualização do I de Moran local existem alguns tipos de mapas, uma vez que pela grande quantidade de dados a visualização por meio de tabelas se torna algo mais trabalhoso e mais propenso há erros. (ALMEIDA, 2012). Neste trabalho serão expostos dois tipos de mapas, o mapa de significância LISA e o mapa de *clusters* LISA.

O primeiro mostra as regiões onde o I de Moran Local foi significativo estatisticamente para a variável de interesse. Dividido entre regiões não significantes e regiões em quatro níveis de significância, 5%, 1%, 0.1% e 0.001%.

Já o segundo tipo de mapa exposto, o mapa de *clusters* utiliza tanto a informação do diagrama de dispersão de Moran como a significância, utilizando 5% de significância e localizando as regiões em seus respectivos quadrantes do diagrama de dispersão. Portanto o mapa é dividido entre não significativo, Alto-Alto, Baixo-Baixo, Alto-Baixo e Baixo-Alto.

## 3.2 MATERIAL

Para o presente trabalho, serão analisados 644 municípios do estado de São Paulo. Apenas um município do estado não está na análise, trata-se do município de Ilhabela, uma vez que este município é uma ilha, ou seja, não possui vizinhos. Por se tratar de um

trabalho onde será usado a contiguidade, este município poderia afetar a análise, portanto foi retirado. A Figura 7 trás os mapas dos municípios que serão analisados.

Figura 7 – Estado de São Paulo - Exceto Ilhabela



Fonte: Elaboração Própria

Os dados de Arrecadação do ISS incluindo receitas da dívida ativa, multas e juros foram retirados do site do Instituto de Pesquisa Econômica Aplicada (IPEA) tendo como fonte o próprio instituto (IPEADATA, 2021). Já os dados relacionados ao PIB foram retirados da Fundação Sistema Estadual de Análise de Dados Estatísticos (SEADE), tendo como fonte o Instituto Brasileiro de Geografia e Estatística (IBGE) (SEADE, 2021). Dados de população tem como fonte o IBGE e estão disponíveis no site do IPEA , foram utilizados para a divisão.(IPEADATA, 2021)

A escolha do ISS se da pela sua incidência sobre a prestação de serviços e não sobre renda ou propriedade como Imposto de Renda (IR) e Imposto Predial e Territorial Urbano (IPTU). Além disso é um imposto importante na composição da receita própria dos municípios brasileiros.

Já o PIB é uma escolha natural para analisar o crescimento econômico, é o principal termômetro da economia de uma determinada região, sendo assim o principal dado utilizado em análises estatísticas.

Ambos são demonstrados de forma per capita, ou seja, o total dividido pela população, para não haver distorções dado o tamanho dos municípios, os dados de população também foram retirados do IPEA, como fonte IBGE.

Já o estado de São Paulo foi escolhido por ser o estado com os maiores valores das variáveis analisadas, tanto de PIB quanto de ISS.

### 3.3 FERRAMENTAS COMPUTACIONAIS

Para a elaboração deste trabalho foi utilizado o software R, uma vez que este é um software de licença gratuita, referência na área de análise estatística e que possui ferramentas gráficas muito avançadas. Os principais pacotes utilizados estão demonstrados na Tabela 2 a seguir:

Tabela 2 – Pacotes utilizados

<b>Pacote</b>	<b>Utilização</b>
rgdal (BIVAND; KEITT; ROWLINGSON, 2021)	Importar os mapas
dplyr (WICKHAM et al., 2020)	Filtrar e unir dados
lubridate (GROLEMUND; WICKHAM, 2011)	Trabalhar com datas
deflateBR (MEIRELES, 2018)	Deflacionar os dados
sf (PEBESMA, 2018)	Operações com mapas
spdep (BIVAND; WONG, 2018)	Calcular os índices
sp(BIVAND; PEBESMA; GOMEZ-RUBIO, 2013)	Plotar mapas
tmap (TENNEKES, 2018)	Plotar mapas

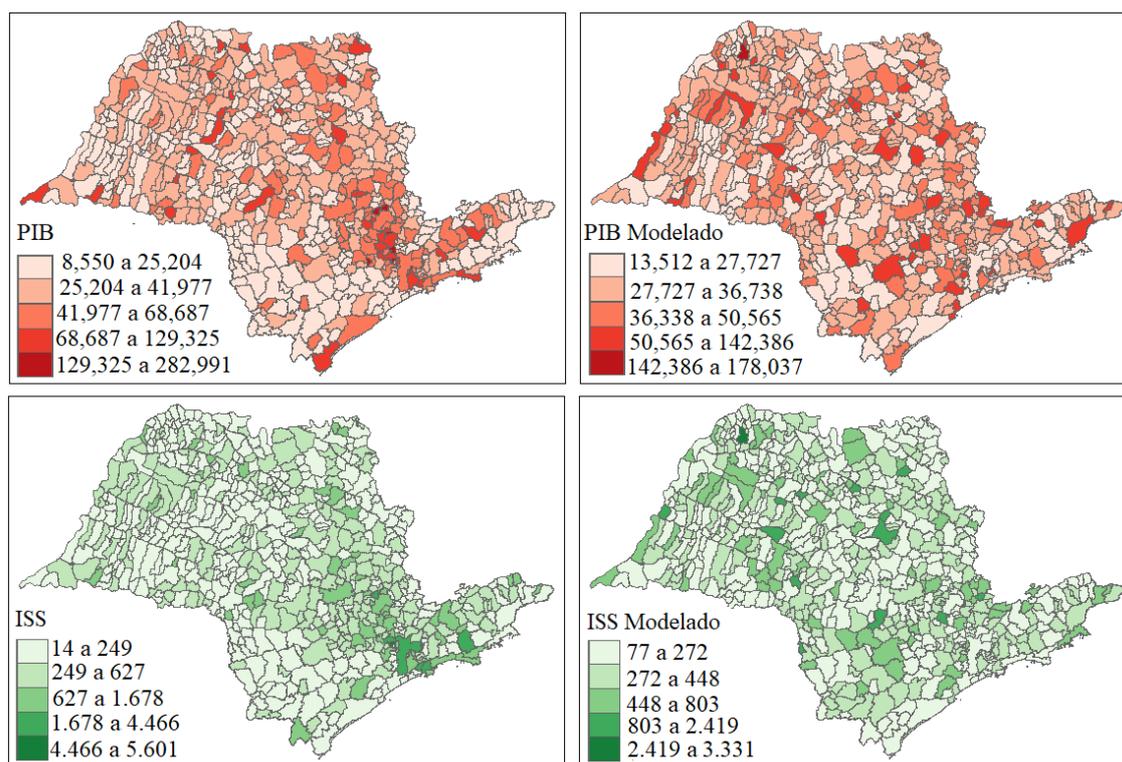
Fonte: Elaboração Própria

## 4 RESULTADOS E DISCUSSÃO

Antes de se iniciar a análise espacial, é necessário alguns passos com os dados. O primeiro é deflacioná-los, uma vez que estão em valores nominais. Para isto foi usado o Índice Geral de Preços - Disponibilidade Interna (IGP-DI). Feita a deflação, foi calculado ISS per capita e PIB per capita, dividindo o total deflacionado pela população total. Para os anos de 2007 e 2010 populações totais e para o restante população estimada pelo IBGE.

Com todos os dados organizados o segundo passo da análise foi calcular a Média Móvel Espacial, para modelar a tendência, fazendo com que a análise não seja prejudicada. A Figura 8 a seguir mostra os dados de PIB e ISS per capita, para o ano de 2011, antes de depois da modelagem de tendência:

Figura 8 – Modelagem de tendência utilizando a Média Móvel Espacial para o PIB e ISS no ano de 2011



Fonte: Elaboração Própria

Como é observado nos mapas anteriores, há uma tendência para a região metropolitana de São Paulo, que foi suavizada a partir da aplicação da Média Móvel Espacial.

Pode-se partir para a análise espacial. O primeiro passo é elaborar a matriz de vizinhança *rainha* para o estado de São Paulo, exemplificada na Figura 9.

Figura 9 – Matriz *rainha*

Fonte: Elaboração Própria

Determinada a matriz de vizinhança, pode-se partir para a análise I de Moran Global para as variáveis. Para isto é necessário calcular o I de Moran esperado, para este estudo, o valor  $E(I) = -0.00155521$ . Ou seja, para o I de Moran Global, valores maiores que  $E(I)$  correspondem há uma autocorrelação positiva, ou seja, se há um município com um valor alto para a variável estudada a propensão é que este tenha vizinhos também tenham valores altos. O inverso também é válido, caso o I de Moran seja menor do que o valor esperado há uma autocorrelação negativa, ou seja o município tem um alto valor da variável e seus vizinhos tendem a ter baixos valores.

Serão analisados a seguir as duas variáveis em estudo. Tanto para a variável PIB, quanto para a variável ISS, em todos os anos houve autocorrelação positiva, com resultados bastante semelhantes na comparação ano a ano como também na comparação entre as variáveis em valores do I de Moran Global.

Além do cálculo do Índice de Moran, é necessário fazer as inferências sobre os dados, para testar se estes são estatisticamente significantes. Para isso foram feitos os testes de Normalidade Assintótica e Permutação Aleatória.

Para o teste de Permutação aleatória foram utilizadas 1000000 permutações. Levando em consideração um intervalo de confiança de 95%, para o teste de normalidade, caso os valores estejam entre  $[-1.96, 1.96]$ , pode-se dizer que as variáveis são independentes, já para o teste de permutação aleatória, considera-se que há dependência espacial caso o p-valor seja menor ou igual a 5%.

A Tabela 3 traz os valores do I de Moran Global, para as duas variáveis estudadas, tanto PIB quanto ISS.

Tabela 3 – I de Moran

<b>Ano</b>	<b>I de Moran - PIB</b>	<b>I de Moran - ISS</b>
2003	0.0627226589689787	0.265750862677184
2004	0.0775244328790948	0.18738446409594
2005	0.0830407268113047	0.25860950218779
2006	0.0820988332470034	0.234935452749591
2007	0.133593406175328	0.242214460143244
2008	0.1277409865687	0.33374568540138
2009	0.151071806698252	0.220291155531872
2010	0.182352703601566	0.196427243579642
2011	0.244792681350757	0.192045677525443
2012	0.239194893870838	0.19664039148344
2013	0.270399721991003	0.196898463748268
2014	0.260979230158486	0.250477497408832
2015	0.331021452895072	0.245632892106985
2016	0.153975313985353	0.267894645260431
2017	0.140850941982012	0.283397190920611
2018	0.133595385406775	0.280269946410366

Fonte: Elaboração Própria

Prosseguindo a análise, a Tabela 4 traz o valor de  $Z(I)$  para o teste de normalidade assintótica e o p-valor para o teste de permutação aleatória, tanto para PIB quanto para ISS.

Tabela 4 – Inferências sobre o I de Moran

<b>Ano</b>	<b>Z(I) - PIB</b>	<b>p-valor - PIB</b>	<b>Z(I) - ISS</b>	<b>p-valor - ISS</b>
2003	2.6653934	0.0031839	11.0843104	0.0000009
2004	3.2791747	0.0010989	7.8347116	0.0000009
2005	3.5079174	0.0006859	10.7881815	0.0000009
2006	3.4688601	0.0007079	9.8064959	0.0000009
2007	5.6041720	0.0000299	10.1083326	0.0000009
2008	5.3614913	0.0000259	13.9038338	0.0000009
2009	6.3289442	0.0000039	9.1992447	0.0000009
2010	7.6260609	0.0000009	8.2096862	0.0000009
2011	10.2152430	0.0000009	8.0279969	0.0000009
2012	9.9831211	0.0000009	8.2185247	0.0000009
2013	11.277083	0.0000009	8.2292261	0.0000009
2014	10.8864464	0.0000009	10.4509738	0.0000009
2015	13.7908688	0.0000009	10.2500838	0.0000009
2016	6.4493432	0.0000599	11.1732061	0.0000009
2017	5.9051183	0.0000859	11.8160461	0.0000009
2018	5.6042541	0.0001879	11.6863694	0.0000009

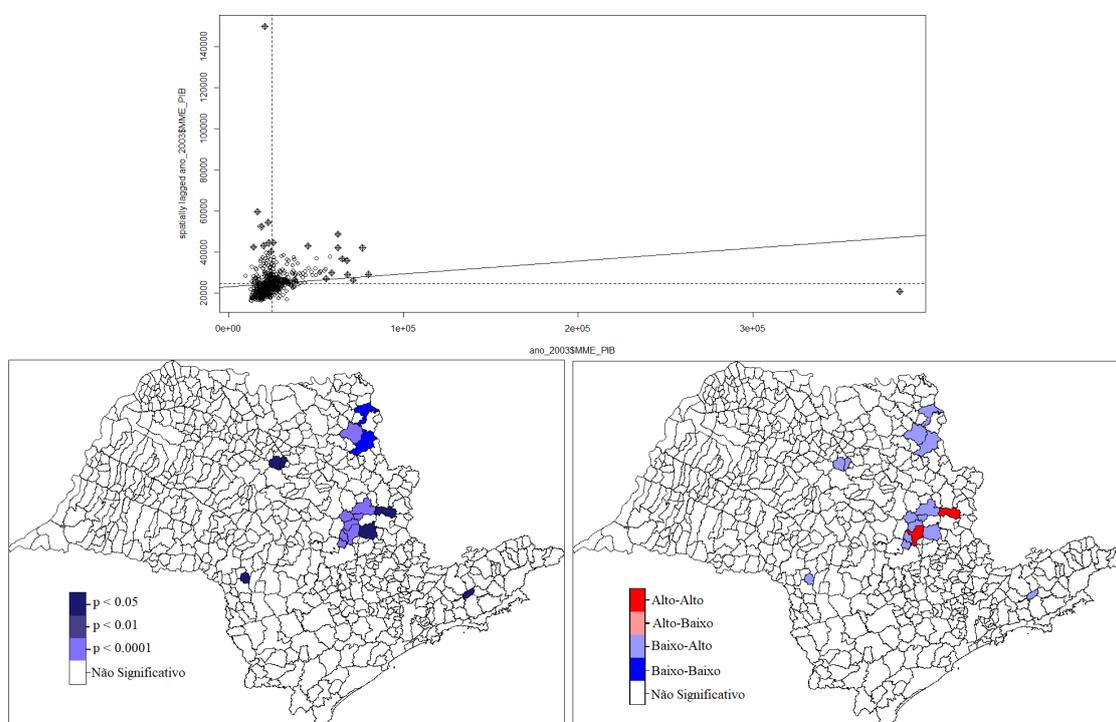
Fonte: Elaboração Própria

Os valores da Tabela 4 demonstram que os dados são estatisticamente significantes uma vez que os valores de  $Z(I)$  se mostraram acima de 1.96 e os p-valores para os teste de permutação aleatória se mostraram abaixo de 5%.

Como a análise foi feita para muitos anos, se tornaria inviável uma análise detalhada para todos eles. Portanto para o prosseguimento da análise foram selecionados os anos de 2003 por ser o primeiro ano do estudo, ano de 2018 por ser o último e o ano de 2011 por ser estar no meio do recorte temporal.

A Figura 10 representa o ano de 2003, onde estão demonstrados os diagramas de dispersão de Moran, além dos mapas de significância LISA e os mapas de *clusters* LISA, para a variável PIB.

Figura 10 – Análise espacial PIB - 2003



Fonte: Elaboração Própria

Para a elaboração dos mapas foi necessário o cálculo do índice de moran local. A partir do cálculo do índice é possível demonstrar os aglomerados espaciais para as variáveis. Deve-se destacar os municípios de Altinópolis, Batatais e Fernando Prestes, que formaram um aglomerado espacial do tipo Baixo-Alto para as duas variáveis. Outros dois municípios se destacaram para as duas variáveis, foram eles Jambeiro onde para o PIB teve relação Baixo-Alto e para o ISS Alto-Alto além do município de Santa Adélia onde para as duas variáveis teve relação Baixo-Alto.

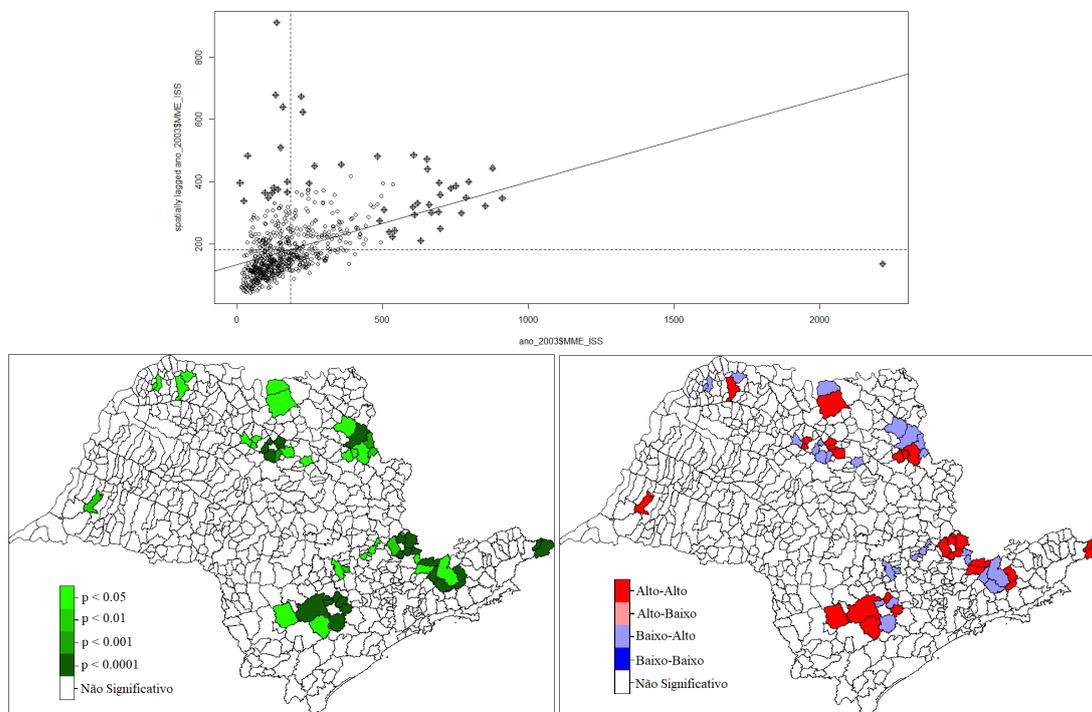
Para a variável PIB, além dos municípios já citados, obteve-se apenas dois municípios com relação Alto-Alto, são eles: Aguaí e Rio Claro. Já para Baixo-Alto, tem-se Analândia, Araras, Charqueada, Corumbataí, Franca, Ipeúna, Manduri, Pirassununga e Santa Cruz da Conceição.

Já para a variável ISS tem-se mais municípios que se destacam, além de mais aglomerados espaciais. O principal aglomerado espacial do tipo Alto-Alto está situado ao sul do estado, nos municípios de Buri, Itapetininga e São Miguel Arcanjo. Além do aglomerado Alto-Alto na região de Campinas, com os municípios de Lindóia, Serra Negra, Tuiti, Sororro e Pinhalzinho. No total 53 municípios tiveram significância estatística, sendo que 28 no quadrante Alto-Alto e 25 no quadrante Baixo-Alto.

Vale citar que para nenhuma das variáveis obteve-se resultados Alto-Baixo e Baixo-Baixo. Ou seja, ou regiões com altos valores de PIB e ISS estão circundados de municípios também com valores mais altos, ou municípios com valores baixo, estão rodeados de valores altos. Este padrão de apenas Alto-Alto e Baixo-Alto seguem para os outros anos analisados 2011 e 2018 mantiveram essa constante para PIB e ISS.

A Figura 11 representa o ano de 2003, onde estão demonstrados os diagramas de dispersão de Moran, além dos mapas de significância LISA e os mapas de *clusters* LISA, para a variável ISS.

Figura 11 – Análise espacial ISS - 2003



Fonte: Elaboração Própria

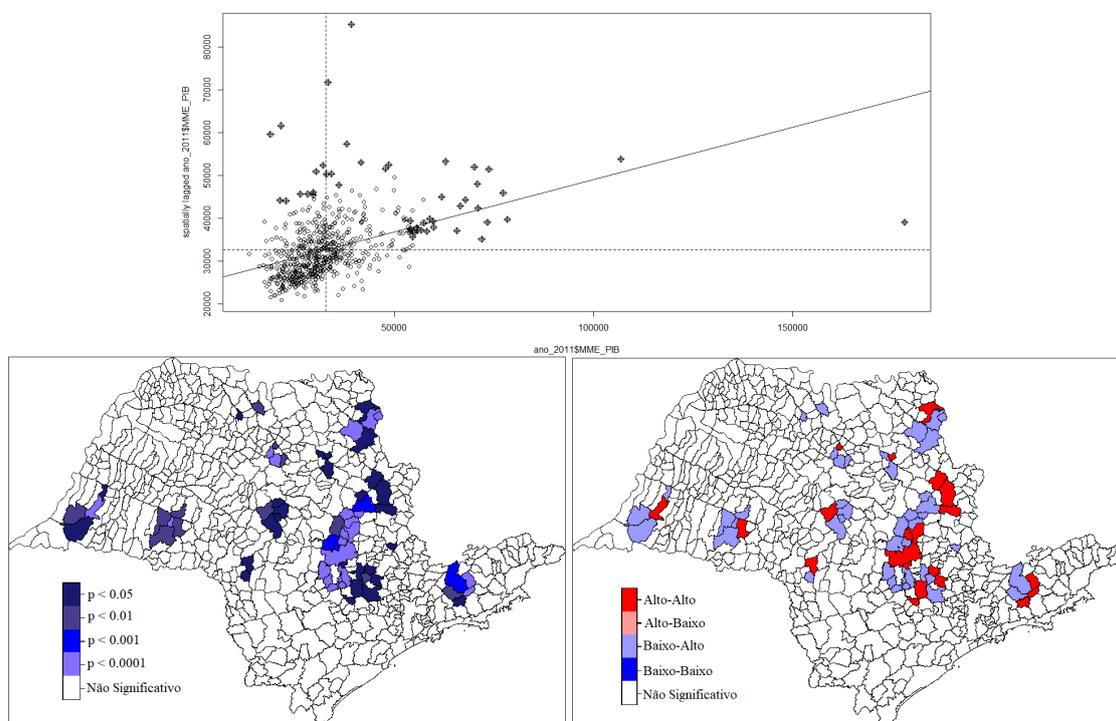
A seguir a análise continuará abordando as variáveis porém para o ano de 2011. Onde houve um aumento significativo dos municípios com autocorrelação espacial para a variável PIB e uma diminuição em relação a variável ISS.

Para a variável PIB no ano de 2011 pode-se observar um grande aglomerado espacial na região central do estado, esse aglomerado abrange as regiões de Campinas e Sorocaba. Ao total, 64 municípios tiveram significância em seus valores do Índice de Moran Local. O que representa quase 10% dos dados, uma parcela significativa.

Dos 64 municípios, 21 são do tipo Alto-Alto os 43 restantes do tipo Baixo-Alto. Piracicaba é dos municípios do quadrante Alto-Alto e algumas cidades do seu entorno, como São Pedro, Itirapina, Charqueada, Tietê, mostraram o padrão Baixo-Alto. Com isso apesar do Índice de Moran Global ser positivo, para alguns casos há uma relação inversa, quando Piracicaba aumenta o seu PIB a propensão é que alguns municípios diminuam. Porém Rio Claro que também faz divisa com Piracicaba, também está no quadrante Alto-Alto mostrando uma influência positiva entre as duas cidades. Representado na figura a seguir.

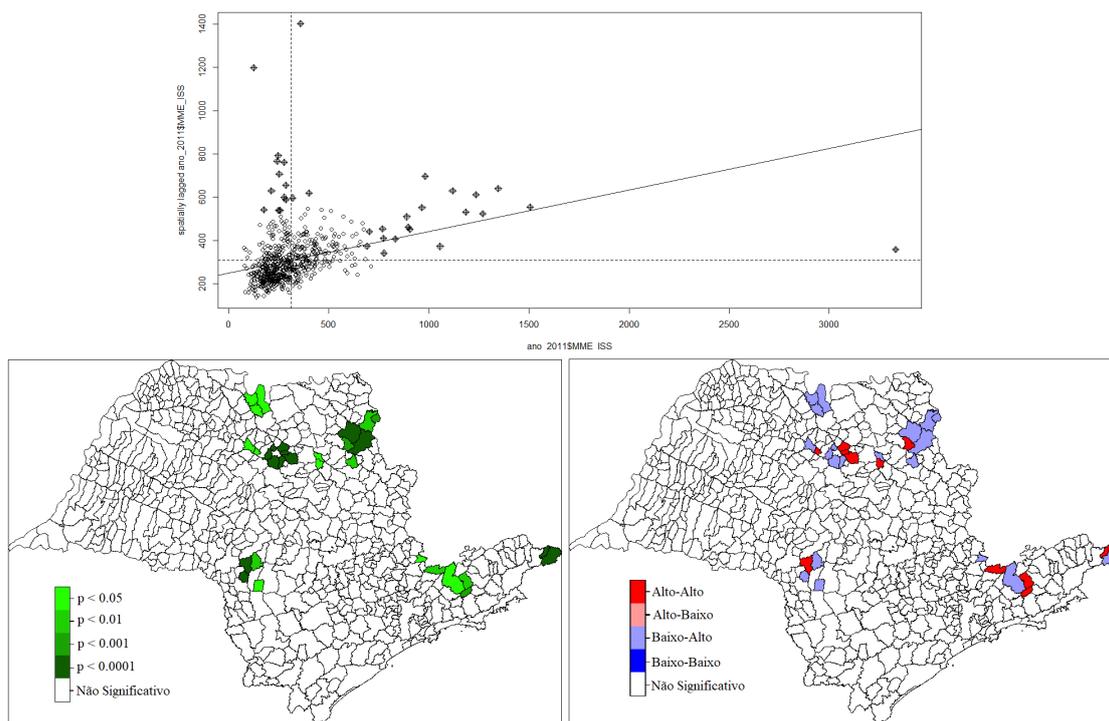
As Figuras 12 e 13 representam o ano de 2011, onde estão demonstrados os diagramas de dispersão de Moran, além dos mapas de significância LISA e os mapas de *clusters* LISA, para a variável PIB e para a variável ISS respectivamente.

Figura 12 – Análise espacial PIB - 2011



Fonte: Elaboração Própria

Figura 13 – Análise espacial ISS - 2011



Fonte: Elaboração Própria

Já o ISS para o ano de 2011, obteve-se menos resultados com significância em relação ao PIB. Apenas 31 municípios demonstraram significância, sendo 11 deles no quadrante Alto-Alto e 20 no Baixo-Alto.

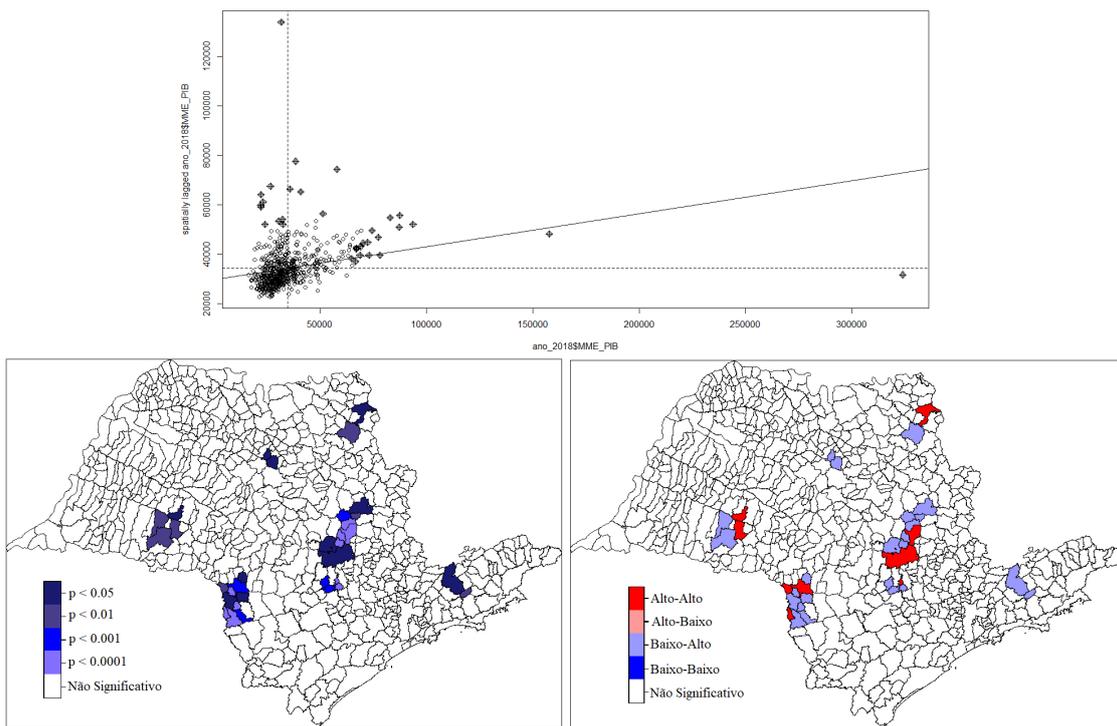
Com destaque para o aglomerado do tipo Alto-Alto para os municípios de Monte Alto, Pirangi e Visto Alegre do Alto, situados na região de Ribeirão Preto. O maior aglomerado do tipo Baixo-Alto para o ISS no ano de 2011, corresponde aos municípios de Serra Azul, Altinópolis, Batatais, Patrocínio Paulista e Itirapuã, localizadas ao norte do Estado de São Paulo.

Em relação ao ano de 2003, houve uma diminuição significativa no número de municípios que demonstraram autocorrelação espacial e significância estatística para a variável ISS. Uma vez que em 2003 foram 53 municípios contra 31 em 2011.

Para prosseguir a análise a seguir será trabalhado o ano de 2018, o último ano em análise. Para a variável PIB houve um aumento em relação ao ano de 2003 e uma diminuição em relação ao ano 2011 dos municípios que obtiveram significância estatística e assim como em todos os anos, apenas os quadrantes Alto-Alto e Baixo-Alto estiveram presentes. Já para o ISS houve uma diminuição em relação aos dois anos trabalhados anteriormente.

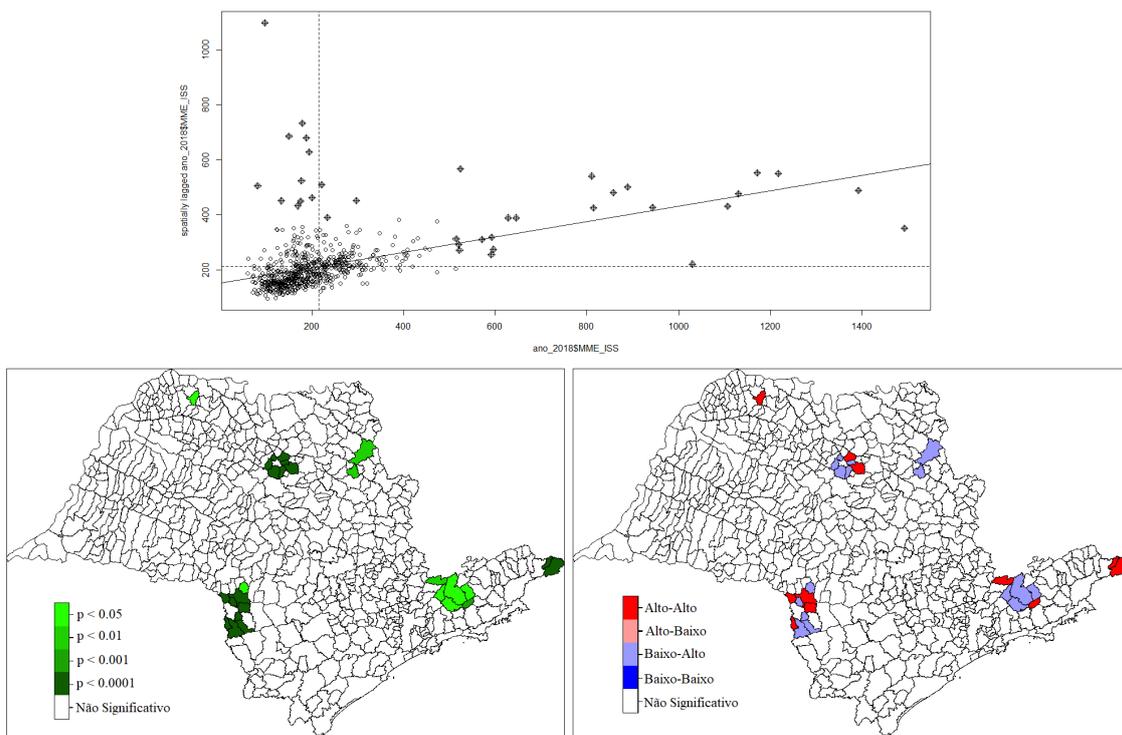
As Figuras 14 e 15 representam o ano de 2018, onde estão demonstrados os diagramas de dispersão de Moran, além dos mapas de significância LISA e os mapas de *clusters* LISA, para a variável PIB e para a variável ISS respectivamente.

Figura 14 – Análise espacial PIB - 2018



Fonte: Elaboração Própria

Figura 15 – Análise espacial ISS - 2018



Fonte: Elaboração Própria.

Para o ano de 2018, tanto PIB quanto o ISS tiveram números abaixo do ano de 2011. Na variável PIB 33 municípios demonstraram significância, contra 27 municípios para o ISS. Para o PIB 9 municípios tem padrão Alto-Alto e 24 padrão Baixo-Alto e para o ISS 11 tem padrão Alto-Alto e 16 Baixo-Alto.

O município de Piracicaba assim como no ano de 2011 também está presente para 2018, também no quadrante Alto-Alto, levando em consideração a variável PIB, porém desta vez com um aglomerado espacial menor do que para o ano de 2011. Um dos destaques é os municípios de Barão de Antonina, Piraju e Timburi, localizados na região de Sorocaba, todos estes tem um padrão Alto-Alto e apesar de Piraju e Timburi serem municípios limítrofes, Barão de Antonina não faz divisa com nenhum dos dois. Porém o município de Fartura une Barão de Antonina a Piraju e Timburi e para a variável PIB, este apresentou padrão Baixo-Alto.

## 5 CONSIDERAÇÕES FINAIS

Com toda a análise realizada, pode-se concluir que para os anos de 2003 à 2018, para as variáveis PIB e ISS, houve autocorrelação espacial em todos os anos de análise para as duas variáveis estudadas. Em todos os anos essa autocorrelação espacial foi positiva e se mostrou estatisticamente significativa para o teste de normalidade assintótica e para o teste de permutação aleatória.

Quanto a análise para o Índice de Moran Local, obteve-se aglomerados espaciais apenas do tipo Alto-Alto e Baixo-Alto, para as duas variáveis. A ausência do padrão Baixo-Baixo, em níveis significantes, mostra que não houve nenhum tipo de problema que fizesse com que as variáveis tivessem menores valores em conjunto durante o período de análise. O inverso é verdadeiro, obteve-se aglomerados do tipo Alto-Alto, demonstrando que muitas vezes os municípios estão interligados em uma curva crescente. O padrão Baixo-Alto obtido também demonstra que para algumas regiões os municípios tem uma certa competição, uma vez que enquanto um município tem valores baixos seus vizinhos crescem.

O trabalho foi feito a partir de uma análise univariada, ou seja, as variáveis foram estudadas individualmente. Uma sugestão para trabalhos futuros pode ser uma análise bivariada para estes mesmos dados, ou até expandir para mais variáveis econômicas como o IDHM, por exemplo, ou os outros impostos municipais que não foram abordados neste trabalho, que são o IPTU e o Imposto de Transmissão de Bens Imóveis (ITBI), podendo assim partir para uma análise multivariada.

## REFERÊNCIAS

- ALMEIDA, E. **Econometria Espacial Aplicada**. [S.l.]: Alínea, 2012.
- ANDRADE, A. L. et al. Introdução à estatística espacial para a saúde pública. 2007.
- ANSELIN, L. Local indicators of spatial association—lisa. **Geographical analysis**, Wiley Online Library, v. 27, n. 2, p. 93–115, 1995.
- BIVAND, R.; KEITT, T.; ROWLINGSON, B. **rgdal: Bindings for the 'Geospatial' Data Abstraction Library**. [S.l.], 2021. R package version 1.5-23. Disponível em: <https://CRAN.R-project.org/package=rgdal>.
- BIVAND, R.; WONG, D. W. S. Comparing implementations of global and local indicators of spatial association. **TEST**, v. 27, n. 3, p. 716–748, 2018. Disponível em: <https://doi.org/10.1007/s11749-018-0599-x>.
- BIVAND, R. S.; PEBESMA, E.; GOMEZ-RUBIO, V. **Applied spatial data analysis with R, Second edition**. Springer, NY, 2013. Disponível em: <https://asdar-book.org/>.
- BREMAEKER, F. E. A importância do iss para os municípios em 2017. **Observatório de Informações Municipais**. Rio de Janeiro, 2018.
- CARDOZO, D. P.; SCHAAB, L. L.; PARRÉ, J. L. Análise espacial da produtividade do café na região sudeste do brasil: 1990-2015. **Revista Economia Ensaios**, v. 34, n. 1, 2019.
- FELJÓ, C. A.; LIMA, F. C. G. de C.; FILHO, N. H. B. **Contabilidade social**. [S.l.]: Elsevier Brasil, 2001.
- FILHO, J. G. **ANÁLISE DE DADOS DE ÁREA APLICADA A INDICADORES DE SEGURIDADE RURAL PARA A CULTURA DO CAFÉ**. Dissertação (Mestrado) — Universidade Federal de Lavras, 2018.
- FRIESTINO, J. K. O. et al. Estatística espacial aplicada aos estudos de incidência de câncer. **Tempus Actas de Saúde Coletiva**, v. 10, n. 2, p. ág–103, 2016.
- GIAMBIAGI, F.; ALEM, A.; PINTO, S. G. B. **Finanças públicas**. [S.l.]: Elsevier Brasil, 2017.
- GOMES, F. A. D. da L. et al. Análise espacial da arrecadação do iss em municípios mineiros. **RAGC**, v. 7, n. 31, 2019.
- GROLEMUND, G.; WICKHAM, H. Dates and times made easy with lubridate. **Journal of Statistical Software**, v. 40, n. 3, p. 1–25, 2011. Disponível em: <http://www.jstatsoft.org/v40/i03/>.
- HÖHER, R. et al. Tocantins: Uma análise espacial do idhm e do pib per capita dos municípios. **DESAFIOS-Revista Interdisciplinar Da Universidade Federal Do Tocantins**, v. 5, n. 4, p. 66–76, 2018.

- HÖHER, R.; SOUZA, O. T. de; FOCHEZATTO, A. Relação entre cooperativismo financeiro e crédito rural com o pib gaúcho: Uma análise espacial. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 16, n. 2, 2020.
- IBGE. 2017. <https://cidades.ibge.gov.br/>. Acessado em 18/03/2021.
- IBGE. 2021. <https://www.ibge.gov.br/estatisticas/economicas/contas-nacionais/9088-produto-interno-bruto-dos-municipios.html?=&t=series-historicas>. Acessado em 18/03/2021.
- IPEADATA. 2021. <http://www.ipeadata.gov.br/Default.aspx>. Acessado em 18/03/2021.
- LIMA, V. M. A. de; CALDARELLI, C. E.; CAMARA, M. R. G. da. Análise do desenvolvimento municipal paranaense: uma abordagem espacial para a década de 2000. **Economia e Desenvolvimento**, v. 26, n. 1, 2014.
- MEIRELES, F. **deflateBR: Deflate Nominal Brazilian Reais**. [S.l.], 2018. R package version 1.1.2. Disponível em: <https://CRAN.R-project.org/package=deflateBR>.
- MONTEIRO, A. M. V. et al. Análise espacial de dados geográficos. **Brasília: Embrapa**, 2004.
- NEGRI, J. A. O. D. et al. Estrutura e dinâmica do setor de serviços no brasil. Instituto de Pesquisa Econômica Aplicada (Ipea), 2006.
- PEBESMA, E. Simple Features for R: Standardized Support for Spatial Vector Data. **The R Journal**, v. 10, n. 1, p. 439–446, 2018. Disponível em: <https://doi.org/10.32614/RJ-2018-009>.
- PÊGAS, P. H. **Manual de contabilidade tributária**. [S.l.]: Grupo Gen-Atlas, 2017.
- PINTO, M. A. N.; PARRÉ, J. L. Evidências empíricas sobre a relação entre o pib e os gastos públicos nos municípios paranaenses: uma abordagem espacial. **Geosul**, v. 34, n. 72, p. 459–485, 2019.
- SANTOS, R. G. dos; NASCIMENTO, S. P. A arrecadação do iptu, no estado do paraná, no período de 1997 a 2011: um olhar sob os impactos da lei de responsabilidade fiscal. **Economia e Desenvolvimento**, v. 26, n. 1, 2014.
- SANTOS, R. G. dos; NASCIMENTO, S. P. do; FELEMA, J. Análise das receitas oriundas do issqn no paraná: Os impactos da lei de responsabilidade fiscal. **Economia & Região**, v. 1, n. 2, p. 26–44, 2013.
- SEADE. 2021. <http://www.imp.seade.gov.br/frontend/#/>. Acessado em 18/03/2021.
- SEFFRIN, R.; ARAÚJO, E. de; BAZZI, C. Análise espacial de área aplicada a produtividade de soja na região oeste do paraná utilizando o software r. **Revista Brasileira de Geomática**, v. 6, n. 1, p. 23–43, 2018.
- TENNEKES, M. tmap: Thematic maps in R. **Journal of Statistical Software**, v. 84, n. 6, p. 1–39, 2018.
- TONI, J. D. **Economia no Setor Público**. [S.l.]: Imprensa Livre, 2010.
- WICKHAM, H. et al. **dplyr: A Grammar of Data Manipulation**. [S.l.], 2020. R package version 1.0.0. Disponível em: <https://CRAN.R-project.org/package=dplyr>.