

**UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE CIÊNCIAS SOCIAIS APLICADAS
DEPARTAMENTO DE ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA**

JOEBSON MAURILIO ALVES DOS SANTOS

**ENSAIOS EM ECONOMIA URBANA: APLICAÇÕES EM ECONOMIA DA SAÚDE,
ECONOMIA DO SETOR PÚBLICO E ECONOMIA DO CRIME**

RECIFE

2022

JOEBSON MAURILIO ALVES DOS SANTOS

**ENSAIOS EM E ECONOMIA URBANA: APLICAÇÕES EM ECONOMIA DA
SAÚDE, ECONOMIA DO SETOR PÚBLICO E ECONOMIA DO CRIME**

Tese de Doutorado apresentado ao Programa de Pós-Graduação em Economia - PIMES do Departamento de Economia da Universidade Federal de Pernambuco como requisito parcial para obtenção do título de Doutor em Ciências Econômicas

Orientadora: Prof.^a Dra. Tatiane Almeida de Menezes

RECIFE

2022

Catálogo na Fonte
Bibliotecária Ângela de Fátima Correia Simões, CRB4-773

S237e Santos, Jobson Maurilio Alves dos
Ensaio em economia urbana: aplicações em economia da saúde,
economia do setor público e economia do crime / Jobson Maurilio Alves
dos Santos. - 2022.
164 folhas: il. 30 cm.

Orientadora: Prof.^a Dra. Tatiane Almeida Menezes.
Tese (Doutorado em Economia) – Universidade Federal de Pernambuco,
CCSA, 2022.
Inclui referências e apêndices.

1. Endogeneidade 2. Variável instrumental. 3. Avaliação de impacto.
I. Menezes, Tatiane Almeida (Orientadora). II. Título.

336 CDD (22. ed.) UFPE (CSA 2022 – 007)

JOEBSON MAURILIO ALVES DOS SANTOS

**ENSAIOS EM ECONOMIA URBANA: APLICAÇÕES EM ECONOMIA DA SAÚDE,
ECONOMIA DO SETOR PÚBLICO E ECONOMIA DO CRIME**

Tese de Doutorado apresentado ao Programa de Pós-Graduação em Economia - PIMES do Departamento de Economia da Universidade Federal de Pernambuco como requisito parcial para obtenção do título de Doutor em Ciências Econômicas

Aprovado em: 23/02/2022.

BANCA EXAMINADORA

Prof. Dra. Tatiane Almeida de Menezes (Orientadora)

Universidade Federal de Pernambuco

Prof. Dr. Raul da Mota Silveira Neto (Examinador Interno)

Universidade Federal de Pernambuco

Prof. Dr. Diego Firmino Costa da Silva (Examinador Interno)

Universidade Federal de Pernambuco

Prof. Dr. Julyan Gleyvisson Machado Goveia Lins (Examinador externo)

Universidade Federal da Bahia

Prof. Dr. Edilberto Tiago de Almeida (Examinador externo)

Universidade Federal da Bahia

A minha família

AGRADECIMENTOS

Agradeço a minha orientadora Tatiane Almeida de Menezes pela total paciência, pelos diversos ensinamentos durante os últimos dez anos e por ser uma referência para mim dentro e fora da sala de aula.

Agradeço a todos os professores do Departamento de Economia da UFPE pelos valiosos ensinamentos que recebi na graduação, no mestrado e no doutorado. Sem dúvida, vocês contribuíram muito para transformar a realidade em que eu vivia e contribuem muito para transformar este mundo em um lugar melhor para todos através da educação.

Agradeço aos amigos que fiz nessa longa e instigante jornada na busca por um pouco mais de conhecimento. Agradeço em especial a Rubens Lopes, Rodrigo Arruda e Edilberto Almeida, por compartilharem um pouco dos seus conhecimentos comigo. A Gilberto Nogueira por sempre me apoiar nas mais diversas situações. A Ricardo Fonseca, Milton Dill, Andrewen Felipe, Andrews Augusto, André Coelho, Daniel Araújo, Filipe Vasconcelos, Filipe Carvalho, Henrique Cirne, Cleiton Farias por estarem sempre ao meu lado em cada desafio que nos deparamos ao longo de toda a nossa jornada acadêmica. A Vitor de Holanda Jó por ser um grande amigo e minha maior referência nas ciências econômicas. Agradeço ainda aos queridos amigos Amanda Aires, Poema Isis, Igor Ézio e Júlia Araújo que foram uma fonte de inspiração.

Agradeço aos amigos Fábio Andrade, João Cláudio, Jebson Candido, Gilmar Leopoldino e Ana Borba pelos seus apoios incondicionais durante toda a minha trajetória acadêmica e por acreditarem que meu sonho poderia se tornar realidade. Sem dúvida, não estaria redigindo este agradecimento sem suas ajudas.

Agradeço a minha querida mãe, Ruti Alves, e minha irmã, Juanita Marília, por estarem sempre ao meu lado e a minha companheira de vida, Cariane Ferraz, por dividir comigo as alegrias e os “perrengues” da vida moderna.

Agradeço ainda aos órgãos governamentais, IBGE, Ministério da Economia, Ministério da Justiça, TCE-PE pela disponibilização dos dados.

Agradeço ao CNPq pelo apoio financeiro concedido para a realização desta pesquisa.

RESUMO

Esta tese aborda três ensaios em economia urbana onde é possível investigar as diversas dimensões da interação humana e como isto pode estar relacionado com o espaço onde estas interações ocorrem. No capítulo 2, investigou-se como a variação exógena do clima pode afetar a dinâmica da disseminação da COVID-19 nos estados brasileiros. Para isso, foi empregado um painel diário dos casos confirmados da COVID-19 referentes a primeira fase da pandemia onde ainda não havia muitas políticas de intervenção para combater a propagação do SARS-CoV-2. Além disso, controlou-se a influência de diversas características dos estados que podem ter influência nas taxas referentes à COVID-19. Os resultados mostraram que estados que apresentam maior temperatura, maior quantidade de incidência solar e maior umidade relativa do ar, apresentam menores taxas diárias de prevalência da COVID-19. No capítulo 3, buscou-se mensurar o impacto dos repasses voluntários do governo federal para realização de obras públicas sobre a probabilidade de paralisação destas. Devido à endogeneidade presente nos dados, foi feito uso do alinhamento partidário comum entre governo municipal e federal com o objetivo de eliminar a endogeneidade citada. Os resultados mostraram que considerando a filiação partidária em comum entre governos como instrumento, quanto maior o montante de repasses do governo federal para o municipal, menor a chance de uma obra pública ser paralisada mesmo considerando a influência de *spillovers* espaciais das covariáveis e diversas mudanças na especificação econométrica. No capítulo 4, avaliou-se o impacto de um programa de segurança pública do governo federal denominado *Em Frente, Brasil*. Aqui, utilizou-se a abordagem de diferenças em diferenças para mensurar o efeito causal do EFB sobre as taxas de homicídios ocorridos nos municípios brasileiros. Todavia, recentes descobertas empíricas mostraram que caso não haja o devido controle de possíveis *spillovers* espaciais do programa, os estimadores obtidos por pela abordagem DiD podem ser enviesados e inconsistente. Os resultados obtidos, levando em consideração os efeitos indiretos da política, mostraram que o EFB reduziu as taxas de homicídios nos municípios tratados em aproximadamente 17%.

Palavras-chave: Endogeneidade; Variável instrumental; Avaliação de Impacto; Efeito *spillover*.

ABSTRACT

This thesis addresses three essays in urban economics where it is possible to investigate the different dimensions of human interaction and how this can be related to the space where these interactions occur. In chapter 2, we investigated how exogenous climate variation can affect the dynamics of the spread of COVID-19 in Brazilian states. For this, a daily panel of confirmed cases of COVID-19 referring to the first phase of the pandemic was used, where there were still not many intervention policies to combat the spread of SARS-CoV-2. In addition, the influence of several characteristics of the states that may influence the rates related to COVID-19 was controlled. The results showed that states that have a higher temperature, greater amount of sunlight and greater relative humidity have lower daily rates of prevalence of COVID-19. In chapter 3, we sought to measure the impact of voluntary transfers from the federal government to carry out public works on the probability of their stoppage. Due to the endogeneity present in the data, the common partisan alignment between municipal and federal government was used in order to eliminate the aforementioned endogeneity. The results showed that considering the common party affiliation between governments as an instrument, the greater the amount of transfers from the federal to the municipal government, the lower the chance of a public work being paralyzed, even considering the influence of spatial spillovers of the covariates and several changes in the econometric specification. In chapter 4, the impact of a public security program of the federal government called *Em Frente, Brasil* was evaluated. Here, the difference-in-differences approach was used to measure the causal effect of the EFB on homicide rates in Brazilian municipalities. However, recent empirical findings have shown that if there is no proper control of possible spatial spillovers from the program, the estimators obtained by the DiD approach can be biased and inconsistent. The results obtained, taking into account the indirect effects of the policy, showed that the EFB reduced homicide rates in the treated municipalities by approximately 17%.

Keywords: Endogeneity; Instrumental variable; Impact Assessment; Spillover effect.

LISTA DE FIGURAS

Figura 2.1- Distribuição espacial das taxas diárias de prevalência da COVID-19 no período de 10 março a 10 abril de 2020 nos estados brasileiros.	25
Figura 2.2- Distribuição espacial dos valores diários das variáveis climáticas no período de 10 março a 10 abril de 2020 nos estados brasileiros.	26
Figura 2.3- Evolução das taxas diárias de prevalência da COVID-19 de 10 de março a 10 de abril de 2020 nos estados e regiões do Brasil.	27
Figura 2.4- Distribuição das taxas diárias de prevalência da COVID-19 de 10 de março a 10 de abril de 2020 nos estados e regiões do Brasil.	27
Figura 3.1. Distribuição espacial das variáveis do percentual de obras paralisadas e percentual médio de repasses	47
Figura 3.2. Curva ROC dos modelos IVPROB1, IVPROB2, IVPROB3, IVPROB4 e IVPROB5.	54
Figura 3.3. Gráfico de dispersão da relação entre o valor dos repasses e as probabilidades de paralisação estimadas nos modelos IVPROB1, IVPROB2, IVPROB3, IVPROB4 e IVPROB5, respectivamente.	54
Figura 4.1. Percentual de redução dos Homicídios pela ótica do governo Federal.....	80

LISTA DE TABELAS

Tabela 2.1. Descrição das variáveis.....	24
Tabela 2.2. Estatísticas descritivas das variáveis.	28
Tabela 2.3. Estimação dos modelos para dados em painel e suas versões espaciais para as taxas diárias de prevalência da COVID-19 nos estados brasileiros de dez de março a dez de abril de 2020.	32
Tabela 2.4. Efeitos marginais diretos, indiretos e totais das variáveis de interesse do Modelo SDM sobre as taxas diárias de prevalência da COVID-19 nos estados brasileiros.....	33
Tabela 3.1 - Estatística descritiva das variáveis socioeconômicas dos municípios de Pernambuco.	46
Tabela 3.2. Resultados das estimações do modelo probabilístico.	51
Tabela 3.3. Resultados das estimações do modelo probabilístico com variável instrumental.	52
Tabela 3.4. Resultados das estimações do modelo probabilístico com variável instrumental e segregação regional.	55
Tabela 3.5. Resultados das estimações do modelo probabilístico com variável instrumental e segregação de tipos de obras.	56
Tabela 3.6. Resultados das estimações do modelo probabilístico com variável instrumental e exclusão de tipos de licitação.	57
Tabela 3.7. Resultados das estimações do modelo probabilístico com variável instrumental e variáveis espaciais.	59
Tabela 3.8. Resultados das estimações do modelo probabilístico com variável instrumental alternativa.	60
Tabela 4.1 - Estatísticas descritivas	81
Tabela 4.2. Resultados das estimações do modelo de Diferenças em Diferenças.....	84
Tabela 4.3. Resultados das estimações do modelo de Diferenças em Diferenças com <i>leads</i> e <i>lags</i>	84
Tabela 4.4. Resultados das estimações do modelo de Diferenças em Diferenças para o teste de falsificação.....	85
Tabela 4.5. Resultados das estimações do modelo de Diferenças em Diferenças para o teste de validação.....	86
Tabela 4.6. Resultados das estimações do modelo de Diferenças em Diferenças com PSM e sem Capitais.....	87
Tabela 4.7. Resultados das estimações do modelo de Diferenças em Diferenças com variáveis espaciais.....	89
A1. Estimação dos modelos para dados em painel e suas versões espaciais para as taxas diárias de prevalência da COVID-19 nos estados brasileiros para média móvel de 14 dias para as variáveis climáticas.	101
A2. Estimação dos modelos para dados em painel e suas versões espaciais para as taxas diárias de prevalência da COVID-19 nos estados brasileiros para média móvel de 11 dias para as variáveis climáticas.	102
A3. Estimação dos modelos para dados em painel e suas versões espaciais para as taxas diárias de prevalência da COVID-19 nos estados brasileiros para média móvel de 7 dias para as variáveis climáticas.	104

B1. Resultados das estimações do modelo probabilístico.	106
B2. Resultados das estimações do modelo probabilístico com variável instrumental.	107
B3. Resultados das estimações do modelo probabilístico com variável instrumental e segregação regional.	111
B4. Resultados das estimações do modelo probabilístico com variável instrumental e segregação de tipos de obras.	113
B5. Resultados das estimações do modelo probabilístico com variável instrumental e exclusão de tipos de licitação.	116
B6. Resultados das estimações do modelo probabilístico com variável instrumental e variáveis espaciais.	119
B7. Resultados das estimações do modelo probabilístico com variável instrumental alternativa.	129
C1. Resultados das estimações do modelo de Diferenças em Diferenças.	133
C2. Resultados das estimações do modelo de Diferenças em Diferenças com <i>leads</i> e <i>lags</i> . .	134
C3. Resultados das estimações do modelo de Diferenças em Diferenças para o teste de falsificação.	135
C4. Resultados das estimações do modelo de Diferenças em Diferenças para o teste de validação.	136
C5. Resultados das estimações do modelo de Diferenças em Diferenças com PSM e sem Capitais.	137
C6. Resultados das estimações do modelo de Diferenças em Diferenças com variáveis espaciais.	138

SUMÁRIO

1	INTRODUÇÃO	13
2	INFLUÊNCIAS CLIMÁTICAS SOBRE AS TAXAS DE PREVALÊNCIA DA COVID-19. APLICAÇÕES COM MODELOS ESPACIAIS PARA DADOS EM PAINEL.....	17
2.1	INTRODUÇÃO.....	17
2.2	REVISÃO DA LITERATURA.....	19
2.3	ESTRATÉGIA EMPÍRICA	23
2.3.1	Dados	23
2.3.2	Estatística Descritiva.....	28
2.3.3	Modelos para Dados em Painel e a sua Versão para Dados Espaciais.....	29
2.4	RESULTADOS	30
2.4.1	Discussão	34
2.5	CONCLUSÃO.....	37
3	PROBABILIDADE DE PARALISAÇÃO DE OBRAS PÚBLICAS: INFLUÊNCIAS ESPACIAIS E O IMPACTO DOS REPASSES RECEBIDOS A PARTIR DA DESCENTRALIZAÇÃO FISCAL	39
3.1	INTRODUÇÃO.....	39
3.2	<i>BACKGROUND</i> E EVIDÊNCIA EMPÍRICAS.....	41
3.3	METODOLOGIA.....	45
3.3.1	Dados	45
3.3.2	Estatísticas Descritivas	46
3.3.3	Modelo para Dados Qualitativos.....	47
3.3.4	Instrumento.....	49
3.3.5	Versão Espacial do Modelo para Dados Qualitativos	50
3.4	RESULTADOS	51
3.4.1	Análise de Heterogeneidade e Robustez	55
3.4.2	Discussão	60
3.5	CONCLUSÃO.....	63

4	PROGRAMA “EM FRENTE, BRASIL” DE COMBATE À	
	CRIMINALIDADE VIOLENTA. UMA ANÁLISE A PARTIR DA ABORDAGEM	
	ESPACIAL DE DIFERENÇAS EM DIFERENÇAS	66
4.1	INTRODUÇÃO	66
4.2	EVIDÊNCIAS EMPÍRICAS	69
4.2.1	Background Institucional	79
4.3	METODOLOGIA.....	81
4.3.1	Dados	81
4.3.2	Estatística Descritiva	81
4.3.3	Efeito Direto do Programa EFB.....	82
4.4	RESULTADOS	83
4.4.1	Robustez	85
4.5	CONCLUSÃO.....	90
	REFERÊNCIAS	933
	APÊNDICE A - RESULTADO COMPLETO DAS ESTIMAÇÕES	101
	APÊNDICE B - RESULTADO COMPLETO DAS ESTIMAÇÕES	106
	APÊNDICE C – RESULTADO COMPLETO DAS ESTIMAÇÕES	133
	APÊNDICE D –ARTIGO PUBLICADO	142

Capítulo 1

INTRODUÇÃO

As relações humanas são objeto de estudo da teoria econômica há bastante tempo. Mais precisamente, a teoria microeconômica é a parte da economia que estuda o comportamento dos indivíduos e suas diversas formas de interação. Com o passar do tempo, as ferramentas fornecidas pela teoria econômica passaram a ser empregada para analisar outras questões relacionadas à vida humana, sua forma de organização e convívio no espaço. Desta forma, a passou-se a ter subsídio teórico para análise de questões como surgimento e desenvolvimento das cidades, determinantes da aglomeração de pessoas e firmas nas cidades, determinantes da criminalidade no espaço, problemas de trânsito, etc. Assim, surge a economia urbana como um ramo da microeconomia que estuda as relações humanas a partir da estrutura e da distribuição espacial de pessoas e firmas.

A distribuição das pessoas no espaço, suas formas de relação e as características do próprio espaço acabam por desempenhar um importante papel para a compreensão dos fatores que estão correlacionados com a qualidade de vida nas cidades. Diversas formulações teóricas como o modelo de cidade monocêntrica, isto é, com apenas um centro de negócios onde as pessoas podem se empregar, permitiu a análise da escolha do local de residência por parte das pessoas e mostrou como esta escolha pode ser influenciada por diversas outras amenidades presentes no espaço. De forma análoga, as firmas buscam se localizar no espaço ao analisar o ambiente de negócios e as amenidades que favorecem o ganho de escala, possibilidade de compartilhamento de conhecimento e de tecnologia. Contudo tanto a escolha locacional dos agentes quanto das firmas são funções de políticas públicas desenvolvidas com o objetivo de maximizar o bem estar social nos espaços urbanos.

A investigação de diversos fenômenos através do espaço tem se mostrado frequente e de grande relevância para ampliação das discussões sobre o objeto de estudo. Em termos quantitativo, o espaço ganha importância na análise estatística à medida que a sua não inclusão nos modelos econométricos podem implicar viés de variável omitida espacial, o que fará com que os estimadores sejam viesados e inconsistentes (LESAGE; PACE, 2009). O entendimento da ocorrência de determinados padrões de comportamento através do espaço tem

tido fundamental para se explicar as diversas dimensões da interação humana (PÁEZ et al., 2010). Entender as estruturas e formas de interação no espaço pode auxiliar a tomada de decisão das pessoas, firmas, governos, entre outros (GIBBONS; OVERMAN; PATACCHINI, 2015).

Levando em conta os apontamentos acima, esta pesquisa investigou relações que fazem parte do grande escopo de análise da economia urbana como no capítulo 2, onde se investigou a influência das características climáticas dos estados brasileiros sobre as taxas da COVID-19 que é uma doença que leva, em muitos casos, a uma Síndrome Respiratória Aguda Grave (SRAG) e é causada pelo SARS-CoV-2 (novo coronavírus). As características climáticas podem ser um importante aliado no combate à disseminação da COVID-19 no Brasil, uma vez que este é um país em desenvolvimento com diversos problemas estruturais e grande desigualdade de renda. É destacar a importância de controlar os fatores que podem indicar vulnerabilidades econômicas, sociais e o perfil de saúde da população dos estados brasileiros.

A necessidade de isolamento reduziu o trabalho presencial e em pouco tempo a crise sanitária transformou-se em crise econômica. Pouca coisa ainda se conhece sobre a forma como a COVID-19 se espalhou entre os países e dentro de cada país. Entretanto esta doença se alastrou de forma rápida e seus determinantes variam tanto com fatores socioeconômicos como ambientais (SNYDER; PARKS, 2020; PORSSE et al., 2020). Compreender as causas e o padrão de contágio do SARS-CoV-2 no território subnacional torna-se, assim, uma importante peça no quebra cabeça que busca traçar o processo de propagação das crises sanitária e econômica (ASCANI et. al., 2021).

Ao propor uma ligação entre a incidência de COVID-19 e as características climáticas das regiões, este artigo pretende ajudar os formuladores de políticas públicas na definição de medidas de prevenção direcionadas a evitar novos surtos da doença. A hipótese assumida é que em períodos de temperaturas mais baixas e menor incidência de luz solar, as pessoas tendem a se concentrar em locais fechados e com pouca ventilação, gerando assim ambientes propícios à propagação do vírus Paez et. al., (2020).

O presente trabalho buscou contribuir com a literatura mensurando o papel das variáveis climáticas sobre o número de casos da COVID-19 nos estados brasileiros. Embora já existam vários trabalhos que desenvolveram esta relação como em Baker et al. (2020), Paez et. al., (2020), Scafetta (2020), Araneda et al. (2021), Tobías e Molina (2020) e Chen et al. (2021), este artigo inova ao estudar um país em desenvolvimento e com grande diversidade climática: equatorial, tropical e subtropical, enquanto a maioria das publicações tomam por base países

desenvolvidos e de clima temperado. Além disto, com o objetivo de controlar o efeito *spillover* inerente a uma pandemia foram utilizados modelos espaciais para dados em painel.

No capítulo 3, investigou-se quais fatores contribuem para a paralisação de uma obra pública. Uma obra pública é paralisada sempre todos os aspectos técnicos e legais para sua concretização não são cumpridos. Por exemplo, atos de ilegalidade durante o processo licitatório, falhas técnicas no projeto, etc. são os principais motivos da paralisação de uma obra (FINOCCHIARO; GUCCIO; PIGNATARO, 2018; GUCCIO; PIGNATARO; RIZZO, 2014).

No Brasil, os governos são hierarquicamente distribuídos desde o ente federal, passando pelo estadual, chegando, por fim, ao municipal. Este último, segundo a teoria da descentralização fiscal, possui diversas vantagens quando da provisão de bens públicos, pois, por estar mais perto da população, conhece suas demandas e prioridades. Além disso, reconhece-se que o governo local pode utilizar os recursos públicos com maior eficiência, uma vez que tais recursos não precisam percorrer um longo caminho dentro da burocracia pública até chegar ao seu destino final. Desta forma, a descentralização fiscal seria uma forma eficaz de promover o uso eficiente dos recursos públicos (BORDIGNON; COLOMBO; GALMARINI, 2008; AMARAL FILHO, 2001).

O governo local, com base na descentralização de recursos, realiza diversas obras pública com recursos originados do governo e federal. Porém, isto ocorre em um ambiente assimétrico em termos de informações, pois os governos de esferas superiores não têm informação sobre o as empresas contratadas nem sobre os benefícios sociais das obras (BESFAMILLE, 2003). Desta forma, os governos centrais podem influenciar a execução de uma obra pública, a nível municipal, através do montante da recursos que colocam à disposição dos governos municipais para que estes executem a obra conforme convênio pactuado entre eles. Assim, utilizou-se como instrumento para os valores recebidos através de repasses a filiação partidária em comum entre o governo local e o governo federal através de um processo de estimação em dois estágios sob a hipótese de existência de estratégia de interação entre os governos das diferentes esferas do poder público (interação vertical) (BRUECKNER, 2003; KELLY, 2000).

Esta pesquisa visou contribuir para a literatura ao explicar quais são os fatores que podem contribuir para que uma obra pública seja paralisada e como a interação entre governos pode modificar a chance de uma obra não ser concluída no tempo correto através dos recursos voluntários que o governo federal coloca à disposição dos governos municipais.

No capítulo 4, mensurou-se o impacto de um programa de segurança pública chamado *Em Frente, Brasil* (EFB) lançado pelo governo federal em setembro de 2019 e durou até abril de 2021. Durante este período as tropas da Força Nacional de Segurança Pública reforçaram o policiamento ostensivo das cidades contempladas, ajudando a diminuir a criminalidade nessas localidades.

Este programa, por se tratar de um quase experimento, permitiu que fossem formados grupos de tratamento e de controle com características bem parecidas, uma vez que tanto as cidades tratadas (aquelas que receberam o programa) quanto as não tratadas (demais cidades) pertencem as mesmas regiões metropolitanas e compartilham de diversas características em comum que são pré-requisito para fazer parte dessas regiões.

Assim, utilizando a abordagem de Diferenças em Diferenças (DiD), este trabalho investigou o efeito causal do EFB sobre as taxas de homicídios ocorridos nas cidades pertencentes as regiões metropolitanas dos estados de Goiás, Pará, Pernambuco, Espírito Santo e Paraná que receberam as tropas da Força Nacional de Segurança.

Este trabalho buscou contribuir para a literatura de avaliação de impacto e economia urbana e do crime ao avaliar o impacto de uma variação exógena do policiamento nas cidades brasileiras a partir da implementação de EFB pelo Governo Federal que tinha o tema da segurança pública como uma de suas pautas de campanha quando das eleições presidenciais de 2018.

Capítulo 2

INFLUÊNCIAS CLIMÁTICAS SOBRE AS TAXAS DE PREVALÊNCIA DA COVID-19. APLICAÇÕES COM MODELOS ESPACIAIS PARA DADOS EM PAINEL

2.1 INTRODUÇÃO

No final de 2019, o mundo conheceu um vírus COVID-19 causador da Síndrome Respiratória Aguda Grave (SARS-CoV-2). Sua rápida disseminação e elevadas taxas de mortalidade fez com que, rapidamente a Organização Mundial da Saúde (OMS) considerasse esta doença uma pandemia. A inexistência de vacinas e tratamento eficazes tornaram inevitáveis medidas não farmacológicas para proteção da população, dentre elas, as que se mostraram mais factíveis de implementação para redução do contágio e para evitar mortes foram a utilização de máscaras e as medidas de distanciamento social (BORJAS, 2020; BARROT; GRASSI; SAUVAGNAT, 2020; TOBÍAS, 2020).

A necessidade de isolamento reduziu o trabalho presencial e em pouco tempo a crise sanitária transformou-se em crise econômica. Pouca coisa ainda se conhece sobre a forma como a COVID-19 se espalhou entre os países e dentro de cada país. Entretanto esta doença se alastrou de forma rápida e seus determinantes variam tanto com fatores socioeconômicos como ambientais (SNYDER; PARKS, 2020; PORSSE et al., 2020). Compreender as causas e o padrão de contágio do SARS-CoV-2 no território subnacional torna-se, assim, uma importante peça no quebra cabeça que busca traçar o processo de propagação das crises sanitária e econômica (ASCANI et. al., 2021).

O presente trabalho busca contribuir com a literatura mensurando o papel das variáveis climáticas sobre o número de casos da COVID-19 nos estados brasileiros. Embora já existam vários trabalhos que desenvolveram esta relação como em Baker et al. (2020), Paez et. al., (2020), Scafetta (2020), Araneda et al. (2021), Tobías e Molina (2020) e Chen et al. (2021), este artigo inova ao estudar um país em desenvolvimento e com grande diversidade climática: equatorial, tropical e subtropical, enquanto a maioria das publicações tomam por base países desenvolvidos e de clima temperado. Além disto, com o objetivo de controlar o efeito *spillover*

inerente a uma pandemia, foram utilizados modelos espaciais para dados em painel. O método de estimação *Generalized Least Square* (GLS) foi aplicado para tratar a presença de correlação serial dos termos de erro e correlação entre as *cross sections* que comprometem a inferência estatística das estimativas obtidas sob o modelo de efeitos fixos.

Ao propor uma ligação entre a incidência de COVID-19 e as características climáticas das regiões, este artigo pretende ajudar os formuladores de políticas públicas na definição de medidas de prevenção direcionadas a evitar novos surtos da doença. A hipótese assumida é que em períodos de temperaturas mais baixas e menor incidência de luz solar, as pessoas tendem a se concentrar em locais fechados e com pouca ventilação, gerando assim ambientes propícios à propagação do vírus (PAEZ et. al., 2020).

Assim, foram utilizados dados diários da taxa de disseminação da doença no período compreendido entre 10 de março a 10 de abril de 2020. A escolha deste intervalo de análise segue os trabalhos de Marow e Urban (2020) e Wang et al. (2021), pois, de acordo com estes autores, no período escolhido para a análise deste trabalho havia menos intervenções sobre as taxas de contágio da COVID-19. Com isso, pode-se estimar o efeito das variáveis climáticas de forma mais acurada.

As variáveis climáticas utilizadas foram o número de horas de luz solar (brilho do sol sem intervenção de nuvens), a temperatura média e a umidade relativa do ar. Para estas variáveis, foram calculadas as médias móveis defasadas dos 7, 11 e 14 dias antecedentes ao dia do diagnóstico da infecção pelo SRAS-CoV-2, pois, em consonância com Lauer et al. (2020), o período para aparição dos sintomas da COVID-19 é de 2,6 a 12,5 dias com intervalos de confiança (IC) de 2,1 a 3,7 e 8,2 a 17,7 para os limites inferiores e superiores do IC, respectivamente, em 95% dos casos confirmados da doença. Ainda segundo o autor citado, o período médio de incubação da COVID-19 é de 5,7 dias (com um intervalo de confiança entre 4,9 a 7,8 dias). Além das variáveis climáticas citadas, foram utilizados como controles variáveis socioeconômicas, variáveis de distanciamento social, como *lockdown* e índice de isolamento social, e variáveis do perfil das condições de saúde da população dos estados do Brasil (DALZIEL et al., 2018; D'ADAMO; YOSHIKAWA; OUSLANDER, 2020; YING-YING et al., 2020).

Esta pesquisa está dividida em mais quatro seções além desta introdução. Na seção 2.2, será apresentada uma revisão da literatura sobre clima e COVID-19. A estratégia empírica e a apresentação dos dados utilizados no presente trabalho encontram-se na seção 2.3. A análise

dos resultados a discussão dos principais achados encontram-se na seção 2.4. Por fim, na seção 2.5 são apresentadas as considerações finais.

Este artigo foi publicado em 18 de janeiro de 2022 na revista científica *Regional Science Policy & Practice* e a versão publicada consta no apêndice D desta tese.

2.2 REVISÃO DA LITERATURA

Condições climáticas têm sido levadas em consideração na hora de determinar os fatores que influenciam a disseminação da pandemia. Nesta etapa, serão discutidos artigos que elencam as razões que tornam os fenômenos climáticos um dos componentes que explicam a contaminação e morte por COVID-19.

Wang et al. (2021) investigaram a relação entre a COVID-19 e as condições climáticas de 100 cidades chinesas onde registrou-se mais de 40 casos confirmados da doença. No entanto, esses autores utilizaram os dados compreendidos entre 19 de janeiro a 15 de fevereiro e destaca que a intervenção do governo a partir do decreto de *lockdown* foi em 24 de janeiro. Os autores ainda utilizaram dados de 15 de março a 25 de abril para 1005 cidades americanas, destacando que a política de *lockdown* fora implementada dia 7 de abril. Assim, com o objetivo de verificar a influência das variáveis climáticas na taxa de disseminação da COVID-19, eles estimaram modelos econométricos fazendo uso de variáveis de controle do perfil socioeconômico, demográfico, de saúde, geográfico das localidades. Já as variáveis climáticas, temperatura e humidade relativa, foram construídas a partir de suas respectivas médias móveis para o período de 6 dias. Os autores destacam ainda que utilizaram as fases iniciais da pandemia, tanto na China quanto nos EUA, pois havia menos intervenções sobre as taxas de contágio da COVID-19 o que permitiu estimar o efeito das variáveis climáticas de forma mais acurada. Os resultados mostraram uma relação negativa e significativa da temperatura e humidade relativa sobre a taxa de reprodução da COVID-19 tanto nos EUA como na China, porém após o período de *lockdown* as variáveis climáticas tiveram a magnitude dos seus impactos sobre a reprodução da COVID-19 diminuída devido ao efeito da restrição de circulação de pessoas impostas pela política de *lockdown*. Como forma de testar a robustez dos resultados, foram utilizadas as médias de 7.5 dias para as variáveis climáticas e controle para correlação espacial. Os resultados das variáveis climáticas continuaram fortemente significantes e consistente com os resultados obtidos anteriormente.

Paez et. al., (2020), investigaram a influência de variáveis climáticas sobre as taxas de contágio da COVID-19 para as províncias da Espanha, uma vez que este foi um dos países mais

afetados pela pandemia. Desta forma, estes autores utilizaram dados das taxas de casos confirmados e dados meteorológicos para um período de 30 dias. Além disso, foram usados dados socioeconômicos e demográficos que serviram como variáveis de controle no modelo de regressão espacial utilizado pelos autores. Os resultados obtidos mostraram províncias com maiores temperaturas e maior umidade do ar têm menos taxas de contágio da COVID-19. Todavia a variável de insolação teve relação positiva com a taxa de contágio da COVID-19, provavelmente por conta das políticas de isolamento social que acabaram por deixar muitas pessoas confinadas em suas casas, não podendo se expor ao sol com frequência. Além disso, os autores destacam que as variáveis de controle se mostraram importantes preditoras da disseminação da COVID-19 no espaço como por exemplo o PIB *per capita* e a presença de transporte coletivos na província que tiveram relação positiva com as taxas da COVID-19, enquanto densidade populacional e percentual de idosos na população tiveram relação negativa com a disseminação do COVID-19.

Marow e Urban (2020) investigaram se o vírus seria sensível às características climáticas sob o argumento de que o clima poderia determinar as taxas de contágio da COVID-19 ao longo do tempo. Para isso, estes autores utilizaram o período inicial da pandemia, pois as intervenções no campo social para reduzir a disseminação do COVID-19 eram raras. Assim, foram utilizados dados a nível de país com exceção da Austrália, EUA, China e Canadá. Para as variáveis climáticas, foram utilizadas as médias móveis de 14 dias para a temperatura média, umidade relativa e absoluta do ar e também variável de isolação que captura a radiação ultra violeta, pois o tempo de infecção do COVID-19 é de 1 a 14 dias. Eles ainda utilizaram variáveis de controle consideradas importantes preditoras do contágio tais como: densidade populacional e percentual de população idosa. Além disso, os autores utilizaram como forma de testar a robustez dos resultados a média das variáveis climáticas para uma janela de 6, 7 e 12 dias. Os resultados obtidos mostraram que 36% da previsão de crescimento da taxa de disseminação da COVID-19 podem ser explicadas pelo tipo de modelo proposto e que 17% da previsão podem ser explicadas pelas variáveis climáticas e sociodemográficas. A variável de isolação se mostrou negativamente correlacionada e estatisticamente significativa com as taxas da COVID-19. Os autores argumentam que achados da literatura apontam que o vírus é sensível a radiação ultra violeta e, alternativamente, o sistema imunológico melhora com a exposição a luz solar devido à absorção de vitamina D. já a umidade absoluta teve correlação negativa com a taxa de prevalência da COVID-19, enquanto a temperatura média teve correlação positiva o que os autores consideraram contrário ao resultado esperado.

Baker et al. (2020) argumentam que as condições climáticas podem ter influência sobre a atual crise de epidemia do COVID-19. A influência direta das variáveis climáticas se dá tanto pelo nível de umidade das localidades, quanto pela temperatura ao qual o vírus se expõe. Estes autores afirmam que a transmissão de vírus como a Influenza ocorre de forma mais acentuada em lugares menos úmidos e que as pandemias atingem picos de casos durante o inverno. Os autores simularam ainda intervenções não farmacêuticas e controlaram os efeitos da densidade populacional das localidades e do padrão de contato social constataram que estas intervenções e variáveis podem determinar o comportamento futuro da doença.

Scafetta (2020) buscou identificar se as características climáticas afetavam a disseminação da COVID-19. Para isso, coletou dados de casos confirmados no mês de dezembro, mês de inverno em Wuhan, China, se espalhando rapidamente nos meses seguintes. De acordo com o autor, fato semelhante ocorreu em cidades da Itália e depois em cidades americanas. O autor ainda buscou identificar a influência de outras variáveis sobre a prevalência da COVID-19 tais como idade mediana da população e nível de poluição do ar. Os resultados obtidos indicam que lugares com temperaturas mais frias e com umidade relativa do ar mais baixa têm uma piora na taxa de disseminação do COVID-19. Constatou-se ainda que regiões com população menos idosa têm menores taxas da COVID-19, porém a variável que mensura a qualidade do ar não teve influência estatisticamente significativa sobre as taxas da COVID-19.

Araneda et al. (2021) investigaram o efeito de variáveis ambientais, mais precisamente variáveis climáticas, sobre as taxas de transmissão da COVID-19 no Chile devido a suas características ambientais como alta latitude e cobertura territorial com variados tipos de clima tais como deserto, semiárido, costa marítima, áreas com gelo entre outras. Além disso, eles utilizam características socioeconômicas como controle. Eles encontram uma relação negativa entre as taxas de disseminação da COVID-19 e as temperatura máxima e média, porém devido a problemas de multicolinearidade, excluíram temperatura máxima, média e altitude. Os resultados mostram que temperatura mínima, pressão atmosférica e umidade relativa tiveram relação negativa e significativa com a taxa de transmissão da COVID-19.

Chen et al. (2021) verificaram como a distância dos países para a linha do equador afeta a taxa de casos confirmados da COVID-19 nestes países sob a hipótese de que países localizados mais próximos da linha do equador têm temperaturas mais elevadas e maior umidade relativa do ar e isso contribuiria para menor taxa de incidência da COVID-19. Os autores controlaram diversos fatores que podem afetar a disseminação do novo coronavírus tais

como quantidade de viagens aéreas, taxa de urbanização, gastos com saúde, entre outros, além de excluir da amostra países que tiveram menos de 100 casos confirmados da COVID-19 e concluíram que países que estão 1000 km mais perto da linha do equador podem esperar uma taxa de casos da COVID-19 por milhão de habitante 33% menor. Os resultados obtidos apontam para uma redução nos casos da COVID-19 no verão devido a temperaturas mais altas e maior radiação ultravioleta do sol. Este fato pode apoiar adoção de políticas públicas para reduzir a disseminação do SARS-CoV-2.

Tobías e Molina (2020) ressaltam a importância de se entender a dinâmica da incidência da COVID-19 a partir das características climáticas das regiões. Para isso, utilizaram *lags* de 7 dias das variáveis climáticas baseados no tempo de incubação do SARS-CoV-2 que é de 5 a 6 dias. Estes autores ainda utilizaram no modelo de regressão de quasi Poisson, tendências lineares e quadráticas, além dos efeitos fixos para a região metropolitana da cidade de Barcelona e concluíram que aumentos na temperatura leva a redução das taxas de incidência da COVID-19, porém destacam que outros climáticos e características socioeconômicas não puderam ser controladas no exercício econométrico realizado por eles.

Paliolol, Pereda e Azzoni (2020) investigaram a influência do clima sobre as taxas de disseminação da COVID-19 através de um painel com 416 regiões de várias partes do mundo por um período de 93 dias. Além disso, foi controlado diversos efeitos fixos que poderiam ter relação com a dinâmica da COVID-19 ao longo do tempo e concluíram que aumento da temperatura nas regiões reduz a transmissão da COVID-19 em até 8,98%, indicando que ainda que possam haver outros determinantes para a taxa de contágio, o clima pode desempenhar um papel importante na hora de se formular políticas públicas com vistas a barra o avanço da COVID-19.

À luz de evidências recentes na literatura, há um esforço dos mais diversos pesquisadores para identificar os fatores que podem influenciar na disseminação do SARS-CoV-2 no espaço, onde as características ambientais podem ser um fator importante no combate à COVID-19 pandemia. Assim, esta pesquisa buscou encontrar evidências do impacto das características climáticas sobre as taxas de prevalência da COVID-19 nos estados do Brasil, visto que este país possui uma grande extensão territorial e possui diferentes tipos de climas em suas regiões, além de fatores socioeconômicos. características de um país em desenvolvimento com acentuada desigualdade de renda e precário acesso aos serviços de saúde para uma parcela significativa da população (PORSSE et al., 2020).

2.3 ESTRATÉGIA EMPÍRICA

2.3.1 Dados

Na presente pesquisa, utilizou-se um banco de dados único com informações do Ministério da saúde sobre os casos confirmados da COVID-19 no período de 10 março a 10 de abril de 2020 nas unidades federativas do Brasil que são compostas de 26 estados e um Distrito Federal. Consta ainda no referido banco, informações do Instituto Nacional de Meteorologia (INMET) sobre as características meteorológicas dos estados brasileiros e o Índice de Isolamento Social desenvolvido pela Inloco¹. Consta ainda no referido banco de dados a quantidades de pessoas que entraram nos estados do Brasil através de voos internacionais, oriunda da Agência Nacional de Aviação (ANAC). Utilizou-se também os dados do Ministério da Saúde (DATASUS) sobre as internações por comorbidades no ano de 2019, do Tribunal Superior Eleitoral (TSE) referentes aos resultados das eleições presidenciais do Brasil nos estados brasileiros no ano de 2018 e do Instituto Brasileiro de Geografia e Estatística (IBGE) referente às características socioeconômicas dos estados brasileiros.

Na Figura 2.1, é apresentada a distribuição espacial das taxas relacionadas à COVID-19 nos estados do Brasil no período de 10 de março a dez de abril. Nela, é possível verificar que a pandemia da COVID-19 começou nos estados do sudeste, sul e parte do nordeste e se espalhou para as demais regiões do país nos dias subsequentes devido à insuficiência de políticas para contenção do SARS-CoV2 ainda na sua fase inicial.

Na Figura 2.2, tem-se a distribuição espacial das variáveis climáticas que são as principais variáveis explicativas de interesse do presente estudo, dado a forma randomizada com que estas ocorrem. Aqui, observa-se que houve uma maior incidência de luz solar nos estados da Região Nordeste e Centro-Oeste no período analisado. Já os estados mais húmidos estão localizados na Região Norte e Nordeste do país. No período analisado, a temperatura média foi maior nos estados da Região Norte e Nordeste.

Na Figura 2.3, são apresentadas as taxas de prevalência da COVID-19 nos estados brasileiros de dez de março a dez de abril. Cada linha dessa figura representa o comportamento das taxas para cada estado da federação. Todos os estados e regiões apresentaram um comportamento exponencial no crescimento da taxa de disseminação do novo coronavírus, com

¹ Empresa fundada em 2014 e sediada na cidade do Recife/PE, com equipes em São Paulo/SP, Nova York/NY e na área da Baía de São Francisco/CA. <https://mapabrasileirodacovid.inloco.com.br/pt/>

destaque para os estados das Regiões Norte, Nordeste e Centro-Oeste que tiveram um crescimento mais acentuado das taxas referentes à COVID-19 vis-à-vis as demais regiões.

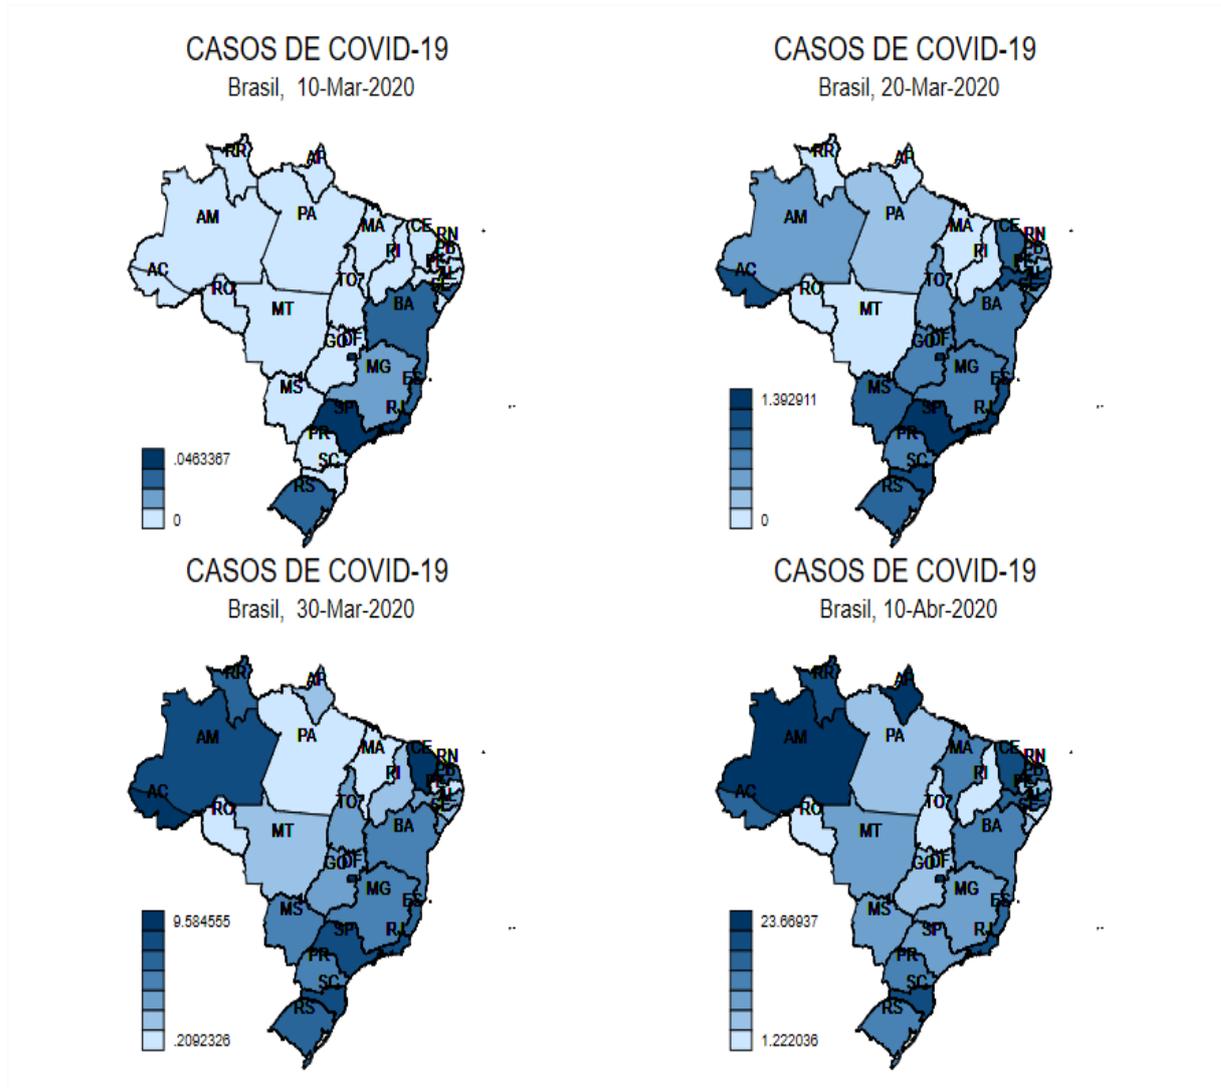
Tabela 2.1. Descrição das variáveis.

VARIÁVEL	DEFINIÇÃO DA VARIÁVEL
Txcases	Taxa de prevalência da COVID-19 por 100 mil habitantes no estado i no dia t .
Controles do Cenário Político	
<i>lockdown</i>	<i>Dummy</i> que assume valor igual a 1 se o estado i decretou <i>lockdown</i> no dia t .
Preswin	<i>Dummy</i> que assume valor igual a 1 se Bolsonaro conquistou pelo menos 50% dos votos válidos nas eleições de segundo turno no estado i no ano de 2018.
Controles Socioeconômicos	
Analf	Proporção de pessoas analfabetas em % (em relação à população total) no estado i .
Pop	Número de habitantes no estado i .
Idoso	Proporção de pessoas idosas em % (em relação à população total) no estado i .
<i>lnrenda</i>	Logaritmo neperiano da renda <i>per capita</i> no estado i .
Expvid	Expectativa de vida ao nascer em anos do estado i no ano de 2019.
Txvooint	Número de pessoas por 100 mil habitantes entrantes no estado i no mês referente ao dia t vindas de países estrangeiro por modal aéreo.
IIS	Índice de Isolamento Social em % no estado i no dia t .
Controles Climáticos	
Sun	Número de horas de brilho do sol sem interferência de nuvens e que as pessoas podem efetivamente se expor no estado i no dia t .
Tmean	Temperatura média em °C no estado i no dia t .
Humi	Umidade relativa do ar em % no estado i no dia t .
Controles do Perfil de Saúde	
Txresp	Proporção de pessoas diagnosticadas com problemas respiratórios em % (em relação à população total) no estado i no ano de 2019.
Txcora	Proporção de pessoas diagnosticadas com problemas de coração em % (em relação a população total) no estado i no ano de 2019.
Txhiper	Proporção de pessoas diagnosticadas internadas com hipertensão em % (em relação à população total) no estado i no ano de 2019.

Nota: [i] o número total de estados já conta com o Distrito Federal.

Fonte: Elaborado pelo Autor.

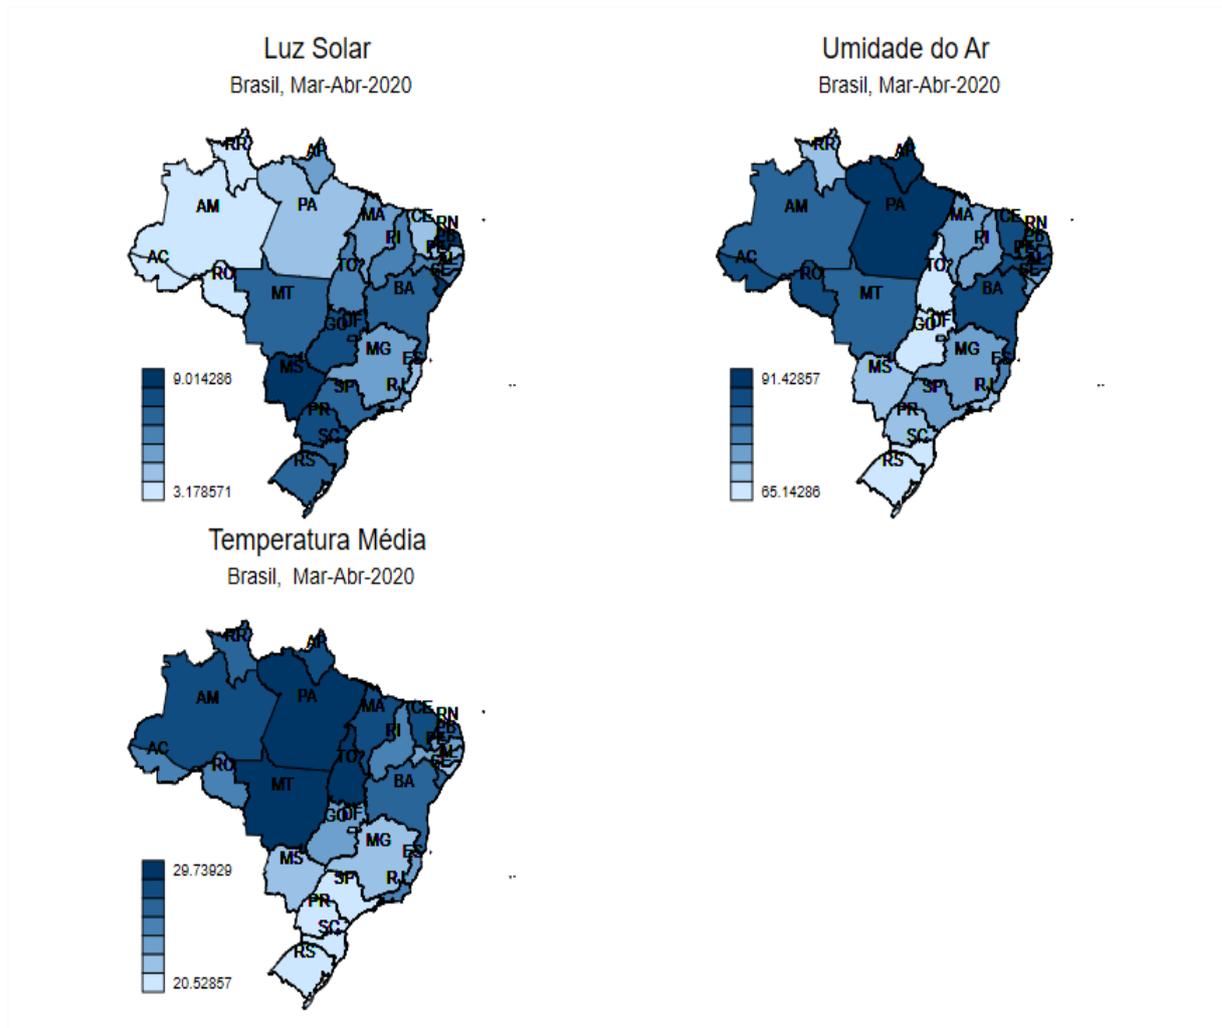
Figura 2.1- Distribuição espacial das taxas diárias de prevalência da COVID-19 no período de 10 março a 10 abril de 2020 nos estados brasileiros.



Legenda dos Estados: Acre - AC; Alagoas - AL; Amapá - AP; Amazonas - AM; Bahia - BA; Ceará - CE; Distrito Federal - DF; Espírito Santo - ES; Goiás - GO; Maranhão - MA; Mato Grosso - MT; Mato Grosso do Sul - MS; Minas Gerais - MG; Pará - PA; Paraíba - PB; Paraná - PR; Pernambuco - PE; Piauí - PI; Roraima - RR; Rondônia - RO; Rio de Janeiro - RJ; Rio Grande do Norte - RN; Rio Grande do Sul - RS; Santa Catarina - SC; São Paulo - SP; Sergipe - SE; Tocantins - TO.

Fonte: Elaborado pelo Autor.

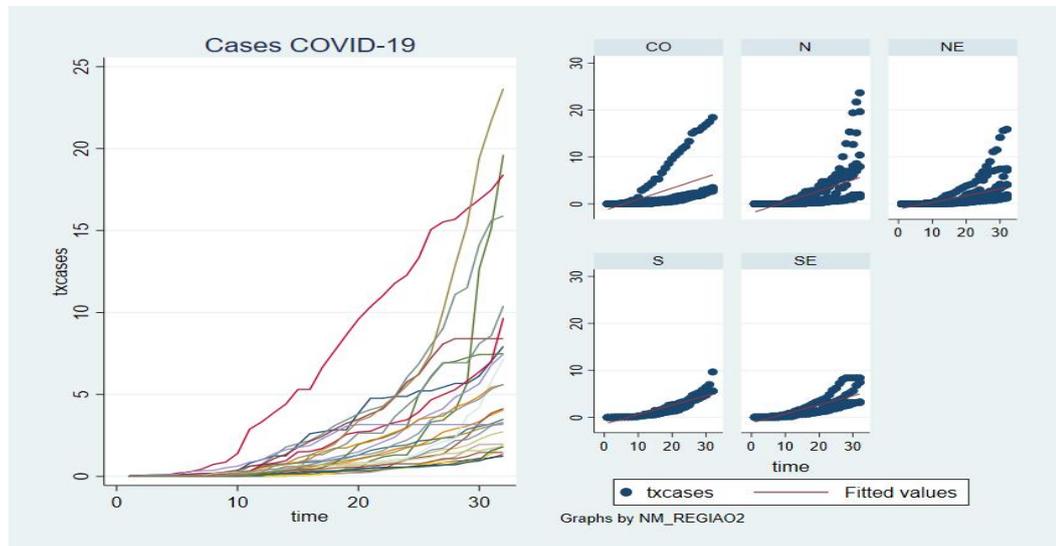
Figura 2.2- Distribuição espacial dos valores diários das variáveis climáticas no período de 10 março a 10 abril de 2020 nos estados brasileiros.



Legenda dos Estados: Acre - AC; Alagoas - AL; Amapá - AP; Amazonas - AM; Bahia - BA; Ceará - CE; Distrito Federal - DF; Espírito Santo - ES; Goiás - GO; Maranhão - MA; Mato Grosso - MT; Mato Grosso do Sul - MS; Minas Gerais - MG; Pará - PA; Paraíba - PB; Paraná - PR; Pernambuco - PE; Piauí - PI; Roraima - RR; Rondônia - RO; Rio de Janeiro - RJ; Rio Grande do Norte - RN; Rio Grande do Sul - RS; Santa Catarina - SC; São Paulo - SP; Sergipe - SE; Tocantins - TO.

Fonte: Elaborado pelo Autor.

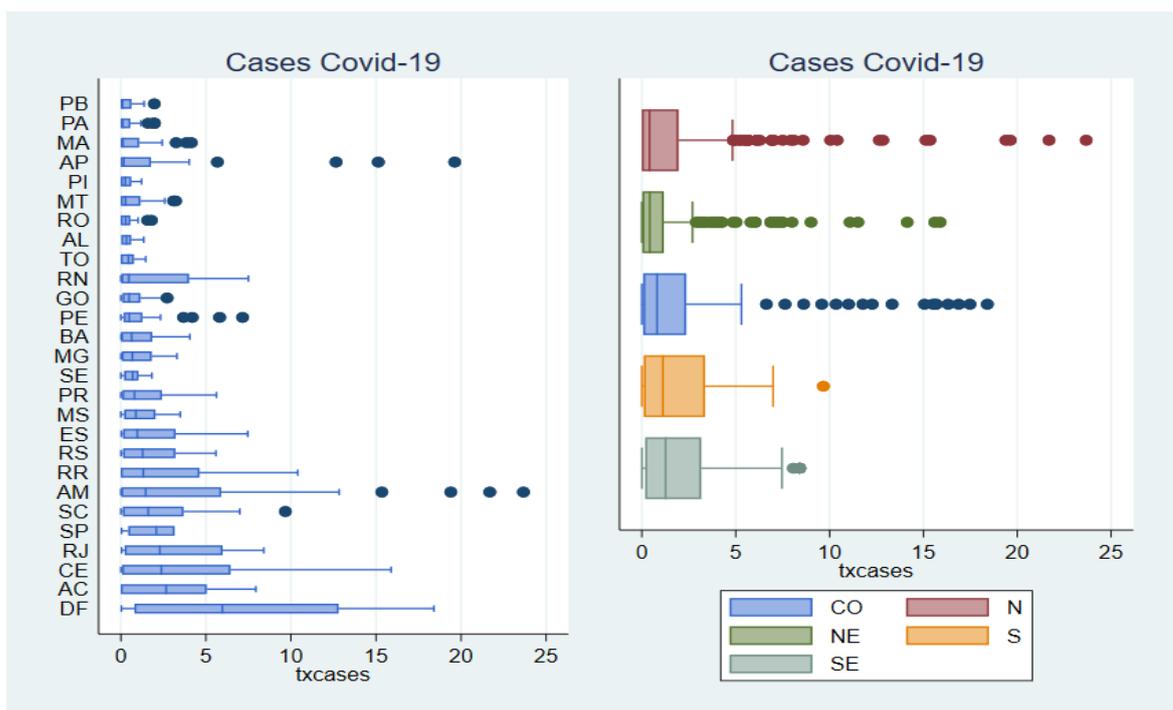
Figura 2.3- Evolução das taxas diárias de prevalência da COVID-19 de 10 de março a 10 de abril de 2020 nos estados e regiões do Brasil.



Fonte: Elaborado pelo Autor.

Na Figura 2.4, é mostrada a dispersão da incidência diária da COVID-19 dentro de cada estado e entre estados, o mesmo ocorrendo para as regiões do país. Alguns estados do Nordeste como o estado da Paraíba (PB), Alagoas (AL), Piauí (PI), Tocantins (TO) e Sergipe (SE), apresentaram menores taxas de disseminação da COVID-19 entre os estados e menor variabilidade dentro do período analisado.

Figura 2.4- Distribuição das taxas diárias de prevalência da COVID-19 de 10 de março a 10 de abril de 2020 nos estados e regiões do Brasil.



Fonte: Elaborado pelo Autor.

Já o estado do Amazonas (AM), na Região Norte, apresentou uma maior variabilidade da taxa de prevalência da COVID-19 e dentro do estado uma das maiores taxas entre estados. Os estados do Sudeste, São Paulo (SP), Rio de Janeiro (RJ), Espírito Santo (ES) e Minas Gerais (MG) apresentaram valores elevados das taxas da COVID-19, porém seus valores foram aproximadamente constantes durante os dias 10 de março a 10 de abril.

Ainda na Figura 4, vê-se (à direita da figura) que as Regiões Centro-Oeste e Norte tiveram grande variação na taxa de disseminação da COVID-19, sendo seguidos pela Região Nordeste. Já as Regiões Sul (S) e Sudeste (SE) tiveram taxas mais constantes ao longo do tempo.

2.3.2 Estatística Descritiva.

Na Tabela 2.2, são apresentadas as variáveis utilizadas no exercício econométrico proposto a seguir. A quantidade média de incidência de luz solar nos estados do Brasil é de 5.75 horas. A temperatura média e umidade relativa do ar são de 26.67° C e 77%, respectivamente. Já a quantidade de estados que utilizaram alguma política de restrição da circulação de pessoas foi em média 69.6%, enquanto a adesão ao isolamento social por parte da população foi, em média, da ordem de 44.8%

Tabela 2.2. Estatísticas descritivas das variáveis.

Variáveis	(1) N	(2) Média	(3) D. Padrão	(4) Mín	(5) Máx
Sunh	864	5.759	3.132	0	11.20
Tmean	864	26.67	2.801	12.25	31.55
Humi	864	77.00	8.553	56	97
Expvid	864	74.71	2.504	70.90	79.40
Pop	864	7,783000	9,084000	605,761	45920000
Idoso	864	7.563	2.495	0.500	12.50
Renda	864	1,238	468.0	635	2,685
Lockdown	864	0.696	0.460	0	1
Preswin	864	0.593	0.492	0	1
Analf	864	0.254	0.0613	0.120	0.360
IIS	864	44.88	9.227	25.70	72.80
Txcases	864	1.799	3.096	0	23.67
Txvooint	864	210.5	390.0	0	1,514
Txcora	864	2.367	1.030	0.918	4.554
Txhiper	864	0.603	0.558	0.0501	2.344
Txresp	864	46.65	12.04	25.50	69.56

Fonte: Elaborado pelo Autor.

2.3.3 Modelos para Dados em Painel e a sua Versão para Dados Espaciais.

As estimações da associação entre as taxas da COVID-19 e as variáveis climáticas, socioeconômicas, do perfil das condições de saúde e suas interações espaciais nos estados brasileiros foram realizadas para um período de 32 dias através da estimação *Generalized Least Squares* (GLS), uma vez que se trata de um painel longo, com período de tempo maior que número de unidades observações (*cross-sections*), o que pode gerar correlação serial de primeira ordem dos termos erro. Este processo de estimação ainda permite que os erros sejam heteroscedásticos e permite controlar a existência de correlação contemporânea, isto é, correlação entre as *cross-sections*, o que implica $E(\mu_{it}, \mu_{jt}) = \sigma_{ij}$ (HOECHLE, 2007; WOOLDRIDGE, 2002). A correlação entre as *cross-sections* surge devido à existência de componentes não observados que acabam criando interdependência entre as unidades de observação e faz com que os estimadores de efeitos fixos e aleatórios não sejam adequados (PESARAN, 2004; HOYOS; SARAFIDIS, 2006). O modelo para dados em painel é dado em (1).

$$y_{it} = clima_{it}\beta + x'_{it}\gamma + a_i + \mu_{it}. \quad (1)$$

onde y_{it} é a taxa de prevalência da COVID-19, no estado i no dia t . $clima_{it}$ é o vetor de variáveis climáticas tais como a quantidade efetiva de luz do sol sem interferência de nuvens, a temperatura média e a umidade relativa do ar no estado i no dia t . x'_{it} é o vetor das demais covariáveis utilizadas como controles. a_i é o conjunto de variáveis não observadas invariante no tempo e μ_{it} é o termo de erro aleatório.

Considerando a existência de efeitos autorregressivos de primeira ordem, tem-se que o termo de erro em (1) fica sendo representado por

$$\mu_{it} = \lambda\mu_{i,t-1} + \varepsilon_{it} \quad (2)$$

Diante do exposto, o estimador de GLS será dado por

$$\hat{\beta}_{GLS} = (X'\hat{\Omega}X)^{-1}X'\hat{\Omega}^{-1}y \quad (3)$$

$$\widehat{Var}(\hat{\beta}_{GLS}) = (X'\hat{\Omega}^{-1}X)^{-1} \quad (4)$$

onde a matriz Ω pode ser escrita como

$$\Omega = \Sigma_{m \times m} \otimes I_{T \times T} \quad (5)$$

e $\hat{\Omega}$ pode ser obtido substituindo $\hat{\Sigma}$ por Σ em (5) através do seguinte cálculo:

$$\hat{\Sigma}_{i,j} = \frac{\hat{\mu}_i' \hat{\mu}_j}{T} \quad (6)$$

Com vistas a uma melhor especificação do modelo econométrico e para resolver possíveis problemas de variável omitida espacial, fez-se uso de modelos espaciais com o objetivo de capturar a influência do espaço nas estimações dos parâmetros propostos. Assim, para mensurar o efeito *spillover* das taxas de COVID-19, usou-se o *Spatial Autorregressive Model* (SAR) que mensura o efeito transbordamento das taxas da COVID-19 para além das fronteiras dos estados.

$$y_{it} = clima_{it}\beta + x'_{it}\gamma + \rho W y_{it} + a_i + \mu_{it} \quad (7)$$

onde $W y_{it}$ é taxa de prevalência da COVID-19 dos estados vizinhos ao estado i no dia t e W é a matriz de ponderação espacial que captura a interação entre regiões com fronteiras em comum.

O efeito do espaço nas estimações econométricas pode ser capturado a partir das defasagens espaciais das variáveis independentes do modelo de regressão. Neste caso, o efeito *spillover* deve ser controlado a partir das covariáveis com o modelo *Spatially-Lagged X Model* (SLX).

$$y_{it} = clima_{it}\beta + x'_{it}\gamma + W clima_{it}\Psi + W X_t \delta + a_i + \mu_{it}. \quad (8)$$

Para controlar o efeito *spillover* da taxa de COVID-19, e das covariáveis. O modelo de regressão utilizado será o *Spatial Durbin Model* (SDM), uma vez que esse modelo possibilita incorporar diversas características do comportamento das variáveis através do espaço na modelagem econométrica (ELHORST, 2010, 2011; GULIYEV, 2020).

$$y_{it} = clima_{it}\beta + x'_{it}\gamma + \rho W y_{it} + W clima_{it}\Psi + W X_t \delta + a_i + \mu_{it}. \quad (9)$$

2.4. RESULTADOS

Para determinar o método de estimação dos modelos propostos, foram feitos preliminarmente alguns testes estatísticos. O primeiro deles foi o teste dos Multiplicadores de Lagrange de Breusch e Pagan para determinar se, devido à estrutura dos dados, seria melhor utilizar o método dos Mínimos Quadrados Ordinários ou métodos para dados longitudinais. O resultado obtido rejeitou a hipótese nula ao nível de 0.1%, indicando que a estimação por MQO não produz estimativas mais consistentes.

Outro teste realizado foi o teste de Woodridge para existência de correlação serial de ordem 1 no termo de erro da regressão, uma vez que os dados utilizados nesta pesquisa são considerados painéis longos, com período de tempo maior que o número de observações ($T > N$). Aqui, rejeitou-se a hipótese nula de não existência de correlação serial ao nível de 0.1%.

Também foi feito o teste de Pesaran para detecção de correlação contemporânea (correlação entre as *cross-sections*) que pode implicar erros heterocedásticos e estimadores não eficientes. Neste teste, a hipótese de que não existe correlação entre as *cross-sections* foi rejeitada ao nível de 0.1%. Neste caso, a estimação do modelo foi feita por *Generalized Least Square* (GLS).

Para constatar a presença de correlação espacial nos dados, foi realizado o teste I de Moran, sob a hipótese nula de não existência de correlação espacial nos dados. Esta hipótese foi rejeitada também ao nível de significância de 0.1%, indicando que as características espaciais dos estados brasileiros podem determinar a taxa de contágio da COVID-19 e devem ser incluídas no modelo de regressão para evitar problema de viés de variável omitida espacial.

Na Tabela 2.3, tem-se os resultados dos exercícios econométricos propostos a partir da estimação dos modelos espaciais para dados em painel. Para testar as hipóteses levantadas sobre os fatores que afetam a disseminação da COVID-19, estimou na coluna (1) o modelo de regressão dado na equação (1). Nas colunas (2), (3) e (4), incluiu-se as características espaciais e estimou-se os modelos SAR, onde controlou-se o efeito do *spillover* espacial da variável dependente, SLX, onde utilizou-se o *lag* espacial das variáveis independentes como controles, e SDM, onde controlou-se os efeitos dos *lags* espaciais das variáveis dependente e independentes, respectivamente.

Os resultados obtidos em todos os modelos mostram uma correlação negativa entre a média móvel de 14 dias da luz solar (*sun14m*) e a taxa de prevalência da COVID-19, indicando que estados com maior incidência de luz solar têm menores taxas de disseminação do SARS-CoV2. Este mesmo resultado é encontrado para as médias móveis de 11 e 7 dias da incidência de luz solar (*sun11m*) e (*sun07m*). Todos os resultados foram significantes do ponto de vista estatístico ao nível de 0.1% ($p\text{-value} < 0.001$).

Também foi encontrado em todos os modelos propostos um efeito negativo entre as médias móveis de 14, 11 e 7 dias da temperatura média (*tmean14m*, *tmean11m* e *tmean07m*), sobre as taxas de incidência da COVID-19, indicando que estados com maior nível de temperatura, têm menores taxas de disseminação do SARS-CoV2. Aqui, os resultados também foram estatisticamente significantes ao nível de 0.1% ($p\text{-value} < 0.001$).

Já as médias móveis de 11 e 7 dias da umidade relativa do ar (*hum11m* e *hum07m*) se mostraram negativas e estatisticamente significativa ($p\text{-value} < 0.001$) apenas nos modelos SLX e SDM (colunas (3) e (4)), indicando que ao se controlar os efeitos das características socioeconômicas, espaciais, os estados com maior umidade relativa do ar, experimentam

diminuição nas taxas relacionadas a COVID-19. Porém estes resultados não foram observados na com a média móvel de 14 dias da umidade relativa.

Tabela 2.3. Estimação dos modelos para dados em painel e suas versões espaciais para as taxas diárias de prevalência da COVID-19 nos estados brasileiros de dez de março a dez de abril de 2020.

Variáveis Independentes	Variável Dependente: <i>txcases</i>			
	(1) GLS	(2) SAR	(3) SLX	(4) SDM
Média Móvel 14 dias				
Sun14m	-0.0831*** (-15.70)	-0.0841*** (-15.85)	-0.0917*** (-17.33)	-0.101*** (-24.24)
Humi14m	0.0253*** (14.56)	0.0250*** (14.56)	0.00186 (0.96)	0.00194 (1.42)
Tmean14m	-0.129*** (-18.53)	-0.132*** (-18.93)	-0.0196* (-2.54)	-0.0255*** (-3.85)
Média Móvel 11 dias				
Sun11m	-0.0624*** (-20.18)	-0.0598*** (-18.15)	-0.0550*** (-16.48)	-0.0522*** (-14.05)
Humi11m	0.00259* (2.09)	0.00278* (2.23)	-0.00625*** (-5.07)	-0.00546*** (-3.88)
Tmean11m	-0.102*** (-16.53)	-0.100*** (-16.06)	-0.0357*** (-7.63)	-0.0446*** (-8.29)
Média Móvel 07 dias				
Sun07m	-0.0226*** (-15.10)	-0.0210*** (-14.09)	-0.0171*** (-8.92)	-0.0169*** (-10.27)
Humi07m	0.000456 (0.68)	0.00118 (1.77)	-0.00491*** (-6.42)	-0.00397*** (-5.42)
Tmean07m	-0.0462*** (-18.20)	-0.0439*** (-17.43)	-0.00528 (-1.34)	-0.00483 (-1.30)
Controles Socioeconômicos	Sim	Sim	Sim	Sim
Controles do Perfil da Saúde	Sim	Sim	Sim	Sim
Outros Controles Espaciais	Não	Não	Sim	Sim
Efeito Fixo Região	Não	Não	Não	Sim
N	864	864	864	864
	M.M 14 dias	M.M 11 dias	M.M. 07 dias	
Lagrange ^a	121.62***	93.23***	78.97***	
Wooldridge ^b	598.32***	589.51***	599.19***	
Pesaran ^c	38.80***	45.65***	48.04***	
Moran ^d	0.245***	0.327***	0.377***	

Nota: [i] o número total de estados já conta com o Distrito Federal. [a] Teste de Lagrange de Breusch-Pagan, onde a hipótese nula é que OLS produz estimadores mais consistentes. [b] Teste de Wooldridge, onde a hipótese nula é a não existência de correlação serial dos termos de erro. [c] Teste de Pesaran, onde a hipótese nula é a não existência de correlação entre as *cross-sections*. [d] Índice de Moran, onde a hipótese nula é de não existência de correlação espacial nos dados. [ii] Estatística t entre parênteses; [iii] *, **, *** indica *significativos estatisticamente* aos níveis 5%, 1% e 0,1%, respectivamente. [#] Os resultados completos das estimações estão no apêndice A.

Fonte: Elaborado pelo Autor.

Em modelos espaciais, as covariáveis utilizadas afetam diretamente a variável dependente em determinada unidade de observação i e afetam, indiretamente, a variável dependente de todas as unidades de observação contíguas à unidade i e a soma desses efeitos resultam no efeito total (LESAGE; PACE, 2009).

Na Tabela 2.4, são apresentados os resultados dos efeitos marginais diretos, indiretos e totais das médias móveis das covariáveis do modelo SDM para as taxas de prevalência da COVID-19. A análise dos efeitos marginais sugerem que elevando em 1% as horas no qual o Estado foi exposto ao sol gera, em média, uma redução no efeito total das taxas de casos confirmados da COVID-19 da ordem de 0.16%, considerando a média móvel de 11 dias e 0.07%, considerando a média móvel de 7 dias, ou seja, elevando a exposição à luz solar em uma hora (o que corresponde a um aumento de 20% na média brasileira de insolação), a redução no número médio de casos por 100 mil habitantes é de 5,58%, 8,93% e 3,9%. Este resultado corresponde a soma dos efeitos diretos e indiretos. Desta forma, a disseminação da doença ocorre mais lentamente quando comparada a estados onde a incidência de luz solar é menor.

Ainda na Tabela 2.4, os efeitos marginais totais das médias móveis da umidade relativa do ar indicam que um aumento de 1% na umidade relativa do ar leva a uma redução da taxa de prevalência da COVID-19 da ordem de 0.049%, para média móvel de 11 dias, e 0.027% para média móvel de 7 dias, indicando que estados com maior umidade relativa têm menores índices de referentes à disseminação da COVID-19.

Tabela 2.4. Efeitos marginais diretos, indiretos e totais das variáveis de interesse do Modelo SDM sobre as taxas diárias de prevalência da COVID-19 nos estados brasileiros.

	Efeitos Diretos	Efeitos Indiretos	Efeitos Totais
M.M. 14 dias			
sun14m	-0.101***	-0.00243	-0.10343
hum14m	0.00194	0.00949**	0.01143
tmean14m	-0.0255***	-0.295***	-0.3205***
M.M. 11 dias			
sun11m	-0.0522***	-0.116***	-0.1682***
hum11m	-0.00546***	-0.0441***	-0.04956***
tmean11m	-0.0446***	-0.182***	-0.2266***
M.M. 07 dias			
Sun07m	-0.0169***	-0.0619***	-0.0788***
hum07m	-0.00397***	-0.0235***	-0.02747***
tmean07m	-0.00483	-0.0650***	-0.06983***

Nota: [i] o número total de estados já conta com o Distrito Federal. [ii] *, **, *** indica *significativos estatisticamente* aos níveis 5%, 1% e 0,1%, respectivamente.

Fonte: Elaborado pelo Autor.

Os resultados dos efeitos marginais totais da temperatura média nos estados brasileiros mostram que aumentos de 1% na média móvel de 14, 11 e 7 dias reduzem as taxas de incidência da COVID-19 em 0.32%, 0.22% e 0.06%, respectivamente, indicando maiores níveis de temperatura média, reduzem as taxas da COVID-19 nos estados brasileiros.

2.4.1 Discussão

O Brasil é um país de dimensões continentais e o maior país da América do Sul. Não obstante, este país apresenta diferenças climáticas acentuadas entre suas regiões que são compostas por áreas de serrado, litoral, mata atlântica, entre outras. Desta forma, o Brasil tem sob o seu território diversos tipos de clima onde os principais são: equatorial, tropical, semiárido, tropical de altitude, tropical atlântico e subtropical (PALIALOL; PEREDA; AZZONI, 2020). Assim, a investigação sobre a influência dos fatores climáticos sobre os casos da COVID-19 nos estados brasileiros se mostrou relevante devido à forma desigual com que o SARS-CoV-2 vem se disseminando através do espaço (CANDIDO et al., 2020).

Ao estudar o Brasil, diversos trabalhos foram desenvolvidos no intuito de explicar o comportamento da COVID-19 no país como em Ajzenman, Cavalcanti e Da Mata (2020), Nicoletis et al. (2021), Mariane, Gagete-Miranda e Rettl (2020), Candido et al. (2020), no entanto nenhum deles se detiveram as questões climáticas.

O período compreendido por esta pesquisa, 10 de março a 10 de abril de 2020, corresponde à fase inicial da pandemia, onde ainda não existiam muitas intervenções não farmacêuticas, restringindo a atividade econômica e o convívio social. Isto permitiu investigar o impacto das variações exógenas do clima sobre a taxa de disseminação da COVID-19. Além disso, foi no início do mês de março que a disseminação do SARS-CoV-2 passou a ocorrer de forma local, ou seja, passou-se a ter contaminação dos residentes dentro do próprio território brasileiro e entre os estados.

Para se analisar a influência do clima sobre a disseminação da COVID-19, foram utilizadas médias móveis de 14, 11 e 7 dias das variáveis climáticas com o objetivo de melhor capturar os efeitos dessas variáveis sobre as taxas correntes de incidência da COVID-19, uma vez que existe um período de incubação do SARS-CoV-2 e de manifestação dos sintomas da COVID-19 (LAUER, 2020; PAEZ et al., 2020).

As condições climáticas dos estados se mostraram uma fonte exógena importante para explicar as taxas de incidência da COVID-19, pois os resultados obtidos mostraram que estados

com que atingem maiores níveis de temperatura e têm maior incidência de luz solar conseguem ter uma redução na taxa de prevalência da COVID-19. Estes resultados corroboram com outros achados na literatura como em Palialol, Pereda e Azzoni (2020), Tobías e Molina (2020), Araneda et al. (2021), Chen et al. (2021) e Wang et al., (2020).

Resultado contrário ao encontrado para a variável de incidência de luz solar pode ser visto em Paez et al. (2020) que encontrou efeito positivo da incidência de luz solar sobre as taxas de prevalência da COVID-19 e atribuiu tal efeito a interferências de outros fatores como possíveis decretos de *lockdown* que diminuiu a circulação de pessoas e suas exposições ao sol.

Nesta pesquisa, foram utilizadas diferentes média móveis das variáveis climáticas para que fossem capturados os efeitos da exposição pretérita ao período do contágio da COVID-19. Os resultados mostraram que quanto menor o tempo médio de exposição à luz solar, menor seu impacto sobre as taxas da COVID-19 e seu impacto redutor sobre a COVID-19 foi verificado em todos os modelos testados. A umidade relativa do ar e temperatura média também fazem parte do rol de variáveis que têm influência sobre as taxas da COVID-19, indicado que lugares mais úmidos têm menor prevalência da COVID-19 (WANG et al., 2020), porém o impacto desta variável se mostrou não significantes estatisticamente para a média móvel de 14 dias. Já estados com temperaturas mais elevadas também têm menor incidência da COVID-19, uma vez que a capacidade de o SARS-CoV-2 permanecer ativo diminui quando as temperaturas atingem mais que 38°C e umidade relativa é maior que 95% (JAAKKOLA et al., 2014; CHAN et al., 2011).

As características sociais, econômicas e o perfil das condições de saúde nas regiões têm determinado a velocidade de disseminação do COVID-19. Buscou-se aqui controlar essas características, uma vez que elas se mostraram influências relevantes na determinação dos fatores que influenciam o contágio da COVID-19. Essas características determinam o grau de vulnerabilidade das localidades diante da pandemia e as medidas que elas adotam com vistas a conter a disseminação do SARS-CoV2 (NOY et. al., 2020; SNYDER; PARKS, 2020; ZHENG et al., 2020). Inicialmente estimou-se o modelo de painel por efeitos fixos para que fosse possível capturar o efeito dos fatores não variantes no tempo, porém não houve significância estatística das variáveis utilizadas devido à presença de correlação entre as *cross-sections* o que implica em heterocedasticidade dos erros e aumento da variância dos estimadores, comprometendo, assim, a significância estatística dos parâmetros estimados por não serem eficientes (PESARAN, 2004; HOYOS; SARAFIDIS, 2006), sendo necessário estimar os modelos por GLS.

Os atuais números referentes à COVID-19 são atribuídos, em muitos casos, às decisões dos líderes políticos das localidades (ALLCOTT et al., 2020; GADARIAN.; GOODMAN; PEPINSKY, 2021). Desta forma, procurou-se controlar o efeito das decisões políticas nos modelos de regressão propostos nesse trabalho. Os resultados obtidos mostraram que estados onde foram adotadas políticas de isolamento social como o *lockdown*, ou até mesmo a adesão voluntária ao distanciamento social, aqui representada pelo índice de isolamento social, têm efeito redutor nas taxas de contágio do SARS-CoV2. Políticas de isolamento social têm sido recomendada como uma forma eficaz de evitar uma disseminação descontrolada do COVID-19 e o colapso do sistema de saúde (TODA, 2020), pois, como mostrado por Gatto et al. (2020), as taxas de disseminação da COVID-19 crescem de forma exponencial com o passar dos dias, o que enseja medidas de isolamento social para frear o avanço do contágio. Estes resultados estão em consonância com os achados de Ajzenman, Cavalcanti e Da Mata (2020) e Mariani, Gagete-Miranda e Retzl (2020).

Um outro fator relevante na disseminação da COVID-19 foi o grau de conexão que uma localidade tem com outras, levando a um efeito de transbordamento do vírus causador da COVID-19 entre as regiões (GULIYEV, 2020). Nesse caso, a proximidade geográfica pode ser um fator determinante para explicar a dinâmica da disseminação do COVID-19 e sua não inclusão nos modelos estatísticos implica viés de variável omitida espacial, tornando as estimativas dos parâmetros enviesadas e inconsistentes (LESAGE; PACE, 2009; ANSELIN, 1988, 2003). Além disso, a conexão entre lugares pode não estar apenas delimitada por fronteiras geográficas em comum, pois com o uso do avião, a locomoção entre países pode levar apenas alguns minutos ou horas, fazendo com que a disseminação do SARS-CoV-2 ocorra de forma mais rápida (SNYDER; PARKS, 2020; NICOLELIS et al., 2021).

As políticas de isolamento social não conseguem por si só ser um fator determinante para a diminuição da prevalência da COVID-19 (CANDIDO et al., 2020), sendo necessário uma combinação de ações baseadas em diversos outros fatores que também influenciam as dinâmicas das taxas referentes à COVID-19, como os fatores climáticos e geográficos para que o resultado final no combate ao SARS-CoV-2 seja maximizado. Os resultados obtidos nesta pesquisa podem ajudar o *policymaker* a entender melhor como as características idiossincráticas das localidades pode influenciar a dinâmica das taxas da COVID-19 no espaço. Desta forma, recursos públicos e esforços para a erradicação da COVID-19 podem ser direcionados para determinado estado que tem as condições climáticas menos favoráveis à diminuição da taxa de prevalência do COVID-19.

2.5. CONCLUSÃO

Recentemente o mundo tem vivido uma pandemia causada pela disseminação de um vírus de origem chinesa chamado de COVID-19. Esse vírus se espalhou rapidamente pelo mundo causando uma doença conhecida por COVID-19 e deixando milhares de mortos em poucos meses. Desde então, diversos pesquisadores buscam descobrir quais fatores são capazes de inibir a propagação do COVID-19 e da taxa incidência da COVID-19.

Esta pesquisa visou contribuir para a literatura ao mensurar os efeitos dinâmicos e espaciais das taxas de disseminação da COVID-19, mostrando como estas taxas podem estar correlacionadas ao longo do espaço e como as variáveis climáticas podem influenciar na dinâmica espaço-temporal do COVID-19 nos estados brasileiros. Mais especificamente, buscou-se mensurar o impacto das variáveis climáticas tais como as horas de luz solar efetiva, aquela sem interferência de nuvens, a temperatura e a umidade relativa do ar sobre as taxas de prevalência da COVID-19 nos estados brasileiros de dez março a dez de abril de 2020 devido à natureza predominantemente exógena destas variáveis. Para isso, usou-se modelos espaciais para dados em painel, incluindo as interações espaciais entre estados.

Procurou-se ainda controlar o efeito de outros conjuntos de variáveis que, como mostrado em diversos trabalhos empíricos, podem afetar as taxas de prevalência da COVID-19. Essas variáveis foram divididas em grupos tais como variáveis socioeconômicas, com o objetivo de controlar os efeitos de características econômicas idiossincráticas dos estados; variáveis do perfil da saúde, estas com o objetivo de controlar o efeito das condições de saúde sobre as taxas da COVID-19; variáveis do cenário político, pois diversos estudos mostraram que as ações governamentais como decretos de distanciamento social têm impactos sobre os atuais números relacionados ao COVID-19, além dos efeitos fixos de região.

Preliminarmente, foram realizados diversos testes estatísticos com o objetivo de escolher o método mais apropriado para estimação dos modelos econométricos haja vista a natureza dos dados. Desta forma, realizou-se o teste dos multiplicadores de Lagrange de Breusch e Pagan, onde rejeitou-se a hipótese de que estimadores de OLS seriam mais consistentes. Realizou-se ainda o teste de Woodridge, onde rejeitou-se a hipótese de não existência de correlação serial dos termos de erro, o teste de Pesaran, onde rejeitou-se a hipótese de não correlação contemporânea e, por último, o teste I de Moran, onde rejeitou-se a hipótese nula de não existência de correlação espacial nos dados.

Diante disso, passou-se a estimar os modelos propostos na metodologia por GLS, fazendo uso das influências das defasagens espaciais e dos efeitos fixos região. Os resultados

mostraram que as variáveis climáticas foram significantes para explicar a incidência da COVID-19 nos estados brasileiros. Foram utilizadas as médias móveis destas variáveis para os períodos de 14, 11 e 7 dias devido ao tempo de incubação do SARS-CoV-2 e ao tempo para aparição dos sintomas da COVID-19. Mostrou-se que a incidência de luz solar tem impacto negativo sobre as taxas da COVID-19, reduzindo a taxa de contaminação pelo SARS-CoV-2 nos estados que têm maior tempo de brilho do sol.

A umidade relativa do ar e a temperatura média também foram significantes para explicar a taxa de prevalência da COVID-19 nos estados do Brasil, tendo ambas um impacto negativo, o que implica redução da incidência da COVID-19 nos estados, pois o SARS-CoV-2 perde a capacidade de permanecer ativo em lugares com temperatura e umidade mais elevadas.

As defasagens espaciais das covariáveis utilizadas nos modelos espaciais de regressão também se mostraram significantes para explicar as taxas da COVID-19 nos estados do Brasil, mostrando que os fatores climáticos e as medidas de isolamento social geram impactos nas taxas de prevalência da COVID-19 não só nos estados onde ocorrem, mas também, de forma indireta, nas taxas referentes à COVID-19 nos estados próximos.

Os resultados sugerem que políticas inter-regionais de combate à COVID-19 devem ser adotadas levando-se em consideração as características ambientais das localidades, devendo estados com menor incidência de luz solar, menor temperatura e menor umidade relativa do ar canalizar recursos para formulação e adoção de políticas de combate à disseminação do SARS-CoV-2 como forma de salvar vidas e reduzir os impactos da pandemia sobre a economia e sobre a saúde da população.

Capítulo 3

PROBABILIDADE DE PARALISAÇÃO DE OBRAS PÚBLICAS: INFLUÊNCIAS ESPACIAIS E O IMPACTO DOS REPASSES RECEBIDOS A PARTIR DA DESCENTRALIZAÇÃO FISCAL

3.1 INTRODUÇÃO

Uma preocupação dos governantes é fornecer bens e serviços público de modo a maximizar o bem estar social. Para isso, é necessário que o governo busque a eficiência na provisão de tais serviços. Esta eficiência garantirá que o governo fornecerá bens públicos com a menor despesa possível.

No Brasil, os governos são hierarquicamente distribuídos desde o ente federal, passando pelo estadual, chegando, por fim, ao municipal. Este último, segundo a teoria da descentralização fiscal, possui diversas vantagens quando da provisão de bens públicos, pois, por estar mais perto da população, conhece suas demandas e prioridades. Além disso, reconhece-se que o governo local pode utilizar os recursos públicos com maior eficiência, uma vez que tais recursos não precisam percorrer um longo caminho dentro da burocracia pública até chegar ao seu destino final. Desta forma, a descentralização fiscal seria uma forma eficaz de promover o uso eficiente dos recursos públicos (BORDIGNON; COLOMBO; GALMARINI, 2008; AMARAL FILHO, 2001).

Diversas evidencias empíricas mostraram que a simples descentralização dos recursos não garante a maximização do bem estar social, pois nem sempre a eficiência no uso dos recursos públicos é alcançada (GUCCIO; PIGNATARO; RIZZO, 2014; SOUSA; CRIBARINETO; STOSIC, 2005). Características específicas das localidades podem ser determinantes na boa gestão do dinheiro público.

O governo local, com base na descentralização de recursos, realiza diversas obras públicas com recursos originados do governo federal. Porém, isto ocorre em um ambiente assimétrico em termos de informações, pois os governos de esferas superiores não têm, em diversas ocasiões, informação sobre as empresas contratadas nem sobre os benefícios sociais das obras (BESFAMILLE, 2003). Desta forma, os governos centrais podem influenciar a execução de uma obra pública, a nível municipal, através do montante de recursos que colocam

à disposição dos governos municipais para que estes executem a obra conforme convênio pactuado entre eles.

A disponibilidade de recursos de governos centrais a cargos de gestores locais nem sempre se traduz em maior eficiência no uso de tais recursos. Desta forma, o simples fato de haver recursos adicionais vindo dos entes superiores pode não ser determinante para conclusão de uma obra (SOUSA; CRIBARI-NETO; STOSIC, 2005).

Diversas obras são simplesmente paralisadas por não atenderem diversos critérios técnicos e legais. Atos ilegais durante as fases de licitação e execução da obra também são responsáveis pelas diversas paralisações ocorridas (CHEAITOU; LARBI; HOUSANI, 2019; OHASHI, 2009).

Diversos fatores podem influenciar a paralisação de uma obra pública. Características socioeconômicas, políticas podem ser preditores importantes da probabilidade de paralisação de obras públicas (FERRAZ; FINAN, 2008; FERRAZ; FINAN, 2011). A transparência do processo de licitação para contratação das empresas também pode influenciar a execução de uma obra pública, pois muitas empresas podem ter problemas de ordem técnica ou orçamentária e não conseguir concluir a obra que foi contratada para realizar (BESFAMILLE, 2003). A transparência na contratação também reduz a formação de conluio das empresas e gera redução de custos para o setor público (OHASHI, 2009).

Diante do exposto, esta pesquisa buscou investigar quais fatores explicam a probabilidade de paralisação de obras públicas com destaque para influência dos valores recebidos voluntariamente pelos prefeitos através do governo federal para realização das obras. Para isso, utilizou-se como instrumento para os valores recebidos através de repasses a filiação partidária em comum entre o governo local e o governo federal através de um processo de estimação em dois estágios sob a hipótese de existência de estratégia de interação entre os governos das diferentes esferas do poder público (interação vertical) (BRUECKNER, 2003; KELLY, 2000).

Os resultados obtidos mostraram que, considerando a hipótese de interação vertical entre governos, utilizando a filiação partidária em comum como variável instrumental, a probabilidade de paralisação de uma obra pública diminui quando se aumenta o valor dos repasses entre governos, mesmo controlando diversas características a nível de obra, de município, de tempo e região. Porém como forma de garantir a robustez deste resultado, outros testes empíricos foram realizados. Primeiro, buscou-se verificar a diferença dos resultados ao segregar amostra por tipo de obra e depois por tipo de licitação utilizada para contratação da

empresa que executou a obra (CHEAITOU; LARBI; HOUSANI, 2019; OHASHI, 2009). Os resultados aqui obtidos mostraram que o impacto negativo do volume de repasses sobre a probabilidade de paralisação de uma obra continua fortemente significativa estatisticamente.

Adicionalmente, buscou-se verificar se a proximidade geográfica poderia influenciar nos resultados devido a interação que ocorre entre cidades no espaço (KIRBY; LESAGE, 2009; LIMA; SILVEIRA NETO, 2015; LIMA; BARBOSA, 2018). Os resultados mostraram que o impacto dos repasses sobre a probabilidade de uma obra pública ser paralisada continuou igual em magnitude e sinal mesmo utilizando três tipos diferentes de matrizes de pesos espaciais e excluindo a região metropolitana da amostra.

Por fim, utilizou-se uma variável instrumental alternativa com o objetivo de capturar o efeito da interação vertical entre governos. Neste caso, utilizou-se a ideologia partidária em comum entre prefeitos e presidente da república como variável capaz de afetar o volume de repasses recebidos. Os resultados mostraram que a correlação entre esse novo instrumento e o volume de repasse é estatisticamente igual a zero, não sendo essa a variável a *proxy* para a interação entre governos.

Esta pesquisa visa contribuir para a literatura ao explicar quais são os fatores que podem contribuir para que uma obra pública seja paralisada e como a interação entre governos pode modificar a chance de uma obra não ser concluída no tempo correto através dos recursos voluntários que o governo federal coloca à disposição dos governos municipais.

Este artigo está dividido em mais 5 seções além desta introdução. Na seção 3.2, discorre-se sobre as evidências empíricas que nortearam esta pesquisa. Na seção 3.3, apresenta-se metodologia proposta e os dados utilizados na investigação do problema de pesquisa ora citado. Na seção 3.4, tem-se a apresentação dos resultados obtidos a partir da estimação dos modelos econométricos propostos. Na seção 3.5 apresenta-se a discussão acerca dos principais achados deste trabalho, confrontando-os com outros achados da literatura recente. Por fim, na seção 3.6 faz-se a conclusão pesquisa.

3.2 BACKGROUND E EVIDÊNCIA EMPÍRICAS

A realização de obras públicas é uma forma de intervenção governamental na economia à medida que impulsiona o desenvolvimento local de forma direta, e demais localidades de forma indireta, e aumenta o bem estar social. O governo federal ao descentralizar recursos para que os governos municipais atendam as demandas da população local acaba por não saber se o recurso público foi empregado de modo a maximizar o bem estar social. Com o objetivo de

garantir a melhor aplicação dos recursos repassados aos municípios e combater possíveis atos de corrupção por parte dos gestores locais, o governo federal utiliza-se dos órgãos de controle para fiscalizar as ações que envolvam o uso dos recursos públicos.

A eficiência do setor público na provisão de bens e serviços tem sido investigada sob as mais diversas óticas, uma vez que uma eficiente alocação dos recursos públicos gera impactos significativos na qualidade de vida da população. Assim, a eficiência na alocação dos recursos públicos implica maximizar a oferta dos serviços públicos ofertados ou, dito de outra forma, implica minimizar a despesa pública para um dado nível de serviço público ofertado (SOUZA; RAMOS, 1999).

Uma forma de se alcançar a eficiência na alocação de recursos públicos é por meio da descentralização fiscal, onde o governo central delega ao governo local a missão de prover determinados bens públicos com o argumento de que o governo local, devido a sua proximidade com a população, leva vantagem no fornecimento de tais bens, pois conhece melhor as necessidades e preferências da população (BORDIGNON; COLOMBO, 2008; TOMMASI; WEINSCHELBAUM, 2007; AMARAL FILHO, 2001). Kappeler et al. (2013) analisaram o efeito da descentralização da receita na provisão de infraestrutura em nível subnacional em 20 países europeus durante o período 1990–2009. Os resultados mostram que após a descentralização da receita, o investimento em infraestrutura subnacional aumenta e que o mesmo efeito não é verificado nos outros tipos de investimentos públicos.

Um contraponto ao argumento de eficácia da utilização de recursos públicos pela descentralização fiscal e feito por Guccio, Pignataro, Rizzo (2014) para o caso de realização de obras públicas na Itália onde mostraram que os governos locais são menos eficientes na fase de execução, vis-à-vis ao governo central, pois sofrem maiores atrasos. Ressaltam ainda que o caso se torna mais evidente quanto menor o tamanho do município e quanto maior o valor externo recebido para execução da obra.

A decisão de realizar obras públicas por parte dos governos locais ocorre em um ambiente de informação assimétrica para o governo central, pois o governo local tem informações sobre a empresa contratada e sobre os potenciais benefícios da obra pública para a localidade. O governo central, por sua vez, apenas financiará parte ou a totalidade do projeto sem o prévio conhecimento dos benefícios para a população (BESFAMILLE, 2003).

A realização de obras públicas apresenta um duplo benefício para a população, pois tem o poder de transferir renda para as camadas mais pobres ao mesmo tempo que cria uma melhora de infraestrutura pública. Assim, a realização de obras públicas, sendo utilizada como variável

de política fiscal, atinge o objetivo o aumento do nível de renda, trazendo os salários do setor privado para os níveis de equilíbrio e a melhoria da infraestrutura tem efeitos no crescimento econômico (GEHRKE; HARTWIG, 2018). Conclusão semelhante é obtida por Berg et al. (2018) que mostrou que programa de obras públicas na Índia (Esquema Nacional de Garantia de Emprego Rural da Índia (NREGS)) aumentou os níveis médios da taxa de crescimento da renda agrícola da ordem de 4,3% ao ano.

A interação entre governos ocorre tanto entre governos de esferas diferentes, como no caso de governo central e governo local, interação vertical, como entre governos de mesma esfera, interação horizontal entre governos (BRUECKNER, 2003). Os gastos do governo em localidades vizinhas podem influenciar gastos do governo em determinada localidade dependendo da proximidade entre as cidades e do nível de interação entre elas (FRIGIO KOPLIN; REID, 1999). A interdependência das cidades, quando constatada, leva-se a concluir que existe um efeito “imitação de comportamento” dos prefeitos em relação a política fiscal e tributária de acordo com Foucault, Madies e Paty (2008) que verificaram tal efeito nos municípios franceses, enquanto Leroux e Carr (2007) verificaram essa interação de governos locais nos municípios do estado de Michigan nos Estados Unidos.

A paralisação de uma obra pública se deve ao não atendimento às leis que regulam tal matéria, além da falta de cumprimento de procedimentos técnicos que podem ou não ser advindo de atos de corrupção como fraudes nas licitações, mudanças de regras, alteração de especificações técnicas, além de que as empresas contratadas para realização dos serviços abandonam a obra por problemas de restrição orçamentária.

De acordo com levantamento do Senado Federal, através da Comissão Especial das Obras Inacabadas (CEOI), no ano de 2016, as razões para uma obra pública vir a ser paralisada são abandono da empresa; impedimento ambiental; interpelação judicial; restrição orçamentária e financeira; paralisação cautelar por órgãos de controle; motivo técnico; titularidade do imóvel ou pendência de desapropriação entre outros².

De acordo com Ferraz e Finan (2008), prefeitos quando são acusados por atos de corrupção tendem a ter menor probabilidade de reeleição quanto maior a quantidade e mais graves são os atos ilícitos constatados pelas autoridades levados ao conhecimento do público. Estes autores constataram, através da análise de uma política de anticorrupção realizada pelo governo federal, que realizou auditoria de forma aleatória em alguns municípios do Brasil, que

2- O relatório elaborado pela CEOI consta em <https://legis.senado.leg.br/comissoes/comissao?codcol=2061>.

a realização das auditorias diminuiu a probabilidade de reeleição do prefeito em 7% em situação que se constatou duas irregularidades para grupo de prefeitos que foram auditados quando comparados a prefeitos que não foram auditados, quando a quantidade de irregularidades associadas à corrupção constatadas pelo programa de auditoria foi de três, a diminuição da probabilidade de reeleição foi da ordem de 14%, o que levou os autores a concluir que os eleitores se importam não só com a corrupção mais com a intensidade da corrupção, punindo os políticos nas urnas.

Em municípios que tinha estação local de rádio que divulgasse os resultados da auditoria, os resultados obtidos foram que a probabilidade de reeleição do prefeito era 11% menor quando havia a constatação de dois atos de corrupção se comparado a prefeitos não auditados, porém quando nenhum ato de irregularidade foi constatado pela equipe de auditoria, a probabilidade de o prefeito se reeleger aumentou em 17% em cidades com rádio local.

Ohashi (2009) examinou o efeito de maior transparência no processo de qualificação do licitante e descobriu que a transparência aprimorada reduz o custo de aquisição em no máximo três por cento, pois a transparência no processo licitatório enfraquece a formação de conluio entre os licitantes.

Ferraz e Finan (2011) estimou que atos de corrupção praticados por governos locais geraram prejuízos da ordem de US\$ 550 milhões por ano. Estes autores estimaram o impacto da reeleição sobre os valores desviados por atos de corrupção e concluíram que em municípios em que prefeitos estão no seu primeiro mandato os recursos desviados são, em média, 27% menor que em municípios onde os prefeitos estão no seu segundo mandato. Sendo assim, os incentivos à reeleição reduzem o desvio de recurso público em US\$ 160 milhões por ano.

No Brasil, existem seis tipos de modalidades de licitação: concorrência, tomada de preços, convite, leilão³ e pregão⁴. A modalidade de licitação pode implicar maior ou menor probabilidade de paralisação de uma obra como mostrado em Castro et al. (2018), pois, segundo eles, a eficiência na execução de uma obra pública pode ser influenciada pela modalidade de licitação, concluindo que a modalidade *concorrência* pode reduzir os desperdícios de recursos públicos ao diminuir os atos de corrupção inerentes aos processos licitatórios. Já para Cheaitou, Larbi e Housani (2019), a escolha de quem vai executar a obra é crucial para o sucesso da

3- Estas cinco primeiras descritas na lei 8.666/93.

4- Esta última criada pela Lei 10.520/2002.

utilização eficiente dos recursos públicos. Sendo assim, argumentaram que a tomada de preço pelo “menor preço” pode ser responsável por baixa qualidade e atrasos nas obras públicas.

Eficiência na utilização dos recursos públicos pode ser influenciada por diversas características socioeconômicas das localidades tais como nível educacional da população (AFONSO, SCHUKNECHT; TANZI, 2010), taxa de urbanização e quantidade de residentes, entre outras (FERRAZ; FINAN, 2008; BROLLO, 2016). Desta forma, tais características, além daquela inerentes à obra, podem ser importantes preditores da probabilidade de paralisação de uma obra pública. Há evidências como em Ferraz e Finan (2011) que argumentaram que cidade onde prefeitos têm maiores incentivos à reeleição têm maior chance de atrair recursos federais para realização de obras públicas e essa chance aumenta com a proximidade da eleição.

Brollo e Troiano (2016) investigaram a relação entre o sexo do gestor público e os níveis de corrupção dos municípios do Brasil e descobriram que gestores locais do sexo feminino tem menor probabilidade de se envolver em atos de corrupção. Eles também constataram que prefeitos do sexo masculino contratam maior número de funcionários temporários em ano de eleição. Além disso, constataram que prefeitas tem menores chances de serem reeleitas quando comparado a oponentes do sexo oposto.

3.3 METODOLOGIA

3.3.1 Dados

Para esta pesquisa serão utilizados os dados das obras públicas ocorridas nos municípios de Pernambuco, nos anos de 2016 a 2018, do Tribunal de Contas do Estado de Pernambuco (TCE-PE). Os dados socioeconômicos dos municípios de Pernambuco são originados do Condepe Fidem e do Instituto Brasileiro de Geografia e Estatística (IBGE) são eles: taxa de desocupados, densidade demográfica, taxa de urbanização, índice de desenvolvimento humano municipal (IDHM), índice de Gini, proporção de pessoas com ensino superior, renda domiciliar per capita. Já os dados de filiação partidária dos prefeitos dos municípios de Pernambuco são oriundos do Tribunal Superior Eleitoral (TSE), enquanto os dados referentes às obras públicas tais como número de paralisações, valor contratado, valor da contrapartida e modalidade de licitação são do TCE-PE. Utilizou-se ainda o índice FIRJAN de Gestão Fiscal (IFGF) elaborado pela Federação das Indústrias do Estado do Rio de Janeiro com os dados declarados pelos municípios à Secretaria do Tesouro Nacional (STN).

3.3.2 Estatísticas Descritivas

Na Tabela 3.1, são apresentados os valores das estatísticas descritivas das variáveis utilizadas na estimação do modelo econométrico. Aqui, é possível ver que 9,43% das obras realizadas e que receberam recursos descentralizados foram paralisadas no período analisado. Já o percentual médio de repasses de recursos foi de 93,65% do valor das obras, limitado ao máximo de 150% do valor após aditivos pela lei 8.666/93. Em relação à filiação partidária, 15,8% dos municípios onde as obras foram realizadas são governados por prefeitos que têm a mesma filiação partidária do governo federal.

Tabela 3.1 - Estatística descritiva das variáveis socioeconômicas dos municípios de Pernambuco.

Variáveis	Descrição	Média	D. Padrão	Mín.	Máx.
Paralisada	<i>Dummy</i> =1 se a obra pública foi paralisada	0.0943	0.292	0	1
Repasso	Porcentagem do valor da obra que foi pago com recursos descentralizados	93.65	19.43	1.130	148.1
Partgov	<i>Dummy</i> =1 se o prefeito é do mesmo partido político do presidente da república	0.158	0.364	0	1
IFGF	Índice FIRJAN da gestão fiscal municipal	0.321	0.185	0.002	0.797
ITM	Índice de Transparência Municipal	577.2	211.2	0	940
POP	População residente	47,062	101,910	4,369	1.538e+06
Pensup	Porcentagem de pessoas com ensino superior	4.764	3.563	1.040	19.11
PIB	Renda domiciliar <i>per capita</i>	14,433	15,638	5,505	118,483
Txdesoc	Taxa de desocupados	9.251	4.042	1.450	20.47
Dens	Densidade demográfica em km ²	474.7	1.435	8.040	9,068
Txurban	Taxa de urbanização	65.47	20.72	12.38	100
Gini	Índice de Gini	0.535	0.0506	0.430	0.680
IDHM	Índice de Desenvolvimento Humano Municipal	0.599	0.0461	0.510	0.770
Reeleição	<i>Dummy</i> =1 se o prefeito está no segundo mandato	0.291	0.454	0	1
SexPref	<i>Dummy</i> =1 se o prefeito é do sexo masculino	0.897	0.304	0	1
Pvot	Proporção de votos do prefeito	0.499	0.182	0.018	1
Pver	Proporção de vereadores do mesmo partido do prefeito	0.212	0.146	0	0.727

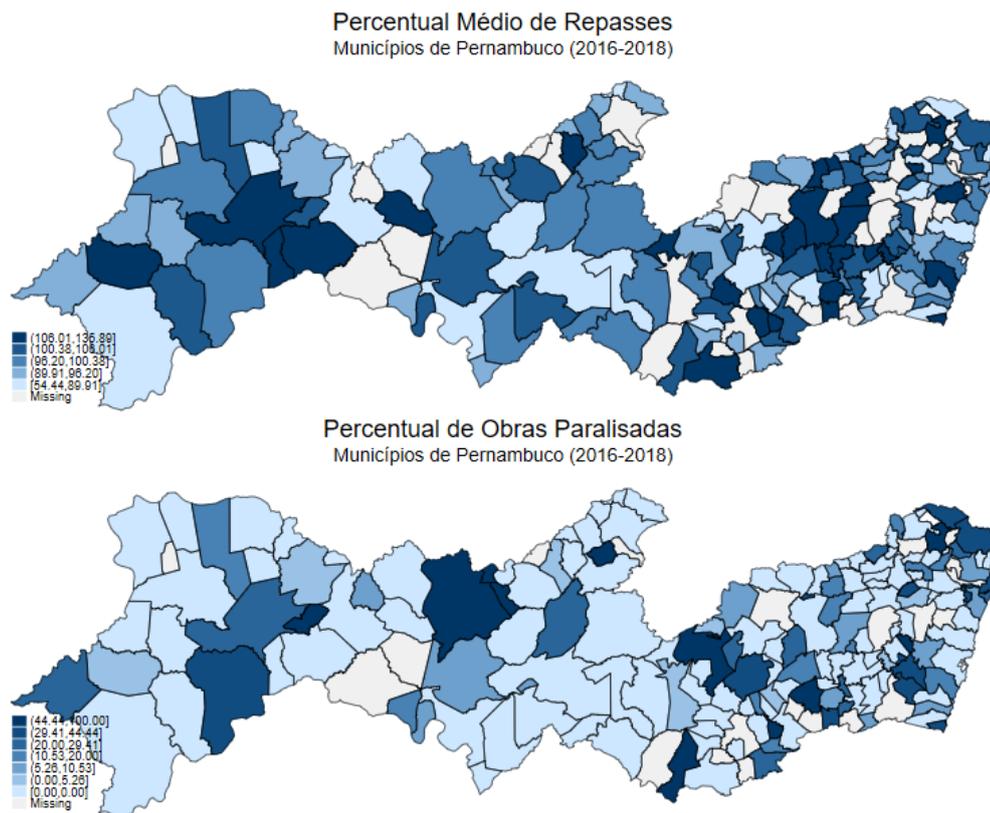
Número de observações 2736

Nota: [i] A base de dados não tem informações de obras realizadas em Fernando de Noronha.

Fonte: Elaborado pelo Autor.

Na Figura 3.1, são apresentadas as distribuições espaciais do percentual de obras paralisadas nos municípios de Pernambuco e o percentual médio de repasses de recursos por município. Nela, é possível verificar maiores volumes médios de repasses recebidos nos municípios da região Agreste e Sertão e, também, menores percentuais de obras paralisadas nos municípios destas regiões quando comparadas com as demais regiões do estado de Pernambuco.

Figura 3.1. Distribuição espacial das variáveis do percentual de obras paralisadas e percentual médio de repasses.



Fonte: Elaborado pelo Autor.

3.3.3 Modelo para Dados Qualitativos

Para testar empiricamente quais são os fatores que afetam a probabilidade de uma obra pública ser paralisada nos municípios de Pernambuco, foi utilizado o modelo *Probit* e suas extensões. A justificativa para o uso deste se dá em virtude de a variável dependente ser qualitativa assumindo o valor um (1) se a obra foi paralisada e zero (0), caso contrário (WANG; IGLESIAS; WOOLDRIDGE, 2013; WOOLDRIDGE, 2010; AMEMIYA, 1978).

$$y_{ij} = \gamma \text{repasse}_{ij} + X\beta + \varepsilon_{ij} \quad (1)$$

y_{ij}^* é uma variável binária que assume valor igual um (1) se a obra pública i foi paralisada no município j e zero (0) caso contrário; ou seja,

$$y_{ij} = \begin{cases} 0 & \text{se } y_{ij}^* < 0 \\ 1 & \text{se } y_{ij}^* \geq 0 \end{cases}$$

X é o vetor das variáveis explicativas utilizadas como controles;

ε_{ij} é o termo de erro aleatório e $\varepsilon_{ij} \sim N(\mathbf{0}, \Sigma)$.

A interação vertical entre os governos - aquela onde há interação entre governos dos diferentes níveis de hierarquia administrativa - quando se analisa a nível de obras públicas, ocorre por meio da celebração de convênios. Estes se caracterizam como uma ferramenta que tem como objetivo disciplinar a transferência de recurso e a execução do objeto de despesa. A prestação de contas deve ser realizada pelos municípios que recebem os recursos, comprovando, inclusive, o cumprimento dos prazos e outras formalidades pactuadas no convênio. Desta forma, pode haver uma forte correlação entre a filiação partidária do gestor municipal, quando é a mesma do governo federal, e a quantidade de recursos obtidos através da celebração de convênios. Neste caso, a filiação partidária afetará a probabilidade de paralisação de uma determinada obra pública apenas porque afeta a quantidade de recursos à disposição do governo local para execução da obra. Desta forma, a filiação partidária entre os governos dos diferentes níveis do poder público foi usada como instrumento para o valor dos repasses recebidos através da estimação do modelo probabilístico com o uso de variável instrumental (BRUECKNER, 2003; KELLY, 2000).

Assim, o modelo na equação (1) será modificado de modo que seja incluída a filiação partidária em um primeiro estágio da regressão (WOOLDRIDGE, 2010; AMEMIYA, 1978).

$$repasse_{ij} = \lambda partgov_{ij} + X\beta + v_{ij} \quad (2)$$

onde $partgov_{ij}$ é uma variável binária que assume valor igual um (1) se o prefeito da cidade j onde a obra i foi realizada é do mesmo partido do governo federal e zero (0) caso contrário; v_{ij} é o termo de erro aleatório do primeiro estágio da regressão.

3.3.4 Instrumento

A interação vertical entre governos ocorre principalmente pela filiação partidária comum. Esta interação através do partido político permite que governos locais tenham maior proximidade de governos hierarquicamente mais altos e, com isso, podem obter maior quantidade de recursos para realização de obras públicas. Neste caso, as chances de uma obra pública ser realizada com êxito podem ser influenciadas pelo volume de recursos que são repassados do governo central para o governo local.

Por outro lado, a fiscalização da aplicação dos recursos públicos cabe a órgãos de controle estatais, porém a legislação veda qualquer interferência política no trabalho de fiscalização dos auditores responsáveis pela detecção de irregularidades que implique paralisação de uma obra pública, pois se tal interferência política fosse possível, a filiação partidária em comum seria um determinante direto da probabilidade de paralisação de uma obra pública.

No caso desta pesquisa, a fiscalização das obras públicas é feita por órgão de controle a nível estadual, Tribunal de Contas do Estado de Pernambuco (TCE/PE), que, além de legalmente independente de qualquer interferência política, não se vincula a esfera federal. Isto reduz problemas de endogeneidade em caso de tentativas de interferência política federal na atividade de controle, uma vez que o órgão não está vinculado a este governo. Não há evidências na literatura recente de que a atuação dos órgãos de controle tivesse quaisquer indícios de atos corruptos por parte dos auditores quando da realização de suas atividades de fiscalização da atuação do governo municipal (FERRAZ; FINAN, 2008; FERRAZ; FINAN, 2011) e pode-se destacar ainda que a chance *ex ante* de um município ser auditado é a mesma ainda que algum já tenha sido auditado anteriormente (AVIS; FERRAZ; FINAN, 2018).

Outro ponto a destacar é que a literatura aponta que a paralisação de uma obra pública pode ocorrer por não cumprimento das leis, de procedimentos técnicos que podem ou não ser originados da prática de atos de corrupção dos agentes envolvidos como, por exemplo, fraudes nas licitações, alteração de especificações técnicas ou de regras, ou as empresas contratadas para realização da obra não terem a tecnologia adequada para a conclusão desta ou não terem recursos orçamentários que viabilizem a conclusão do serviço contratado (CHEAITOU; LARBI; HOUSANI, 2019; CASTRO et al., 2018; OHASHI, 2009). Assim, não há evidências de que os fatores citados sofram qualquer influência da filiação partidária comum entre o governo local e o governo federal, haja vista que o uso dos recursos públicos para realização de obras públicas é um fator que pode potencializar os resultados eleitorais e, conforme evidências

recentes, os atos de corrupção aumentam as chances de derrota política, não sendo plausível acreditar que o governo central repassaria recursos para governos locais, utilizando a filiação partidária comum como fator de decisão para o repasse, onde a chance de corrupção e deterioração da sua imagem política fosse mais acentuada (FERRAZ; FINAN, 2008; FERRAZ; FINAN, 2011; AVIS; FERRAZ; FINAN, 2018).

O uso do alinhamento político através da filiação partidária comum entre políticos locais e centrais pode ser um fator facilitador para a transferência de recursos entre governos. Lima e Barbosa (2018) mostraram, para o estado de Santa Catarina no Brasil, que municípios onde o prefeito era do mesmo partido político do presidente conseguiam obter maior quantidade de recursos do governo federal para aplicar em reparos aos danos causados por desastres naturais.

Desta forma, esta pesquisa utilizou a filiação partidária em comum entre governo federal e municipal como variável instrumental para o volume de recursos voluntários recebidos através da celebração de convênios, pois seria este o canal pelo qual a filiação partidária em comum afetaria a probabilidade de paralisação de uma obra pública.

3.3.5 Versão Espacial do Modelo para Dados Qualitativos

Outro fato a considerar é a existência de *spillover* espacial das covariáveis incluídas no modelo. Para verificar esta hipótese, foi utilizado o modelo *Spatial Lagged of X* (SLX) que inclui as defasagens espaciais de primeira ordem das variáveis independentes. A inclusão de variáveis espaciais no modelo econométrico reduz problemas de endogeneidade, uma vez que resolve o problema de viés de variável omitida espacial que torna os estimadores viesados e inconsistentes, pois as defasagens espaciais das variáveis independentes podem ser importantes preditoras do comportamento da variável dependente no espaço (BALTAGI; EGGER; KESINA, 2018; ELHORST et al., 2017; ARIMA, 2016; LACOMBE; LESAGE, 2015; LESAGE; PACE, 2009).

$$y_{ij} = \gamma \text{repasse}_{ij} + X\beta + WX\theta + \varepsilon_{ij} \quad (4)$$

W é uma matriz de ponderação espacial de dimensão $n \times n$ e que captura a interação entre regiões através do espaço e WX é a defasagem espacial das covariáveis do modelo. A equação (4) corresponde ao segundo estágio do modelo de regressão, enquanto o primeiro estágio da regressão é dado por

$$\text{repasse}_{ij} = \lambda \text{partgov}_{ij} + X\beta + WX\theta + v_{ij} \quad (5)$$

onde também é incluído as defasagens espaciais, WX , das covariáveis incluídas no modelo proposto.

Neste trabalho, optou-se por não incluir a defasagem espacial da variável dependente como regressor através do uso dos modelos *Spatial Autorregressive Model* (SAR) e *Spatial Durbin Model* (SDM), pois esta variável seria uma potencial fonte de endogeneidade, o que pode trazer problemas à estratégia de identificação e à atribuição do efeito causal do volume de repasses recebidos sobre a probabilidade de paralisação das obras públicas (LIMA; BARBOSA, 2018; GIBBONS; OVERMAN, 2012).

3.4. RESULTADOS

Os resultados da estimação do modelo Probit encontram-se na Tabela 3.2. Em todos os modelos propostos, o percentual de repasses recebidos do governo central não foi estatisticamente significativo ao nível usual de 5%. Provavelmente em decorrência das diversas fontes de endogeneidades presentes. Percebe-se ainda que o modelo com maior quantidade de variáveis é preferível aos demais, utilizando o Pseudo R2 como critério, uma vez que esta estatística apresentou valores mais altos à medida que foram sendo incluídas mais variáveis no modelo de regressão.

Tabela 3.2. Resultados das estimações do modelo probabilístico.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)				
	(1) PROBIT1	(2) PROBIT2	(3) PROBIT3	(4) PROBIT4	(5) PROBIT5
<i>Repassse</i>	-0.0010 (0.002)	-0.0000 (0.002)	-0.0001 (0.002)	-0.0010 (0.002)	-0.0010 (0.002)
Controles Socioecon	Não	Sim	Sim	Sim	Sim
Controles Obras	Não	Não	Sim	Sim	Sim
E.F. Tempo	Não	Não	Não	Sim	Sim
E.F Região	Não	Não	Não	Sim	Sim
Tendência Linear	Não	Não	Não	Não	Sim
Pseudo R2	0.0002	0.0550	0.0648	0.1896	0.1895
N	2736	2736	2736	2736	2736

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano k que é igual a um (1) se é do ano k e zero (0) caso contrário, onde k assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do i -ésimo município. Assume valor igual um (1) se pertence a região g e zero (0) caso contrário. g representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Tendência Linear – interação entre as variáveis socioeconômicas e a variável correspondente aos anos 2016, 2017, 2018. [iv] Erro-padrão entre parênteses; [v] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [vi] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice B.

Fonte: Elaborado pelo Autor.

Diante disto, foi estimado o modelo Probit fazendo uso da filiação partidária em comum entre prefeitos e o governo federal como variável instrumental com o objetivo de eliminar o efeito das endogeneidades existentes que podem estar determinando conjuntamente os repasses e a probabilidade de paralisação de uma obra pública. Estes resultados estão na Tabela 2.

Um instrumento para ser válido precisa ser correlacionado com a variável independente potencialmente endógena e não ser correlacionado com nenhuma outra variável, observada ou não observada, que possa determinar a variável dependente (ANGRIST; PISCHKE, 2008). Assim, para testar a relevância da hipótese de que os governos dos diferentes níveis do poder usam estratégia de interação vertical, o que implicaria em maiores repasses de recursos para municípios onde os prefeitos têm filiação partidária comum com o governante central, estimou-se o primeiro estágio do modelo de regressão, juntamente com o resultado do segundo estágio.

Tabela 3.3. Resultados das estimações do modelo probabilístico com variável instrumental.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)				
	(1) IVPROBIT1	(2) IVPROBIT2	(3) IVPROBIT3	(4) IVPROBIT4	(5) IVPROBIT5
<i>Repassse</i>	-0.0500*** (0.002)	-0.0523*** (0.003)	-0.0525*** (0.003)	-0.0515*** (0.005)	-0.0515*** (0.005)
<i>First Stage</i>	2.0233* (0.791)	2.2957** (0.792)	2.2688** (0.801)	2.5176** (0.838)	2.5170** (0.838)
Controles Socioecon	Não	Sim	Sim	Sim	Sim
Controles Obras	Não	Não	Sim	Sim	Sim
E.F. Tempo	Não	Não	Não	Sim	Sim
E.F Região	Não	Não	Não	Sim	Sim
Tendência Linear	Não	Não	Não	Não	Sim
Wald Test	19.94***	17.57***	16.97***	9.85***	9.86***
N	2736	2736	2736	2736	2736

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano k que é igual a um (1) se é do ano k e zero (0) caso contrário, onde k assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do i -ésimo município. Assume valor igual um (1) se pertence a região g e zero (0) caso contrário. g representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Tendência Linear – interação entre as variáveis socioeconômicas e a variável correspondente aos anos 2016, 2017, 2018. [iv] Erro-padrão entre parênteses; [v] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [vi] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice B.

Fonte: Elaborado pelo Autor.

Os resultados dessa estimação estão na Tabela 3.3. Aqui, observa-se uma correlação positiva e estatisticamente significativa entre a filiação partidária em comum entre prefeitos e governo federal (variável instrumental) e a proporção de repasses que os prefeitos receberam destes. Este resultado indica que prefeitos que são dos mesmos partidos do presidente da república recebem, em média, maiores repasses voluntários de recursos para realização de obras

públicas. Sendo assim, a condição de relevância do instrumento proposto é atendida em todas as especificações propostas.

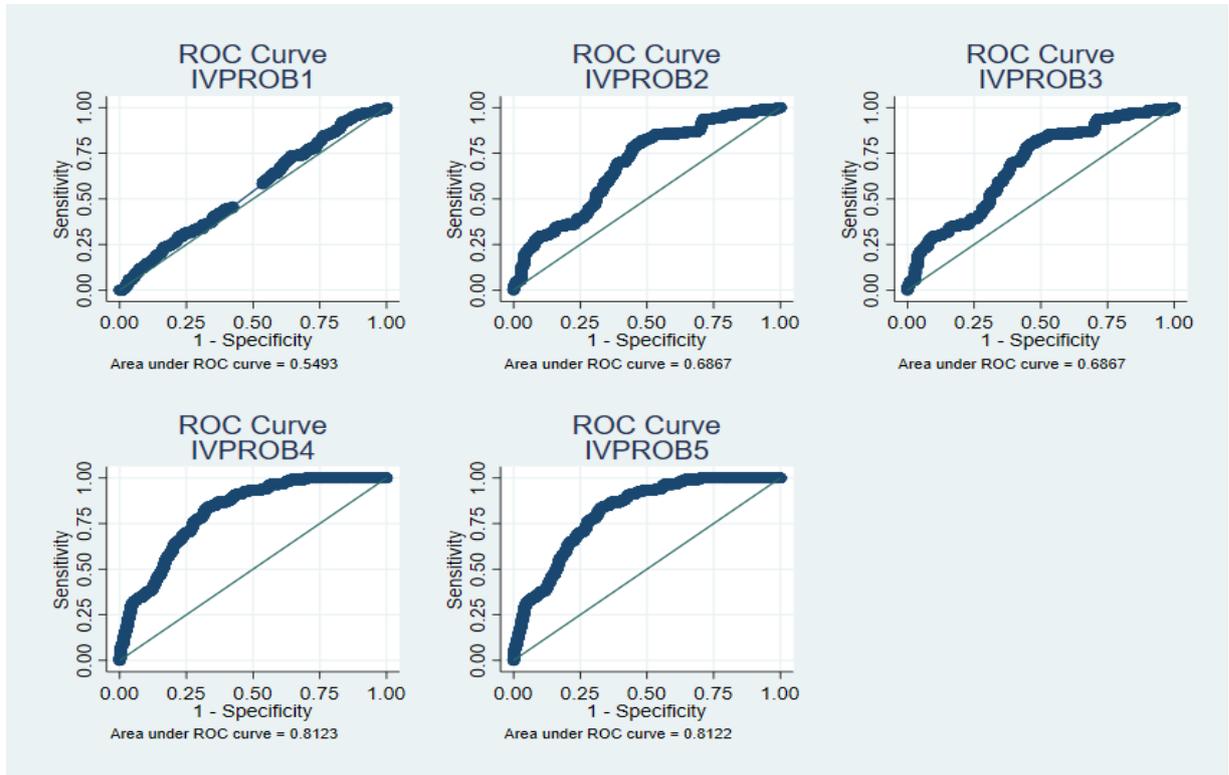
Ainda na Tabela 3.3, tem-se os resultados do segundo estágio da regressão onde é possível verificar que há uma diminuição na probabilidade de paralisação de obras públicas quando se aumenta o volume de recursos recebidos pelo governo local. Na coluna (1), estimou-se o modelo Probit com IV, porém sem a adição de nenhuma variável de controle. Nas colunas (2) a (5), foram adicionadas diversas variáveis de controles além dos efeitos fixos de obra, de tempo e de região administrativa e foi considerada ainda uma tendência linear das variáveis socioeconômicas com o objetivo de capturar mudanças nestas características ao longo do tempo, porém os resultados permaneceram estatisticamente significativos ao nível de 0.1%.

Os resultados encontrados, entre outras coisas, podem ser explicados devido ao fato de que o insucesso no fornecimento do bem público pode fazer com que a população associe a filiação partidária dos chefes do executivo de cada nível esfera administrativa à má prestação do serviço público. Adicionalmente a isso, o cumprimento ao que determina a legislação também é outro fator que força o governo local a se empenhar para que a obra seja efetivamente entregue dentro do cronograma previsto para que não sofra as sanções previstas nas leis que regem à celebração de convênios.

Na Figura 3.2, mensurou-se a capacidade de o modelo discriminar as categorias da variável dependente, através da curva *Receiver Operating Characteristic* (ROC). Se a área sob a curva for menor ou igual a 0.5, o modelo não consegue discriminar as categorias da variável explicadas. Os resultados mostram que os modelos IVPROB1, IVPROB2, IVPROB3 discriminam de forma aceitável as categorias da variável dependente, pois os valores sob a curva ROC foram da ordem de 0.54 e 0.68 e 0.68, respectivamente e discriminam de forma muito boa as categorias da variável dependente nos modelos IVPROB4, IVPROB5, pois os valores sob a curva ROC foram da ordem de 0.81 e 0.81, respectivamente, indicando uma melhor eficiência global do modelo econométrico quando da inclusão de todo o conjunto de variáveis explicativas do modelo de acordo com Hosmer & Lemeshow (1989).

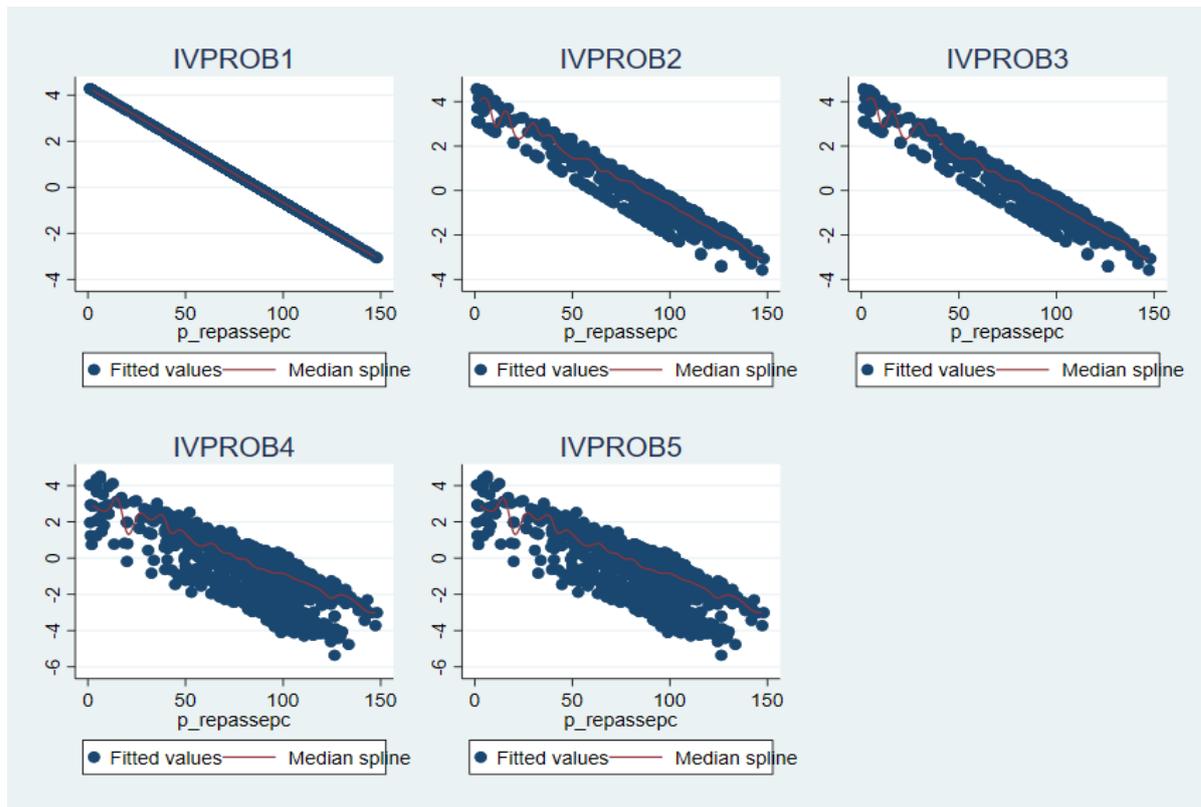
A qualidade do ajuste entre a probabilidade média estimada de paralisação das obras realizadas pelo governo e o valor recebido do governo federal é mostrada na Figura 3.3. Aqui, tem-se uma visão da relação negativa entre o valor dos repasses recebidos pelo governo local para realização de uma obra pública e a probabilidade de paralisação desta. Esta relação se mantém mesmo quando se inclui um grande conjunto de variáveis de controle.

Figura 3.2. Curva ROC dos modelos IVPROB1, IVPROB2, IVPROB3, IVPROB4 e IVPROB5.



Fonte: Elaborado pelo Autor.

Figura 3.3. Gráfico de dispersão da relação entre o valor dos repasses e as probabilidades de paralisação estimadas nos modelos IVPROB1, IVPROB2, IVPROB3, IVPROB4 e IVPROB5, respectivamente.



Fonte: Elaborado pelo Autor.

3.4.1 Análise de Heterogeneidade e Robustez

Apesar dos resultados mostrados anteriormente serem bastante fortes do ponto de vista estatístico, é necessário realizar alguns testes para garantir a robustez dos resultados encontrados. Assim, foi realizado diversos exercícios econométricos com o objetivo de verificar como os resultados variam com as mudanças de especificação do modelo econométrico, a exploração de efeitos heterogêneos e mudança de instrumento.

Tabela 3.4. Resultados das estimações do modelo probabilístico com variável instrumental e segregação regional.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)				
	(1) IVPROBIT1	(2) IVPROBIT2	(3) IVPROBIT3	(4) IVPROBIT4	(5) IVPROBIT5
	Agreste Central excluído	Agreste Meridional excluído	Agreste Setentrional excluído	Região Metropolitana excluída	Sertão do São Francisco excluído
<i>Repassse</i>	-0.0498*** (0.005)	-0.0509*** (0.005)	-0.0536*** (0.004)	-0.0575*** (0.004)	-0.0488*** (0.005)
<i>First Stage</i>	3.3927*** (0.960)	2.9242** (0.941)	1.9156* (0.861)	1.7440* (0.849)	3.0167** (0.979)
Controles Socioecon	Sim	Sim	Sim	Sim	Sim
Controles Obras	Sim	Sim	Sim	Sim	Sim
E.F. Tempo	Sim	Sim	Sim	Sim	Sim
E.F Região	Sim	Sim	Sim	Sim	Sim
Wald Test	9.75***	9.64***	8.86***	9.53***	9.40***
N	2313	2438	2522	2433	2371

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano *k* que é igual a um (1) se é do ano *k* e zero (0) caso contrário, onde *k* assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do *i*-ésimo município. Assume valor igual um (1) se pertence a região *g* e zero (0) caso contrário. *g* representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Erro-padrão entre parênteses; [iv] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [v] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice B.

Fonte: Elaborado pelo Autor.

Na Tabela 3.4 são apresentados os resultados do modelo Probit com IV, excluindo-se da amostra as regiões de desenvolvimento que têm PIB *per capita* acima do valor do PIB *per capita* mediano do estado de Pernambuco, pois os recursos públicos canalizados para estas regiões podem afetar de forma diferente a probabilidade média de paralisação de uma obra pública se comparado a probabilidade média de paralisação de uma obra para o estado de Pernambuco como um todo. Nas colunas (1), (2) e (3), excluiu-se os municípios das regiões de desenvolvimento Agreste Central, Agreste Meridional e Agreste Setentrional, enquanto nas colunas (5) e (6) excluíram-se os municípios da região metropolitana e do Sertão do São

Francisco, respectivamente. Os resultados permaneceram fortemente significantes do ponto de vista estatístico, indicando que obras localizadas em municípios que recebem maior volume de repasses têm menor chance de sofrerem paralisação. Entretanto esse resultado é um pouco mais acentuado para os municípios fora da região metropolitana, conforme resultado na coluna (5).

Para Kappeler et al. (2013) o tipo de obra pode ser um fator que atrai mais ou menos recursos descentralizados. Além disso, a população pode desejar mais um tipo de obra a outros e isso pode ter efeito sobre a alocação dos recursos públicos destinados a determinados tipos de obra. Desta forma, foi realizado um exercício econométrico excluindo determinados tipos de obra da amostra. Os resultados deste exercício encontram-se na Tabela 3.5. Nas colunas (1) e (2), têm-se os resultados do modelo Probit com IV, excluindo da amostra as obras de pavimentação. Já nas colunas (3) e (4) foram excluídas as obras de construção/reformas de hospitais e, por fim, nas colunas (5) e (6) foram excluídas as obras de construção/reforma de escolas.

Tabela 3.5. Resultados das estimações do modelo probabilístico com variável instrumental e segregação de tipos de obras.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)					
	(1) IVPROBIT1	(2) IVPROBIT2	(3) IVPROBIT3	(4) IVPROBIT4	(5) IVPROBIT5	(6) IVPROBIT6
	Obras de Pavimentação excluídas		Obras em Hospitais excluídas		Obras em Escolas Excluídas	
<i>Repasses</i>	-0.0512*** (0.003)	-0.0497*** (0.004)	-0.0545*** (0.003)	-0.0532*** (0.005)	-0.0511*** (0.004)	-0.0499*** (0.006)
<i>First Stage</i>	2.3532* (0.978)	3.0163** (1.018)	1.7044* (0.863)	2.1536* (0.915)	2.4157** (0.826)	2.6202** (0.863)
Control. Econ	Sim	Sim	Sim	Sim	Sim	Sim
Control. Obras	Sim	Sim	Sim	Sim	Sim	Sim
E.F. Tempo	Não	Sim	Não	Sim	Não	Sim
E.F Região	Não	Sim	Não	Sim	Não	Sim
Wald Test	17.94***	10.72***	11.43***	7.72***	14.81***	7.82***
N	1844	1844	2374	2374	2590	2590

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano k que é igual a um (1) se é do ano k e zero (0) caso contrário, onde k assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do i -ésimo município. Assume valor igual um (1) se pertence a região g e zero (0) caso contrário. g representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Erro-padrão entre parênteses; [iv] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [v] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice B.

Fonte: Elaborado pelo Autor.

Em todos os testes, os resultados foram estatisticamente significativos e se mantiveram próximo aos obtidos anteriormente, indicando que o volume de recursos públicos recebido dos

governo federal diminui a probabilidade de uma obra pública ser paralisada e que esse efeito é marginalmente maior quando se exclui da amostra as obras relativas à construção/reforma de hospitais, indicando que não existe muita heterogeneidade de efeito dos repasses de recursos sobre a probabilidade de paralisação de uma obra pública por tipo de obra.

Tabela 3.6. Resultados das estimações do modelo probabilístico com variável instrumental e exclusão de tipos de licitação.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)					
	(1) <i>IVPROBIT1</i>	(2) <i>IVPROBIT2</i>	(3) <i>IVPROBIT3</i>	(4) <i>IVPROBIT4</i>	(5) <i>IVPROBIT5</i>	(6) <i>IVPROBIT6</i>
	Tomada de Preço excluída		Carta Convite excluída		Concorrência excluída	
<i>Repassse</i>	-0.0471*** (0.006)	-0.0464*** (0.009)	-0.0539*** (0.003)	-0.0534*** (0.005)	-0.0536*** (0.003)	-0.0519*** (0.005)
<i>First Stage</i>	4.9103** (1.533)	4.5298** (1.555)	1.8004* (0.840)	1.8687* (0.886)	2.1063* (0.833)	2.6262** (0.890)
Control. Econ	Sim	Sim	Sim	Sim	Sim	Sim
Control. Obras	Sim	Sim	Sim	Sim	Sim	Sim
E.F. Tempo	Não	Sim	Não	Sim	Não	Sim
E.F Região	Não	Sim	Não	Sim	Não	Sim
Wald Test	9.57***	6.26**	17.08***	11.55***	21.04***	14.33***
N	986	986	2341	2341	2482	2482

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano *k* que é igual a um (1) se é do ano *k* e zero (0) caso contrário, onde *k* assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do *i*-ésimo município. Assume valor igual um (1) se pertence a região *g* e zero (0) caso contrário. *g* representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Erro-padrão entre parênteses; [iv] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [v] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice B.

Fonte: Elaborado pelo Autor.

Para Cheaitou, Larbi e Housani (2019) e Ohashi (2009) um fator importante para determinar a paralisação de uma obra pública é que o tipo de processo licitatório haja vista que a empresa contratada para a execução da obra pública pode ser um fator determinante para aumentar sua probabilidade de paralisação. Sendo assim, realizou-se as estimações do modelo econométrico, excluindo da amostra obras por tipo licitação que fora realizada para contratação da empresa executora da obra. Os resultados deste exercício encontram-se na Tabela 3.6. Nas colunas (1) e (2), têm-se os resultados do modelo Probit com IV, excluindo da amostra as obras que foram licitadas por tomada de preço, que ocorre quando são realizadas obras de engenharia de até R\$ 1.500.000,00 e demais obras de até R\$ 650.000,00. Já nas colunas (3) e (4) foram excluídas as obras que foram licitadas por carta convite, que ocorre quando são realizadas obras de engenharia de até R\$ 150.000,00 e demais obras de até R\$ 80.000,00 e, por fim, nas colunas (5) e (6) foram excluídas as obras que foram licitadas por concorrência, que ocorre quando são

realizadas obras de engenharia acima de R\$ 1.500.000,00 e demais obras acima de R\$ 650.000,00.

Os resultados obtidos mostram que há um impacto ligeiramente menor dos repasses de recursos na paralisação de obras públicas quando são excluídas as obras que foram licitadas por tomada de preços. Já quando se excluem obras licitadas por carta convite e por concorrência, os resultados são similares.

A interação entre regiões no espaço é um fator bastante consolidado na literatura e a proximidade entre cidades pode gerar os mais diversos tipos de interação. LeSage e Pace (2009) argumentam sobre a importância de se incluir no modelo de regressão efeitos de possíveis *spillovers* locais a partir da defasagem espacial das variáveis independentes do modelo. Kirby e LeSage (2009) mostraram a importância da inclusão das características socioeconômicas das regiões vizinhas como variáveis preditoras do comportamento do tempo de deslocamento até o trabalho. Em outra aplicação, Lima e Silveira Neto (2015) destaca que o crescimento econômico das regiões é fortemente influenciado pela dinâmica do crescimento que ocorre nas regiões vizinhas. Sendo assim, para que se estime de forma consistente os determinantes do crescimento econômico, a influência da interação espacial deve ser considerada no processo de estimação. Já Lima e Barbosa (2018) mostraram que a influência de desastres naturais vai além dos efeitos diretos sobre as regiões atingidas, há também efeitos indiretos do desastre sobre regiões próximas devido à interação entre regiões que ocorre devido às suas proximidades geográficas. Chagas, Azzoni e Almeida (2016) também verificaram efeitos indiretos das queimadas em plantações de cana de açúcar devido à proximidade geográfica entre as cidades e controlar esses efeitos *spillovers* produz estimativas consistentes dos modelos de regressão.

Desta forma, para se levar em consideração a interação entre cidade a partir das suas distâncias geográficas, estimou-se o modelo econométrico incluindo as defasagens espaciais das variáveis independentes geradas sob três óticas com o objetivo de reduzir os efeitos de escolhas *ad hoc* da matriz que melhor captura a interação espacial entre localidades (GIBBONS; OVERMAN; PATACCHINI, 2015). Assim, foram utilizadas as matrizes de ponderação espacial *Queen*, que define interação espacial entre regiões a partir de suas fronteiras geográficas comuns, e *k vizinhos mais próximos* com o objetivo de verificar a robustez dos resultados para diversos tipos de especificação de matriz (LIMA; BARBOSA, 2018; CHAGAS; AZZONI; ALMEIDA, 2016).

Os resultados deste exercício estão na Tabela 3.7, onde é possível observar que tanto utilizando a matriz *Queen* na coluna (1), e na coluna de (2) a (5) têm-se os resultados

considerando os 5 vizinhos mais próximos. Em todas as especificações do modelo espacial, os resultados permanecem fortemente significantes do ponto de vista estatístico indicando que, em média, obras que recebem maiores recursos descentralizados têm menor probabilidade de paralisação.

Tabela 3.7. Resultados das estimações do modelo probabilístico com variável instrumental e variáveis espaciais.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)				
	(1)	(2)	(3)	(4)	(5)
	IVPROBIT1	IVPROBIT2	IVPROBIT3	IVPROBIT4	IVPROBIT5
	Contiguidade	2 vizinhos mais próximos	3 vizinhos mais próximos	4 vizinhos mais próximos	5 vizinhos mais próximos
<i>Repassse</i>	-0.0525*** (0.006)	-0.0522*** (0.006)	-0.0521*** (0.006)	-0.0520*** (0.006)	-0.0520*** (0.006)
<i>First Stage</i>	1.9354* (0.986)	1.9669* (0.980)	1.9486* (0.955)	1.9777* (0.955)	1.9777* (0.955)
Control. Econ.	Sim	Sim	Sim	Sim	Sim
Control. Obras	Sim	Sim	Sim	Sim	Sim
Control. Espacial	Sim	Sim	Sim	Sim	Sim
E.F. Tempo	Sim	Sim	Sim	Sim	Sim
E.F Região	Sim	Sim	Sim	Sim	Sim
Wald Test	4.56**	4.56**	4.31*	5.05*	5.05*
N	2736	2736	2736	2736	2736

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano *k* que é igual a um (1) se é do ano *k* e zero (0) caso contrário, onde *k* assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do *i*-ésimo município. Assume valor igual um (1) se pertence a região *g* e zero (0) caso contrário. *g* representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco [iii] Erro-padrão entre parênteses; [iv] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [v] Controle Espacial representa as defasagens espaciais das variáveis de controle; [vi] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice B.

Fonte: Elaborado pelo Autor.

Por fim, realizou-se um teste com um instrumento alternativo com o objetivo de mostrar que a filiação partidária em comum entre prefeitos e presidente da república é um determinante do volume de recursos descentralizados para realização de obras e, conseqüentemente, afeta sua chance de paralisação. Neste exercício, foi utilizado a ideologia partidária (esquerda, direita ou centro) em comum entre governo local e central como variável instrumental para os recursos repassados a prefeitos por parte do governo federal. Os resultados obtidos estão na Tabela 3.8 e mostram que ser prefeito de um partido político que tem a mesma ideologia partidária do presidente não é um fator determinante para receber maior volume de recursos vindo do governo federal para realização de uma obra pública. O primeiro estágio da regressão não foi estatisticamente significativo, indicando que a ideologia partidária não é um instrumento válido

dado que viola a condição de relevância do instrumento proposto, não sendo possível atribuir um efeito causal do montante de recursos descentralizados sobre as chances de uma obra pública ser paralisada.

Tabela 3.8. Resultados das estimações do modelo probabilístico com variável instrumental alternativa.

Variáveis	Variável Dependente: <i>Paralisada</i> (dicotômica)				
	(1) IVPROBIT1	(2) IVPROBIT2	(3) IVPROBIT3	(4) IVPROBIT4	(5) IVPROBIT5
Independentes					
<i>Repassse</i>	-0.0441*** (0.008)	0.0536*** (0.004)	0.0530*** (0.004)	0.0553*** (0.002)	0.0553*** (0.002)
First Stage	-1.6580* (0.760)	0.7081 (0.737)	0.8767 (0.729)	0.4646 (0.758)	0.4645 (0.758)
Control. Econ	Não	Sim	Sim	Sim	Sim
Control. Obras	Não	Não	Sim	Sim	Sim
E.F. Tempo	Não	Não	Não	Sim	Sim
E.F Região	Não	Não	Não	Sim	Sim
Tendência Linear	Não	Não	Não	Não	Sim
Wald Test	4.48*	3.73	4.56*	3.56	3.56
N	2736	2736	2736	2736	2736

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano *k* que é igual a um (1) se é do ano *k* e zero (0) caso contrário, onde *k* assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do *i*-ésimo município. Assume valor igual um (1) se pertence a região *g* e zero (0) caso contrário. *g* representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Erro-padrão entre parênteses; [iv] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [v] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice B.

Fonte: Elaborado pelo Autor.

3.4.2. Discussão

A oferta de bens e serviços públicos por parte dos governantes tem como objetivo proporcionar um maior nível de bem estar social, observando o princípio da eficiência da alocação dos recursos públicos. Essa eficiência alocativa implica uma minimização do dispêndio público com a realização dos diversos serviços prestados pelos governos à população (SOUZA; RAMOS, 1999; TOMMASI; WEINSCHELBAUM, 2007).

Sob o argumento de vantagem alocativa os governos locais recebem dos governos estadual e federal recursos públicos para realização de obras de interesse comum, pois conhecem as necessidades da região melhor que os governos hierarquicamente superiores. Desta forma, devido à assimetria informacional, os governos centrais delegam aos governos locais a missão de oferecer bens e serviços públicos de acordo com as necessidades e preferências locais (BESFAMILLE, 2003; BORDIGNON; COLOMBO; GALMARINI, 2008).

Os impactos da realização de obras públicas em determinada localidade vão além do fornecimento do serviço que é fundamenta a execução da obra. Há uma melhoria da infraestrutura dos locais que recebem as obras e as pessoas mais pobres conseguem uma melhora dos seus níveis renda (BERG et al., 2018). Porém, a execução de uma obra pública deve obedecer a diversos critérios técnicos e legais para sua realização. A não observância a tais critérios implicam paralisação das obras e a desperdício de dinheiro público, além de não atingimento do objetivo fim que é a oferta do serviço público (CHEAITOU; LARBI; HOUSANI, 2019; OHASHI, 2009).

Em municípios onde são constatados maiores quantidade de atos de corrupção, o governo local acaba por ter uma diminuição das suas chances de conseguir reeleição e quanto maior a gravidade do ato ilícito praticado pelo gestor local, maior o impacto na sua probabilidade de conseguir se reeleger a um segundo mandato (FERRAZ; FINAN, 2008). Desta forma, maiores níveis de transparência pública nos atos da administração pública podem reduzir os prejuízos causados aos cofres públicos por causa de atos ilícitos praticados pelos governos (FERRAZ; FINAN, 2011).

A escolha da empresa que vai realizar uma obra pública deve seguir o princípio da transparência pública, pois diversos problemas de ordem técnica e legal podem surgir durante a fase de execução da obra devido à assimetria de informação entre contratante (ente público) e contratado (empresa) (BESFAMILLE, 2003). Além disso, a transparência pública quando aplicada ao processo de escolha das empresas reduz custos para o governo, pois enfraquece possíveis conluios entre as empresas (OHASHI, 2009).

A busca pela eficiência alocativa dos recursos públicos pode ser influenciada por diversas características intrínsecas das regiões. Assim, a chance de paralisação de uma obra pública pode ser influenciada tanto por características inerentes à obra como seu tipo, o tipo de licitação feita para a escolha da empresa que executará a obra (CHEAITOU; LARBI; HOUSANI, 2019; FINOCCHIARO; GUCCIO; PIGNATARO, 2018), quanto por características socioeconômicas (AFONSO, SCHUKNECHT; TANZI, 2010) e espaciais dos municípios onde essas obras ocorrem. Além disso, características do gestor e do cenário político podem influenciar as probabilidades de paralisação de uma obra pública (FERRAZ; FINAN, 2008; BROLLO, 2016) e sua adição como variáveis de controle melhoram a especificação do modelo econométrico.

Os resultados mostraram que sem a presença de interação vertical entre governo local e federal, o efeito do volume de repasses voluntários entre governos na probabilidade de

paralisação de obras públicas não é estatisticamente diferente de zero. Já quando se considera possível interação vertical entre governos, considerando a filiação partidária em comum como variável instrumental, o volume de recursos passa a ter efeito negativo e estatisticamente significativo sobre a paralisação de obras públicas, isto é, causa uma redução na probabilidade de paralisação para aumentos do montante de recursos repassados do governo federal para o municipal, pois governos locais recebem, em média, maior quantidade de recursos quando têm mesma filiação partidária dos governos hierarquicamente superiores conforme resultado mostrado no primeiro estágio do processo de estimação (LIMA; BARBOSA, 2018; BRUECKNER, 2003; KELLY, 2000).

Para verificar a robustez dos resultados obtidos, foram feitos outros testes de especificação econométrica, de heterogeneidade do efeito e mudança do instrumento proposto. Primeiramente, foi estimado o modelo com IV excluindo da amostra regiões de desenvolvimento do estado de Pernambuco que podem influenciar os resultados nas demais regiões. Os resultados mostraram que mesmo excluindo regiões da amostra, um maior volume de recursos repassados pelo governo central influencia negativamente a chance de paralisação de uma obra pública e que esse impacto é um pouco maior quando se exclui a região metropolitana da amostra.

Testou-se ainda a influência do tipo de obra quando da estimação do impacto do repasse sobre a probabilidade de paralisação de obras públicas, levando em consideração os achados de Kappeler et al. (2013) que descobriu que o tipo de obra a ser realizada influencia o volume de recurso que serão descentralizados do governo federal para o municipal. Os resultados obtidos nesta pesquisa mostraram que não há diferença significativa na probabilidade paralisação de uma obra pública quando se exclui da amostra tipos específicos de obra.

Ato contínuo, procurou-se identificar se havia alguma heterogeneidade dos resultados quanto ao tipo de licitação utilizada para a contratação da empresa que executaria a obra pública de acordo com as conclusões de Cheaitou, Larbi e Housani (2019) e Ohashi (2009). Os resultados mostraram que fazendo uso de IV, que há um impacto marginalmente menor dos repasses de recursos na paralisação de obras públicas quando se excluiu da amostra as obras que foram licitadas por tomada de preços, não havendo diferença nos resultados quando se excluiu obras licitadas por carta convite e por concorrência.

Com a finalidade de garantir maior robustez dos resultados obtidos, foi adicionado ao modelo econométrico a defasagem espacial das covariáveis com o objetivo de levar em consideração a interação espacial que ocorre nas cidades devido a suas proximidades

geográficas (KIRBY; LESAGE, 2009; LIMA; SILVEIRA NETO, 2015; LIMA; BARBOSA, 2018) e, desta forma, reduzir os problemas de viés de variável omitida espacial conforme LeSage e Pace (2009). Para isso, foram utilizados tipos diferentes de matrizes de ponderação espacial (*Queen e k vizinhos mais próximos*) com o objetivo de capturar os mais diferentes tipos de interação que pode ocorrer entre as cidades no espaço, uma vez que a escolha da matriz de pesos espaciais ocorre muitas vezes de maneira *ad hoc* (GIBBONS; OVERMAN; PATACCHINI, 2015). Os resultados obtidos mostraram que o impacto do volume de recursos descentralizados para realização de obras públicas é negativo na probabilidade de paralisação de uma obra pública, ou seja, obras que recebem maior quantidade de recursos descentralizados têm menor chance de paralisação.

Por fim, foi proposto o uso de uma variável instrumental alternativa que pudesse capturar possível interação vertical entre governo local e central e que tivesse influência sobre o volume de recursos descentralizados e, conseqüentemente sobre a paralisação de uma obra pública. O instrumento alternativo foi a ideologia partidária comum entre governantes, porém seu efeito sobre o volume de recursos repassados não foi estatisticamente diferente de zero. Este resultado ajuda a corroborar com a hipótese de que é a filiação partidária comum entre governantes a *proxy* que captura a interação vertical entre governos.

3.5. CONCLUSÃO

A presente pesquisa buscou investigar os fatores que podem contribuir para que uma obra pública venha a ser paralisada, o que resulta em atrasos no fornecimento do bem ou serviço público objetivo daquela obra e em desperdício de recursos públicos. Para isso, utilizou-se um modelo probabilístico e sua versão espacial como teste de robustez para verificar possíveis influências espaciais que poderiam invalidar a estratégia de identificação. A principal variável de interesse foram os valores repassados voluntariamente pelo governo federal para os prefeitos sob o argumento da descentralização fiscal que preconiza que o governo local, por conhecer melhor as necessidades e preferências de sua região, empregaria de maneira mais eficiente os recursos públicos e, por conseguinte, geraria maior nível de bem estar social. Assim, verificou-se o impacto dos repasses voluntários sobre a probabilidade de paralisação de uma obra pública nos municípios do estado de Pernambuco. Aqui foi adotada uma hipótese adjacente de que o volume de recursos descentralizados é influenciado pela existência de interação vertical entre governos e a *proxy* para capturar este efeito foi a filiação partidária comum entre os prefeitos e

o governo federal. Neste caso, prefeitos com mesma filiação partidária do governo federal receberiam maiores volumes de recursos voluntários deste governo para utilizar nas obras públicas, diminuindo, assim, a probabilidade de paralisação destas.

Os resultados mostraram que a probabilidade de uma obra vir a ser paralisada em determinado município diminui quando se aumenta os valores recebidos através de repasses do governo central, utilizando a filiação partidária comum como instrumento. Como forma de garantir a validade dos resultados, incluiu-se no modelo econométrico variáveis das características socioeconômicas dos municípios, do cenário político, além dos efeitos fixos de obra e região administrativa. Os resultados obtidos se mantiveram válidos mesmo diante da inclusão de um grande conjunto de variáveis.

Adicionalmente, para garantir a robustez dos resultados, explorou-se a heterogeneidade de efeitos dos repasses sobre a paralisação de obras públicas, segregando a amostra para determinadas regiões do estado de Pernambuco, para determinados tipos de obra e tipos de licitação utilizadas para contratação das empresas executoras das obras. Os resultados continuaram indicando um impacto negativo do volume de repasses sobre a probabilidade paralisação de obras públicas com um efeito maior quando se exclui da amostra a região metropolitana e marginalmente menor quando se exclui obras licitadas pela modalidade tomada de preços.

Outro fato levado em consideração nos testes empíricos foi a inclusão da interação espacial entre as cidades devido a suas proximidades geográficas, e a não inclusão de variáveis espaciais levaria a problemas de endogeneidade causados por variáveis espaciais omitidas. Os resultados obtidos também foram fortemente significantes do ponto de vista estatístico, mesmo considerando três tipos de interação espacial a partir do uso das matrizes espaciais *Queen*, e *k vizinhos mais próximos*, mostrando que após a inclusão das defasagens espaciais das covariáveis do modelo econométrico proposto, o volume de repasses causa uma diminuição da probabilidade de uma obra pública ser paralisada.

Testou-se ainda outro instrumento que servisse para capturar a interação vertical entre governos. Neste caso, usou-se a ideologia partidária em comum entre prefeitos e o presidente da república como *proxy* para capturar a interação entre governos capaz de influenciar o volume de repasses destinados à execução de obras pelos governos locais, porém houve violação da hipótese relevância do instrumento utilizado, pois os resultados do primeiro estágio não foram estatisticamente significantes, indicando que a ideologia em comum entre governos não influencia o montante de recursos descentralizados.

Os resultados obtidos nesta pesquisa contribuem para literatura de economia do setor público ao evidenciar como os governos locais podem interagir com o governo central e como isso pode influenciar a captação de recursos públicos e, a partir disso, verificar um efeito causal do montante de recursos descentralizados sobre as chances de uma obra pública ser paralisada. Estes resultados são particularmente importantes do ponto de vista social, uma vez que a não conclusão de obras públicas é uma grande fonte de desperdício de recursos públicos o que leva a uma diminuição do bem estar social, pois diversos bens e serviços deixam de ser ofertados ou são ofertados em quantidades subótimas devido à má gestão dos recursos por parte dos governos locais.

Capítulo 4

PROGRAMA “EM FRENTE, BRASIL” DE COMBATE À CRIMINALIDADE VIOLENTA. UMA ANÁLISE A PARTIR DA ABORDAGEM ESPACIAL DE DIFERENÇAS EM DIFERENÇAS

4.1 INTRODUÇÃO

A violência urbana tem sido tema de diversos debates entre acadêmicos, políticos e a população de um modo geral, uma vez que o crescimento dos índices de criminalidade nas cidades reduz o nível de bem estar social devido aos custos que impõe à sociedade (MACHIN; MARIE, 2011).

Diversos fatores têm sido associados ao aumento da criminalidade violenta. De acordo com a teoria econômica do crime, a decisão do agente quanto ao cometimento de crimes é fruto de uma ponderação entre custo e benefício do ato criminoso, e sempre que o benefício da atividade ilícita supera os custos, incluindo os custos de oportunidade de auferir renda lícita, o agente criminoso escolherá cometer crimes (EHRLICH, 1973; BECKER, 1968).

As características das cidades assumem relevância quanto à decisão dos indivíduos de cometerem ou não crimes. O nível de criminalidade depende do quão adensadas são as cidades e do tamanho da força policial, pois esses fatores influenciam a probabilidade de captura do criminoso (MELO, 2019; MACHIN; MARIE, 2011; DI TELLA; SCHARGRODSKY, 2004; LEVITT, 2002). Variações na renda, que aumente a desigualdade social, também têm influência nos níveis de criminalidade (DIX-CARNEIRO; SOARES; ULYSSEA, 2018; KELLY, 2000). Além disso, o criminoso, ao ponderar custos e benefícios, escolherá cometer crimes em cidades onde o benefício esperado do crime seja maximizado. Desta forma, ele se locomoverá no espaço em respostas às características do ambiente e às ações dos governos, gerando *spillover* de crimes entre as localidades (MENEZES et al., 2013).

Os governos, por sua vez, buscam reduzir os níveis de violência fazendo diversos investimentos públicos em segurança, assistência social, educação, etc. No campo da segurança pública, uma das formas de o governo lidar com aumentos dos índices de criminalidade é aumentar o nível de policiamento nas áreas consideradas violentas com o objetivo de reprimir

ações criminosas e aumentar a sensação de segurança da população (BLATTMAN et al., 2021; MACDONALDS; FAGAN; GELLER, 2016).

A contratação de mais policiais está, em geral, associada a um aumento da violência nos locais onde ocorrem o aumento do efetivo policial (LEVITT, 2002). Desta forma, avaliar o impacto desse aumento da força policial sobre a criminalidade é uma tarefa difícil devido à endogeneidade presente na relação entre essas variáveis que acabam por se determinarem de forma simultânea (LIN, 2009).

Diversos trabalhos tentaram identificar o impacto dissuasivo da presença policial sobre os mais diversos tipos de crimes ocorridos. Apesar de haver uma previsão teórica da presença dissuasiva da força policial sobre a criminalidade, os achados empíricos nem sempre confirmam esta previsão (CHALFIN; MACCRARY, 2018), uma vez que fatores não observados podem determinar de forma conjunta os níveis de policiamento e de violência nas regiões (LEVITT, 2002; EVANS; OWENS, 2007).

Diversas pesquisas buscaram explorar variações exógenas do quantitativo policial com o objetivo de contornar os problemas de endogeneidade e mensurar o efeito dissuasivo da presença policial sobre a criminalidade como em Bindler e Hjalmarsson (2021), Blattman et al. (2021), Mello (2019), MacDonalds, Fagan e Geller (2016), Machin e Marie (2011), Tella e Schargrodsky (2004) conforme será discorrido na revisão de literatura.

Este trabalho buscou contribuir para a literatura de avaliação de impacto e economia urbana e do crime ao explorar uma variação exógena na força policial em algumas cidades do Brasil para identificar seu impacto sobre o nível de criminalidade, pois o Brasil é um país em desenvolvimento que tem uma das maiores economias do mundo e também altos índices de violência em todas as regiões do seu território.

Diversas políticas públicas foram implementadas ao longo do tempo com o objetivo de reduzir as taxas de crimes ocorridos nas diversas regiões do Brasil (CARAZZA; SILVEIRA NETO; EMANUEL, 2020; BIDERMAN, MELO; SCHNEIDER, 2010), e de reduzir o nível de desigualdade que é bastante acentuada dentro do território brasileiro (CHIODA; MELO; SOARES, 2015; DIX-CARNEIRO; SOARES; ULYSSEIA, 2018).

Desta forma, a presente pesquisa analisou o impacto do programa *Em Frente, Brasil* (EFB) de combate à criminalidade violenta sobre as taxas de homicídios ocorridos nas cidades brasileiras no período de janeiro 2017 a maio de 2021. Este programa de política pública consistiu em enviar tropas da Força Nacional de Segurança Pública para alguns municípios

brasileiros nas cinco regiões do país. Cada região do Brasil⁵ teve um município contemplado pelo programa e que recebeu reforço no seu policiamento ostensivo a partir do envio das tropas federais para estas cidades. Todas as cidades contempladas pelo EFB fazem parte da região metropolitana do estado ao que pertence, mas a escolha da cidade que recebeu tropas da Força Nacional de Segurança foi baseada em decisão política que parece não estar relacionada diretamente com os níveis de criminalidade, uma vez que as cidades escolhidas não são as mais violentas das suas respectivas regiões metropolitanas.

O programa *Em Frente, Brasil* foi implementado pelo Governo Federal em setembro de 2019 e durou até abril de 2021. Durante este período as tropas da Força Nacional de Segurança Pública reforçaram o policiamento ostensivo das cidades contempladas, ajudando a diminuir a criminalidade nessas localidades.

Este programa, por se tratar de um quase experimento, permitiu que fossem formados grupos de tratamento e de controle com características bem parecidas, uma vez que tanto as cidades tratadas (aquelas que receberam o programa) quanto as não tratadas (demais cidades) pertencem as mesmas regiões metropolitanas e compartilham de diversas características em comum que são pré-requisito para fazer parte dessas regiões.

Assim, utilizando a abordagem de Diferenças em Diferenças (DiD), este trabalho investigou o efeito causal do EFB sobre as taxas de homicídios ocorridos nas cidades pertencentes as regiões metropolitanas dos estados de Goiás, Pará, Pernambuco, Espírito Santo e Paraná que receberam as tropas da Força Nacional de Segurança.

Os resultados obtidos na estimação do *framework* básico de DiD mostraram que houve um impacto negativo e estatisticamente significativo do EFB sobre a taxa de homicídios das cidades tratadas da ordem de 10,7%. Outros testes foram realizados como forma de verificar a robustez dos resultados encontrados. Primeiro verificou-se a existência de efeitos antecipatórios do programa (efeito placebo) e também se houve efeitos defasados. Os resultados deste exercício mostraram que não houve nenhum desses efeitos na estimação do modelo DiD.

Foi proposto ainda um teste de falsificação, utilizando as taxas de mortes por suicídio, afogamento, acidentes de trânsito e acidente exceto trânsito como *outcomes*. Os resultados encontrados indicaram que o EFB não teve impacto em nenhum desses tipos de morte. Além disso, buscou-se validar o resultado de que o EFB foi um programa desenvolvido para combater a criminalidade através de um teste chamado no contexto desse trabalho de teste de validação,

⁵ O Brasil é dividido em cinco regiões, são elas: região Norte; região Sul; região Sudeste; região Nordeste; região Centro-Oeste.

onde foi mensurado o impacto indireto do EFB sobre o mercado de drogas ilícitas, utilizando como *outcome* as taxas de mortes por overdose. Os resultados indicaram que o EFB teve um impacto negativo nas taxas de morte por overdose da ordem de 0.24%.

Mais dois testes foram realizados como forma de garantir a robustez dos resultados. Um deles consistiu em fazer um pareamento a partir das características observáveis dos municípios para que fosse possível selecionar um grupo de controle o mais parecido possível com o grupo de tratamento. Em outro teste, foram excluídas as capitais do grupo de controle sob a hipótese de que sua proximidade com as cidades tratadas poderia ter influenciado a escolha do tratamento. Em ambos os testes, os resultados não foram muito diferentes daqueles alcançados com o a estimação do modelo do *framework* básico.

Por fim, considerou-se a hipótese de que poderia existir efeitos *spillovers* do programa, impactando de forma indireta as cidades não tratadas. Assim, utilizou-se a abordagem da econometria espacial para se estimar o modelo DiD. Aqui, os resultados mostraram que houve efeito *spillover* do EFB sobre as unidades não tratadas, indicando um impacto negativo do EFB sobre as taxas de criminalidade dos municípios vizinhos àquele tratado. Desta forma, o efeito final da política pode ser decomposto em efeito direto e efeito indireto, onde o efeito direto é o efeito do tratamento sobre os tratados e que foi da ordem de 14% e o efeito indireto que, no caso desta pesquisa, é o efeito do tratamento sobre as unidades não tratadas da ordem de 3%.

Este artigo está dividido em mais 4 seções além desta introdução. Na seção 2, têm-se as evidências empíricas que nortearam esta pesquisa. Na seção 3, apresenta-se metodologia proposta e os dados utilizados na investigação do problema de pesquisa ora citado. Na seção 4, apresentam-se os resultados obtidos a partir da estimação dos modelos econométricos propostos. Por fim, na seção 5 faz-se a conclusão pesquisa.

4.2 EVIDÊNCIAS EMPÍRICAS

Políticas de combate à criminalidade têm sido frequentemente implementadas pelos governos. Carazza, Silveira Neto e Emanuel (2020) analisaram o efeito do toque de recolher de jovens menores de idade sobre a criminalidade no estado de São Paulo. A política consistiu em autorizar na região de Fernandópolis, a partir de agosto de 2015, o recolhimento, pelas forças de segurança pública, de pessoas menores de idade desacompanhadas de seus pais ou responsável adultos a partir das 23h. Assim, estes autores utilizaram a abordagem de diferenças em diferenças com o objetivo de mensurar o impacto do toque de recolher para pessoas menores

de 18 anos sobre as taxas de criminalidade na região de Fernandópolis. Os resultados obtidos mostraram que a política do toque de recolher reduziu em 17,9% as taxas de furto, porém a política não teve efeitos estatisticamente significantes nas taxas de roubos nem de furtos de veículos nem nas taxas de homicídios.

Foram feitos testes adicionais com o objetivo de garantir robustez aos resultados encontrados. Para isso, utilizaram um teste placebo da política através da técnica de *leads e lags*, onde testaram a existência de efeitos antecipatórios da política por parte dos agentes e testaram o efeito da política para períodos pós implementação. Os resultados mostraram que não houve efeito antecipação da política para os crimes de furto, mas houve este efeito para os crimes de roubo. Houve ainda um efeito pós tratamento para os crimes de furto e de roubo 3 anos após implementação da política.

Outro teste realizado foi a exclusão de municípios pertencentes ao grupo de controle que são vizinhos de algum município tratado para que possíveis efeitos *spillovers* da política pública não tornasse os resultados enviesados.

Estes autores fizeram também um pareamento em observáveis entre o grupo de controle e tratamento através de um *Propensity Score Matching* (PSM). Os resultados obtidos nestes testes mostraram que o efeito da política do toque de recolher sobre os furtos foi estatisticamente significativo em ambos os testes.

Por último, estes autores utilizaram afogamentos e suicídios como *outcomes* com objetivo de realizar testes de falsificação, uma vez que se espera que o toque de recolher não tenha efeito sobre esses tipos de morte. Os resultados destes testes não foram estatisticamente significantes como esperado.

Em outra análise de impacto de política pública voltadas ao combate da criminalidade, Biderman, Melo e Schneider (2010) utilizaram a abordagem de diferenças em diferenças para estimar o efeito causal da Lei Seca sobre os homicídios ocorridos na região metropolitana de São Paulo. A Lei Seca consistiu em uma política que proibia bares de funcionar em determinados horários do dia. Estes autores identificaram que no período de março de 2011 a agosto de 2004 apenas 16 dos 39 municípios da região metropolitana de São Paulo tinham adotado a citada lei.

A tendência temporal comum entre tratados e não tratados e a queda do número de homicídios dos tratados e não tratados não é prova do efeito da lei exclusivamente porque as cidades decidiram de forma endógena a adesão ao programa e outras ações para redução dos homicídios podem ter ocorrido de forma concomitante a implementação da Lei Seca haja vista

que as cidades que aderiram estão entre as mais violentas do estado de São Paulo.

Para se atingir o objetivo da pesquisa, os autores começaram estimando o impacto da Lei Seca sobre o consumo de álcool nas cidades da região metropolitana de São Paulo a partir dos dados dos valores gastos pelas famílias com consumo de cerveja e cachaça oriundos da Pesquisa Orçamento familiar – POF. Os resultados deste exercício econométrico mostraram que a Lei Seca diminuiu o valor gasto em bares com cerveja em aproximadamente R\$28.00 que representa 70 % do valor médio gasto pelas famílias com esse tipo de bebida. A Lei Seca também foi responsável pela diminuição de R\$2.20 do valor gasto em bares com cachaça pelas famílias o que representa 58% do valor médio gasto com cachaça. Quando o modelo é reestimado considerando a compra de cerveja em lojas para consumo em outro local, a Lei Seca foi responsável pelo aumento no valor gasto com cerveja da ordem de R\$11.00, indicando um pequeno efeito substituição nos hábitos de consumo de cerveja por parte das famílias. Para cachaça, não houve efeito substituição estatisticamente significativa.

Os autores, por fim, estimaram o modelo de diferenças em diferenças para mensurar o impacto da Lei Seca sobre os homicídios ocorridos na região metropolitana de São Paulo. Os resultados obtidos mostraram que cidades que adotaram a Lei Seca tiveram uma redução de 10%, em média, na taxa de homicídios por 100 mil habitantes. Depois disso, exploraram a heterogeneidade de adesão das cidades à Lei Seca e estimaram novamente os modelos considerando apenas os municípios tratados. Os resultados obtidos foram idênticos ao anterior.

Quando se passou a controlar o efeito *spillover* no modelo, nenhuma das variáveis foram estatisticamente significantes. Como teste de validação, os autores utilizaram lesões corporais e depois mortes no trânsito como variáveis dependentes. Os resultados mostraram que a Lei Seca teve impacto negativo na taxa de lesões corporais, mas não teve resultado relevante sobre as mortes por acidentes de carro, e uma das possíveis causas para isso é que o acidente pode ocorrer fora dos limites da cidade tratada. Já nos testes de falsificação, utilizaram roubos de veículos, a bancos e de cargas como *outcomes*, porém a Lei Seca não teve impacto em nenhum desses crimes.

Muitas pesquisas aplicadas têm investigado como a variação no efetivo policial pode influenciar as taxas de crimes ocorridos, uma vez que a presença policial é considerada um fator dissuasivo da atividade criminosa. Contudo há diversas evidências na literatura que não conseguiram constatar uma relação significativa entre essas variáveis ou que encontraram uma relação contrária ao esperado (relação positiva entre efetivo policial e criminalidade). Estes resultados são devidos a diversos problemas de endogeneidade presentes na relação entre

quantitativo policial e criminalidade como argumentam Tella e Schargrodsky (2004) que destacaram que o problema de endogeneidade se deve a fatores não observados que podem determinar de forma conjunta o crime e o tamanho da força policial. Estes autores investigaram se aumentos na força policial causam redução da criminalidade. Para isso, utilizaram um ataque terrorista ocorrido a um centro judaico na cidade de Buenos Aires, Argentina, onde morreram mais de 85 pessoas e houve mais de 300 feridos. Após esse fato, o governo intensificou a segurança nos locais onde existiam centros judaicos e islâmicos.

Devido ao fato de a localização destes centros ser exógena à criminalidade das respectivas regiões onde eles estão instalados, o aumento no policiamento nessas regiões pode ser considerado não diretamente ligado à criminalidade da localidade e, desta forma, pode-se atribuir um efeito causal do aumento do policiamento sobre a criminalidade. Os autores utilizaram como *proxy* para criminalidade o furto de veículos ocorridos nos bairros de Buenos Aires no período de abril a dezembro de 1994. Os resultados mostraram que nos bairros onde houve reforço do policiamento houve uma redução de 75% nos furtos de veículos quando comparados com o grupo de controle. Os autores ainda argumentaram que o efeito dissuasivo da presença policial é local, pois não encontram efeito *spillover* do aumento da presença policial nos crimes ocorridos nos bairros vizinhos.

Com o objetivo de mensurar o impacto que a atividade policial tem sobre a criminalidade, e contornar os problemas de endogeneidade, Levitt (2002) utilizou dados para os municípios americanos de 1975 a 1995. Porém devido a fatores não observados que podem determinar conjuntamente a quantidade de policiais e a taxa de crimes, o autor utilizou a quantidade de bombeiros como instrumento para o tamanho da força policial. O autor argumenta que aumentos na quantidade de bombeiros nas cidades está correlacionada com aumentos na força policial, porém fatores observados e não observados que determinam a taxa de criminalidade não estariam correlacionados com o instrumento e, desta forma, o instrumento seria exógeno. Os resultados obtidos mostraram que há a quantidade per capita de policiais afetam negativamente a taxa de criminalidade, tanto os crimes violentos quanto os crimes contra a propriedade e que o uso de variável instrumental ajudou a resolver o viés da estimação por mínimos quadrados ordinários alterando a magnitude dos coeficientes estimados.

Mello (2019) mensurou o impacto da quantidade de policiais sobre as taxas de criminalidade nas cidades americanas, explorando uma variação exógena na quantidade de policia nos estados americanos a partir de uma política de concessão para contratação de policiais ocorrida em 2009 no governo Obama. Para isso, o autor utilizou dados de

criminalidade no período de 2004 a 2014 com 4327 cidades, a abordagem de diferenças em diferenças e mínimos quadrados em dois estágios, onde a interação entre a política e o tratamento foi utilizada como instrumento para a quantidade de policiais nas cidades no primeiro estágio da regressão.

Os resultados alcançados nesta pesquisa mostraram que a política causou um aumento de 3.2% no quantitativo de policial e reduziu 3.5% a taxa de criminalidade. Também foi verificado que o impacto da política é mais significativo sobre os crimes violentos quando comparado com o efeito sobre os crimes contra a propriedade. A elasticidade do crime violento em relação ao aumento do quantitativo policial foi de -1.3, enquanto a elasticidade dos crimes contra propriedade em relação ao aumento do quantitativo policial foi da ordem de -0.8. Para testar a robustez dos resultados obtidos, o autor reestimou o modelo de regressão considerando apenas as cidades tratadas e as cidades vizinhas a elas para verificar a influência de efeitos *spillover* da política, porém o resultado teve pouca mudança em relação ao obtido anteriormente.

Outro estudo do efeito do aumento do efetivo policial sobre a violência urbana pode ser visto em Evans e Owens (2007) que investigaram o efeito de um programa de contratação de policiais sobre as taxas de crimes ocorridos nas cidades americanas. O programa Community Oriented Policing Services (COPS) foi um programa de aumento do efetivo policial nas cidades americanas criado em 1994. Os autores utilizaram uma estimação em dois estágios sob o argumento de que os valores disponibilizados pelo programa de contratação tiveram impacto direto no aumento do efetivo policial e indiretamente no número de crimes. Os resultados obtidos confirmaram as hipóteses testadas pelos autores e mostraram que o programa teve impacto redutor em na maioria dos tipos de crimes testados. A partir disso, foram estimados o benefício e o custo social do programa em termos monetários. O custo estimado da adoção do programa para a amostra considerada foi de 4.4 bilhões de dólares, enquanto o benefício da redução da criminalidade foi da ordem de 2.9 bilhões.

Chalfin e MacCrary (2018) buscaram averiguar se o nível de policiamento tem impacto sobre a criminalidade nos EUA. Os autores argumentaram que embora haja uma previsão teórica de uma relação negativa entre nível de policiamento e criminalidade, os trabalhos empíricos têm encontrado resultado oposto ou não têm encontrado relação significativa entre estas variáveis.

Os autores argumentaram que existia um erro da medida do quantitativo de policiais referente ao ano de 2003. Segundo o órgão responsável pela divulgação dos dados, existiam

aproximadamente 28 mil policiais na cidade de Nova York em 2003, porém como esse valor era 25% discrepante aos anos de 2002 e 2004. Após analisarem outras fontes de informação, os autores descobriram se tratar de um erro do órgão responsável pelo fornecimento da informação.

Para testar o efeito da polícia sobre as taxas de criminalidade, foram utilizados dados de 242 cidades com mais de 50 mil habitantes de pelo menos 44 estados americanos no período de 1960 a 2010. Os dados sobre o quantitativo de policias foram oriundos de diferentes fontes para diminuir os riscos de erro de medida. Além disso, coletaram-se dados socioeconômicos e demográficos que podem estar correlacionados com a criminalidade.

Os autores adotaram algumas estratégias econométricas para estimar a elasticidade-polícia do crime em diversos tipos de crimes tais como homicídios, furtos de veículos e roubos. Os resultados foram obtidos a partir de uma regressão de Mínimos Quadrados Ordinários (MQO) e em seguida passaram a utilizar a abordagem de Variáveis Instrumentais (IV) e Método dos Momentos Generalizados (GMM).

Os resultados obtidos sob MQO mostraram elasticidades-polícia de -0.20 para homicídios, -0.20 para roubos e -0.13 para furtos de veículos. Já as elasticidades obtidas por IV foram maiores em magnitude quando comparadas com aquelas obtidas por MQO, são elas: -0.80 para homicídios, -0.59 para roubo e -0.46 para furtos de veículos. Os resultados obtidos sob GMM foram muito parecidos em magnitude com aqueles produzidos por IV. Os autores ainda estimaram retorno social do investimento na contratação de policiais e concluíram que para cada dólar gasto com policiamento, o retorno social é da ordem de 1.63 dólares.

Machin e Marie (2011) utilizaram um experimento quase natural para mensurar o impacto do policiamento nas taxas de criminalidade na Inglaterra e no País de Gales. O citado experimento foi fruto da implementação de uma política pública que consistiu em aumentar o nível de policiamento em determinadas áreas (consideradas como grupo de tratados), em detrimento de outras áreas (consideradas como grupo de controle). Assim, a partir da utilização do método de diferenças em diferenças, os autores mensuraram o efeito da política sobre as áreas tratadas e verificaram que estas áreas tiveram uma redução das taxas de roubos após a adoção da política.

Os autores destacaram que as áreas escolhidas para intervenção do programa foram as áreas que apresentaram grande incidência de roubos no período pré tratamento, indicando um viés de seleção na escolha das áreas, porém a tendência dos crimes pré tratamento das áreas

tratadas e de controle são parecidas, indicando uma composição estável dos grupos e permitindo a comparação entre eles.

Os resultados obtidos mostraram que a política causou uma redução da ordem de 15% no número de roubos ocorridos nas áreas tratadas. Os autores ainda calcularam o benefício social da redução da criminalidade pós política e concluíram que o valor do benefício da redução dos roubos foi entre 58 a 127 milhões de libras, enquanto o custo do programa foi em torno de 24 milhões de libras.

Bindler e Hjalmarsson (2021) tiveram como objeto de estudo identificar o impacto da criação da primeira polícia profissional da Inglaterra sobre as taxas de criminalidade. Esta polícia foi criada em 1829 e chamada de London Metropolitan Police (The MET). Segundo eles, a The MET se destacava das outras forças de segurança da época pelo fato de ter um maior número de oficiais empregados em tempo integral e remunerados. A partir da criação da The MET, os autores utilizaram a abordagem de um quase experimento para medir o efeito causal da criação da primeira polícia profissional sobre o crime. Os resultados obtidos mostraram uma queda de 0.3% para aumentos de 1% no efetivo policial.

Blattman et al. (2021) analisaram o efeito de uma política de combate à violência urbana na cidade de Bogotá, Colômbia. O governo desta cidade escolheu, no ano de 2016, aproximadamente 2000 lugares com níveis de violência diferentes, aumentou a quantidade de patrulhas policiais e promoveu outras melhorias como, por exemplo, melhoria na iluminação e limpeza das ruas.

Utilizando dados georreferenciados dos crimes ocorridos e das patrulhas policiais, os autores puderam mensurar o efeito causal da política pública de melhoria da segurança sobre as taxas de criminalidade. Os resultados obtidos mostraram um resultado direto de pequena magnitude, porém os autores encontraram efeitos *spillovers* da política dentro de um raio de 250 metros, principalmente nos crimes contra a propriedade.

MacDonalds, Fagan e Geller (2016) investigaram o efeito causal de um aumento no policiamento na cidade de Nova York, através da implementação da política denominada Operação de Impacto sobre o nível de criminalidade no período de 2004 a 2012. Esta política consistiu em aumentar o nível da atividade policial em determinadas áreas chamadas zona de impacto. Assim, utilizando um modelo de diferenças em diferenças, os autores conseguiram obter resultados que mostraram que o número de crimes reduziu nas áreas onde houve a implementação da política e, além disso, foi verificado um aumento no número de prisões nas zonas de impacto.

Lin (2009) investigou a relação entre nível de policiamento e criminalidade nos estados americanos no período de 1970 a 2000. Como *proxy* para criminalidade, o autor utilizou crimes violentos e crimes contra a propriedade. O autor ainda destaca que devido a problemas de endogeneidade, a relação entre crime e polícia pode ser enviesada e inconsistente.

Eles utilizaram a abordagem de variáveis instrumentais reduzir o viés de simultaneidade existente entre o número de policias e a quantidade de crimes ocorridos. Como instrumento, o autor utilizou a taxa estadual de impostos sobre vendas para o nível de policiamento local sob o argumento de que esse seria o canal pelo qual são repassados recursos entre governos estadual e local e que permite a contratação de mais policiais. Os resultados obtidos com uso de variável instrumental mostraram uma relação negativa entre criminalidade e nível de policiamento com elasticidade da ordem de -0.9 para os crimes contra a propriedade e -1.1 para os crimes violentos. Essas elasticidades são de maior magnitude que aquelas obtidas sob a estimação por mínimos quadrados ordinários.

Diversos fatores que afetam os agentes econômicos podem ter influência sobre o nível de violência a qual as pessoas estão expostas. Chioda, Melo e Soares (2015) investigaram o impacto do programa de transferência de renda *Bolsa Família* sobre as taxas de criminalidade do estado de São Paulo. Para isso, eles verificaram como a quantidade de alunos matriculados em escolas que recebem *Bolsa Família* influencia a criminalidade ocorrida no entorno destas escolas. Porém os autores destacaram que o recebimento da renda do *Bolsa Família* está condicionado a uma série de características socioeconômicas das localidades que são correlacionadas com os crimes ocorridos o que impedem a identificação do efeito causal do programa de transferência de renda sobre a violência.

Para resolver o problema da endogeneidade da política, os autores exploram a expansão desta política em 2008 que antes atendia a crianças de até 15 anos e passou a atender jovens de 16 e 17 anos. Esta expansão permitiu que fosse criado um instrumento que capturasse a variação exógena da política a partir da expansão da política e da composição demográfica inicial das escolas para que fosse possível atribuir um efeito causal do *Bolsa Família* sobre o crime.

As *proxies* utilizadas para a criminalidade foram os roubos, furtos, homicídios, vandalismos e crimes relacionados ao tráfico de drogas no período de 2006 a 2009. Também utilizaram dados das escolas municipais e estaduais do censo escolar, onde constam características dos alunos, dos professores e da infraestrutura da escola. Para criar a variável dependente do trabalho, os autores atribuíram os crimes ocorridos no bairro mais próximo às escolas como sendo os crimes ocorridos no distrito escolar. Os resultados obtidos mostraram

que a expansão do *Bolsa Família* (para atender jovens de 16 e 17 anos) reduziu os crimes no entorno das escolas em 6.5%.

Os autores não encontraram diferenças do impacto do *Bolsa Família* nos crimes ocorridos em dias com aulas e dias sem aulas. Os resultados foram mais significantes nos crimes de roubo, porém crimes relacionados ao tráfico de drogas e homicídios também sofreram impactos desta política. Os autores afirmam ainda que o *Bolsa Família* teve efeito *spillover* para outras áreas que não estavam contempladas quando foram definidos os alvos da política de transferência de renda.

Soares (2004) buscou identificar as causas da heterogeneidade das taxas de criminalidade entre diversos países. Para este autor, as diferenças nas taxas de criminalidade entre os países ocorrem, em parte, por causa da subnotificação dos crimes ocorridos. A diferença entre os crimes ocorridos e os crimes reportados às autoridades pode estar relacionada a questões culturais, religiosas, nível de desenvolvimento econômicos entre outros fatores que influenciam o comportamento dos agentes econômicos na hora de reportar um crime às autoridades.

Os resultados obtidos mostraram que as taxas de crimes reportados são altamente correlacionadas com o nível de desenvolvimento dos países, medido através da renda *per capita*, indicando que quanto mais rico um país, maior a quantidade de crimes reportados. Assim, este autor relata que a correlação existente entre criminalidade e desenvolvimento econômico é falsa, pois o desenvolvimento está fortemente correlacionado com a fração de crimes que são reportados em relação à quantidade de crimes ocorridos.

Diante da constatação acima, o autor passou a utilizar os dados de criminalidade oriundos de uma pesquisa de vitimização que apresenta menor quantidade de subnotificação quando comparada aos dados oficiais de criminalidade. Os resultados obtidos mostraram que o desenvolvimento econômico não tem relação estatisticamente significativa com a taxa de criminalidade. Já a desigualdade tem correlação positiva com os crimes de furto e de agressão, enquanto o nível de educação tem relação negativa com estes crimes.

Bourguignon, Nuñez e Sanches (2003) realizaram um estudo que investigou a relação entre desigualdade de renda e criminalidade nas cidades da Colômbia. Os autores argumentaram que o efeito da desigualdade sobre a criminalidade não é bem esclarecido na literatura empírica, pois há trabalhos que encontraram relação positiva entre estas variáveis, enquanto outros trabalhos não encontram evidências estatísticas desta relação.

Os autores destacam que as diferentes medidas de desigualdade podem apresentar diferentes relações com as taxas de criminalidade. Desta forma, foi usado um modelo estrutural para identificar qual parte da distribuição de renda teria impacto sobre as taxas de crimes ocorridos ao longo do tempo nas 7 maiores cidades da Colômbia, uma vez que este país apresenta elevadas taxas de criminalidade para os padrões internacionais. Os resultados encontrados mostraram que a parte relevante da distribuição de renda onde políticas de redistribuição seriam capazes de afetar as taxas de crimes da sociedade seria na parte da distribuição onde as pessoas ganham até 80% da renda média.

Dix-Carneiro, Soares e Ulysseia (2018) investigaram o impacto da abertura econômica ocorrida nos anos 90 no Brasil sobre as taxas de criminalidade. A política consistiu em uma redução unilateral de tarifas entre os anos de 1990 e 1995 que o Brasil adotou e que teve efeitos variados em diferentes partes do país.

Os autores utilizaram os homicídios ocorridos nas microrregiões do Brasil como *proxy* para a criminalidade no período de 1980 a 2010 e construíram uma variável que captura a mudança de tarifas a partir da política de abertura comercial. Os resultados obtidos mostraram que regiões que tiveram maiores reduções de tarifas experimentaram um aumento na taxa de homicídios.

Eles ainda argumentaram que um dos canais de efeito da política sobre a criminalidade foi a piora no mercado de trabalho após a implementação da política tarifária e, por isso, houve um aumento na taxa de homicídios ao longo do tempo.

DeAngelo, Gittings e Ross (2018) investigaram o efeito de uma política que tornava o porte de maconha como conduta de baixa prioridade de repressão por parte da polícia sobre o número de prisões por porte da droga. Os autores argumentaram que embora legisladores estejam cada vez mais propensos a flexibilizar o porte da maconha em pequena quantidade, sob o pretexto de utilizar os recursos empregados nesse tipo de delito em crimes mais graves, os policiais continuam a reprimir a posse da maconha por parte das pessoas.

Os autores utilizaram a implementação de uma política de flexibilização da posse de maconha em pequena quantidade em alguns distritos de Los Angeles. Porém como a política não tem a formalidade de uma lei no sentido de obrigar os policiais a cumprirem o que determina a citada política pública, os autores acreditam que o comportamento dos policiais não teria mudado com a iniciativa de considerar a posse de maconha em pequena quantidade como baixa prioridade de repressão. Os resultados mostraram que a política teve um efeito

reduzidor no número de prisões em decorrência da posse de pequena quantidade de maconha considerado contravenção, mas não teve efeito nos crimes relacionados ao tráfico de drogas.

Os autores destacam que embora tenha havido uma diminuição das prisões por posse de maconha nas áreas tratadas, houve um aumento das prisões por posse de maconha nas áreas não tratadas, indicando que não houve uma mudança de comportamento por parte dos policiais na repressão à posse de maconha, mas sim uma mudança na área de atuação dado a imposição da política nas áreas tratadas.

Desta forma, pode-se constatar um efeito *spillover* da política de tornar a posse de maconha um fato de baixa prioridade para atuação policial. Os mecanismos por trás deste resultado podem ser variados. Pode-se ter havido um descontentamento da força policial com a política de baixa prioridade em determinada área e estes passaram a atuar de forma mais incisiva em áreas que não foram afetadas pela política. Outra possível explicação decorre do fato de a polícia já estar tratando a posse de baixa quantidade de maconha como baixa prioridade e a política despertou a polícia no sentido de agir contra este delito nas áreas que não foram afetadas pela política.

4.2.1 Background Institucional

O governo federal lançou em 28 de agosto de 2019 o Programa *Em Frente, Brasil* (EFB) de enfrentamento à criminalidade violenta no país. Este programa deveria ocorrer a partir de um esforço conjunto dos governos Federal, Estadual e Municipal. O EFB consistiu no envio de tropas da Força Nacional de Segurança Pública (FNSP) para determinadas cidades do Brasil, aumentando o quantitativo policial nas ruas das cidades escolhidas.

A Força Nacional de Segurança Pública é composta por membros das polícias militar, civil, bombeiros militares e peritos dos estados brasileiros e do Distrito Federal. Esta polícia foi criada em 2004 com o objetivo de atuar no policiamento ostensivo em situações de emergência ou calamidade pública visando garantir a preservação da ordem pública. Esta força permite ações de segurança pública do governo Federal na esfera estadual.

O EFB foi implementado em cinco cidades, cada uma representando uma região do Brasil. As cidades contempladas foram: **Ananindeua**, no estado do Pará, na região Norte; **Paulista**, no estado de Pernambuco, na região Nordeste; **Cariacica**, no estado do Espírito Santo, na Região Sudeste; **São José dos Pinhais**, no estado do Paraná, na região Sul; **Goiânia**, no estado de Goiás, na região Centro-Oeste. A escolha dos municípios que receberam o

programa se deu por razões não muito claras. Todos os municípios escolhidos pertencem as regiões metropolitanas dos estados onde estão localizados, porém eles não são os municípios mais violentos nem são a capital do estado, com exceção da cidade de Goiânia. Segundo o governo Federal, a escolha foi feita a partir do comprometimento dos gestores estaduais e locais com o programa, a média dos homicídios dos últimos 3 anos anteriores ao lançamento do programa, além de considerar a situação fiscal dos estados.

De acordo com o governo Federal, o programa foi desenvolvido em eixos, onde cada um representa uma fase do EFB. No primeiro eixo, foi definido a delimitação geográfica do programa, onde decidiu-se abranger as 5 regiões do Brasil e daí, definir os locais onde seria mais factível de haver uma gestão integrada de segurança pública com adesão dos gestores locais. O segundo eixo, tratou da repressão qualificada lançando mão do uso da FNSP para atuar no policiamento ostensivo, combatendo a criminalidade violenta. O terceiro eixo visa a uma atuação multidisciplinar relativa ao fornecimento de serviços nas áreas de educação, saúde, lazer, entre outros. O quarto e último eixo diz respeito ao monitoramento de indicadores e metas formuladas para atender aos objetivos definidos para o programa⁶.

Um mês após o lançamento do programa EFB, o governo Federal avaliou a eficácia do programa e o considerou bem sucedido, pois houve uma redução da criminalidade em todas as cidades que receberam apoio da Força Nacional de Segurança para fazer o policiamento ostensivo. Após a avaliação do governo, o resultado obtido foi de que o programa EFB reduziu os homicídios em 53%, considerando a média de redução dos municípios que foram contemplados pelo programa⁷. Na Figura 4.1, segue o percentual de redução dos homicídios de acordo com o a avaliação do governo Federal.

Figura 4.1. Percentual de redução dos Homicídios pela ótica do Governo Federal

HOMICÍDIO DOLOSO			
MUNICÍPIO	SET 2018	SET 2019	VARIAÇÃO
ANANINDEUA	18	7	-61,1%
CARIACICA	19	11	-42,1%
GOIÂNIA	35	14	-60,0%
PAULISTA	6	4	-33,3%
SÃO JOSÉ DOS PINHAIS	5	3	-40,0%
TOTAL	83	39	-53,0%

Fonte: Ministério da Justiça e Segurança Pública.

⁶ <https://www.justica.gov.br/news/collective-nitf-content-1567102301.36>

⁷ <https://www.justica.gov.br/news/collective-nitf-content-1570024970.38>

O programa EFB durou até o mês de abril de 2021. As demais fases do programa, contudo, não foram colocadas em prática e não há ainda uma definição quanto à continuidade do programa.

4.3 METODOLOGIA

4.3.1 Dados

Na Tabela 4.1, são apresentadas as estatísticas descritivas das variáveis socioeconômicas e da taxa de homicídios dos municípios das regiões metropolitanas do estado de Goiás, Pará, Pernambuco, Espírito Santo e Paraná. Os dados referentes aos homicídios ocorridos foram obtidos a partir dos dados divulgados pelo Ministério da Justiça e Segurança Pública (MJSP) para o período de janeiro de 2017 a maio de 2021. As variáveis socioeconômicas foram coletadas do censo demográfico de 2010 realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Estas variáveis farão parte da estimação dos modelos econométricos propostos na estratégia empírica.

4.3.2 Estatística Descritiva

Tabela 4.1 - Estatísticas descritivas

Variáveis	Descrição	Média	D. Padrão	Mín.	Máx.
Txhom	Taxa de homicídio por 100 mil habitantes	3.493	4.924	0	69.84
Espvida	Expectativa de vida em anos	74.27	1.484	70.85	77.17
Fectot	Taxa de fecundidade	2.045	0.330	1.350	2.850
Testud	Anos de estudo	9.493	0.685	7.400	11.05
Gini	Índice de Gini	0.482	0.0572	0.380	0.680
Rendapc	Renda <i>per capita</i>	608.7	264.6	241.1	1,867
Pformal	Percentual de emprego formal	56.94	11.43	32.25	76.32
Penerg	Percentual de domicílios com acesso à energia elétrica	99.58	0.761	96.06	100
Aesgo	Percentual de domicílios com acesso à água tratada e esgoto	4.732	6.800	0	41.54
Pmasc	Proporção de homens de 20 a 29 anos na população	0.0909	0.0107	0.0668	0.148
Pop	População	168280.8	337626	3232	1751907

Fonte: Elaborado pelo Autor.

Para estimar o impacto do programa EFB sobre a taxa de criminalidade, usou-se a abordagem de Diferenças em Diferenças (DiD), uma vez que o programa permite que sejam formados grupos de controle e tratamento. Para isso, foram selecionadas as cinco regiões metropolitanas onde o programa fora implementado, considerando como grupo de tratamento os municípios que receberam efetivamente a Força Nacional de Segurança e como grupo de controle os demais municípios que pertencem a região metropolitana, mas não foram contemplados pelo EFB.

Destaca-se aqui que para se atribuir o efeito causal da política, o grupo de controle e o grupo de tratamento têm de ser parecidos em relação à tendência de criminalidade ao longo do tempo. Como os municípios tanto do grupo de tratamento quanto do grupo de controle pertencem as regiões metropolitanas dos seus respectivos estados, pode-se afirmar que existe certa homogeneidade entre os grupos, uma vez que estes municípios têm de ter diversas características em comum para poderem fazer parte de uma região metropolitana⁸. Sendo assim, o grupo de controle parece ser um bom contrafactual para o grupo de tratamento.

4.3.3 Efeito Direto do Programa EFB

O modelo básico para avaliação do impacto direto do programa EFB sobre os municípios que receberam a política é dado na seguinte equação:

$$y_{ikt} = \alpha + \beta EFB_{ikt} + \gamma X_{ikt} + \mu_i + \theta_{kt} + \varepsilon_{it} \quad (1)$$

onde y_{ikt} é a taxa de homicídios por 100 mil habitantes no município i no mês k e ano t . EFB_{ikt} é uma variável *dummy* que assume o valor 1 (um) se o município i recebeu o tratamento do programa EFB no mês k e ano t e 0 (zero), caso contrário. X_{ikt} é o vetor de variáveis de controle variante no tempo, enquanto μ_i e θ_{kt} são os efeitos fixos de cidade e de tempo, respectivamente. ε_{ikt} é o termo de erro idiossincrático do modelo de regressão (ANGRIST; PISCHKE, 2008; BERTRAND; DUFLO; MULLAINATHAN, 2004; WOOLDRIDGE, 2010).

Os efeitos fixos de cidade permitem controlar a heterogeneidade observada e não observadas das cidades. Já os efeitos fixos de mês permitem controlar choques ocorridos no tempo que podem afetar a taxa de criminalidade de todos os municípios. O parâmetro β é o

⁸ http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2015/lei/113089.htm

estimador de DiD que representa o efeito causal do choque na taxa de homicídios devido à implementação do programa *Em Frente, Brasil* (EFB) de combate à criminalidade violenta.

Diversos problemas podem surgir durante a implementação de um programa. As unidades de observação podem mudar de comportamento com vistas a fazer parte do grupo afetado ou não afetado (controle) através de um processo de auto seleção. Para garantir que o programa afetou as unidades tratadas apenas na ocasião de sua implementação, utilizou-se um modelo de com efeitos antecipatórios heterogêneos (ou teste placebo) para verificar se a política teve algum impacto sobre a variável de resposta antes mesmo de ser efetivamente implementada. Também pode se testar um efeito defasado do tratamento quando o impacto aparece nos períodos posteriores à implementação do programa. Esses testes são conhecidos na literatura com *leads* e *lags* (LIMA; BARBOSA, 2018; CARAZZA; SILVEIRA NETO; EMANUEL, 2020; BIDERMAN; MELO; SCHNEIDER, 2010). Assim para testar os efeitos dos *leads* e *lags*, utilizou-se o modelo da equação (2).

$$y_{ikt} = \alpha + \sum_{n=1}^N \delta_{(k-n)t} EFB_{i(k-n)t} + \beta EFB_{ikt} + \sum_{n=1}^N \delta_{(k+n)t} EFB_{i(k+n)t} + \gamma X_{ikt} + \mu_i + \theta_{kt} + \varepsilon_{it} \quad (2)$$

onde o termo $EFB_{i(k-n)t}$ representa o efeito antecipatório do programa e seu impacto sobre a variável de resposta é capturado por $\delta_{(k-n)t}$. Já o efeito defasado do programa (ou persistente) é representado por $EFB_{i(k+n)t}$ e seu impacto sobre a variável de resposta é capturado por $\delta_{(k+n)t}$.

4.4 RESULTADOS

Os resultados da estimação do modelo de DiD encontram-se na Tabela 4.2. Nela, ver-se que o impacto do EFB sobre a taxa de homicídios é negativo e estatisticamente significativo ao nível de 5%. Na coluna (1) o modelo de DiD foi estimado sem a adição das variáveis de controle variantes no tempo. Nas colunas (2) e (3) foram adicionadas as covariáveis, porém na coluna (3) controlou-se o efeito fixo mês por ano. Em todas as especificações do modelo DiD, a magnitude do efeito causal do EFB sobre os homicídios foi da ordem de 0,107, indicando que a presença da Força Nacional de segurança Pública nas cidades tratadas reduziu a taxa de homicídios em 10,7%.

Tabela 4.2. Resultados das estimações do modelo de Diferenças em Diferenças.

Variáveis Independentes	Variável Dependente: <i>lntxhomi</i>		
	DID1 (1)	DID2 (2)	DID3 (3)
EFB	-0.1073* (0.047)	-0.1073* (0.047)	-0.1074* (0.048)
Controles Socioecon	Não	Sim	Sim
E.F. Mês	Sim	Sim	Não
E.F. Ano	Sim	Sim	Não
E.F. Cidade	Sim	Sim	Sim
E.F. Mês*Ano	Não	Não	Sim
R2	0.3277	0.3277	0.3359
Observações	4134	4134	4134

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice C.

Fonte: Elaborado pelo Autor.

Tabela 4.3. Resultados das estimações do modelo de Diferenças em Diferenças com *leads e lags*.

Variáveis Independentes	Variável Dependente: <i>lntxhomi</i>		
	DID1 (1)	DID2 (2)	DID3 (3)
EFB	-0.1029* (0.052)	-0.1029* (0.052)	-0.1031* (0.052)
EFB_1	0.0074 (0.060)	0.0074 (0.060)	0.0079 (0.060)
EFB_2	0.0776 (0.064)	0.0776 (0.064)	0.0774 (0.064)
EFB1	-0.2675 (0.140)	-0.2675 (0.140)	-0.2678 (0.141)
Controles Socioecon	Não	Sim	Sim
E.F. Mês	Sim	Sim	Não
E.F. Ano	Sim	Sim	Não
E.F. Cidade	Sim	Sim	Sim
E.F. Mês*Ano	Não	Não	Sim
R2	0.3277	0.3277	0.3359
Observações	4134	4134	4134

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice C.

Fonte: Elaborado pelo Autor.

Na Tabela 4.3, verificou-se se houve efeitos antecipatórios do EFB por parte dos agentes (conhecidos por *leads*), indicando, assim, que o programa teve efeito sobre os homicídios nas cidades tratadas ainda antes da sua implementação. Esses efeitos estão representados pelas variáveis EFB_1 e EFB_2 que considerou implementação da política 12 meses e 24 meses antes, respectivamente. Também foi testado se o programa continuou a impactar os homicídios

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice C.

Fonte: Elaborado pelo Autor.

Os resultados obtidos no teste de falsificação mostram que não houve impacto do programa EFB em nenhuma das variáveis dependentes propostas, indicando que o impacto do EFB é verificado em situações de onde o resultado depende do cometimento de um crime.

O programa EFB foi concebido para combater a criminalidade violenta nos municípios brasileiros. O programa escolheu inicialmente 5 cidades pertencentes a 5 regiões metropolitanas distintas. A implementação do programa consistiu em enviar a Força Nacional de Segurança Pública para aumentar o quantitativo de policiamento ostensivo nas ruas das cidades escolhidas para receber o programa. Esse aumento do policiamento ostensivo teve impactos negativos sobre os homicídios ocorridos nas cidades pertencentes ao grupo de tratamento, como foi constatado nos resultados obtidos nesta pesquisa. Isso indica que o aumento do quantitativo policial teve um efeito dissuasivo na prática de homicídios.

Embora não haja a disponibilidade de dados para se testar diretamente o impacto do EFB sobre o consumo de drogas ilícitas, a literatura mostrou evidências de que a atuação policial tem efeito dissuasivo na atividade relacionada ao mercado de drogas ilícitas (DEANGELO, GITTINGS; ROSS, 2018; JORGENSEN, 2018).

Tabela 4.5. Resultados das estimações do modelo de Diferenças em Diferenças para o teste de validação.

Variáveis Independentes	Variável Dependente: <i>lntxover</i>		
	OVER1 (1)	OVER 2 (2)	OVER 3 (3)
EFB	-0.0024* (0.001)	-0.0024* (0.001)	-0.0024* (0.001)
Controles Socioecon	Não	Sim	Sim
E.F. Mês	Sim	Sim	Não
E.F. Ano	Sim	Sim	Não
E.F. Cidade	Sim	Sim	Sim
E.F. Mês*Ano	Não	Não	Sim
R2	0.0227	0.0227	0.0318
Observações	4134	4134	4134

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice C.

Fonte: Elaborado pelo Autor.

Esta pesquisa buscou evidenciar o impacto do EFB sobre o mercado de drogas substâncias ilícitas de forma indireta a partir de um teste de validação, onde foi testado o impacto do EFB sobre as mortes por overdose decorrentes do consumo de drogas. A hipótese assumida aqui é que o EFB tem um impacto negativo sobre o tráfico de drogas, reduzindo a

compra e a venda de substâncias ilícitas nas cidades de que receberam o programa. Os resultados deste teste estão na Tabela 4.5. Aqui, pode-se constatar que o EFB tem um impacto negativo da ordem de 0.24% sobre as taxas de morte por overdose nos municípios que receberam as tropas da Força Nacional de Segurança. Este resultado é estatisticamente significativo ao nível de 5% em todas as especificações propostas.

Com o objetivo de garantir maior confiabilidade aos resultados já obtidos, foram realizados mais dois exercícios de robustez. No primeiro deles, estimou-se o modelo básico de DiD a partir de um pareamento utilizando escores de propensão com o objetivo de formar grupos de controle o mais parecido possível com o grupo de tratamento em relação as suas características observáveis (CARAZZA; SILVEIRA NETO; EMANUEL, 2020). No segundo exercício, exclui-se da amostra as capitais dos estados que faziam parte do grupo de controle sob a hipótese de que o tratamento pode estar correlacionado com a proximidade entre cidade tratada e a capital. Os resultados de ambos os testes estão na Tabela 4.6. Nas colunas (1) a (3) tem-se os resultados do modelo DiD a partir do *Propensity Score Matching*, e nas colunas (4) a (6), têm-se os resultados sem as capitais na amostra. Em todas as especificações, o impacto do EFB sobre a taxa de homicídios se mostrou negativo e significativo ao nível de 5%, ficando sua magnitude próxima de 11%.

Tabela 4.6. Resultados das estimações do modelo de Diferenças em Diferenças com PSM e sem Capitais.

Variáveis Independentes	Variável Dependente: <i>lntxhom</i>					
	Propensity Score Matching			Capitais Excluídas		
	(1) PSM1	(2) PSM2	(3) PSM3	(4) CAP1	(5) CAP2	(6) CAP3
EFB	-0.1066* (0.054)	-0.1071* (0.053)	-0.1072* (0.053)	-0.1097* (0.048)	-0.1097* (0.048)	-0.1098* (0.049)
Controles Socioecon	Não	Sim	Sim	Não	Sim	Sim
E.F. Mês	Sim	Sim	Não	Sim	Sim	Não
E.F. Ano	Sim	Sim	Não	Sim	Sim	Não
E.F. Cidade	Sim	Sim	Sim	Sim	Sim	Sim
Mês*Ano	Não	Não	Sim	Não	Não	Sim
R2	0.0370	0.2485	0.2568	0.3238	0.3238	0.3325
Observações	4134	4134	4134	3922	3922	3922

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice C.

Fonte: Elaborado pelo Autor.

Há uma crescente discussão na literatura sobre como fatores espaciais podem influenciar o resultado potencial de um *outcome* e como a não inclusão de variáveis que capturem a

interação espacial nos modelos estatísticos podem levar as estimativas obtidas a se tornarem enviesadas (CHAGAS; AZZONI; ALMEIDA, 2016; MELLO, 2019; LIMA; BARBOSA, 2018).

Delgado e Florax (2015) mostraram que uma política pode gerar efeitos diretos sobre os resultados potenciais do grupo de tratamento e resultados indiretos sobre os resultados potenciais do grupo de controle. Para estimar esses efeitos, usou-se o modelo *Spatial Lagged of X* (SLX) em consonância com Halleck Vega e Elhorst (2015) e que é dado pela seguinte equação:

$$y_{ikt} = \alpha + \beta EFB_{ikt} + \rho W EFB_{ikt} + \gamma X_{ikt} + \lambda W X_{ikt} + \mu_i + \theta_{kt} + \varepsilon_{it} \quad (3)$$

onde W é a matriz de pesos espaciais que captura a interação espacial entre as cidades. $W EFB_{ikt}$ representa o efeito *spillover* do tratamento e $W X_{ikt}$ representa o efeito *spillover* das características observáveis variante no tempo. Os resultados dessa estimação se encontram na Tabela 4.7.

Na coluna (1), estão os resultados do modelo espacial com o uso da matriz de ponderação espacial binária, porém sem a adição das defasagens espaciais das variáveis independentes. Na coluna (2), foram incluídas as defasagens espaciais das covariáveis. Já nas colunas (3) e (4), foram utilizadas as matrizes de 2 vizinhos e 4 vizinhos mais próximos como forma de dar maior robustez aos resultados obtidos, uma vez que a escolha da matriz de pesos espacial se dá de forma *ad hoc* em diversas aplicações (GIBBONS; OVERMAN; PATACCHINI, 2015). Neste teste optou-se por estimar apenas o modelo SLX, que utiliza apenas o *lag* espacial das variáveis independentes como variáveis de controle, para se evitar os problemas de endogeneidade que decorrem da inclusão do *lag* espacial da variável dependente como nos modelos *Spatial Autorregressive Model* (SAR) e no *Spatial Durbin Model* (SDM) (LIMA; BARBOSA, 2018; GIBBONS; OVERMAN, 2012).

Em todos os modelos estimados, o impacto do programa EFB sobre a taxa de homicídios é negativo e significativo estatisticamente, indicando que cidades que receberam o EFB teve redução na taxa de homicídios da ordem de 14%. Em todos os modelos estimados também foi possível verificar o efeito *spillover* da política, indicando que além do efeito direto sobre os municípios do grupo tratado, a política teve efeitos indiretos sobre os municípios vizinhos do grupo de controle. A magnitude dos efeitos indiretos está compreendida no intervalo entre -1.88% e -3.55%, indicando que o EFB causou uma redução da taxa de homicídios nas cidades

vizinhas as cidades tratadas. Estes valores foram calculados a partir do produto entre o coeficiente do efeito *spillover* (λ) e o percentual de tratados na vizinhança em conformidade com Delgado e Florax (2015).

Chagas, Azzoni e Almeida (2016) destacam que o impacto indireto da política que está sendo avaliada é mensurado tanto para unidades tratadas quanto para as não tratadas, uma vez que a metodologia proposta por Delgado e Florax (2015) não leva em conta o efeito *spillover* do tratamento de forma segregada para tratados e para não tratados. Nesse caso, dever-se-ia estimar o modelo espacial considerando dois tipos de interação do tratamento no espaço: considerar o efeito *spillover* do tratamento sobre os tratados (através de uma Matriz espacial do tipo $W_{T,T}$) e considerar o efeito *spillover* do tratamento sobre os não tratados (através de uma Matriz espacial do tipo $W_{T,NT}$), pois o efeito local do tratamento pode atingir unidades tratadas e/ou não tratadas localizadas na vizinhança de uma unidade tratada. É oportuno destacar que os resultados estimados a partir da equação (3) são válidos para mensurar o efeito indireto do tratamento, uma vez que na amostra utilizada nesta pesquisa, só existe uma unidade tratada por região metropolitana. Sendo assim, só há efeito *spillover* do tratamento sobre unidades não tratadas dado que não há outra cidade tratada na vizinhança de uma cidade que recebeu o tratamento.

Tabela 4.7. Resultados das estimações do modelo de Diferenças em Diferenças com variáveis espaciais.

Variáveis Independentes	Variável Dependente: <i>lntxhom</i>			
	(1) SLX1	(2) SLX2	(3) SLX3	(4) SLX4
EFB	-0.1459** (0.052)	-0.1459** (0.052)	-0.1276** (0.049)	-0.1403** (0.052)
wEFB	-0.3967* (0.164)	-0.3967* (0.164)	-0.3317** (0.109)	-0.4492* (0.179)
% Tratados	9.11%	9.11%	5.72%	6.88%
<i>Efeito Spillover</i>	-3.55%	-3.55%	-1.88%	-3.02%
Controles Socioecon	Sim	Sim	Sim	Sim
Controles Espaciais	Não	Sim	Sim	Sim
E.F. Mês	Sim	Sim	Não	Sim
E.F. Ano	Sim	Sim	Não	Sim
E.F. Cidade	Sim	Sim	Sim	Sim
Matriz Espacial	Binária	Binária	2 Vizinhos	4 Vizinhos
R2	0.3285	0.3285	0.3285	0.3284
Observações	4134	4134	4134	4134

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$; [#] Os resultados completos das estimações estão no apêndice C.

Fonte: Elaborado pelo Autor.

4.5 CONCLUSÃO

Este trabalho teve como objetivo avaliar o programa de política pública de combate à criminalidade violenta denominado *Em Frente, Brasil*. O EFB foi um programa desenvolvido e implementado pelo Governo Federal em cinco cidades brasileiras, uma em cada região do Brasil, e consistiu no envio da Força Nacional de Segurança Pública para reforçar o policiamento ostensivo e atuar no combate à criminalidade nas cidades escolhidas para receber o programa.

Todas as cidades escolhidas para receber as tropas da Força Nacional de Segurança ficam localizadas nas regiões metropolitanas dos estados a que pertencem. Desta forma, foi possível formar grupos de controle e tratamento com características parecidas para que fosse possível mensurar o efeito causal do EFB sobre a criminalidade das cidades contempladas pelo programa através da estimação de um modelo de diferenças em diferenças.

A *proxy* escolhida para a criminalidade foi a taxa de homicídios por 100 mil habitantes no período de janeiro de 2017 a abril de 2021. Assim após estimação do modelo básico de DiD, os resultados mostraram que o EFB teve um impacto negativo e estatisticamente significativo sobre as taxas de homicídios das cidades tratadas. No modelo básico a diminuição das taxas de homicídios causadas pelo EFB foi da ordem de 10.7%.

Para garantir a robustez dos resultados obtidos, foram propostos diversos testes de robustez comumente utilizados na literatura de avaliação de impacto. O primeiro deles foi um teste placebo, onde considerou-se a possibilidade de haver efeitos antecipatórios do programa por parte dos agentes. Desta forma, foram consideradas a implementação do EFB 12 e 24 meses anteriores ao verdadeiro período de implementação. Também considerou-se haver efeito defasados do EFB (ou persistente) no caso de o efeito do programa durar além de seu período de vigência. Em ambos os casos, os resultados obtidos nesses testes não foram estatisticamente significativos, indicando que não houve efeitos antecipatórios nem efeitos defasados do EFB.

Também foi feito um teste de falsificação, onde foram utilizadas outras taxas de morte que se espera não ter nenhuma relação com o programa EFB. Neste teste foram utilizadas as taxas de mortes por suicídio, afogamento, acidentes de trânsito e acidente exceto aqueles ocorridos no trânsito como variável dependente no modelo DiD. Neste teste não foi encontrado nenhuma relação entre o EFB e as taxas de mortes citadas.

Foi realizado ainda um teste de validação, onde buscou-se mensurar de forma indireta o impacto do EFB com o tráfico de drogas e entorpecentes. Para isso, foi utilizado como *outcome*

as taxas de mortes em decorrência de overdose. Os resultados indicaram que o EFB teve um impacto negativo nas taxas de morte por overdose da ordem de 0.24%.

Ainda foram realizados mais dois testes de robustez dos resultados encontrados. Um deles consistiu em fazer um pareamento, estimando um escore de propensão, a partir das características observáveis dos municípios para que fosse possível selecionar um grupo de controle que corresponda ao grupo de tratados na ausência de tratamento, sendo, desta forma, considerado um bom contrafactual. Em outro teste, foram excluídas as capitais do grupo de controle sob a hipótese de que sua proximidade com as cidades tratadas poderia ter influenciado a escolha do tratamento. Em ambos os testes, os resultados não diferiram aos encontrados na estimação do modelo DiD básico.

Por fim, em consonância com a literatura recente, considerou-se a hipótese de que poderia existir efeitos *spillovers* do programa, impactando de forma indireta as cidades não tratadas vizinhas àquelas que receberam as tropas da Força Nacional de Segurança. Assim, utilizou-se a abordagem da econometria espacial para se estimar o modelo DiD. Aqui, os resultados mostraram que houve efeito *spillover* do EFB sobre as unidades não tratadas, indicando um impacto negativo do EFB sobre as taxas de criminalidade dos municípios vizinhos àquele tratado. Desta forma, o efeito final da política pode ser decomposto em efeito direto e efeito indireto, onde o efeito direto é o efeito do tratamento sobre os tratados e que foi da ordem de 14% e o efeito indireto que, no caso desta pesquisa, é o efeito do tratamento sobre as unidades não tratadas da ordem de 3.5%. Sendo assim, pode-se considerar o efeito total do EFB sobre a taxa de homicídios da ordem de 17.3%.

Este trabalho buscou contribuir para a literatura de avaliação de impacto e economia urbana e do crime ao avaliar o impacto de uma variação exógena do policiamento nas cidades brasileiras a partir da implementação de EFB pelo Governo Federal que tinha o tema da segurança pública como uma de suas pautas de campanha quando das eleições presidenciais de 2018. Um ano após implementação do EFB o Governo Federal fez uma avaliação do impacto do EFB sobre as taxas de homicídios nas cidades que receberam o programa e concluiu que houve uma redução de 53% nas referidas taxas. Porém a magnitude do efeito total causal do EBF sobre as taxas de homicídios de aproximadamente 17% obtida nesta pesquisa é bem diferente dos 53% de redução da taxa de homicídios nas cidades que receberam o EFB e que o Governo Federal atribuiu ao programa. A estimativa de redução de 53% das taxas de homicídio não pode ser atribuída ao EFB de forma isolada, pois durante o período de vigência do programa diversos fatores podem ter influenciado as taxas de criminalidade e fazer uma simples diferença

da quantidade de crimes pré e pós programa (como mostrado no site oficial do Governo Federal) não é a maneira correta de se avaliar o impacto da política pública justamente porque diversos fatores que determinam a tendência da criminalidade não estão sendo isolados do efeito da política.

REFERÊNCIAS

- AFONSO, A.; SCHUKNECHT, L.; TANZI, V. Public sector efficiency: evidence for new EU member states and emerging markets. **Applied Economics**. 42:17, 2147-2164, 2010. <https://doi.org/10.1080/00036840701765460>.
- AJZENMAN, N.; CAVALCANTI, T.; DA MATA, D. **More Than Words: Leaders' Speech and Risky Behavior during a Pandemic** (April 22, 2020). Available at SSRN: <https://ssrn.com/abstract=3582908> or <http://dx.doi.org/10.2139/ssrn.3582908>
- ALLCOTT, H.; BOXELL, A.; CONWAY, J.; GENTZKOW, M.; THALER, M.; YANG, D. Polarization and public health: partisan differences in social distancing during the coronavirus pandemic. **Journal of Public Economics**, Volume 191, 104254, 2020. <https://doi.org/10.1016/j.jpubeco.2020.104254>.
- AMARAL FILHO, J. A Endogeneização no Desenvolvimento Econômico Regional e Local. **Planejamento e Políticas Públicas**, n. 23, 2001.
- AMEMIYA, T. The estimation of a simultaneous equation generalized probit model. **Econometrica** 46: 1193–1205, 1978. <https://doi.org/10.2307/1911443>.
- ANGRIST, J. D.; PISCHKE, J. **Mostly harmless econometrics: An empiricist's companion**. Princeton University press, 2008. <https://doi.org/10.2307/j.ctvc4j72>.
- ANSELIN, Luc. **Spatial Econometrics: methods and models**. Kluwer Academic Publishers, 1988.
- _____. Spatial Externalities, Spatial Multipliers, and Spatial Econometrics. **International Regional Science Review**, v.26, n. 2, p.153–166, 2003. <https://doi.org/10.1177/0160017602250972>.
- ARANEDA, F.; YÁÑEZ, A.; NÚÑEZ, D.; BOYERO, L.; TONIN, A.; CORNEJO, A.; URBINA, M.; DÍAZ, M.; MUÑOZ, G.; ESSE, C. Environmental determinants of COVID-19 transmission across a wide climatic gradient in Chile. **Scientific Reports**, 2021. <https://doi.org/10.1038/s41598-021-89213-4>.
- ARIMA, E. A Spatial Probit Econometric Model of Land Change: The Case of Infrastructure Development in Western Amazonia, Peru. **PLoS ONE**, 2016. <https://doi.org/10.1371/journal.pone.0152058>.
- AVIS, E.; FERRAZ, C.; FINAN, F. Do Government Audits Reduce Corruption? Estimating the Impacts of Exposing Corrupt Politicians. **Journal of Political Economy**, vol. 126, no. 5, 2018. <https://doi.org/10.1086/699209>.

BAKER, R.; YANG, W.; VECCHI, G.; METCALF, C.; GRENFELL, B. Susceptible supply limits the role of climate in the early SARS-CoV-2 pandemic. **Science**, Vol 369, Issue 6501, pp. 315-319, 2020. DOI: 10.1126/science.abc2535.

BALTAGI, B; EGGER, P; KESINA, M. Generalized spatial autocorrelation in a panel-probit model with an application to exporting in China. **Empir Econ**, 55, pages193–211, 2018. <https://doi.org/10.1007/s00181-017-1409-0>.

BARRETO, Y.; SILVEIRA NETO, R.; CARAZZA, L. Uber and traffic safety: Evidence from Brazilian cities. **Journal of Urban Economics**. Volume 123, 103347, 2020. <https://doi.org/10.1016/j.jue.2021.103347>

BARROT, J.; GRASSI, B.; SAUVAGNAT, J. Sectoral effects of social distancing. **AEA Papers and Proceedings**, 111: 277-81. 2021. DOI: 10.1257/pandp.20211108.

BECKER, G. Crime and Punishment: An Economic Approach. **Journal of Political Economy**, 76, 175–209, 1968.

BERG, E.; BHATTACHARYYA, S.; RAJASEKHAR, D.; MANJULA, R. Can public works increase equilibrium wages? Evidence from India’s National Rural Employment Guarantee. **World Development**. Volume 103, Pages 239-254, 2018.

BERTRAND, M., DUFLO, E., & MULLAINATHAN, S. How much should we trust difference-in-differences estimates? **Quarterly Journal of Economics**, 119, 249–275, 2004. <https://doi.org/10.1162/003355304772839588>.

BESFAMILLE, M. Local public works and intergovernmental transfers under asymmetric information. **Journal of Public Economics** 88 (2003) 353 – 375.

BIDERMAN, C., DE MELLO, J. M., & SCHNEIDER, A. Dry laws & homicides: Evidence from the São Paulo metropolitan area. **The Economic Journal**, 120(543), 157–182, 2010. <https://doi.org/10.1111/j.1468-0297.2009.02299.x>

BINDLER, B.; HJALMARSSON, R. The impact of the first professional police forces on crime. **Journal of the European Economic Association**, Volume 19, Issue 6, pages 3063–3103, 2021. <https://doi.org/10.1093/jeaa/jvab011>.

BLATTMAN, C.; GREEN, D.; ORTEGA, D.; TOBÓN, S. Place-Based Interventions at Scale: The Direct and Spillover Effects of Policing and City Services on Crime. **Journal of the European Economic Association**, Volume 19, Issue 4, pages 2022–2051, 2021. <https://doi.org/10.1093/jeaa/jvab002>.

BORDIGNON, M.; COLOMBO, L.; GALMARINI, U. Fiscal federalism and lobbying. **Journal of Public Economics** 92, 2288–2301, 2008. <https://doi.org/10.1016/j.jpubeco.2008.05.003>.

BORJAS, G. Demographic determinants of testing incidence and Covid-19 infections in New York City neighbourhoods. **Covid Economics**, 2020.

BOURGUIGNON, F.; NUÑEZ, J.; SANCHEZ, F. A structural model of crime and inequality in Colombia. **Journal of the European Economic Association**. 1(2–3):440–449, 2003.

BROLLO, F.; TROIANO, U. What happens when a woman wins an election? Evidence from close races in Brazil. **Journal of Development Economics**, Volume 122, Pages 28-45, 2016. <https://doi.org/10.1016/j.jdeveco.2016.04.003>.

BRUECKNER, J. Strategic Interaction Among Governments: An Overview of Empirical Studies. **International Regional Science Review**, 26: 175, 2003. <https://doi.org/10.1177/0160017602250974>.

CANDIDO, D.; CLARO, M.; JESUS, J.; SOUZA, W.; MOREIRA, F.; DELLICOUR, S.; MELLAN, T.; PLESSIS, L. PEREIRA, R.; SALES, F.; MANULI, M.; THÉZÉ, J. ALMEIDA, L.; MENEZES, M.; VOLOCH, C.; FUMAGALLI, M.; COLETTI, T. Evolution and epidemic spread of SARS-CoV-2 in Brazil. **Science** 369, 1255–1260, 2020. DOI: 10.1126/science.abd2161.

CARAZZA, L.; SILVEIRA NETO, R.; EMANUEL, L. Juvenile curfew and crime reduction: Evidence from Brazil. *Papers in Regional Science*, Volume 100, Issue 2, Pages 561-579, 2020. <https://doi.org/10.1111/pirs.12573>.

CASTRO, M.; GUCCIO, C.; PIGNATARO, G.; RIZZO, I. Is competition able to counteract the inefficiency of corruption? The case of Italian public works. **Econ Polit Ind**, 45(2), 2018. DOI: 10.1007/s40812-017-0086-5.

CASTRO, M.; KIM, S.; BARBERIA, L.; RIBEIRO, A.; GURZENDA, S.; KARINA BRAGA RIBEIRO, K.; ABBOTT, E.; BLOSSOM, J.; RACHE, B.; SINGER, B. Spatiotemporal pattern of COVID-19 spread in Brazil. **Science** 372, 821–826, 2021. DOI: 10.1126/science.abh1558.

CHAGAS, A.; AZZONI, C.; ALMEIDA, A. A spatial difference-in-differences analysis of the impact of sugarcane production on respiratory diseases. **Regional Science and Urban Economics**, 59, 24–36, 2016. <https://doi.org/10.1016/j.regsciurbeco.2016.04.002>.

CHALFIN, A., MCCRARY, J. Are U.S. cities underpoliced?: theory and evidence. **Rev. Econ. Stat.** 1–55, 2018. https://doi.org/10.1162/REST_a_00694.

CHAN, K. H.; MALIK PEIRIS, J. S.; LAM, S. Y.; POON, L. L. M.; YUEN, K. Y.; SETO, W. H. (2011). “The Effects of Temperature and Relative Humidity on the Viability of the SARS Coronavirus.” **Advances in Virology**, 2011. <https://doi.org/10.1155/2011/734690>.

CHEAITOU, A.; LARBI, R.; HOUSANI, B. Decision making framework for tender evaluation and contractor selection in public organizations with risk considerations. **Socio-Economic Planning Sciences**. Volume 68, 100620, 2019. <https://doi.org/10.1016/j.seps.2018.02.007>.

CHEN, S.; PRETTNER, K.; KUHN, M; GELDSETZER, M.; WANG, C.; BÄRNIGHAUSEN, T.; Bloom, D. Climate and the spread of COVID-19. **Scientific Reports**, 11, 9042, 2021.

CHIODA, L.; MELLO, J. M.; SOARES, R. R. Spillovers from conditional cash transfer programs: Bolsa Família and crime in urban Brazil. **Economics of Education Review**, 54, 306–320, 2016. <https://doi.org/10.1016/j.econedurev.2015.04.005>.

CROWLEY, F.; DORIAN, J. COVID-19, occupational social distancing and remote working potential: An occupation, sector and regional perspective. **Regional Science Policy and Practice**, Volume12, Issue6, Pages 1211-1234 2020. <https://doi.org/10.1111/rsp3.12347>.

D'ADAMO, H.; YOSHIKAWA; T. OUSLANDER, J. Coronavirus Disease 2019 in Geriatrics and Long-Term Care:The ABCDs of COVID-19. **Journal of the American Geriatrics Society**, Volume 68, Issue5, Pages 912-917, 2020. <https://doi.org/10.1111/jgs.16445>.

DALZIEL, B.; KISSLER, S.; GOG, J.; VIBOUD, J.; BJØRNSTAD, O.; METCALF, C.; GRENFELL, B. Urbanization and humidity shape the intensity of influenza epidemics in U.S. cities. **Science**, Vol 362, Issue 6410 • pp. 75-79, 2020. DOI: 10.1126/science.aat6030.

DeANGELO, G.; GITTINGS, R.; ROSS, A. Police Incentives, Policy Spillovers, and the Enforcement of Drug Crimes. **Revw Law Econ.**, Volume 14 Issue 1, 2018. <https://doi.org/10.1515/rle-2016-0033>.

DELGADO, M., & FLORAX, R. Difference-in-differences techniques for spatial data: local autocorrelation and spatial interaction. **Economics Letters**, 137, 123–126, 2015. <https://doi.org/10.1016/j.econlet.2015.10.035>.

DI TELLA, R., & SCHARGRODSKY, E. Do police reduce crime? Estimates using the allocation of police forces after a terrorist attack. *American Economic Review*, 94(1), 115–133, 2004. <https://doi.org/10.1257/000282804322970733>.

DIX-CARNEIRO, R.; SOARES, R.; ULYSSEA, G. Economic Shocks and Crime: Evidence from the Brazilian Trade Liberalization. **American Economic Journal: Applied Economics**, 10(4): 158–195, 2018. <https://doi.org/10.1257/app.20170080>.

ELHORST, J. P. **Spatial Panel Data Models**, Vol. C.2, Springer, chapter 2, pp. 377–407, 2010.

ELHORST, J. P. ‘Dynamic spatial panels: models, methods, and inferences’, **Journal of Geographical Systems** 14, 5–28, 2011.

ELHORST, J.; HEIJNEN, P.; SAMARINA, A.; JACOBS, J. Transitions at Different Moments in Time: A Spatial Probit Approach. **Journal of Applied Econometrics**, vol. 32, issue 2, 422-439, 2017.

EVANS, W.N.; OWENS, E.G. COPS and crime. **J. Public Econ.** 91 (1), 181–201, 2007.

FERRAZ, C.; FINAN, F. Electoral Accountability and Corruption: Evidence from the Audits of Local Governments. **American Economic Review**, 101: 1274–1311, 2011.

FERRAZ, C.; FINAN, F. Exposing Corrupt Politicians: The Effects of Brazil's Publicly Released Audits on Electoral Outcomes. **The Quarterly Journal of Economics**, Vol. 123, No. 2, pp. 703-745, 2008.

FIGLIO, D. N.; KOLPIN, V.; REID, W. Do states play welfare games? **Journal of Urban Economics** 46: 437-54. 1999.

FINOCCHIARO, M.; GUCCIO, C., PIGNATARO, G. Is competition able to counteract the inefficiency of corruption? The case of Italian public works. **Econ Polit Ind** 45, 55–84 (2018). <https://doi.org/10.1007/s40812-017-0086-5>.

FOUCAULT, M.; MADIES, T.; PATY, S. Public Spending Interactions and Local Politics. Empirical Evidence from French Municipalities. **Public Choice**, Vol. 137, No. 1/2, pp. 57-80, 2008.

GADARIAN, S.; GOODMAN, S.; PEPINSKY, T. Partisanship, Health Behavior, and Policy Attitudes in the Early Stages of the COVID-19 Pandemic. **PLoS ONE**, 2021.

GATTO, M.; BERTUZZOB, E.; MARIA, L.; MICCOLID, S.; CARRARO, L.; CASAGRANZIA, R.; RINALDO, A. Spread and dynamics of the COVID-19 epidemic in Italy: Effects of emergency containment measures. **PNAS**, 117 (19) 10484-10491, 2020. <https://doi.org/10.1073/pnas.2004978117>.

GEHRKE, L.; HARTWIG, R. Productive effects of public works programs: What do we know? What should we know? **Development Review**. Volume 107, July 2018, Pages 111-124.

GIBBONS, S.; OVERMAN, H. Mostly pointless spatial econometrics? **Journal of Regional Science**, 52(2), 172–191, 2012.

GIBBONS, S.; OVERMAN, H. G.; PATAACCHINI, E. **Spatial Methods. Handbook of Regional and Urban Economics**, Elsevier 5, 115–168, 2015.

GUCCIO, C; PIGNATARO, G.; RIZZO, I. Do local governments do it better? Analysis of time performance in the execution of public works. **European Journal of Political Economy**. Volume 34, June 2014, Pages 237-252.

GULIYEV, H. Determining the spatial effects of COVID-19 using the spatial panel data model. **Spatial statistics**, Volume 38, 100443, 2020.

HALLECK VEGA, S.; ELHORST, J. P. The SLX Model. **Journal of Regional Science**, 55(3), 339–363, 2015.

HOECHLE, D. Robust standard errors for panel regressions with cross-sectional dependence. **Stata Journal** 7: 281–312, 2007.

HOSMER, D. W. & LEMESHOW, S. **Applied logistic regression**. New York: John Wiley & Sons, Inc., 1989.

HOYOS, R.; SARAFIDIS, V. Testing for cross-sectional dependence in panel-data models. **The Stata Journal** 6, Number 4, pp. 482–496, 2006.

JAAKKOLA, K.; SAUKKORIPI, A.; JOKELAINEN, J.; JUVONEN, R.; KAUPPILA, J.; VAINIO, O.; ZIEGLER, T.; RÖNKKÖ, E.; JAAKKOLA, J.; IKÄHEIMO, T. Decline in temperature and humidity increases the occurrence of influenza in cold climate. **Environmental Health**, 28;13(1):22, 2014.

JORGENSEN, C. Badges and Bongs: Police Officers' Attitudes Toward Drugs **SAGE Open** October-December 2018: 1–17. <https://doi.org/10.1177/2158244018805357>.

KAPPELER, A.; SOLÉ-OLLÉ, A.; STEPHAN, A.; VÄLILÄ, T. Does fiscal decentralization foster regional investment in productive infrastructure? **European Journal of Political Economy** 31 15–25, 2013.

KELLY, M. Inequality and crime. **Review of Economics and Statistics**, 82 (4): 530-539, 2000.

KIRBY, D.K.; J.P. LESAGE. Changes in commuting to work times over the 1990 to 2000 period. **Regional Science & Urban Economics**, 39(4), 460–71, 2009.

LACOMBE, D; LeSAGE, J. Use and interpretation of spatial autoregressive Probit models. **Ann Reg Sci.**, 2015. DOI 10.1007/s00168-015-0705-x.

LAUER, S.; GRANTZ, K.; BI, Q; JONES, F.; ZHENG, Q.; MEREDITH, H.; AZMAN, A.; REICH, A.; LESSLER, L. The Incubation Period of Coronavirus Disease 2019 (COVID-19) From Publicly Reported Confirmed Cases: Estimation and Application. **Annals of Internal Medicine**, 5;172(9):577-582, 2020. <https://doi.org/10.7326/M20-0504>.

LEROUX, K.; CARR, J. Explaining Local Government Cooperation on Public Works: Evidence from Michigan. **Public Works Management & Policy**. 2007. <https://doi.org/10.1177/1087724X07302586>.

LESAGE, J.P.; PACE, R. K. **Introduction to Spatial Econometrics**. Chapman and Hall/CRC Press, 2009.

LEVITT, S. D. Using electoral cycles in police hiring to estimate the effects of police on crime: Reply. **American Economic Review**, 92(4), 1244–1250, 2002. <https://doi.org/10.1257/00028280260344777>.

LIMA, R.; BARBOSA, V. Natural disasters, economic growth and spatial spillovers: Evidence from a flash flood in Brazil. **Papers in Regional Science**, 2018.

LIMA, R.; SILVEIRA NETO, R. Physical and Human Capital and Brazilian Regional Growth: A Spatial Econometric Approach for the Period 1970–2010, **Regional Studies**, 2015.

LIN, M. J. More police, less crime: evidence from US state data. **Int. Rev. Law Econ.** 29 (2), 73–80, 2009. <https://doi.org/10.1016/j.irle.2008.12.003>

MACDONALD J, FAGAN J, GELLER A. The Effects of Local Police Surges on Crime and Arrests in New York City. **PLoS ONE** 11(6): e0157223, 2016. <https://doi.org/10.1371/journal.pone.0157223>.

MACHIN, S., MARIE, O. Crime and police resources: the street crime initiative. **J. Eur. Econ. Assoc.** 9 (4), 678–701, 2011.

MARIANI, L.; MIRANDA, J.; RETTL, P. Words can hurt: How political communication can change the pace of an epidemic. **Covid Economics**. Issue 12, 1 May 2020.

MELLO, S. More COPS, less crime. **Journal of Public Economics**, 172 (2019) 174–200, 2019.

MENEZES, T., SILVEIRA-NETO, R., MONTEIRO, C., & RATTON, J. L. Spatial correlation between homicide rates and inequality: Evidence from urban neighborhoods. **Economics Letters**, 120(1), 97–99, 2013. <https://doi.org/10.1016/j.econlet.2013.03.040>.

MEROW, C.; URBAN, M. Seasonality and uncertainty in global COVID-19 growth rates. **PNAS**, 117 (44) 27456-27464, 2020.

NICOLELIS, M.; RAIMUNDO, R.; PEIXOTO, P.; ANDREAZZI, C. The impact of super-spreader cities, highways, and intensive care availability in the early stages of the COVID-19 epidemic in Brazil. **Scientific Reports**, 13001, 2021.

NOY, I.; DOAN, N.; FERRARINI, B.; PARK, D. Measuring the economic risk of Covid-19. **Global Policy**. Volume 11, Issue 4, September 2020, Pages 413-423, 2020.

OHASHI, H. Effects of Transparency in Procurement Practices on Government Expenditure: A Case Study of Municipal Public Works. **Review of Industrial Organization**, 34, pages 267–285, 2009 – Springer.

PAEZ, A.; LOPEZ, F.; MENEZES, T.; CAVALCANTI, R.; PITA, M. A Spatio-Temporal Analysis of the Environmental Correlates of COVID-19. Incidence in Spain. **Geographical Analysis**, 0, 1–25, 2020.

PALIALOL, B.; PEREDA, P.; AZZONI, C. Does weather influence COVID-19 transmission? **Regional Science Policy & Practice**, Volume 12, Issue 6, pages 981-1004, 2020.

PESARAN, M. H. General diagnostic tests for cross section dependence in panels. University of Cambridge, Faculty of Economics, Cambridge **Working Papers in Economics** No. 0435, 2004.

PORSSE, A.; SOUSA, K.; CARVALHO, T.; VALE, V. The economic impacts of COVID-19 in Brazil based on an interregional CGE approach. **Regional Science Policy and Practice**, Volume 12, Issue 6, pages 1105-1121, 2020.

SCAFETTA, N. Distribution of the SARS-CoV-2 Pandemic and Its Monthly Forecast Based on Seasonal Climate Patterns. **International Journal of Environmental Research and Public Health**, 17;17(10):3493, 2020. doi: 10.3390/ijerph17103493.

SNYDER, B.; PARKS, V. Spatial Variation in Socio-ecological Vulnerability to COVID-19 in the Contiguous United States. **Health & Place**, Volume 66, 102471, 2020.

SOARES, R. Development, crime and punishment: accounting for the international differences in crime rates. *Journal of Development Economics*, 73 (2004), 155– 184, 2004.

SOUSA, M.; CRIBARI-NETO, F.; STOSIC, B. Explaining DEA Technical Efficiency Scores in an Outlier Corrected Environment: The Case of Public Services in Brazilian Municipalities. *Brazilian Review of Econometrics* v. 25, no 2, pp. 287–313, 2005.

SOUZA, M.; RAMOS, F. Eficiência técnica e retornos de escala na produção de serviços públicos municipais: o caso do nordeste e do sudeste brasileiro. *Rev. Bras. Econ.* 53 (4) 1999 <https://doi.org/10.1590/S0034-71401999000400002>.

TOBIÁS, A. Evaluation of the lockdowns for the SARS-CoV-2 epidemic in Italy and Spain after one month follow up. *Science of the Total Environment*, 10;725:138539, 2020.

TOBIÁS, A.; MOLINA, T. Is temperature reducing the transmission of COVID-19? *Environmental Research*, 186:109553, 2020.

TODA, A. Susceptible-Infected-Recovered (SIR) Dynamics of COVID-19 and Economic Impact. *arXiv:2003.11221 [q-bio.PE]*, 2020.

TOMMASI, M.; WEINSCHELBAUM, F. Centralization vs. Decentralization: a principal-agent analysis. *Journal of Public Economic Theory*, 9 (2), pp. 369–389, 2007.

WANG, H; IGLESIAS, E; WOOLDRIDGE, J. Partial maximum likelihood estimation of spatial probit models. *Journal of Econometrics*. Volume 172, Issue 1, Pages 77-89, 2013. <https://doi.org/10.1016/j.jeconom.2012.08.005>.

WANG, J.; TANG, K.; FENG, K.; LV, W.; CHEN, K.; WANG, F. Impact of temperature and relative humidity on the transmission of COVID-19: a modelling study in China and the United States. *BMJ Open*, 2021. doi: 10.1136/bmjopen-2020-043863.

WOOLDRIDGE, J. M. *Econometric Analysis of Cross Section and Panel Data*. 2^a ed. Cambridge, MA: MIT Press, 2010.

YING-YING, ZHENG; YI-TONG, MA; JIN-YING, ZHANG; XIANG, XIE. Covid-19 and the cardiovascular system. *Nature Review Cardiologist* 17, 259–260, 2020. <https://doi.org/10.1038/s41569-020-0360-5>.

APÊNDICE A - RESULTADO COMPLETO DAS ESTIMAÇÕES

A1. Estimação dos modelos para dados em painel e suas versões espaciais para as taxas diárias de prevalência da COVID-19 nos estados brasileiros para média móvel de 14 dias para as variáveis climáticas.

Variáveis Independentes	Variável Dependente: <i>txcases</i>			
	(1) GLS	(2) SAR	(3) SLX	(4) SDM
sunhours14m	-0.0831*** (0.005)	-0.0841*** (0.005)	-0.0917*** (0.005)	-0.1012*** (0.004)
tempmaxima14m	-0.1293*** (0.007)	-0.1318*** (0.007)	-0.0196* (0.008)	0.0019 (0.001)
humidity14m	0.0253*** (0.002)	0.0250*** (0.002)	0.0019 (0.002)	-0.0255*** (0.007)
lockdown	-0.0496*** (0.007)	-0.0501*** (0.007)	-0.0548*** (0.005)	-0.0563*** (0.003)
sii14m	-0.0884*** (0.003)	-0.0900*** (0.003)	-0.0058 (0.004)	-0.0094** (0.003)
analf	8.4223*** (2.165)	8.7024*** (2.226)	19.0574* (9.491)	13.4608 (11.403)
lnpop	0.8042** (0.285)	0.8250** (0.289)	-0.9798* (0.383)	0.9717* (0.470)
older	0.8086*** (0.164)	0.8025*** (0.165)	1.2966*** (0.334)	1.0489* (0.431)
lnrendpc	4.1700*** (0.840)	4.1532*** (0.868)	1.0627 (1.381)	-2.0994 (1.744)
lifeexp	-1.0976*** (0.120)	-1.0836*** (0.118)	-0.4711 (0.465)	-0.6063 (0.580)
presidentwin	-1.3163*** (0.322)	-1.3226*** (0.329)	-1.6031 (1.236)	-6.0528* (2.372)
txvooint	-0.0011*** (0.000)	-0.0011*** (0.000)	0.0002 (0.000)	0.0003* (0.000)
txresp1	-0.0183*** (0.005)	-0.0186*** (0.005)	0.0575*** (0.011)	0.0037 (0.014)
txcora	0.9198*** (0.173)	0.9114*** (0.173)	1.3418*** (0.240)	0.0549 (0.388)
txhiper	2.3313*** (0.682)	2.3868*** (0.679)	5.0827*** (1.114)	8.5475*** (1.829)
Wtxca		-0.0177** (0.006)		-0.0277*** (0.003)
Wpresid1			4.5142*** (1.185)	7.4408** (2.488)
Wsun14			-0.0094 (0.009)	-0.0024 (0.007)
Whum14			0.0032 (0.004)	0.0095** (0.003)
Wtmean14			-0.2914*** (0.017)	-0.2953*** (0.014)
Wlock14			-1.0812*** (0.071)	-0.9718*** (0.039)

Wsii14			-0.0598*** (0.007)	-0.0644*** (0.005)
Wanalf1			23.8898 (12.631)	22.0815 (15.510)
Wlnpop1			-1.9054 (1.998)	-4.8921* (2.309)
Wold1			0.7061 (0.572)	0.9384 (0.687)
Wlnrend1			5.2488 (4.799)	13.7969* (5.650)
Wtxvooin1			-0.0010*** (0.000)	-0.0000 (0.000)
Wtxcor1			-1.9603 (1.292)	-5.0588* (2.125)
Wtxresp1			-0.1913** (0.070)	-0.2994*** (0.085)
Wtxhip1			8.3168* (3.549)	-0.7543 (4.329)
_cons	62.9250*** (14.178)	62.0758*** (12.562)	15.9787 (33.540)	23.9953 (42.929)
Efeito Fixo Região	Não	Não	Não	Sim
N	864	864	864	864

Nota: [i] o número total de estados já conta com o Distrito Federal. [ii] Estatística t entre parênteses; [iii] *, **, *** indica *significativos estatisticamente* aos níveis 5%, 1% e 0,1%, respectivamente.

Fonte: Elaborado pelo autor.

A2. Estimação dos modelos para dados em painel e suas versões espaciais para as taxas diárias de prevalência da COVID-19 nos estados brasileiros para média móvel de 11 dias para as variáveis climáticas.

	(1) Txcases b/se	(2) txcases b/se	(3) txcases b/se	(4) txcases b/se
sunhours11m	-0.0624*** (0.003)	-0.0598*** (0.003)	-0.0550*** (0.003)	-0.0522*** (0.004)
humidity11m	0.0026* (0.001)	0.0028* (0.001)	-0.0063*** (0.001)	-0.0055*** (0.001)
tempmean11m	-0.1018*** (0.006)	-0.1000*** (0.006)	-0.0357*** (0.005)	-0.0446*** (0.005)
lockdown	-0.0611*** (0.005)	-0.0608*** (0.005)	-0.0680*** (0.004)	-0.0633*** (0.005)
sii11m	-0.0402*** (0.002)	-0.0398*** (0.002)	-0.0039 (0.002)	-0.0111*** (0.003)
analf	7.3016*** (1.537)	6.7186*** (1.580)	18.6220 (9.575)	16.4088 (12.085)
lnpop	0.5403** (0.196)	0.4904* (0.200)	-0.9529** (0.368)	1.1859* (0.483)
older	0.5497*** (0.117)	0.6074*** (0.121)	1.3548*** (0.305)	1.1470** (0.435)
lnrendpc	4.7812***	4.4792***	0.7396	-3.5137

	(0.477)	(0.504)	(1.678)	(2.101)
lifeexp	-0.8596***	-0.8824***	-0.3981	-0.4260
	(0.092)	(0.094)	(0.482)	(0.646)
presidentwin	-1.5002***	-1.3863***	-1.1389	-6.2854*
	(0.258)	(0.267)	(1.376)	(2.768)
txvooint	-0.0009***	-0.0009***	0.0003	0.0002
	(0.000)	(0.000)	(0.000)	(0.000)
txresp1	-0.0168***	-0.0156***	0.0529***	-0.0001
	(0.004)	(0.004)	(0.011)	(0.015)
txcora	0.7280***	0.7255***	1.2868***	-0.0003
	(0.131)	(0.133)	(0.226)	(0.456)
txhiper	1.4564**	1.4933**	5.4238***	9.4840***
	(0.545)	(0.555)	(1.131)	(2.075)
Wtxca		0.0171***		0.0160**
		(0.004)		(0.006)
Wpresid1			3.3783**	6.5391*
			(1.261)	(3.026)
Wsun11			-0.1254***	-0.1161***
			(0.006)	(0.007)
Whum11			-0.0490***	-0.0441***
			(0.002)	(0.003)
Wtmean11			-0.2031***	-0.1821***
			(0.010)	(0.010)
Wlock11			-1.5539***	-1.4430***
			(0.054)	(0.061)
Wsii11			-0.0090	-0.0066
			(0.005)	(0.005)
Wanalf1			20.2047	25.0026
			(14.578)	(18.417)
Wlnpop1			-1.8849	-5.1549
			(2.059)	(2.778)
Wold1			0.6283	0.6357
			(0.560)	(0.779)
Wlnrend1			5.4526	14.5435*
			(4.904)	(6.760)
Wtxvooin1			-0.0006***	0.0001
			(0.000)	(0.000)
Wtxcor1			-1.7711	-4.6683
			(1.367)	(2.546)
Wtxresp1			-0.1618*	-0.2684**
			(0.064)	(0.094)
Wtxhip1			8.6822*	-0.8992
			(3.679)	(4.943)
_cons	16.8290***	20.8800***	12.2299	14.7626
	(3.756)	(4.148)	(31.783)	(45.477)
Efeito Fixo	Não	Não	Não	Sim
Região				
N	864	864	864	864

Nota: [i] o número total de estados já conta com o Distrito Federal. [ii] Estatística t entre parênteses; [iii] *, **, *** indica *significativos estatisticamente* aos níveis 5%, 1% e 0,1%, respectivamente.

Fonte: Elaborado pelo autor.

A3. Estimação dos modelos para dados em painel e suas versões espaciais para as taxas diárias de prevalência da COVID-19 nos estados brasileiros para média móvel de 7 dias para as variáveis climáticas.

	(1)	(2)	(3)	(4)
	Txcases	txcases	txcases	txcases
	b/se	b/se	b/se	b/se
sunhours07m	-0.0226*** (0.001)	-0.0210*** (0.001)	-0.0171*** (0.002)	-0.0169*** (0.002)
humidity07m	0.0005 (0.001)	0.0012 (0.001)	-0.0049*** (0.001)	-0.0040*** (0.001)
tempmean07m	-0.0462*** (0.003)	-0.0439*** (0.003)	-0.0053 (0.004)	-0.0048 (0.004)
lockdown	-0.0758*** (0.005)	-0.0741*** (0.005)	-0.0413*** (0.004)	-0.0439*** (0.003)
sii07m	-0.0275*** (0.001)	-0.0258*** (0.001)	0.0041** (0.002)	0.0020 (0.002)
Analf	9.2373*** (1.431)	8.1638*** (1.395)	20.1765* (9.892)	15.7395 (12.173)
Lnpop	0.7506*** (0.183)	0.6865*** (0.181)	-0.7707 (0.406)	1.3509** (0.517)
Older	0.5830*** (0.136)	0.5833*** (0.136)	1.5129*** (0.350)	1.1744* (0.495)
lnrendpc	4.7117*** (0.746)	4.6143*** (0.725)	0.7222 (1.667)	-3.9745 (2.155)
lifeexp	-0.8600*** (0.097)	-0.8581*** (0.098)	-0.3827 (0.495)	-0.4312 (0.649)
presidentwin	-1.3797*** (0.316)	-1.3045*** (0.309)	-0.8972 (1.388)	-6.7955* (2.752)
txvooint	-0.0009*** (0.000)	-0.0009*** (0.000)	0.0001 (0.000)	0.0001* (0.000)
txresp1	-0.0109** (0.004)	-0.0107** (0.004)	0.0568*** (0.012)	0.0041 (0.016)
txcora	0.7142*** (0.125)	0.6752*** (0.121)	1.2232*** (0.239)	-0.0473 (0.508)
txhiper	1.8337*** (0.514)	1.6899** (0.516)	5.8179*** (1.254)	9.2158*** (1.950)
Wtxca		0.0430*** (0.003)		0.0664*** (0.004)
Wpresid1			4.5243*** (1.367)	7.2621* (3.016)
Wsun07			-0.0585*** (0.004)	-0.0619*** (0.003)
Whum07			-0.0243*** (0.001)	-0.0235*** (0.001)
Wtmean07			-0.0742*** (0.005)	-0.0650*** (0.005)
Wlock07			-1.0081***	-0.9151***

			(0.046)	(0.043)
Wsii07			-0.0119***	-0.0142***
			(0.003)	(0.003)
Wanalf1			16.0896	21.4521
			(13.437)	(17.815)
Wlnpop1			-1.3405	-5.0196
			(2.110)	(2.762)
Wold1			0.8584	0.6638
			(0.579)	(0.869)
Wlnrend1			3.4515	13.7261*
			(5.010)	(6.929)
Wtxvooin1			-0.0006	0.0004
			(0.000)	(0.000)
Wtxcor1			-2.3774	-5.0192
			(1.354)	(2.795)
Wtxresp1			-0.1652*	-0.2660*
			(0.075)	(0.113)
Wtxhip1			10.0596**	-1.6942
			(3.857)	(5.288)
_cons	10.8653*	12.8424*	4.6994	14.9980
	(5.085)	(5.286)	(33.461)	(43.796)
Efeito Fixo	Não	Não	Não	Sim
Região				
N	864	864	864	864

Nota: [i] o número total de estados já conta com o Distrito Federal. [ii] Estatística t entre parênteses; [iii] *, **, *** indica *significativos estatisticamente* aos níveis 5%, 1% e 0,1%, respectivamente.

Fonte: Elaborado pelo Autor.

APÊNDICE B - RESULTADO COMPLETO DAS ESTIMAÇÕES

B1. Resultados das estimações do modelo probabilístico.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)				
	(1) PROBIT1	(2) PROBIT2	(3) PROBIT3	(4) PROBIT4	(5) PROBIT5
p_repasspc	-0.0010 (0.002)	-0.0000 (0.002)	-0.0001 (0.002)	-0.0010 (0.002)	-0.0010 (0.002)
txdesoc		0.0228* (0.010)	0.0223* (0.010)	0.0045 (0.016)	
dens		0.0003*** (0.000)	0.0003*** (0.000)	0.0004*** (0.000)	
txurban		-0.0033 (0.003)	-0.0032 (0.003)	-0.0023 (0.003)	
gini		2.3360* (1.123)	2.6290* (1.133)	5.0833*** (1.374)	
prop_ens_sup		-0.0984*** (0.028)	-0.1010*** (0.029)	-0.1492*** (0.034)	
lnpibpc		-0.0141 (0.088)	-0.0110 (0.090)	-0.0083 (0.124)	
IFGF		0.0427 (0.233)	0.0856 (0.239)	0.1733 (0.258)	0.1736 (0.258)
2.dsexo_pref		0.0534 (0.114)	0.0551 (0.115)	0.1852 (0.133)	0.1851 (0.133)
p_vot_pref		0.7613** (0.278)	0.7434** (0.287)	0.6219 (0.330)	0.6208 (0.330)
p_ver_pref		-0.7843** (0.261)	-0.8179** (0.266)	-0.5779 (0.312)	-0.5781 (0.312)
itm		-0.0004* (0.000)	-0.0004** (0.000)	-0.0004* (0.000)	-0.0004* (0.000)
idhm		0.9233 (0.861)	0.8624 (0.882)	0.7447 (1.095)	
reeleicao		-0.3319*** (0.092)	-0.3519*** (0.093)	-0.3969*** (0.107)	-0.3965*** (0.107)
lnpop		0.0030 (0.067)	-0.0109 (0.068)	0.0265 (0.086)	
2.classif_obra			-0.2684* (0.122)	-0.3044* (0.133)	-0.3044* (0.133)
3.classif_obra			0.1257 (0.152)	0.0790 (0.170)	0.0790 (0.170)
4.classif_obra			-0.0727 (0.077)	-0.0650 (0.084)	-0.0650 (0.084)
2.tipo_licit			-0.0569 (0.116)	-0.0702 (0.125)	-0.0701 (0.125)
3.tipo_licit			0.2076 (0.116)	0.2034 (0.127)	0.2035 (0.127)
4.tipo_licit			-0.7316* (0.326)	-0.6391 (0.339)	-0.6391 (0.339)

5.tipo_licit		-0.1029	-0.1097	-0.1098	
		(0.129)	(0.145)	(0.145)	
c.txdesoc#c.ano				0.0000	
				(0.000)	
c.dens#c.ano				0.0000***	
				(0.000)	
c.txurban#c.ano				-0.0000	
				(0.000)	
c.gini#c.ano				0.0025***	
				(0.001)	
c.prop_ens_su				-0.0001***	
p#c.ano				(0.000)	
c.lnpibpc#c.ano				-0.0000	
				(0.000)	
c.idhm#c.ano				0.0004	
				(0.001)	
c.lnpop#c.ano				0.0000	
				(0.000)	
_cons	-	-2.7012**	-2.6095*	-9.1496***	-9.1436***
	1.2173**				
	*				
	(0.163)	(1.047)	(1.056)	(1.349)	(1.349)
E.F. Tempo	Não	Não	Não	Sim	Sim
E.F Região	Não	Não	Não	Sim	Sim
Tendência	Não	Não	Não	Não	Sim
Linear					
Pseudo R2	0.0002	0.0550	0.0648	0.1896	0.1895
N	2736	2736	2736	2736	2736

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano *k* que é igual a um (1) se é do ano *k* e zero (0) caso contrário, onde *k* assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do *i*-ésimo município. Assume valor igual um (1) se pertence a região *g* e zero (0) caso contrário. *g* representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Tendência Linear – interação entre as variáveis socioeconômicas e a variável correspondente aos anos 2016, 2017, 2018. [iv] Erro-padrão entre parênteses; [v] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [vi] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

B2. Resultados das estimações do modelo probabilístico com variável instrumental.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)				
	(1) <i>IVPROBIT1</i>	(2) <i>IVPROBIT2</i>	(3) <i>IVPROBIT3</i>	(4) <i>IVPROBIT4</i>	(5) <i>IVPROBIT5</i>
p_repasspec	-0.0500***	-0.0523***	-0.0525***	-0.0515***	-0.0515***

	(0.002)	(0.003)	(0.003)	(0.005)	(0.005)
txdesoc		-0.0017	-0.0008	-0.0074	
		(0.007)	(0.007)	(0.009)	
dens		0.0001	0.0001	0.0002*	
		(0.000)	(0.000)	(0.000)	
txurban		0.0038*	0.0035*	0.0041	
		(0.002)	(0.002)	(0.002)	
gini		0.3759	0.4372	1.7295	
		(0.687)	(0.718)	(1.196)	
prop_ens_sup		-0.0794***	-0.0804***	-0.1343***	
		(0.020)	(0.020)	(0.029)	
lnpibpc		-0.1540*	-0.1294*	-0.1120	
		(0.061)	(0.062)	(0.076)	
IFGF		-0.2622	-0.2427	-0.2115	-0.2114
		(0.143)	(0.145)	(0.173)	(0.173)
2.dsexo_pref		0.0627	0.0556	0.1158	0.1158
		(0.076)	(0.075)	(0.093)	(0.093)
p_vot_pref		0.6384**	0.5874**	0.6294**	0.6288**
		(0.201)	(0.202)	(0.229)	(0.228)
p_ver_pref		-0.0877	-0.1044	-0.0118	-0.0117
		(0.173)	(0.177)	(0.212)	(0.212)
itm		-0.0001	-0.0001	-0.0002	-0.0002
		(0.000)	(0.000)	(0.000)	(0.000)
idhm		0.4722	0.2557	0.8428	
		(0.564)	(0.571)	(0.664)	
reeleicao		-0.0670	-0.0759	-0.1376	-0.1374
		(0.066)	(0.068)	(0.096)	(0.096)
lnpop		-0.0274	-0.0357	-0.0105	
		(0.044)	(0.044)	(0.053)	
2.classif_obra			-0.1331	-0.1692	-0.1691
			(0.082)	(0.096)	(0.096)
3.classif_obra			-0.0292	-0.0110	-0.0110
			(0.083)	(0.095)	(0.095)
4.classif_obra			-0.1513**	-0.1438**	-0.1438**
			(0.047)	(0.052)	(0.052)
2.tipo_licit			-0.1053	-0.0762	-0.0761
			(0.068)	(0.076)	(0.076)
3.tipo_licit			0.2070*	0.2236*	0.2236*
			(0.083)	(0.090)	(0.090)
4.tipo_licit			-0.0682	-0.0601	-0.0599
			(0.190)	(0.223)	(0.223)
5.tipo_licit			-0.0887	-0.0874	-0.0874
			(0.082)	(0.092)	(0.092)
c.txdesoc#c.ano					-0.0000
					(0.000)
c.dens#c.ano					0.0000*
					(0.000)
c.txurban#c.ano					0.0000

o					(0.000)
c.gini#c.ano					0.0009 (0.001)
c.prop_ens_su p#c.ano					-0.0001***
c.lnpibpc#c.ano					(0.000) -0.0001
o					(0.000)
c.idhm#c.ano					0.0004 (0.000)
c.lnpop#c.ano					-0.0000 (0.000)
_cons	4.3373*** (0.348)	5.6279*** (0.941)	5.7462*** (0.946)	1.7720 (2.342)	1.7772 (2.339)
FIRST STAGE	Variável Dependente: <i>Repassé</i>				
part_pres	2.0233* (0.791)	2.2957** (0.792)	2.2688** (0.801)	2.5176** (0.838)	2.5170** (0.838)
txdesoc		-0.1821 (0.105)	-0.1619 (0.104)	-0.1903 (0.127)	
dens		-0.0007 (0.001)	-0.0007 (0.001)	0.0009 (0.001)	
txurban		0.0949*** (0.025)	0.0874*** (0.026)	0.1004*** (0.030)	
gini		-8.9670 (9.868)	-9.5199 (10.132)	-8.4299 (12.087)	
prop_ens_sup		-0.9407*** (0.253)	-0.9362*** (0.252)	-1.4521*** (0.289)	
lnpibpc		-3.0901** (0.992)	-2.6184** (1.007)	-2.2897* (1.026)	
IFGF		-5.6108* (2.293)	-5.5114* (2.293)	-6.2795* (2.448)	-6.2775* (2.448)
2.dsexo_pref		0.4978 (1.220)	0.3558 (1.200)	0.4054 (1.286)	0.4057 (1.286)
p_vot_pref		8.4137* (3.295)	7.5526* (3.281)	8.5919* (3.524)	8.5913* (3.524)
p_ver_pref		3.6177 (2.407)	3.4746 (2.384)	5.1354* (2.400)	5.1352* (2.400)
itm		0.0008 (0.002)	0.0008 (0.002)	0.0003 (0.002)	0.0003 (0.002)
idhm		2.9559 (8.826)	-0.9652 (8.823)	8.5158 (9.396)	
reeleicao		0.4090 (0.776)	0.3487 (0.767)	-0.0011 (0.894)	-0.0012 (0.894)
lnpop		-0.2751 (0.732)	-0.3650 (0.743)	-0.1023 (0.785)	
2.classif_obra			-1.0445	-1.0547	-1.0546

			(1.225)	(1.195)	(1.195)
3.classif_obra			-1.2517	-0.7230	-0.7231
			(1.283)	(1.297)	(1.297)
4.classif_obra			-2.4328**	-2.3254**	-2.3254**
			(0.773)	(0.774)	(0.774)
1.tipo_licit			0.0000	0.0000	0.0000
			(.)	(.)	(.)
2.tipo_licit			-1.4636	-0.8371	-0.8371
			(1.101)	(1.129)	(1.129)
3.tipo_licit			2.7796*	2.8141*	2.8136*
			(1.380)	(1.356)	(1.356)
4.tipo_licit			3.2591	4.0288	4.0289
			(2.324)	(2.383)	(2.383)
5.tipo_licit			-1.1096	-0.8184	-0.8183
			(1.283)	(1.314)	(1.314)
c.txdesoc#c.ano					-0.0001
					(0.000)
c.dens#c.ano					0.0000
					(0.000)
c.txurban#c.ano					0.0000***
					(0.000)
c.gini#c.ano					-0.0042
					(0.006)
c.prop_ens_supe#c.ano					-0.0007***
					(0.000)
c.lnpibpc#c.ano					-0.0011*
					(0.001)
c.idhm#c.ano					0.0042
					(0.005)
c.lnpop#c.ano					-0.0001
					(0.000)
_cons	93.3343***	124.2766***	125.6499**	109.6662***	109.6698***
			*		
	(0.423)	(10.177)	(10.078)	(11.645)	(11.646)
E.F. Tempo	Não	Não	Não	Sim	Sim
E.F Região	Não	Não	Não	Sim	Sim
Wald Test	19.94***	17.57***	16.97***	9.85***	9.86***
N	2736	2736	2736	2736	2736

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano **k** que é igual a um (1) se é do ano **k** e zero (0) caso contrário, onde **k** assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do **i**-ésimo município. Assume valor igual um (1) se pertence a região **g** e zero (0) caso contrário. **g** representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Tendência Linear – interação entre as variáveis socioeconômicas e a variável correspondente aos anos 2016, 2017, 2018. [iv] Erro-padrão entre parênteses; [v] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [vi] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

B3. Resultados das estimações do modelo probabilístico com variável instrumental e segregação regional.					
Variável Dependente: <i>Paralisada</i> (dicotômica)					
Variáveis Independentes	(1) IVPROBIT1	(2) IVPROBIT2	(3) IVPROBIT3	(4) IVPROBIT4	(5) IVPROBIT5
	Agreste Central excluído	Agreste Meridional excluído	Agreste Setentrional excluído	Região Metropolitana excluída	Sertão do São Francisco excluído
p_repasspc	-0.0498*** (0.005)	-0.0509*** (0.005)	-0.0536*** (0.004)	-0.0575*** (0.004)	-0.0488*** (0.005)
txdesoc	0.0023 (0.011)	-0.0143 (0.010)	-0.0111 (0.012)	-0.0103 (0.009)	-0.0143 (0.010)
dens	0.0002** (0.000)	0.0002* (0.000)	0.0002* (0.000)	0.0004 (0.000)	0.0002* (0.000)
txurban	0.0057* (0.002)	0.0036 (0.003)	0.0047 (0.003)	0.0034 (0.002)	0.0049* (0.002)
gini	0.9331 (1.183)	1.6515 (1.256)	1.9276 (1.091)	1.6981 (1.022)	2.1070 (1.315)
prop_ens_sup	-0.1037*** (0.026)	-0.1516*** (0.036)	-0.1331*** (0.026)	-0.1034*** (0.031)	-0.1324*** (0.030)
lnpibpc	-0.2005* (0.086)	-0.1329 (0.084)	-0.1084 (0.071)	-0.0176 (0.077)	-0.1231 (0.078)
IFGF	0.0938 (0.217)	-0.2124 (0.185)	-0.3385 (0.185)	-0.2954 (0.174)	-0.1379 (0.189)
2.dsexo_pref	0.3500** (0.120)	0.0944 (0.100)	0.0516 (0.097)	0.1326 (0.090)	0.1127 (0.097)
p_vot_pref	0.7641*** (0.224)	0.7109** (0.253)	0.7138** (0.237)	0.5889* (0.237)	0.6793** (0.242)
p_ver_pref	0.3948 (0.206)	-0.2230 (0.255)	0.0251 (0.227)	0.0952 (0.181)	-0.2552 (0.271)
itm	-0.0002 (0.000)	-0.0001 (0.000)	-0.0001 (0.000)	-0.0000 (0.000)	-0.0002 (0.000)
idhm	0.6895 (0.759)	-0.0704 (0.770)	1.4513* (0.697)	0.1296 (0.701)	0.8944 (0.707)
reeleicao	-0.4287** (0.160)	-0.1637 (0.092)	-0.1269 (0.100)	-0.0259 (0.098)	-0.1142 (0.101)
lnpop	-0.0539 (0.058)	0.0605 (0.070)	0.0094 (0.054)	-0.1009 (0.052)	0.0054 (0.060)
2.classif_obra	-0.1120 (0.096)	-0.2047 (0.105)	-0.1423 (0.092)	-0.1434 (0.098)	-0.2375* (0.107)
3.classif_obra	-0.0179 (0.109)	-0.0273 (0.104)	-0.1112 (0.095)	0.0348 (0.085)	-0.0167 (0.110)
4.classif_obra	-0.1010 (0.060)	-0.1703** (0.055)	-0.1023* (0.051)	-0.1076* (0.052)	-0.1645** (0.056)
2.tipo_licit	-0.1106 (0.098)	-0.1131 (0.084)	-0.0845 (0.074)	0.0382 (0.072)	-0.0897 (0.080)
3.tipo_licit	0.2206* (0.098)	0.2302* (0.101)	0.1999* (0.093)	0.1478 (0.091)	0.1825 (0.097)

4.tipo_licit	-0.0292 (0.261)	-0.0215 (0.224)	-0.0747 (0.199)	0.0000 (.)	-0.1006 (0.231)
5.tipo_licit	-0.0125 (0.102)	-0.1104 (0.095)	-0.0734 (0.096)	-0.0352 (0.087)	-0.1743 (0.111)
_cons	2.1977 (2.148)	1.8043 (2.512)	1.7753 (2.303)	3.4228 (2.115)	1.0783 (2.479)
Variável Dependente: <i>Repassé</i>					
FIRST STAGE					
part_pres	3.3927*** (0.960)	2.9242** (0.941)	1.9156* (0.861)	1.7440* (0.849)	3.0167** (0.979)
txdesoc	-0.1273 (0.137)	-0.2297 (0.129)	-0.3684* (0.146)	-0.2442 (0.127)	-0.2546 (0.139)
dens	0.0008 (0.001)	0.0009 (0.001)	0.0009 (0.001)	0.0035 (0.005)	0.0006 (0.001)
txurban	0.0996** (0.033)	0.1072*** (0.032)	0.1512*** (0.034)	0.0819* (0.033)	0.1149*** (0.032)
gini	-18.1569 (13.347)	-10.9507 (12.924)	5.1071 (12.748)	4.9874 (12.334)	-8.1692 (12.749)
prop_ens_sup	-1.1948*** (0.306)	-1.4168*** (0.321)	-1.6914*** (0.303)	-1.0591** (0.328)	-1.3815*** (0.299)
lnpibpc	-3.6337*** (1.095)	-2.6948* (1.094)	-2.0360* (1.035)	-0.8036 (1.059)	-2.2623* (1.057)
IFGF	-3.1914 (2.742)	-5.1278 (2.648)	-8.7367*** (2.571)	-6.7463** (2.484)	-5.8851* (2.813)
2.dsexo_pref	2.8389* (1.416)	-0.5466 (1.302)	-0.3342 (1.416)	1.0451 (1.296)	0.2464 (1.391)
p_vot_pref	13.5477*** (3.446)	8.6044* (3.667)	9.3377** (3.594)	7.6463* (3.607)	9.8092* (3.904)
p_ver_pref	9.3205*** (2.527)	3.5909 (2.551)	5.5027* (2.547)	4.3197 (2.440)	3.1710 (3.118)
itm	0.0006 (0.002)	-0.0004 (0.002)	0.0000 (0.002)	0.0018 (0.002)	-0.0005 (0.002)
idhm	9.2891 (10.899)	5.9579 (10.729)	15.4833 (9.810)	-0.3968 (10.132)	8.4139 (10.255)
reeleicao	-1.6939 (1.045)	-1.0651 (0.986)	-0.0439 (0.906)	1.3669 (0.877)	0.7590 (0.935)
lnpop	0.3479 (0.768)	0.0209 (0.828)	0.0449 (0.807)	-1.5774* (0.772)	0.0692 (0.919)
2.classif_obra	-0.6348 (1.307)	-1.5212 (1.284)	-1.1520 (1.251)	-0.8061 (1.217)	-1.7094 (1.331)
3.classif_obra	-0.9005 (1.435)	-1.4505 (1.378)	-1.5245 (1.351)	0.5576 (1.171)	-0.9112 (1.610)
4.classif_obra	-2.0661* (0.850)	-2.7813*** (0.799)	-1.7392* (0.800)	-1.4523 (0.772)	-2.5287** (0.875)
2.tipo_licit	0.1243 (1.221)	-1.3804 (1.223)	-1.2239 (1.164)	0.3333 (1.089)	-1.1029 (1.195)
3.tipo_licit	3.5543* (1.471)	2.5534 (1.475)	2.4979 (1.426)	2.0447 (1.346)	1.9097 (1.494)
4.tipo_licit	5.0692	4.2009	1.9035	0.0000	3.9277

	(3.195)	(2.560)	(2.364)	(.)	(2.485)
5.tipo_licit	0.3354	-1.6579	-0.4924	-0.1045	-1.3386
	(1.486)	(1.375)	(1.390)	(1.238)	(1.617)
_cons	113.3275**	116.5678***	95.0404***	109.0665***	107.2272***
	*				
E.F. Tempo	(12.135)	(12.333)	(12.205)	(11.823)	(12.832)
	Sim	Sim	Sim	Sim	Sim
E.F Região	Sim	Sim	Sim	Sim	Sim
Wald Test	9.75***	9.64***	8.86***	9.53***	9.40***
N	2313	2438	2522	2433	2371

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano **k** que é igual a um (1) se é do ano **k** e zero (0) caso contrário, onde **k** assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do **i**-ésimo município. Assume valor igual um (1) se pertence a região **g** e zero (0) caso contrário. **g** representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Tendência Linear – interação entre as variáveis socioeconômicas e a variável correspondente aos anos 2016, 2017, 2018. [iv] Erro-padrão entre parênteses; [v] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [vi] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

B4. Resultados das estimações do modelo probabilístico com variável instrumental e segregação de tipos de obras.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)					
	(1)	(2)	(3)	(4)	(5)	(6)
	IVPROBIT1	IVPROBIT2	IVPROBIT3	IVPROBIT4	IVPROBIT5	IVPROBIT6
	Obras de Pavimentação excluídas		Obras em Hospitais excluídas		Obras em Escolas Excluídas	
<i>Repass</i>	-0.0512*** (0.003)	-0.0497*** (0.004)	-0.0545*** (0.003)	-0.0532*** (0.005)	-0.0511*** (0.004)	-0.0499*** (0.006)
txdesoc	-0.0063 (0.007)	-0.0135 (0.011)	-0.0039 (0.008)	-0.0039 (0.010)	0.0008 (0.008)	-0.0059 (0.010)
dens	0.0000 (0.000)	0.0002* (0.000)	0.0000 (0.000)	0.0002 (0.000)	0.0001 (0.000)	0.0002** (0.000)
txurban	0.0044* (0.002)	0.0055* (0.003)	0.0034 (0.002)	0.0036 (0.002)	0.0032 (0.002)	0.0036 (0.002)
gini	0.3235 (0.779)	1.1583 (1.097)	-0.2410 (0.739)	0.9039 (1.326)	0.6887 (0.796)	1.9477 (1.368)
prop_ens_sup	-0.0831*** (0.021)	-0.1543*** (0.030)	-0.0592** (0.021)	-0.1129*** (0.033)	-0.0850*** (0.022)	-0.1372*** (0.031)
lnpibpc	-0.2256** (0.069)	-0.1603 (0.083)	-0.1180 (0.063)	-0.1140 (0.075)	-0.1163 (0.064)	-0.1137 (0.080)
IFGF	0.0041 (0.182)	-0.0501 (0.208)	-0.2497 (0.147)	-0.1711 (0.174)	-0.2870 (0.152)	-0.2653 (0.182)
2.dsexo_pref	0.1391 (0.085)	0.1404 (0.102)	0.0785 (0.082)	0.1367 (0.102)	0.0704 (0.080)	0.1272 (0.098)
p_vot_pref	0.4758* (0.228)	0.6329* (0.272)	0.6271** (0.208)	0.5676* (0.232)	0.6402** (0.217)	0.6856** (0.246)
p_ver_pref	-0.2630	-0.1736	-0.0719	0.0158	-0.1301	-0.0575

	(0.216)	(0.256)	(0.192)	(0.223)	(0.194)	(0.237)
itm	-0.0000	-0.0001	-0.0001	-0.0002	-0.0001	-0.0002
	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)	(0.000)
idhm	0.0084	0.6107	-0.1516	0.6692	0.2953	1.0679
	(0.658)	(0.786)	(0.615)	(0.728)	(0.587)	(0.695)
reeleicao	-0.0867	-0.2095*	-0.0716	-0.1549	-0.0982	-0.1638
	(0.075)	(0.105)	(0.072)	(0.099)	(0.071)	(0.103)
lnpop	0.0065	0.0652	0.0004	0.0237	-0.0304	0.0028
	(0.054)	(0.065)	(0.044)	(0.052)	(0.046)	(0.057)
2.classif_obra	0.0000	0.0000			-0.1407	-0.1765
	(.)	(.)			(0.084)	(0.101)
3.classif_obra	0.0683	0.1577	-0.0346	-0.0231		
	(0.098)	(0.122)	(0.082)	(0.095)		
4.classif_obra	-0.0183	0.0271	-0.1482**	-0.1453**	-0.1526**	-0.1409**
	(0.072)	(0.088)	(0.047)	(0.051)	(0.048)	(0.053)
2.tipo_licit	-0.1826*	-0.1479	-0.0963	-0.0818	-0.1229	-0.0984
	(0.078)	(0.091)	(0.072)	(0.080)	(0.071)	(0.082)
3.tipo_licit	0.1013	0.1044	0.2846**	0.2766**	0.2042*	0.2150*
	(0.111)	(0.122)	(0.088)	(0.094)	(0.084)	(0.091)
4.tipo_licit	-0.2564	-0.2700	-0.0027	-0.0430	-0.0918	-0.0868
	(0.193)	(0.229)	(0.206)	(0.239)	(0.200)	(0.242)
5.tipo_licit	-0.0242	0.0053	-0.0951	-0.1059	-0.0652	-0.0801
	(0.086)	(0.100)	(0.087)	(0.100)	(0.088)	(0.103)
_cons	6.1918***	1.7889	6.0042***	2.1422	5.2280***	0.9619
	(0.891)	(2.221)	(0.928)	(2.505)	(1.037)	(2.654)
<hr/>						
FIRST STAGE	Variável Dependente: <i>Repass</i>					
part_pres	4.9103**	4.5298**	1.8004*	1.8687*	2.1063*	2.6262**
	(1.533)	(1.555)	(0.840)	(0.886)	(0.833)	(0.890)
txdesoc	-0.1790	-0.3491	-0.0994	-0.1300	-0.1824	-0.2123
	(0.196)	(0.225)	(0.111)	(0.134)	(0.107)	(0.131)
dens	-0.0008	-0.0008	-0.0002	0.0013	-0.0012	0.0004
	(0.001)	(0.001)	(0.001)	(0.001)	(0.001)	(0.001)
txurban	0.0724	0.0770	0.0766**	0.0906**	0.0896***	0.1085***
	(0.053)	(0.059)	(0.028)	(0.032)	(0.027)	(0.032)
gini	16.8924	33.9125	-5.9389	-5.1870	-16.6584	-16.2470
	(17.294)	(22.808)	(11.111)	(13.414)	(10.611)	(12.289)
prop_ens_sup	-0.8102*	-1.1908*	-0.9032**	-1.3448***	-1.0001***	-1.5285***
	(0.376)	(0.473)	(0.305)	(0.341)	(0.275)	(0.308)
lnpibpc	-6.8810***	-6.7380***	-1.5374	-1.0519	-2.6915**	-2.5913*
	(1.715)	(2.009)	(1.112)	(1.138)	(1.040)	(1.047)
IFGF	-0.9683	-6.4475	-5.4007*	-6.8052**	-5.3581*	-5.7132*
	(3.832)	(4.312)	(2.457)	(2.581)	(2.409)	(2.564)
2.dsexo_pref	1.2142	0.6891	1.3765	1.4050	0.5332	0.4376
	(2.440)	(2.794)	(1.290)	(1.372)	(1.249)	(1.347)
p_vot_pref	5.4858	1.5974	8.9908**	10.6358**	7.0165	7.1796
	(5.977)	(6.979)	(3.402)	(3.774)	(3.614)	(3.811)
p_ver_pref	4.1168	3.1606	3.9599	5.0879*	3.6797	6.0396*
	(4.721)	(4.885)	(2.457)	(2.443)	(2.497)	(2.547)
itm	-0.0044	-0.0044	0.0017	0.0009	0.0019	0.0015

	(0.003)	(0.003)	(0.002)	(0.002)	(0.002)	(0.002)
idhm	23.2682 (16.312)	29.0483 (17.224)	1.8686 (9.673)	9.7303 (10.346)	-4.0788 (9.368)	5.6090 (10.089)
reeleicao	-2.1814 (1.503)	-2.9308 (1.678)	1.4962 (0.805)	1.2926 (0.946)	0.3044 (0.805)	0.0663 (0.969)
lnpop	-0.3462 (1.285)	0.4531 (1.413)	-0.7172 (0.811)	-0.7070 (0.869)	0.0537 (0.778)	0.2213 (0.825)
2.classif_obra	-5.3228* (2.387)	-4.7218* (2.146)	-0.2233 (1.299)	-0.1640 (1.253)	-0.3089 (1.221)	-0.5735 (1.206)
3.classif_obra	-5.0855 (2.871)	-5.2468 (2.996)	-0.3648 (1.401)	0.2881 (1.408)	-1.3963 (1.287)	-1.0208 (1.317)
4.classif_obra	-2.7245 (1.391)	-2.4912 (1.424)	-1.5251 (0.836)	-1.3948 (0.837)	-2.7116*** (0.821)	-2.6064** (0.825)
2.tipo_licit	0.0000 (.)	0.0000 (.)			-0.7940 (1.111)	-0.3365 (1.136)
3.tipo_licit	3.7640* (1.634)	3.8006* (1.817)	2.3795 (1.415)	2.4721 (1.381)		
4.tipo_licit	3.3563 (2.508)	3.8669 (2.725)	3.1659 (2.343)	4.0403 (2.408)	3.3356 (2.335)	4.1222 (2.392)
5.tipo_licit	-0.2859 (1.666)	-0.5668 (1.744)	-1.1190 (1.267)	-0.8796 (1.302)	-1.0803 (1.284)	-0.6361 (1.313)
_cons	139.1739*** (19.902)	122.9010** (21.508)	112.4687* (10.923)	99.3246*** (12.723)	127.5063** (10.500)	114.0139** (12.187)
<hr/>						
FIRST STAGE	Variável Dependente: <i>Repassé</i>					
part_pres	2.3532* (0.978)	3.0163** (1.018)	1.7044* (0.863)	2.1536* (0.915)	2.4157** (0.826)	2.6202** (0.863)
txdesoc	-0.1897 (0.128)	-0.2522 (0.151)	-0.1935 (0.111)	-0.1272 (0.137)	-0.1589 (0.109)	-0.1782 (0.132)
dens	-0.0010 (0.001)	0.0010 (0.001)	-0.0014* (0.001)	0.0001 (0.001)	-0.0005 (0.001)	0.0012 (0.001)
txurban	0.1067** (0.033)	0.1106** (0.040)	0.0820** (0.028)	0.0807* (0.032)	0.0830** (0.027)	0.0948** (0.031)
gini	-4.5727 (13.185)	-6.2742 (16.038)	-14.9802 (11.009)	-18.8563 (12.818)	-9.6835 (10.516)	-10.1586 (12.472)
prop_ens_sup	-1.2048*** (0.316)	-1.8999*** (0.370)	-0.6651* (0.270)	-1.0836*** (0.308)	-0.9424*** (0.261)	-1.4518*** (0.297)
lnpibpc	-3.9400*** (1.182)	-3.4565** (1.205)	-2.2932* (1.010)	-2.3072* (1.019)	-2.4064* (1.042)	-2.1108* (1.061)
IFGF	-3.0215 (3.001)	-4.0232 (3.172)	-4.7691* (2.385)	-4.5768 (2.540)	-6.3150** (2.367)	-7.1230** (2.532)
2.dsexo_pref	2.2589 (1.468)	2.0232 (1.578)	0.9126 (1.325)	0.8174 (1.419)	0.6414 (1.278)	0.7191 (1.362)
p_vot_pref	6.5650 (4.040)	7.6382 (4.293)	8.8864** (3.382)	8.3950* (3.601)	8.2803* (3.487)	9.3889* (3.733)
p_ver_pref	0.8135 (3.090)	3.0535 (3.117)	3.2017 (2.534)	4.9565 (2.550)	3.6132 (2.484)	4.9703* (2.495)
itm	0.0011 (0.002)	0.0004 (0.002)	0.0013 (0.002)	0.0005 (0.002)	0.0013 (0.002)	0.0006 (0.002)

idhm	-4.2045 (11.274)	9.1425 (11.942)	-5.0792 (9.824)	7.4316 (10.563)	0.2703 (9.048)	11.3309 (9.608)
reeleicao	-0.2612 (1.049)	-1.4815 (1.144)	0.0638 (0.802)	-0.6379 (0.911)	0.0842 (0.783)	-0.2681 (0.918)
lnpop	0.1135 (0.950)	0.9306 (0.992)	0.2591 (0.740)	0.6741 (0.766)	-0.2223 (0.770)	0.0897 (0.814)
2.classif_obra	0.0000 (.)	0.0000 (.)			-1.0282 (1.225)	-1.0358 (1.198)
3.classif_obra	-0.1788 (1.553)	0.5590 (1.582)	-1.1853 (1.293)	-0.8245 (1.327)		
4.classif_obra	-1.0931 (1.177)	-1.0963 (1.154)	-2.3861** (0.774)	-2.3439** (0.774)	-2.4808** (0.774)	-2.3560** (0.774)
2.tipo_licit	-2.6953 (1.381)	-1.7184 (1.430)	-1.5593 (1.197)	-1.2261 (1.226)	-1.5646 (1.133)	-0.8333 (1.164)
3.tipo_licit	2.7464 (2.011)	3.2029 (1.974)	3.8819** (1.362)	3.6632** (1.365)	2.6991 (1.382)	2.7207* (1.360)
4.tipo_licit	-1.7993 (3.039)	-1.0353 (3.089)	3.1773 (2.793)	3.4583 (2.823)	3.3508 (2.317)	4.1855 (2.382)
5.tipo_licit	-0.0108 (1.438)	0.5033 (1.487)	-1.1923 (1.358)	-0.9954 (1.383)	-0.5474 (1.354)	-0.3250 (1.381)
_cons	130.0888*** (12.119)	106.9624** (14.244)	119.5507* (10.580)	105.0672** (12.085)	121.0948** (10.442)	104.0632** (12.096)
E.F. Tempo	Não	Sim	Não	Sim	Não	Sim
E.F Região	Não	Sim	Não	Sim	Não	Sim
Wald Test	17.94***	10.72***	11.43***	7.72***	14.81***	7.82***
N	1844	1844	2374	2374	2590	2590

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano *k* que é igual a um (1) se é do ano *k* e zero (0) caso contrário, onde *k* assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do *i*-ésimo município. Assume valor igual um (1) se pertence a região *g* e zero (0) caso contrário. *g* representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Tendência Linear – interação entre as variáveis socioeconômicas e a variável correspondente aos anos 2016, 2017, 2018. [iv] Erro-padrão entre parênteses; [v] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [vi] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

B5. Resultados das estimações do modelo probabilístico com variável instrumental e exclusão de tipos de licitação.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)					
	(1)	(2)	(3)	(4)	(5)	(6)
	<i>IVPROBIT1</i>	<i>IVPROBIT2</i>	<i>IVPROBIT3</i>	<i>IVPROBIT4</i>	<i>IVPROBIT5</i>	<i>IVPROBIT6</i>
	Tomada de Preço excluída		Carta Convite excluída		Concorrência excluída	
<i>Repassse</i>	-0.0471*** (0.006)	-0.0464*** (0.009)	-0.0539*** (0.003)	-0.0534*** (0.005)	-0.0536*** (0.003)	-0.0519*** (0.005)
<i>txdesoc</i>	0.0093 (0.015)	0.0065 (0.025)	0.0036 (0.008)	-0.0055 (0.009)	-0.0033 (0.007)	-0.0118 (0.010)

dens	0.0001 (0.000)	0.0002 (0.000)	0.0001 (0.000)	0.0002* (0.000)	0.0000 (0.000)	0.0002* (0.000)
txurban	0.0017 (0.004)	0.0026 (0.005)	0.0031 (0.002)	0.0040 (0.002)	0.0034 (0.002)	0.0043 (0.002)
gini	0.6088 (1.209)	2.9091 (1.636)	0.5053 (0.760)	1.5282 (1.237)	-0.0138 (0.743)	1.6574 (1.352)
prop_ens_sup	-0.0540* (0.027)	-0.1169** (0.042)	-0.0841** (0.026)	-0.1283*** (0.035)	-0.0795*** (0.021)	-0.1441*** (0.031)
lnpibpc	-0.4883*** (0.147)	-0.5279** (0.203)	-0.0654 (0.067)	-0.0304 (0.081)	-0.1346* (0.063)	-0.1187 (0.077)
IFGF	-0.2323 (0.273)	-0.3807 (0.325)	-0.1978 (0.162)	-0.2475 (0.187)	-0.2378 (0.150)	-0.1885 (0.179)
2.dsexo_pref	0.2573 (0.196)	0.3262 (0.285)	0.0980 (0.080)	0.1355 (0.092)	0.0658 (0.076)	0.1275 (0.097)
p_vot_pref	0.8898 (0.489)	0.6723 (0.664)	0.5848** (0.201)	0.6307** (0.232)	0.5318* (0.216)	0.5376* (0.243)
p_ver_pref	-0.2355 (0.398)	-0.3979 (0.590)	-0.0090 (0.176)	0.0786 (0.198)	-0.0829 (0.180)	0.0313 (0.219)
itm	-0.0003 (0.000)	-0.0003 (0.000)	-0.0001 (0.000)	-0.0002 (0.000)	-0.0000 (0.000)	-0.0001 (0.000)
idhm	0.9238 (1.131)	1.3795 (1.408)	0.4103 (0.620)	0.8533 (0.690)	0.1302 (0.612)	0.8279 (0.743)
reeleicao	-0.1696 (0.108)	-0.2678 (0.149)	-0.0226 (0.082)	-0.0597 (0.113)	-0.0500 (0.063)	-0.1037 (0.092)
lnpop	0.0593 (0.095)	0.1567 (0.147)	-0.0585 (0.048)	-0.0626 (0.055)	-0.0116 (0.046)	0.0080 (0.057)
2.classif_obra	-0.4540* (0.183)	-0.4157* (0.185)	-0.0741 (0.086)	-0.0987 (0.098)	-0.0565 (0.076)	-0.1190 (0.094)
3.classif_obra	-0.0897 (0.193)	-0.0338 (0.255)	-0.0039 (0.086)	0.0150 (0.095)	-0.0264 (0.084)	-0.0000 (0.100)
4.classif_obra	-0.2174* (0.087)	-0.2017* (0.096)	-0.1016* (0.051)	-0.0963 (0.054)	-0.1458** (0.050)	-0.1282* (0.058)
2.tipo_licit	0.0000 (.)	0.0000 (.)			-0.0681 (0.068)	-0.0424 (0.078)
3.tipo_licit	0.2672** (0.100)	0.2775* (0.117)	0.1775* (0.087)	0.1903* (0.092)		
4.tipo_licit	-0.1136 (0.239)	-0.1278 (0.312)	-0.0668 (0.201)	-0.0309 (0.230)	-0.0263 (0.182)	-0.0399 (0.222)
5.tipo_licit	-0.0489 (0.113)	-0.0891 (0.130)	-0.0883 (0.080)	-0.0868 (0.089)	-0.0840 (0.080)	-0.0742 (0.092)
_cons	6.6499*** (1.525)	1.6946 (3.780)	5.2997*** (0.972)	2.1830 (2.363)	6.0013*** (0.958)	1.7269 (2.526)
FIRST STAGE	Variável Dependente: <i>Repasse</i>					
part_pres	4.9103** (1.533)	4.5298** (1.555)	1.8004* (0.840)	1.8687* (0.886)	2.1063* (0.833)	2.6262** (0.890)
txdesoc	-0.1790 (0.196)	-0.3491 (0.225)	-0.0994 (0.111)	-0.1300 (0.134)	-0.1824 (0.107)	-0.2123 (0.131)
dens	-0.0008	-0.0008	-0.0002	0.0013	-0.0012	0.0004

	(0.001)	(0.001)	(0.001)	(0.001)	(0.001)	(0.001)
txurban	0.0724	0.0770	0.0766**	0.0906**	0.0896***	0.1085***
	(0.053)	(0.059)	(0.028)	(0.032)	(0.027)	(0.032)
gini	16.8924	33.9125	-5.9389	-5.1870	-16.6584	-16.2470
	(17.294)	(22.808)	(11.111)	(13.414)	(10.611)	(12.289)
prop_ens_sup	-0.8102*	-1.1908*	-0.9032**	-1.3448***	-1.0001***	-1.5285***
	(0.376)	(0.473)	(0.305)	(0.341)	(0.275)	(0.308)
lnpibpc	-6.8810***	-6.7380***	-1.5374	-1.0519	-2.6915**	-2.5913*
	(1.715)	(2.009)	(1.112)	(1.138)	(1.040)	(1.047)
IFGF	-0.9683	-6.4475	-5.4007*	-6.8052**	-5.3581*	-5.7132*
	(3.832)	(4.312)	(2.457)	(2.581)	(2.409)	(2.564)
2.dsexo_pref	1.2142	0.6891	1.3765	1.4050	0.5332	0.4376
	(2.440)	(2.794)	(1.290)	(1.372)	(1.249)	(1.347)
p_vot_pref	5.4858	1.5974	8.9908**	10.6358**	7.0165	7.1796
	(5.977)	(6.979)	(3.402)	(3.774)	(3.614)	(3.811)
p_ver_pref	4.1168	3.1606	3.9599	5.0879*	3.6797	6.0396*
	(4.721)	(4.885)	(2.457)	(2.443)	(2.497)	(2.547)
itm	-0.0044	-0.0044	0.0017	0.0009	0.0019	0.0015
	(0.003)	(0.003)	(0.002)	(0.002)	(0.002)	(0.002)
idhm	23.2682	29.0483	1.8686	9.7303	-4.0788	5.6090
	(16.312)	(17.224)	(9.673)	(10.346)	(9.368)	(10.089)
reeleicao	-2.1814	-2.9308	1.4962	1.2926	0.3044	0.0663
	(1.503)	(1.678)	(0.805)	(0.946)	(0.805)	(0.969)
lnpop	-0.3462	0.4531	-0.7172	-0.7070	0.0537	0.2213
	(1.285)	(1.413)	(0.811)	(0.869)	(0.778)	(0.825)
2.classif_obra	-5.3228*	-4.7218*	-0.2233	-0.1640	-0.3089	-0.5735
	(2.387)	(2.146)	(1.299)	(1.253)	(1.221)	(1.206)
3.classif_obra	-5.0855	-5.2468	-0.3648	0.2881	-1.3963	-1.0208
	(2.871)	(2.996)	(1.401)	(1.408)	(1.287)	(1.317)
4.classif_obra	-2.7245	-2.4912	-1.5251	-1.3948	-2.7116***	-2.6064**
	(1.391)	(1.424)	(0.836)	(0.837)	(0.821)	(0.825)
2.tipo_licit	0.0000	0.0000			-0.7940	-0.3365
	(.)	(.)			(1.111)	(1.136)
3.tipo_licit	3.7640*	3.8006*	2.3795	2.4721		
	(1.634)	(1.817)	(1.415)	(1.381)		
4.tipo_licit	3.3563	3.8669	3.1659	4.0403	3.3356	4.1222
	(2.508)	(2.725)	(2.343)	(2.408)	(2.335)	(2.392)
5.tipo_licit	-0.2859	-0.5668	-1.1190	-0.8796	-1.0803	-0.6361
	(1.666)	(1.744)	(1.267)	(1.302)	(1.284)	(1.313)
part_pres	4.9103**	4.5298**	1.8004*	1.8687*	2.1063*	2.6262**
	(1.533)	(1.555)	(0.840)	(0.886)	(0.833)	(0.890)
_cons	139.1739**	122.9010*	112.4687**	99.3246***	127.5063*	114.0139**
	*	**	*	**	**	*
	(19.902)	(21.508)	(10.923)	(12.723)	(10.500)	(12.187)
E.F. Tempo	Não	Sim	Não	Sim	Não	Sim
E.F Região	Não	Sim	Não	Sim	Não	Sim
Wald Test	9.57***	6.26**	17.08***	11.55***	21.04***	14.33***
N	986	986	2341	2341	2482	2482

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano **k** que é igual a um (1) se é do ano **k** e zero (0) caso contrário, onde **k** assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do *i*-ésimo município. Assume valor igual um (1) se pertence a região **g** e zero (0) caso contrário. **g** representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Tendência Linear – interação entre as variáveis socioeconômicas e a variável correspondente aos anos 2016, 2017, 2018. [iv] Erro-padrão entre parênteses; [v] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [vi] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

B6. Resultados das estimações do modelo probabilístico com variável instrumental e variáveis espaciais.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)				
	(1)	(2)	(3)	(4)	(5)
	IVPROBIT1	IVPROBIT2	IVPROBIT3	IVPROBIT4	IVPROBIT5
	Contiguidade	2 vizinhos mais próximos	3 vizinhos mais próximos	4 vizinhos mais próximos	5 vizinhos mais próximos
<i>Repassse</i>	-0.0525*** (0.006)	-0.0522*** (0.006)	-0.0521*** (0.006)	-0.0520*** (0.006)	-0.0520*** (0.006)
txdesoc	0.0168 (0.012)	-0.0053 (0.011)	0.0089 (0.011)	0.0067 (0.012)	0.0067 (0.012)
dens	-0.0000 (0.000)	0.0002 (0.000)	0.0002 (0.000)	0.0002 (0.000)	0.0002 (0.000)
txurban	0.0019 (0.003)	0.0030 (0.003)	0.0012 (0.004)	0.0024 (0.003)	0.0024 (0.003)
gini	3.0420 (1.924)	2.3465 (1.498)	1.6145 (1.423)	1.8464 (1.309)	1.8464 (1.309)
prop_ens_sup	-0.1132*** (0.027)	-0.1313*** (0.029)	-0.1609*** (0.035)	-0.1443*** (0.031)	-0.1443*** (0.031)
lnpibpc	0.1442 (0.089)	-0.0548 (0.094)	-0.0156 (0.089)	-0.0177 (0.087)	-0.0177 (0.087)
IFGF	-0.1189 (0.193)	-0.2882 (0.184)	-0.2893 (0.200)	-0.1576 (0.195)	-0.1576 (0.195)
1.dsexo_pref	0.0000 (.)	0.0000 (.)	0.0000 (.)	0.0000 (.)	0.0000 (.)
2.dsexo_pref	0.2117 (0.131)	0.2872* (0.113)	0.2192* (0.107)	0.2175 (0.112)	0.2175 (0.112)
p_vot_pref	0.9216*** (0.269)	0.7218** (0.278)	0.6275* (0.259)	0.5611* (0.251)	0.5611* (0.251)
p_ver_pref	-0.0234 (0.244)	-0.0869 (0.246)	-0.0180 (0.230)	0.0072 (0.240)	0.0072 (0.240)
itm	-0.0002 (0.000)	-0.0002 (0.000)	-0.0003 (0.000)	-0.0002 (0.000)	-0.0002 (0.000)
idhm	0.5690 (0.877)	0.1100 (0.839)	1.1658 (0.812)	1.4147 (0.784)	1.4147 (0.784)
reeleicao	-0.0535 (0.124)	-0.0020 (0.119)	-0.0501 (0.119)	-0.0766 (0.120)	-0.0766 (0.120)
lnpop	-0.1749* (0.076)	-0.0088 (0.063)	0.0079 (0.067)	-0.0624 (0.064)	-0.0624 (0.064)

2.classif_obra	-0.2131 (0.109)	-0.1788 (0.112)	-0.1807 (0.106)	-0.1640 (0.101)	-0.1640 (0.101)
3.classif_obra	0.0073 (0.104)	-0.0009 (0.096)	0.0079 (0.106)	0.0180 (0.104)	0.0180 (0.104)
4.classif_obra	-0.1559** (0.053)	-0.1392** (0.053)	-0.1240* (0.053)	-0.1265* (0.052)	-0.1265* (0.052)
2.tipo_licit	-0.0300 (0.080)	-0.0312 (0.077)	-0.0449 (0.078)	-0.0504 (0.078)	-0.0504 (0.078)
3.tipo_licit	0.2459** (0.092)	0.2766** (0.094)	0.2950** (0.097)	0.2689** (0.097)	0.2689** (0.097)
4.tipo_licit	-0.0857 (0.273)	-0.0288 (0.267)	-0.0450 (0.281)	-0.0477 (0.266)	-0.0477 (0.266)
5.tipo_licit	-0.0724 (0.092)	-0.0321 (0.094)	-0.0610 (0.099)	-0.0480 (0.095)	-0.0480 (0.095)
wtxdesoc	-0.0382 (0.025)				
wdens	0.0006*** (0.000)				
wtxurban	-0.0218** (0.008)				
wgini	-8.2166** (2.714)				
wprop_ens_sup	0.1857** (0.060)				
wlnpibpc	0.4294 (0.250)				
wIFGF	1.1897 (0.622)				
wdsexo_pref	0.3950 (0.274)				
wp_vot_pref	2.3105* (1.084)				
wp_ver_pref	-1.1732* (0.565)				
witm	0.0010 (0.001)				
widhm	-2.8145 (2.535)				
wreeleicao	-0.8497*** (0.205)				
wlnpop	0.0795 (0.138)				
wdlicit1	-0.1260 (0.592)				
wdlicit2	0.9944 (0.526)				
wdlicit3	-0.7972 (0.671)				
wdlicit4	2.7879				

	(2.094)		
wdlicit5	0.0000		
	(.)		
w2txdesocI		-0.0135	
		(0.017)	
w2densI		-0.0001	
		(0.000)	
w2txurbanI		-0.0005	
		(0.003)	
w2giniI		-2.3294	
		(1.331)	
w2prop_ens_sup I		0.1529***	
		(0.043)	
w2lnpibpcI		-0.0049	
		(0.211)	
w2IFGFI		1.2356*	
		(0.581)	
w2dsexo_prefI		0.1189	
		(0.168)	
w2p_vot_prefI		0.9393*	
		(0.472)	
w2p_ver_prefI		0.0249	
		(0.333)	
w2itmI		-0.0001	
		(0.000)	
w2idhmI		-0.2495	
		(1.328)	
w2reeleicaoI		-0.1105	
		(0.113)	
w2lnpopI		1.0199	
		(0.749)	
w2dlicit1I		0.1794	
		(0.340)	
w2dlicit2I		-0.1577	
		(0.337)	
w2dlicit3I		-0.5187	
		(0.410)	
w2dlicit4I		0.2587	
		(0.994)	
w2dlicit5I		0.0000	
		(.)	
w3txdesocI			-0.0231
			(0.019)
w3densI			0.0000
			(0.000)
w3txurbanI			0.0055
			(0.005)
w3giniI			-7.2364**

w3prop_ens_sup I	(2.693) 0.1577***	
w3lnpibpcI	(0.043) 0.2922	
w3IFGFI	(0.247) 1.8199**	
w3dsexo_prefI	(0.615) 0.2317	
w3p_vot_prefI	(0.217) 1.6013**	
w3p_ver_prefI	(0.559) 0.5348	
w3itmI	(0.591) -0.0009*	
w3idhmI	(0.000) 1.2826	
w3reeleicaoI	(1.452) -0.4588*	
w3lnpopI	(0.184) -0.0421	
w3dlicit1I	(0.098) 0.5597	
w3dlicit2I	(0.367) 0.4854	
w3dlicit3I	(0.473) 0.5294	
w3dlicit4I	(0.588) -0.2524	
w3dlicit5I	(1.592) 0.0000	
	(.)	
w4txdesocI		-0.0074
w4densI		(0.023)
w4txurbanI		-0.0000
w4giniI		(0.000)
w4prop_ens_sup I		-0.0007
w4lnpibpcI		(0.004)
w4IFGFI		-6.9682*
w4dsexo_prefI		(2.886)
		0.1507**
		(0.050)
		0.2703
		(0.216)
		1.9488**
		(0.731)
		0.1176
		(0.295)

w4p_vot_prefI	1.2895	
	(0.706)	
w4p_ver_prefI	0.3651	
	(0.633)	
w4itmI	-0.0005	
	(0.001)	
w4idhmI	2.0696	
	(1.932)	
w4reeleicaoI	-0.4544*	
	(0.201)	
w4lnpopI	-0.0716	
	(0.119)	
w4dlicit1I	0.3888	
	(0.473)	
w4dlicit2I	0.2380	
	(0.572)	
w4dlicit3I	0.5842	
	(0.740)	
w4dlicit4I	0.4787	
	(1.684)	
w4dlicit5I	0.0000	
	(.)	
w5txdesocI		-0.0074
		(0.023)
w5densI		-0.0000
		(0.000)
w5txurbanI		-0.0007
		(0.004)
w5giniI		-6.9682*
		(2.886)
w5prop_ens_sup I		0.1507**
		(0.050)
w5lnpibpcI		0.2703
		(0.216)
w5IFGFI		1.9488**
		(0.731)
w5dsexo_prefI		0.1176
		(0.295)
w5p_vot_prefI		1.2895
		(0.706)
w5p_ver_prefI		0.3651
		(0.633)
w5itmI		-0.0005
		(0.001)
w5idhmI		2.0696
		(1.932)
w5reeleicaoI		-0.4544*
		(0.201)

w5lnpopI					-0.0716 (0.119)
w5dlicit1I					0.3888 (0.473)
w5dlicit2I					0.2380 (0.572)
w5dlicit3I					0.5842 (0.740)
w5dlicit4I					0.4787 (1.684)
w5dlicit5I					0.0000 (.)
_cons	-0.2382 (3.637)	-9.7380 (9.931)	-1.6555 (5.028)	-0.7767 (4.893)	-0.7767 (4.893)
<hr/>					
FIRST STAGE	Variável Dependente: <i>Repasse</i>				
part_pres	1.9354* (0.986)	1.9669* (0.980)	1.9486* (0.955)	1.9778* (0.955)	1.9778* (0.955)
txdesoc	0.1356 (0.157)	-0.1650 (0.155)	0.0234 (0.152)	-0.0318 (0.151)	-0.0318 (0.151)
dens	-0.0019 (0.002)	-0.0001 (0.001)	-0.0002 (0.001)	0.0000 (0.001)	0.0000 (0.001)
txurban	0.0526 (0.032)	0.0899** (0.034)	0.0819* (0.033)	0.0888* (0.035)	0.0888* (0.035)
gini	3.2481 (14.559)	6.5924 (15.117)	-4.4515 (12.839)	1.2741 (13.077)	1.2741 (13.077)
prop_ens_sup	-1.6524*** (0.383)	-1.6511*** (0.364)	-1.9195*** (0.379)	-1.8643*** (0.396)	-1.8643*** (0.396)
lnpibpc	2.0131 (1.253)	-0.6112 (1.274)	-0.7440 (1.183)	-0.8835 (1.137)	-0.8835 (1.137)
IFGF	-4.2669 (2.535)	-6.4723** (2.476)	-7.2691** (2.488)	-5.2553* (2.490)	-5.2553* (2.490)
2.dsexo_pref	0.7261 (1.342)	2.7234 (1.396)	1.8337 (1.366)	1.6660 (1.444)	1.6660 (1.444)
p_vot_pref	12.8066** (3.929)	8.6852* (3.800)	8.0717* (3.667)	7.5357* (3.763)	7.5357* (3.763)
p_ver_pref	3.7076 (2.583)	2.8684 (2.596)	3.3915 (2.576)	4.1575 (2.688)	4.1575 (2.688)
itm	0.0000 (0.002)	0.0002 (0.002)	-0.0007 (0.002)	-0.0005 (0.002)	-0.0005 (0.002)
idhm	2.2358 (11.150)	-6.8172 (10.830)	10.2674 (10.746)	14.8436 (10.682)	14.8436 (10.682)
reeleicao	1.4650 (0.946)	2.0840* (0.941)	1.3393 (0.956)	1.1260 (0.969)	1.1260 (0.969)
lnpop	-1.5326 (0.994)	-0.0058 (0.898)	0.2140 (0.946)	-0.4787 (0.984)	-0.4787 (0.984)
2.classif_obra	-1.6708 (1.135)	-1.0919 (1.170)	-1.3442 (1.142)	-1.1644 (1.170)	-1.1644 (1.170)
3.classif_obra	-0.7676 (1.281)	-0.3538 (1.320)	-0.8957 (1.327)	-0.7095 (1.307)	-0.7095 (1.307)

4.classif_obra	-2.2451**	-2.0749**	-2.0073**	-2.0606**	-2.0606**
	(0.757)	(0.774)	(0.769)	(0.768)	(0.768)
2.tipo_licit	-0.1414	-0.5560	-0.6463	-0.5999	-0.5999
	(1.133)	(1.125)	(1.123)	(1.135)	(1.135)
3.tipo_licit	3.4461*	3.7612**	3.8739**	3.4875*	3.4875*
	(1.340)	(1.330)	(1.323)	(1.364)	(1.364)
4.tipo_licit	3.7852	4.5934	4.6400*	4.4633	4.4633
	(2.342)	(2.395)	(2.326)	(2.343)	(2.343)
5.tipo_licit	-0.9211	-0.0674	-0.2562	-0.3058	-0.3058
	(1.296)	(1.312)	(1.317)	(1.321)	(1.321)
wtxdesoc	-0.8207*				
	(0.332)				
wdens	0.0105***				
	(0.003)				
wtxurban	-0.2142*				
	(0.086)				
wgini	-108.5631**				
	(37.242)				
wprop_ens_sup	2.7188**				
	(0.922)				
wlnpibpc	3.7785				
	(3.027)				
wIFGF	16.4038				
	(8.702)				
wdsexo_pref	8.8137*				
	(3.684)				
wp_vot_pref	58.4495***				
	(10.594)				
wp_ver_pref	-20.1193*				
	(8.253)				
witm	-0.0066				
	(0.010)				
widhm	-13.1881				
	(30.362)				
wreeleicao	-12.3615***				
	(2.947)				
wlnpop	0.9633				
	(2.066)				
wdlicit1	6.1782				
	(7.533)				
wdlicit2	15.0237				
	(7.754)				
wdlicit3	-9.1689				
	(9.768)				
wdlicit4	19.6655				
	(26.589)				
wdlicit5	0.0000				
	(.)				
w2txdesocI		-0.2377			

	(0.250)	
w2densI	-0.0008	
	(0.001)	
w2txurbanI	-0.0268	
	(0.051)	
w2giniI	-32.3218	
	(18.762)	
w2prop_ens_sup	2.9376***	
I		
	(0.591)	
w2lnpibpcI	-2.9928	
	(2.721)	
w2IFGFI	9.3380	
	(5.989)	
w2dsexo_prefI	2.3639	
	(2.352)	
w2p_vot_prefI	11.3536	
	(6.212)	
w2p_ver_prefI	0.2825	
	(4.445)	
w2itmI	-0.0061	
	(0.005)	
w2idhmI	8.4719	
	(19.206)	
w2reeleicaoI	-1.9945	
	(1.671)	
w2lnpopI	9.2264	
	(9.643)	
w2dlicit1I	7.4711	
	(4.075)	
w2dlicit2I	0.1289	
	(4.901)	
w2dlicit3I	-6.1672	
	(5.743)	
w2dlicit4I	5.4786	
	(15.188)	
w2dlicit5I	0.0000	
	(.)	
w3txdesocI		-0.4958
		(0.284)
w3densI		0.0010
		(0.001)
w3txurbanI		0.0318
		(0.066)
w3giniI		-75.6144**
		(28.768)
w3prop_ens_sup		2.2566***
I		
		(0.595)

w3lnpibpcI	0.3150 (2.469)	
w3IFGFI	20.4391** (7.631)	
w3dsexo_prefI	2.1252 (3.127)	
w3p_vot_prefI	27.7031*** (7.751)	
w3p_ver_prefI	0.5557 (6.628)	
w3itmI	-0.0178** (0.006)	
w3idhmI	21.0752 (22.123)	
w3reeleicaoI	-5.0932* (2.466)	
w3lnpopI	-0.2161 (1.399)	
w3dlicit1I	9.4443 (5.074)	
w3dlicit2I	6.3950 (6.339)	
w3dlicit3I	1.8805 (7.029)	
w3dlicit4I	13.5527 (21.482)	
w3dlicit5I	0.0000 (.)	
w4txdesocI		-0.3691 (0.317)
w4densI		0.0010 (0.001)
w4txurbanI		-0.0247 (0.068)
w4giniI		-74.2166* (35.653)
w4prop_ens_sup I		2.2919** (0.738)
w4lnpibpcI		1.5732 (2.849)
w4IFGFI		18.3320* (7.498)
w4dsexo_prefI		3.5919 (4.212)
w4p_vot_prefI		24.1839* (10.440)
w4p_ver_prefI		-4.5479 (6.748)

w4itmI	-0.0156*	
	(0.007)	
w4idhmI	12.6631	
	(26.867)	
w4reeleicaoI	-5.0075	
	(2.976)	
w4lnpopI	-0.8879	
	(1.672)	
w4dlicit1I	3.7606	
	(6.588)	
w4dlicit2I	0.3015	
	(7.675)	
w4dlicit3I	0.0309	
	(9.177)	
w4dlicit4I	29.4844	
	(22.524)	
w4dlicit5I	0.0000	
	(.)	
w5txdesocI		-0.3691
		(0.317)
w5densI		0.0010
		(0.001)
w5txurbanI		-0.0247
		(0.068)
w5giniI		-74.2166*
		(35.653)
w5prop_ens_sup I		2.2919**
		(0.738)
w5lnpibpciI		1.5732
		(2.849)
w5IFGFI		18.3320*
		(7.498)
w5dsexo_prefI		3.5919
		(4.212)
w5p_vot_prefI		24.1839*
		(10.440)
w5p_ver_prefI		-4.5479
		(6.748)
w5itmI		-0.0156*
		(0.007)
w5idhmI		12.6631
		(26.867)
w5reeleicaoI		-5.0075
		(2.976)
w5lnpopI		-0.8879
		(1.672)
w5dlicit1I		3.7606
		(6.588)

w5dlicit2I					0.3015 (7.675)
w5dlicit3I					0.0309 (9.177)
w5dlicit4I					29.4844 (22.524)
w5dlicit5I					0.0000 (.)
_cons	61.9577 (37.109)	14.8574 (91.136)	87.1114** (29.258)	95.4926** (35.692)	95.4926** (35.692)
E.F. Tempo	Sim	Sim	Sim	Sim	Sim
E.F Região	Sim	Sim	Sim	Sim	Sim
Wald Test	4.56**	4.56**	4.31*	5.05*	5.05*
N	2736	2736	2736	2736	2736

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano **k** que é igual a um (1) se é do ano **k** e zero (0) caso contrário, onde **k** assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do *i*-ésimo município. Assume valor igual um (1) se pertence a região **g** e zero (0) caso contrário. **g** representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Tendência Linear – interação entre as variáveis socioeconômicas e a variável correspondente aos anos 2016, 2017, 2018. [iv] Erro-padrão entre parênteses; [v] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [vi] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

B7. Resultados das estimações do modelo probabilístico com variável instrumental alternativa.

Variáveis Independentes	Variável Dependente: <i>Paralisada</i> (dicotômica)				
	(1) IVPROBIT1	(2) IVPROBIT2	(3) IVPROBIT3	(4) IVPROBIT4	(5) IVPROBIT5
<i>Repassse</i>	-0.0441*** (0.008)	0.0536*** (0.004)	0.0530*** (0.004)	0.0553*** (0.002)	0.0553*** (0.002)
<i>txdesoc</i>		0.0147 (0.008)	0.0144 (0.008)	0.0108 (0.007)	
<i>dens</i>		0.0001 (0.000)	0.0001 (0.000)	-0.0000 (0.000)	
<i>txurban</i>		-0.0059*** (0.002)	-0.0056*** (0.002)	-0.0060*** (0.002)	
<i>gini</i>		0.8980 (0.818)	1.1073 (0.874)	0.7094 (1.056)	
<i>prop_ens_sup</i>		0.0267 (0.032)	0.0208 (0.032)	0.0683* (0.029)	
<i>lnpibpc</i>		0.1429* (0.057)	0.1173* (0.059)	0.1111 (0.057)	
<i>IFGF</i>		0.2845* (0.134)	0.2883* (0.139)	0.3297* (0.141)	0.3296* (0.142)
<i>2.dsexo_pref</i>		-0.0379 (0.069)	-0.0264 (0.069)	-0.0344 (0.076)	-0.0344 (0.076)
<i>p_vot_pref</i>		-0.2388 (0.293)	-0.1552 (0.286)	-0.3748 (0.224)	-0.3749 (0.224)

p_ver_pref	-0.3415 (0.248)	-0.3824 (0.250)	-0.2856 (0.163)	-0.2856 (0.163)	
itm	-0.0001 (0.000)	-0.0002 (0.000)	-0.0000 (0.000)	-0.0000 (0.000)	
idhm	0.1299 (0.564)	0.3455 (0.563)	-0.3484 (0.542)		
reeleicao	-0.1172 (0.099)	-0.1365 (0.101)	-0.0652 (0.080)	-0.0652 (0.080)	
lnpop	0.0302 (0.042)	0.0312 (0.044)	0.0262 (0.045)		
2.classif_obra		-0.0259 (0.097)	0.0228 (0.080)	0.0228 (0.079)	
3.classif_obra		0.1019 (0.085)	0.0492 (0.074)	0.0492 (0.074)	
4.classif_obra		0.1090 (0.057)	0.1233** (0.047)	0.1233** (0.047)	
2.tipo_licit		0.0735 (0.072)	0.0499 (0.065)	0.0499 (0.065)	
3.tipo_licit		-0.0832 (0.108)	-0.1322 (0.085)	-0.1322 (0.085)	
4.tipo_licit		-0.3658 (0.230)	-0.2681 (0.166)	-0.2680 (0.166)	
5.tipo_licit		0.0275 (0.082)	0.0338 (0.075)	0.0338 (0.075)	
c.txdesoc#c.ano				0.0000 (0.000)	
c.gini#c.ano				0.0004 (0.001)	
c.txurban#c.ano				-0.0000*** (0.000)	
c.dens#c.ano				-0.0000 (0.000)	
c.prop_ens_sup#c.ano				0.0000* (0.000)	
c.lnpiipc#c.ano				0.0001 (0.000)	
c.idhm#c.ano				-0.0002 (0.000)	
c.lnpop#c.ano				0.0000 (0.000)	
_cons	3.4278** (1.127)	-7.2512*** (0.654)	-7.3553*** (0.623)	-6.9256*** (1.490)	-6.9248*** (1.489)
<hr/>					
FIRST STAGE	Variável Dependente: <i>Repasse</i>				
ideol	-1.6580* (0.760)	0.7081 (0.737)	0.8767 (0.729)	0.4646 (0.758)	0.4645 (0.758)
txdesoc		-0.1744 (0.105)	-0.1522 (0.105)	-0.1855 (0.127)	
dens		-0.0009 (0.001)	-0.0008 (0.001)	0.0007 (0.001)	

txurban	0.0974*** (0.025)	0.0908*** (0.026)	0.1043*** (0.030)	
gini	-6.1870 (9.809)	-6.5648 (10.050)	-4.3682 (11.856)	
prop_ens_sup	-0.9238*** (0.253)	-0.9210*** (0.253)	-1.4620*** (0.291)	
lnpibpc	-2.7602** (0.988)	-2.3004* (1.006)	-2.0137* (1.024)	
IFGF	-5.2233* (2.290)	-5.1082* (2.289)	-5.6930* (2.450)	-5.6912* (2.450)
2.dsexo_pref	0.9293 (1.194)	0.7710 (1.176)	0.8741 (1.271)	0.8743 (1.271)
p_vot_pref	7.5967* (3.321)	6.6617* (3.300)	7.5545* (3.569)	7.5540* (3.569)
p_ver_pref	2.9023 (2.354)	2.7919 (2.331)	4.1516 (2.333)	4.1517 (2.333)
itm	0.0005 (0.002)	0.0005 (0.002)	0.0000 (0.002)	0.0000 (0.002)
idhm	1.7526 (8.799)	-1.8613 (8.809)	7.4734 (9.436)	
reeleicao	0.6535 (0.765)	0.5924 (0.760)	0.4457 (0.876)	0.4455 (0.876)
lnpop	-0.6354 (0.752)	-0.7494 (0.762)	-0.4730 (0.795)	
2.classif_obra		-0.9244 (1.220)	-0.9013 (1.193)	-0.9013 (1.193)
3.classif_obra		-1.3167 (1.283)	-0.8152 (1.297)	-0.8153 (1.297)
4.classif_obra		-2.4492** (0.772)	-2.3345** (0.773)	-2.3345** (0.773)
2.tipo_licit		-1.6692 (1.104)	-1.0254 (1.132)	-1.0254 (1.132)
3.tipo_licit		2.7490* (1.369)	2.7361* (1.349)	2.7356* (1.349)
4.tipo_licit		3.1305 (2.346)	3.8872 (2.385)	3.8874 (2.385)
5.tipo_licit		-1.0705 (1.283)	-0.8104 (1.316)	-0.8102 (1.316)
c.txdesoc#c.ano				-0.0001 (0.000)
c.gini#c.ano				-0.0022 (0.006)
c.txurban#c.ano				0.0001*** (0.000)
c.dens#c.ano				0.0000 (0.000)
c.prop_ens_sup#c.ano				-0.0007*** (0.000)
c.lnpibpc#c.ano				-0.0010*

c.idhm#c.ano					(0.001)
					0.0037
c.lnpop#c.ano					(0.005)
					-0.0002
					(0.000)
_cons	94.7195***	124.0545**	125.3865*	109.5607**	109.5640**
		*	**	*	*
	(0.595)	(10.236)	(10.132)	(11.763)	(11.763)
E.F. Tempo	Não	Não	Não	Sim	Sim
E.F Região	Não	Não	Não	Sim	Sim
Tendência Linear	Não	Não	Não	Não	Sim
Wald Test	4.48*	3.73	4.56*	3.56	3.56
N	2736	2736	2736	2736	2736

Nota: [i] E. F. Tempo - vetor de variável *dummy* do ano **k** que é igual a um (1) se é do ano **k** e zero (0) caso contrário, onde **k** assume valores entre 2016 a 2018; [ii] E. F. Região – vetor de variável *dummy* que representa a região de desenvolvimento do **i**-ésimo município. Assume valor igual um (1) se pertence a região **g** e zero (0) caso contrário. **g** representa as regiões de desenvolvimento: Agreste Central, Agreste Meridional, Agreste Setentrional, Mata Norte, Mata Sul, Metropolitana, Pajeú, Sertão Central, Sertão de Itaparica, Sertão do Araripe, Sertão do Moxotó, Sertão do São Francisco; [iii] Tendência Linear – interação entre as variáveis socioeconômicas e a variável correspondente aos anos 2016, 2017, 2018. [iv] Erro-padrão entre parênteses; [v] Wald Test – teste de exogeneidade das variáveis explicativas, onde a hipótese nula é: variáveis explicativas exógenas; [vi] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

APÊNDICE C – RESULTADO COMPLETO DAS ESTIMAÇÕES

C1. Resultados das estimações do modelo de Diferenças em Diferenças.

Variáveis Independentes	Variável Dependente: <i>lntxhomi</i>		
	DID1 (1)	DID2 (2)	DID3 (3)
Dtime	-0.0005 (0.053)	-0.0005 (0.053)	-0.3695** (0.114)
Treated	-0.2837 (0.221)	-0.8317*** (0.182)	-0.8316*** (0.182)
Efb	-0.1073* (0.047)	-0.1073* (0.047)	-0.1074* (0.048)
Espvida		0.2096* (0.089)	0.2096* (0.088)
Fectot		-1.6066 (0.891)	-1.6066 (0.884)
E_anosestudo		1.1673** (0.452)	1.1673** (0.448)
lnrdpct		-0.9456 (1.553)	-0.9456 (1.541)
Agua_esgoto		0.0329 (0.082)	0.0329 (0.082)
T_luz		-2.4799*** (0.457)	-2.4799*** (0.453)
Pmasc20_29		6.6248 (9.436)	6.6248 (9.388)
Gini		-9.3940* (4.573)	-9.3940* (4.536)
P_formal		0.0155 (0.019)	0.0155 (0.019)
lnpop		-0.0430 (0.326)	-0.0430 (0.323)
_Cons	1.6899*** (0.219)	235.2030*** (43.991)	235.1351*** (43.621)
E.F. Mês	Sim	Sim	Não
E.F. Ano	Sim	Sim	Não
E.F Cidade	Sim	Sim	Sim
E.F. Mês*Ano	Não	Não	Sim
R2	0.3277	0.3277	0.3359
Observações	4134	4134	4134

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

C2. Resultados das estimações do modelo de Diferenças em Diferenças com *leads* e *lags*.

Variáveis Independentes	Variável Dependente: <i>Intxhomi</i>		
	DID1 (1)	DID2 (2)	DID3 (3)
Dtime_1	-0.0603 (0.045)	-0.0603 (0.045)	0.1794 (0.111)
Dtime_2	-0.0375 (0.046)	-0.0375 (0.046)	0.2172* (0.109)
Dtime	0.0034 (0.061)	0.0034 (0.061)	-0.3697** (0.114)
Dtime1	0.0344 (0.126)	0.0344 (0.126)	-0.2645* (0.124)
Treated	-0.3002 (0.223)	-0.8482*** (0.186)	-0.8482*** (0.186)
Efb	-0.1029* (0.052)	-0.1029* (0.052)	-0.1031* (0.052)
Efb_1	0.0074 (0.060)	0.0074 (0.060)	0.0079 (0.060)
Efb_2	0.0776 (0.064)	0.0776 (0.064)	0.0774 (0.064)
Efb1	-0.2675 (0.140)	-0.2675 (0.140)	-0.2678 (0.141)
Espvida		0.2096* (0.089)	0.2096* (0.088)
Fectot		-1.6066 (0.890)	-1.6066 (0.885)
E_anosestudo		1.1673** (0.452)	1.1673** (0.449)
Lnrpct		-0.9456 (1.553)	-0.9456 (1.543)
Agua_esgoto		0.0329 (0.082)	0.0329 (0.082)
T_luz		-2.4799*** (0.458)	-2.4799*** (0.454)
Pmasc20_29		6.6248 (9.442)	6.6248 (9.394)
Gini		-9.3940* (4.577)	-9.3940* (4.542)
P_formal		0.0155 (0.019)	0.0155 (0.019)
Inpop		-0.0430 (0.326)	-0.0430 (0.324)
_Cons	1.7020*** (0.219)	235.2151*** (44.060)	235.1362*** (43.688)
E.F. Mês	Sim	Sim	Não
E.F. Ano	Sim	Sim	Não
E.F. Cidade	Sim	Sim	Sim
E.F. Mês*Ano	Não	Não	Sim
R2	0.3277	0.3277	0.3359

Observações 4134 4134 4134

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

C3. Resultados das estimações do modelo de Diferenças em Diferenças para o teste de falsificação.

A	Variável Dependente: <i>lntxsuic</i>			Variável Dependente: <i>lntxafog</i>		
	(1)	(2)	(3)	(4)	(5)	(6)
Variáveis Independentes	SUIC1	SUIC2	SUIC3	AFOG1	AFOG2	AFOG3
Dtime	0.0067 (0.005)	0.0067 (0.005)	-0.0015 (0.002)	-0.0025 (0.002)	-0.0025 (0.002)	-0.0001 (0.000)
Treated	-0.0485 (0.051)	-0.0047 (0.013)	-0.0047 (0.013)	-0.0009 (0.001)	-0.0009 (0.001)	-0.0033 (0.003)
Efb	-0.0061 (0.005)	-0.0061 (0.005)	-0.0061 (0.005)	0.0016 (0.002)	0.0016 (0.002)	0.0016 (0.002)
Espvida		0.0232 (0.015)	0.0232 (0.015)			-0.0013 (0.001)
Fectot		-0.1798 (0.162)	-0.1798 (0.161)			-0.0044 (0.005)
E_anosestudo		0.0666 (0.067)	0.0666 (0.067)			0.0018 (0.002)
Inrdpct		-0.3280 (0.244)	-0.3280 (0.244)			0.0037 (0.007)
Agua_esgoto		-0.0160 (0.012)	-0.0160 (0.012)			0.0001 (0.000)
T_luz		0.0749 (0.043)	0.0749 (0.043)			0.0001 (0.002)
Pmasc20_29		-1.1857 (1.007)	-1.1857 (1.019)			-0.1231 (0.132)
Gini		0.8479 (0.553)	0.8479 (0.553)			-0.0266 (0.031)
P_formal		0.0037 (0.003)	0.0037 (0.003)			0.0003 (0.000)
lnpop		-0.0630 (0.054)	-0.0630 (0.054)			-0.0017 (0.002)
_Cons	0.0532 (0.050)	-7.0885 (3.838)	-7.0918 (3.895)	0.0015 (0.002)	0.0015 (0.002)	0.0756 (0.224)
B	Variável Dependente: <i>lntxacid</i>			Variável Dependente: <i>lntxotacid</i>		
Variáveis independentes	ACID1	ACID2	ACID 3	OTACID1	OTACID 2	OTACID 3
Dtime	0.0492** (0.019)	0.0492** (0.019)	-0.0982** (0.034)	-0.0818 (0.044)	-0.0818 (0.044)	0.3033** (0.112)
Treated	-0.1064 (0.090)	-0.480*** (0.106)	-0.4805*** (0.106)	0.0587 (0.079)	1.068*** (0.180)	1.06*** (0.180)
Efb	0.0107 (0.022)	0.0107 (0.022)	0.0107 (0.022)	-0.0202 (0.030)	-0.0202 (0.030)	-0.0205 (0.030)
Espvida		0.0563	0.0563		0.0410	0.0410

		(0.051)	(0.051)		(0.043)	(0.044)
Fectot		-0.4175	-0.4175		-4.58***	-4.58***
		(0.394)	(0.392)		(0.667)	(0.667)
E_anosestudo		0.5436*	0.5436*		2.8385***	2.8385**
		(0.220)	(0.217)		(0.393)	(0.392)
Inrdpct		-0.3703	-0.3703		-	-
					11.7163***	11.7163*
		(0.752)	(0.748)		(1.210)	(1.211)
Agua_esgoto		-0.0150	-0.0150		-0.7660***	-
						0.7660**
		(0.037)	(0.037)		(0.075)	(0.074)
T_luz		-0.2517	-0.2517		4.1901***	4.1901**
		(0.252)	(0.253)		(0.397)	(0.399)
Pmasc20_29		2.8447	2.8447		-12.7836	-12.7836
		(5.923)	(5.962)		(8.851)	(8.876)
Gini		-1.9726	-1.9726		45.6268***	45.6268*
		(2.289)	(2.270)		(3.885)	(3.876)
P_formal		0.0242*	0.0242*		0.1050***	0.1050**
		(0.012)	(0.012)		(0.012)	(0.012)
Inpop		-0.2499	-0.2499		-2.1862***	-
						2.1862**
		(0.168)	(0.167)		(0.222)	(0.222)
_Cons	0.1372	21.3680	21.4229	0.0251	-	-
					361.9158*	361.972
					**	0***
		(0.088)	(23.575)	(23.660)	(0.080)	(37.906)
E.F. Mês	Sim	Sim	Não	Sim	Sim	Não
E.F. Ano	Sim	Sim	Não	Sim	Sim	Não
E.F. Cidade	Sim	Sim	Sim	Sim	Sim	Sim
E.F. Mês*Ano	Não	Não	Sim	Não	Não	Sim
(A) R2	0.0257	0.0257	0.0337	0.0224	0.0224	0.0300
(B) R2	0.1292	0.1292	0.1389	0.4541	0.4541	0.4589
Observações	4134	4134	4134	4134	4134	4134

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

C4. Resultados das estimações do modelo de Diferenças em Diferenças para o teste de validação.

Variável Dependente: <i>lntxover</i>		
OVER1	OVER 2	OVER 3

Variáveis Independentes	(1)	(2)	(3)
Dtime	0.0003 (0.002)	0.0003 (0.002)	0.0029 (0.003)
Treated	0.0013* (0.001)	-0.0112 (0.009)	-0.0112 (0.009)
Efb	-0.0024* (0.001)	-0.0024* (0.001)	-0.0024* (0.001)
Espvida		0.0012 (0.003)	0.0012 (0.003)
Fectot		-0.0241 (0.021)	-0.0241 (0.021)
E_anosestudo		0.0058 (0.007)	0.0058 (0.007)
Lnrpct		-0.0434 (0.045)	-0.0434 (0.045)
Agua_esgoto		-0.0020 (0.002)	-0.0020 (0.002)
T_luz		0.0340 (0.029)	0.0340 (0.029)
Pmasc20_29		-0.8211 (0.684)	-0.8211 (0.683)
Gini		0.0936 (0.101)	0.0936 (0.102)
P_formal		0.0015 (0.001)	0.0015 (0.001)
lnpop		-0.0107 (0.010)	-0.0107 (0.010)
_Cons	-0.0001 (0.001)	-3.1359 (2.666)	-3.1363 (2.661)
E.F. Mês	Sim	Sim	Não
E.F. Ano	Sim	Sim	Não
E.F. Cidade	Sim	Sim	Sim
E.F. Mês*Ano	Não	Não	Sim
R2	0.0227	0.0227	0.0318
Observações	4134	4134	4134

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

C5. Resultados das estimações do modelo de Diferenças em Diferenças com PSM e sem Capitais.

Variáveis Independentes	Variável Dependente: <i>lntxhom</i>					
	Propensity Score Matching			Capitais Excluídas		
	(1) PSM1	(2) PSM2	(3) PSM3	(4) CAP1	(5) CAP2	(6) CAP3
Dtime	-0.0018	-0.0016	-0.3695**	-0.0015	-0.0015	-0.3631**

	(0.062)	(0.056)	(0.120)	(0.056)	(0.056)	(0.119)
Treated	0.0406	0.0410	0.0410	-0.2824	-0.1181	-0.1180
	(0.047)	(0.043)	(0.043)	(0.221)	(0.462)	(0.459)
Efb	-0.1066*	-0.1071*	-0.1072*	-0.1097*	-0.1097*	-0.1098*
	(0.054)	(0.053)	(0.053)	(0.048)	(0.048)	(0.049)
	(0.072)	(0.064)		(0.064)	(0.064)	
Psc	0.7277***	-0.7001***	-0.7004***			
	(0.070)	(0.082)	(0.081)			
Espvida		0.0652***	0.0649***		0.4733*	0.4733*
		(0.015)	(0.015)		(0.214)	(0.212)
Fectot		0.0658	0.0643		0.8023	0.8023
		(0.065)	(0.065)		(0.434)	(0.429)
E_anosestudo		-0.1192***	-0.1197***		0.1642	0.1642
		(0.026)	(0.026)		(0.103)	(0.102)
Lnrpct		-0.8390***	-0.8387***		1.6258***	1.6258***
		(0.064)	(0.063)		(0.443)	(0.440)
Agua_esgoto		-0.0048	-0.0048		0.1453***	0.1453***
		(0.003)	(0.003)		(0.033)	(0.033)
T_luz		0.0874**	0.0868**		-3.9789***	-3.9789***
		(0.027)	(0.027)		(0.708)	(0.700)
Pmasc20_29		12.6240***	12.6383***		74.2790*	74.2790*
		(1.447)	(1.465)		(36.367)	(36.026)
Gini		0.2926	0.2867		-5.3541	-5.3541
		(0.351)	(0.351)		(6.479)	(6.428)
P_formal		-0.0011	-0.0011		-0.1388*	-0.1388*
		(0.002)	(0.002)		(0.064)	(0.063)
lnpop		0.3093***	0.3095***		0.9902***	0.9902***
		(0.019)	(0.019)		(0.219)	(0.217)
_Cons	1.2556***	-	-10.4030***	1.6841***	342.2013**	342.134***
		10.4103***			*	
	(0.058)	(3.024)	(3.002)	(0.219)	(55.998)	(55.386)
E.F. Mês	Sim	Sim	Não	Sim	Sim	Não
E.F. Ano	Sim	Sim	Não	Sim	Sim	Não
E.F Cidade	Sim	Sim	Sim	Sim	Sim	Sim
Mês*Ano	Não	Não	Sim	Não	Não	Sim
R2	0.0370	0.2485	0.2568	0.3238	0.3238	0.3325
Observações	4134	4134	4134	3922	3922	3922

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

C6. Resultados das estimações do modelo de Diferenças em Diferenças com variáveis espaciais.

Variáveis Independentes	Variável Dependente: <i>lntxhom</i>			
	(1)	(2)	(3)	(4)
	SLX1	SLX2	SLX3	SLX4
Dtime	-0.4026*	-0.4026*	-0.3486**	-0.4665*
	(0.168)	(0.168)	(0.119)	(0.183)
Treated	-0.8234***	-1.2100***	-2.2485***	-0.0258

	(0.183)	(0.270)	(0.406)	(0.227)
Efb	-0.1459**	-0.1459**	-0.1276**	-0.1403**
	(0.052)	(0.052)	(0.049)	(0.052)
Wefb	0.0441*	0.0441*		
	(0.018)	(0.018)		
Espvida	0.2109*	-0.3586**	0.2188***	0.0857
	(0.089)	(0.126)	(0.058)	(0.111)
Fectot	-1.8473*	-1.1641**	0.8963*	-0.2417
	(0.895)	(0.387)	(0.366)	(0.351)
E_anosestudo	1.2859**	-0.0222	0.1679	-0.2370
	(0.454)	(0.096)	(0.099)	(0.133)
lnrdpct	-1.3725	-2.4908***	1.0787*	-0.2809
	(1.558)	(0.691)	(0.516)	(0.635)
Agua_esgoto	0.0016	-0.0878	0.0038	0.0519
	(0.083)	(0.045)	(0.022)	(0.046)
T_luz	-2.3728***	0.5133**	-0.8899**	0.1224
	(0.458)	(0.171)	(0.312)	(0.230)
Pmasc20_29	7.5369	-51.1765***	4.0900	-12.4865
	(9.486)	(15.274)	(6.610)	(9.238)
Gini	-8.0349	-2.1435	-12.4943***	-2.7690
	(4.596)	(2.231)	(3.000)	(3.247)
P_formal	0.0191	0.1024***	-0.0202	0.0111
	(0.019)	(0.024)	(0.011)	(0.024)
lnpop	-0.1186	0.1906**	0.5752***	0.2548*
	(0.326)	(0.068)	(0.103)	(0.115)
Wespvida		-1.2800***		
		(0.267)		
Wfectot		1.8578		
		(1.430)		
We_anosestudo		-0.2835		
		(0.204)		
Wlnrdpct		4.2705***		
		(1.107)		
Wagua_esgoto		0.0999***		
		(0.027)		
Wt_luz		0.0693		
		(0.295)		
Wpmasc20_29		108.9553*		
		(43.192)		
Wgini		-23.7502***		
		(6.906)		
Wp_formal		-0.0629***		
		(0.017)		
Wlnpop		1.0575***		
		(0.173)		
W2invefb			0.0369**	
			(0.012)	
W2invespvida			0.6971***	
			(0.130)	

W2infectot			0.0696 (0.423)	
W2inve_anosestudo			-0.4281* (0.168)	
W2invlnrdpct			-4.7782*** (0.938)	
W2invagua_esgoto			0.0134 (0.026)	
W2invt_luz			0.5275 (0.308)	
W2invpmasc20_29			-39.2421*** (10.090)	
W2invgini			17.0212*** (4.302)	
W2invp_formal			0.0303 (0.017)	
W2invlnpop			-0.1838 (0.148)	
W4invefb				0.0499* (0.020)
W4invespvida				-0.3511* (0.153)
W4infectot				-2.1608* (0.886)
W4inve_anosestudo				-0.3524 (0.304)
W4invlnrdpct				2.0355* (1.035)
W4invagua_esgoto				0.0637 (0.038)
W4invt_luz				-0.3359 (0.629)
W4invpmasc20_29				-39.4086 (37.488)
W4invgini				-18.4880*** (3.749)
W4invp_formal				-0.0186 (0.012)
W4invlnpop				0.2260 (0.165)
_Cons	226.5896*** (44.001)	47.0886 (41.900)	-10.4681 (31.240)	51.1833 (45.970)
% Tratados	9.11%	9.11%	5.72%	6.88%
<i>Efeito Spillover</i>	-3.55%	-3.55%	-1.88%	-3.02%
E.F. Mês	Sim	Sim	Não	Sim
E.F. Ano	Sim	Sim	Não	Sim
E.F. Cidade	Sim	Sim	Sim	Sim
Matriz Espacial	Binária	Binária	2 Vizinhos	4 Vizinhos
R2	0.3285	0.3285	0.3285	0.3284

Observações	4134	4134	4134	4134
-------------	------	------	------	------

Nota: [i] Erro-padrão robusto entre parênteses; [ii] E. F.=Efeitos Fixos; [iii] Mês*Ano = Interação entre as variáveis Mês e Ano; [iv] * $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$.

Fonte: Elaborado pelo Autor.

APÊNDICE D –ARTIGO DO PUBLICADO

Climate Influences on COVID-19 Prevalence Rates: An Application of a Panel Data Spatial Model

ABSTRACT

The present study aims to measure the impact of climate characteristics on the incidence rate of COVID-19 in Brazilian states given the exogenous nature of these variables. We used a daily panel for the period from March 10 to April 10, 2020, the first phase of the pandemic, as there were few intervention policies to contain the spread of COVID-19 during that period, and it was estimated, through GLS, spatial models to control the presence of spatial spillover, first-order autoregressive errors and correlation between cross-sections. Considering the COVID-19 incubation period and the time it takes for COVID-19 symptoms to manifest, the econometric models were estimated using the 14-, 11- and 7- day moving averages of the climate variables. The results showed that increases of 1% in the solar incidence, average temperature and relative humidity of the air reduced COVID-19 prevalence rates by 0.16%, 0.049% and 0.22%, respectively, considering the 11-day moving average.

Keywords: COVID-19. Spatial model. Climate variables. Social isolation. Lockdown.
JEL classification: R120; R15; I10.

1 INTRODUCTION

Towards the end of 2019, the COVID-19 virus began to spread around the world, causing Severe Acute Respiratory Syndrome (SARS-CoV-2). The World Health Organization (WHO) quickly considered this disease a pandemic because of its rapid spread and high mortality rates. The initial lack of effective vaccines and treatment forced governments worldwide to recommend the adoption of non-pharmacological measures to protect against contagion. The most significant procedures included the use of masks and social distancing (Borjas, 2020; Barrot; Grassi; Sauvagnat, 2020; Tobías, 2020).

The social distancing requirement produced far reaching impacts in the workplace and, the health crisis soon became an economic crisis. Little is known about how the disease spread between countries and within each country. However, we now understand that the virus spread in a non-random way and its determinants vary both with socioeconomic and environmental factors (Snyder; Parks, 2020; Porsse et al., 2020). Understanding the causes of its contagion pattern in the subnational territory becomes an important piece in the puzzle that seeks to trace the process of propagation of health and economic crises (Ascani et. al., 2021).

The present study aims to contribute to the literature by measuring the role of climate variables on the number of COVID-19 cases and deaths in Brazil. Although there are already

several studies that develop this relationship (Baker et al., 2020; Paez et al., 2020; Scafetta, 2020; Araneda et al., 2021; Tobías and Molina, 2020; Chen et al., 2021) our article contributes in two ways: first, studying a developing country with great climatic diversity: equatorial, tropical, subtropical and temperate our article contributes to the study of a developing country with great climatic diversity: equatorial, tropical, subtropical and temperate and with a large part of the Amazon forest. Second, to the presence of spatial correlation in the data set inherent in a pandemic process, this research used spatial models for panel data and the Generalized Least Squares (GLS) estimation method to control for the presence of the serial correlation of error terms and correlation between cross-sections.

Contributing to clarify the link between the incidence of COVID-19 and the climatic characteristics, the research intends to help policy makers to define targets to prevent new outbreaks of the disease and proposing inter-regional policies to combat COVID-19 taking into account the environmental characteristics of the locality. Our hypothesis is that in regions of lower temperatures people tend to concentrate in enclosed places with little ventilation, thus generating favorable environments for the spread of the virus (Paez et al., 2020). We have used daily data on the rate of COVID-19 cases and deaths in the period from March 10 to April 10, 2020. The choice of this time period for analysis follows researches such as Marow and Urban (2020) and Wang et al. (2021). According to these authors, during the initial stage of the outbreak there were fewer interventions on the contagion rates of COVID-19 which makes it possible to estimate the effect of climatic variables more accurately.

The climate variables used were the number of hours of sunlight (brightness of the sun without cloud intervention), the average temperature and the relative humidity of the air. For these variables, the delineated moving averages of 7, 11 and 14 days prior to the day of diagnosis of SARS-CoV-2 infection were calculated because, in line with Lauer et al. (2020), the time it takes until the onset of COVID-19 symptoms is 2.6 to 12.5 days, with confidence intervals (CIs) from 2.1 to 3.7 and 8.2 to 17.7 for the lower and upper limits, respectively, in 95% of confirmed disease cases. Additionally, according to the cited author, the average incubation period of COVID-19 is 5.7 days (with a confidence interval between 4.9 and 7.8 days). Paez et al. (2020) highlighted that the mean incubation time of SARS-CoV-2 is 5 days and that this value is the same for other human coronaviruses, such as SARS, MERS and non-SARS human coronaviruses. In addition to the climate variables mentioned, socioeconomic control variables, social-distancing variables, such as *lockdown* and the social isolation index, and variables of the profile of the health conditions of the population of Brazilian states

(D'ADAMO; YOSHIKAWA; OUSLANDER, 2020; YING-YING et al., 2020) are also considered.

This research is divided into four more sections besides this introduction. In section 2 we present the background. The empirical strategy and the data set are in section 3. The analysis of the results and the discussion can be found in section 4. Finally, in the fifth section the final considerations are presented.

2. BACKGROUND

Climatic conditions have been taken into account when determining the factors influencing the spread of the pandemic. At this stage, articles will be discussed that list the reasons that make climate phenomena one of the components that explain contamination by COVID-19.

Wang et al. (2021) investigated the relationship between COVID-19 and weather conditions in 100 Chinese cities where more than 40 confirmed cases of the disease were recorded. However, these authors used data from January 19th to February 15th and highlights that the government intervention after the lockdown decree took place on January 24th. The authors also used data from March 15th to April 25th for 1,005 American cities, noting that the lockdown policy was implemented on April 7th. Thus, to verify the influence of climatic variables on the rate of dissemination of COVID-19, they estimated econometric models using control variables for the socioeconomic, demographic, health, and geographic profile of the locations. The climatic variables, temperature, and relative humidity were constructed from their respective moving averages for a period of 6 days. The authors also point out that they used the initial phases of the pandemic, both in China and in the US, as there were fewer interventions on the COVID-19 contagion rates, which allowed them to estimate the effect of climate variables more accurately. The results showed a negative and significant relationship of temperature and relative humidity on the reproduction rate of COVID-19 in both the US and China, but after the lockdown period, climate variables had the magnitude of their impacts on the reproduction of COVID-19 decreased due to the effect of restrictions on the movement of people imposed by the lockdown policy. As a way to test the robustness of the results, averages of 7.5 days were used for the climatic variables and control for spatial correlation. The results of the climatic variables continued to be highly significant and consistent with the results obtained previously.

Paez et. al. (2020) investigated the influence of climatic variables on the COVID-19 contagion rates for the provinces of Spain since this was one of the countries most affected by the pandemic. Thus, these authors used data from confirmed case rates and meteorological data for a period of 30 days. In addition, socioeconomic and demographic data that served as control variables in the spatial regression model used by the authors were used. The results obtained showed provinces with higher temperatures and higher air humidity have lower COVID-19 contagion rates. However, the heatstroke variable had a positive relationship with the COVID-19 contagion rate, probably due to the social isolation policies that ended up leaving many people confined to their homes, not being able to expose themselves to the sun frequently. In addition, the authors highlight that the control variables proved to be important predictors of the dissemination of COVID-19 in space, such as GDP per capita and the presence of public transport in the province, which had a positive relationship with COVID-19 rates, while population density and percentage of elderly people in the population had a negative relationship with the dissemination of COVID-19.

Merow and Urban (2020) investigated whether the virus would be sensitive to climate characteristics under the argument that climate could determine COVID-19 contagion rates over time. For this, these authors used the initial period of the pandemic, as interventions in the social field to reduce the spread of COVID-19 were rare. Thus, country-level data were used except Australia, the USA, China, and Canada. For the climatic variables, the 14-day moving averages were used for the average temperature, relative and absolute air humidity, and also the isolation variable that captures ultraviolet radiation, since the COVID-19 infection time is from 1 to 14 days. They also used control variables considered important predictors of contagion, such as population density and percentage of the elderly population. In addition, the authors used, as a way to test the robustness of the results, the average of the climatic variables for a window of 6, 7, and 12 days. The results obtained showed that 36% of the predicted growth in the dissemination rate of COVID-19 can be explained by the type of model proposed and that 17% of the prediction can be explained by climatic and sociodemographic variables. The isolation variable was negatively correlated and statistically significant with the COVID-19 rates. The authors argue that literature findings indicate that the virus is sensitive to ultraviolet radiation and, alternatively, the immune system improves with exposure to sunlight due to vitamin D absorption. COVID-19, while the mean temperature had a positive correlation, which the authors considered contrary to the expected result.

Baker et al. (2020) argue that climatic conditions may influence the current COVID-19 epidemic crisis. The direct influence of climatic variables is due to both the humidity level of the locations and the temperature to which the virus is exposed. These authors claim that the transmission of viruses such as Influenza occurs more strongly in less humid places and that pandemics reach peak cases during the winter. The authors also simulated non-pharmaceutical interventions and controlled for the effects of local population density and social contact patterns and found that these interventions and variables can determine the future behavior of the disease.

Scafetta (2020) sought to identify whether climatic characteristics affected the dissemination of COVID-19. To do so, the author collected data from confirmed cases in December, the winter month in Wuhan, China, spreading rapidly over the following months. According to the author, a similar fact occurred in cities in Italy and later in American cities. The author also sought to identify the influence of other variables on the prevalence of COVID-19, such as the median age of the population and the level of air pollution. The results obtained indicate that places with colder temperatures and lower relative humidity have a worse dissemination rate of COVID-19. It was also found that regions with a less elderly population have lower COVID-19 rates, but the variable that measures air quality did not have a statistically significant influence on the COVID-19 rates.

Araneda et al. (2021) investigated the effect of climatic variables on COVID-19 transmission rates in Chile due to its environmental characteristics such as high latitudes and land cover with varied types of climates such as desert, semiarid, coastline, areas with ice, among others. Furthermore, they use socioeconomic characteristics as a control. They found a negative relationship between COVID19 dissemination rates and maximum and average temperature, but due to multicollinearity issues, they excluded maximum, average, and altitude temperature. The results show that minimum temperature, atmospheric pressure, and relative humidity had a negative and significant relationship with the transmission rate of COVID19.

Chen et al. (2021) verified how the distance of countries to the equator affects the rate of confirmed cases of COVID-19 in these countries under the hypothesis that countries located closer to the equator have higher temperatures and higher relative humidity and this would contribute to a lower incidence rate of COVID-19. The authors controlled for several factors that may affect the spread of the new coronavirus, such as the amount of air travel, urbanization rate, health expenses, among others, in addition to excluding from the sample countries that had less than 100 confirmed cases of COVID-19 and concluded that countries that are 1000 km

closer to the equator can expect a 33% lower rate of COVID-19 cases per million inhabitants. The results obtained point to a reduction in the cases of COVID-19 in summer due to higher temperatures and greater ultraviolet radiation from the sun. This fact can support the adoption of public policies to reduce the spread of SARS-CoV-2.

Tobías and Molina (2020) emphasize the importance of understanding the dynamics of the incidence of COVID-19 based on the climatic characteristics of the regions. For this, they used 7-day lags of the climatic variables based on the SARS-CoV-2 incubation time, which is 5 to 6 days. These authors also used linear and quadratic trends in the Quasi-Poisson regression model, in addition to fixed effects for the metropolitan region of the city of Barcelona, and concluded that temperature increases lead to a reduction in the incidence rates of COVID-19, but they emphasize that other climatic and socioeconomic characteristics could not be controlled in the econometric exercise performed by them.

Paliolol et al. (2020) investigated the influence of climate on the dissemination rates of COVID-19 through a panel of 416 regions from various parts of the world over a period of 93 days. In addition, several fixed effects that could be related to the dynamics of COVID-19 over time were controlled, and they concluded that an increase in temperature in the regions reduces COVID-19 transmission by up to 8.98%, indicating that even though they can If there are other determinants for the contagion rate, the climate can play an important role when formulating public policies to stop the advance of COVID-19.

In light of recent evidence in the literature, there is an effort by the most diverse researchers to identify the factors that can influence the spread of SARS-CoV-2 in space, where environmental characteristics can be an important factor in combating the COVID-19 pandemic. Thus, this research sought to find evidence of the impact of climate characteristics on the prevalence rates of COVID-19 in the states of Brazil, as this country has a large territorial extension and has different types of climates in its regions, in addition to socioeconomic characteristics of a developing country with accentuated income inequality and precarious access to health services for a significant part of the population (PORSSE et al., 2020).

3. EMPIRICAL STRATEGY

3.1 Dataset

In the present study, we used a single database with information from the Ministry of Health on confirmed COVID-19 cases and those that resulted in death from March 10 to April

10, 2020, in 26 Brazilian states and the Federal District. This database also has information from the National Institute of Meteorology (INMET) on the meteorological characteristics of Brazilian states and the Social Isolation Index developed by Inloco,⁹ as well as the number of people who entered these states through international flights, provided by the National Aviation Agency (ANAC). Data from the DataSUS of the Ministry of Health on hospitalizations for comorbidities in 2019, the Superior Electoral Court (TSE) on the results of Brazilian presidential elections in Brazilian states in 2018, and the Brazilian Institute of Geography and Statistics (IBGE) on the socioeconomic characteristics of Brazilian states were also used.

Table 1. Variable descriptions.

Variable	VARIABLE DEFINITION
Txcases	COVID-19 prevalence rate per 100,000 inhabitants in state i on day t .
Political Landscape Controls	
<i>Lockdown</i>	<i>Dummy</i> that takes a value of 1 if state i decreed a <i>lockdown</i> on day t .
Govwin	<i>Dummy</i> that takes a value of 1 if Bolsonaro won at least 50% of the valid votes in the second round of elections in state i in 2018.
Socioeconomic Controls	
Analf	Percentage of illiterate people (in relation to the total population) in state i .
Pop	Number of inhabitants in state i .
Older	Percentage of elderly people (in relation to the total population) in state i .
Income	Neperian logarithm of <i>per capita income</i> in state i .
Lifeexp	Life expectancy at birth in state i (<i>years</i>) in 2019.
pflight	Number of people per 100,000 inhabitants entering state i from foreign countries by airplane in the month referring to t -day.

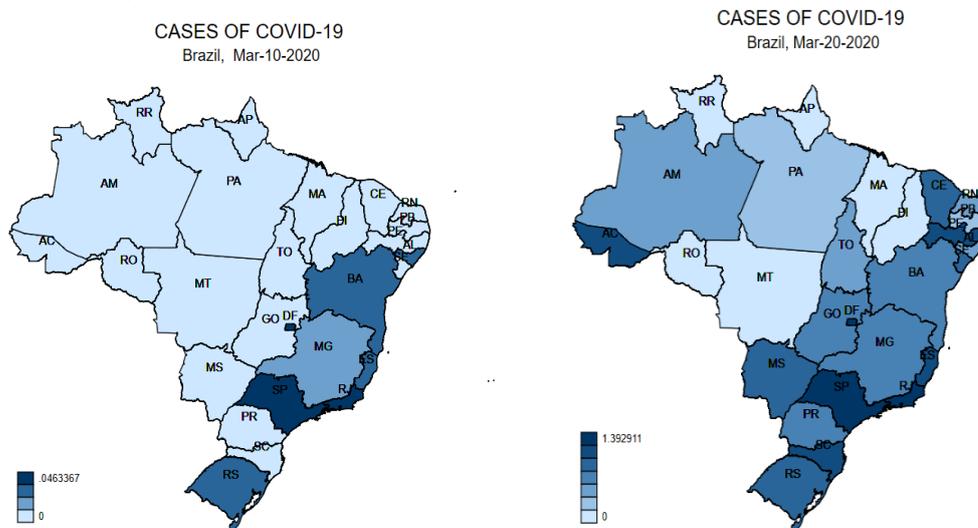
⁹ This company was founded in 2014 and is headquartered in Reef/PE, with teams in São Paulo/SP, New York/NY and the San Francisco Bay Area/CA. <https://mapabrasileirodacovid.inloco.com.br/pt/>

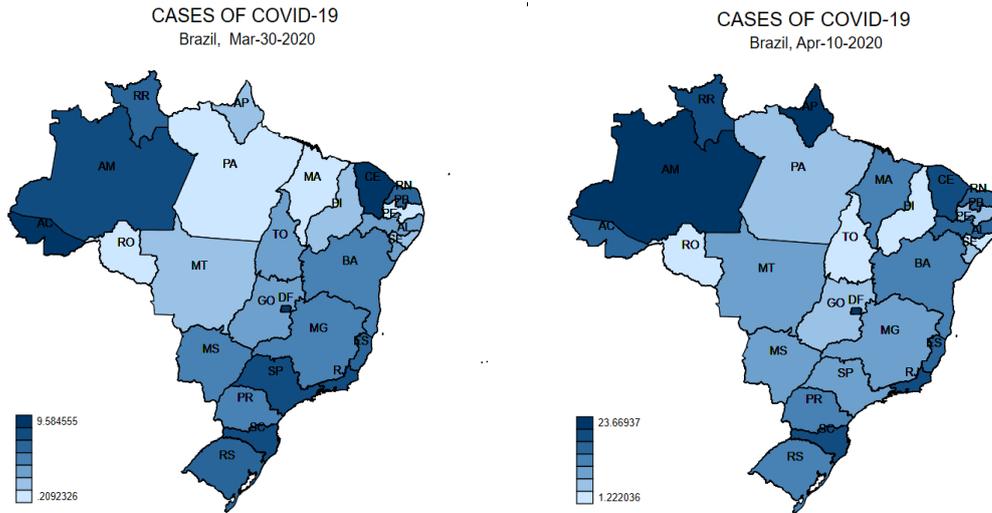
Sii	Social Isolation Index (in %) in state <i>i</i> on day <i>t</i> .
Climate Controls	
Sun	Number of hours of sun brightness without cloud interference and that people can effectively expose themselves in state <i>i</i> on day <i>t</i> .
Tmean	Average temperature (in °C) in state <i>i</i> on day <i>t</i> .
Humi	Relative humidity (in %) in state <i>i</i> on day <i>t</i> .
Health Profile Controls	
Txresp	Percentage of people diagnosed with respiratory problems (in relation to the total population) in state <i>i</i> in 2019.
Txheart	Percentage of people diagnosed with heart problems (compared to the total population) in state <i>i</i> in 2019.
Txhiper	Percentage of people diagnosed with hypertension (in relation to the total population) in state <i>i</i> in 2019.

Note: [i] the total number of states includes the Federal District.

Figure 1 shows the spatial distribution of rates related to COVID-19 in Brazilian states from March 10 to April 10, 2020. It is possible to verify that in the Brazilian states, COVID-19 first appeared in the southeastern, southern and northeastern states and spread to the other regions of the country in the following days due to insufficient policies to contain SARS-CoV-2, as the pandemic was in its initial phase during this period.

Figure 1- Spatial distribution of the daily prevalence rates of COVID-19 from March 10 to April 10, 2020, in the Brazilian states.

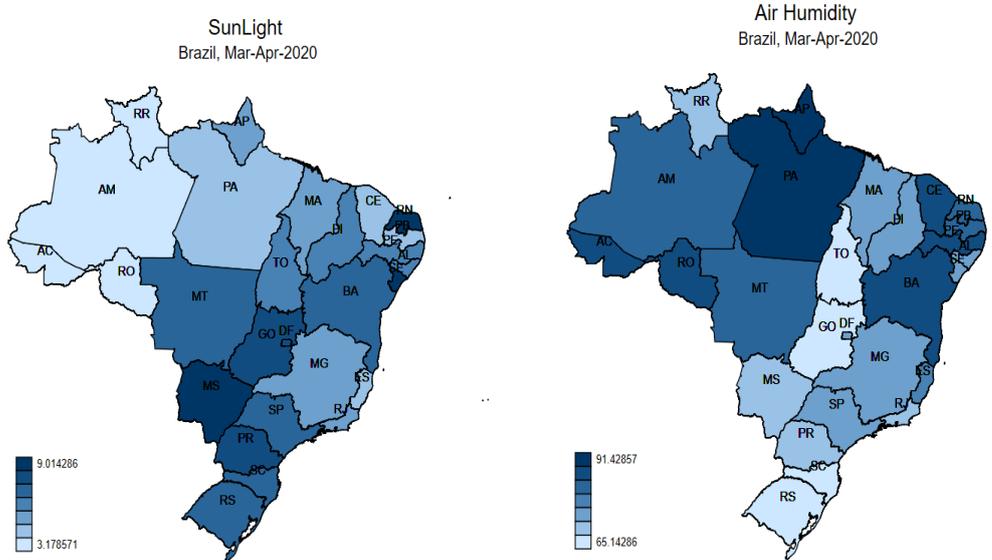


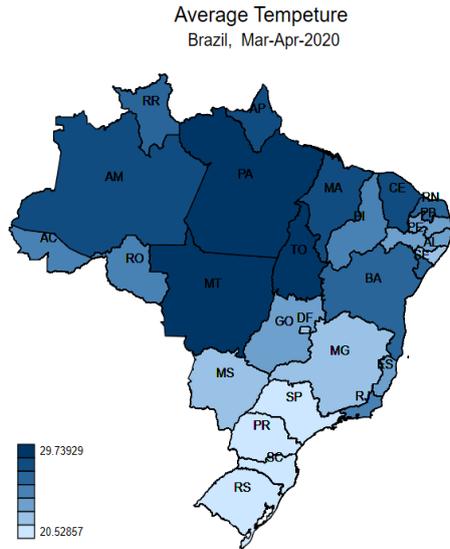


States label: Acre - AC; Alagoas - AL; Amapá - AP; Amazonas - AM; Bahia - BA; Ceará - CE; Distrito Federal - DF; Espírito Santo - ES; Goiás - GO; Maranhão - MA; Mato Grosso - MT; Mato Grosso do Sul - MS; Minas Gerais - MG; Pará - PA; Paraíba - PB; Paraná - PR; Pernambuco - PE; Piauí - PI; Roraima - RR; Rondônia - RO; Rio de Janeiro - RJ; Rio Grande do Norte - RN; Rio Grande do Sul - RS; Santa Catarina - SC; São Paulo - SP; Sergipe - SE; Tocantins - TO.

Figure 2 shows the spatial distribution of climate variables, which are the main explanatory variables of interest in the present study, given the randomized way in which they occur. It is observed that there was a higher incidence of sunlight in the northeastern and midwestern states in the analyzed period. The wettest states were located in the northern region of the country. In the analyzed period, the mean temperature was higher in the northern and northeastern states.

Figure 2- Spatial distribution of the daily values of climate variables from March 10 to April 10, 2020, in the Brazilian states.





States label: Acre - AC; Alagoas - AL; Amapá - AP; Amazonas - AM; Bahia - BA; Ceará - CE; Distrito Federal - DF; Espírito Santo - ES; Goiás - GO; Maranhão - MA; Mato Grosso - MT; Mato Grosso do Sul - MS; Minas Gerais - MG; Pará - PA; Paraíba - PB; Paraná - PR; Pernambuco - PE; Piauí - PI; Roraima - RR; Rondônia - RO; Rio de Janeiro - RJ; Rio Grande do Norte - RN; Rio Grande do Sul - RS; Santa Catarina - SC; São Paulo - SP; Sergipe - SE; Tocantins - TO.

Figure 3 shows the prevalence rates of COVID-19 in the Brazilian states from March 10 to April 10. Each line of this figure represents the behavior of the rates for each Brazilian state. All states and regions showed exponential growth in terms of the spread rate of SARS-CoV-2, especially in the states in the northern, northeastern and midwestern regions, which showed more pronounced growth compared to other regions.

Figure 3- Evolution of the daily prevalence rates of COVID-19 from March 10 to April 10, 2020, in the states and regions of Brazil.

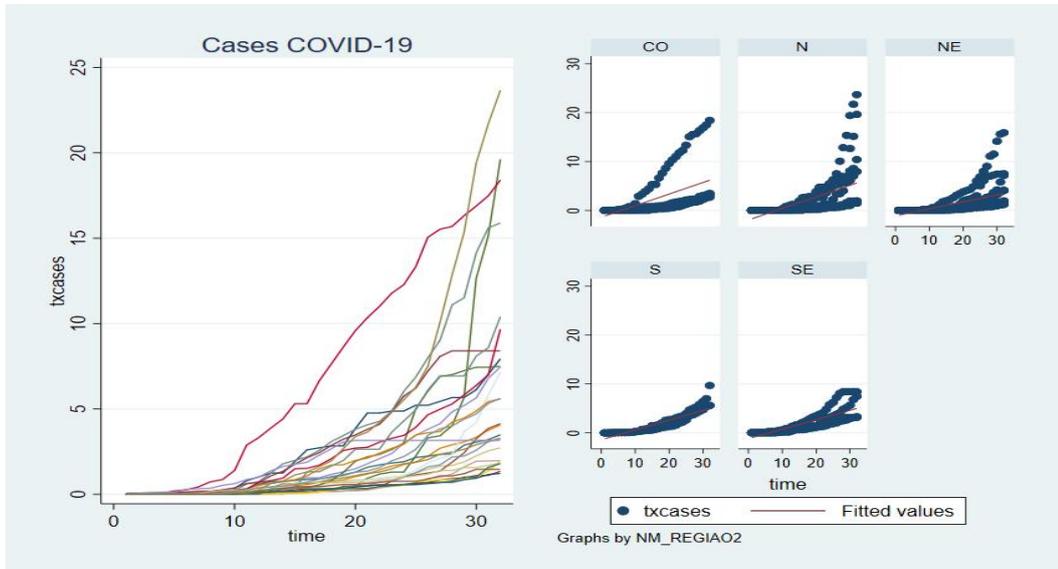
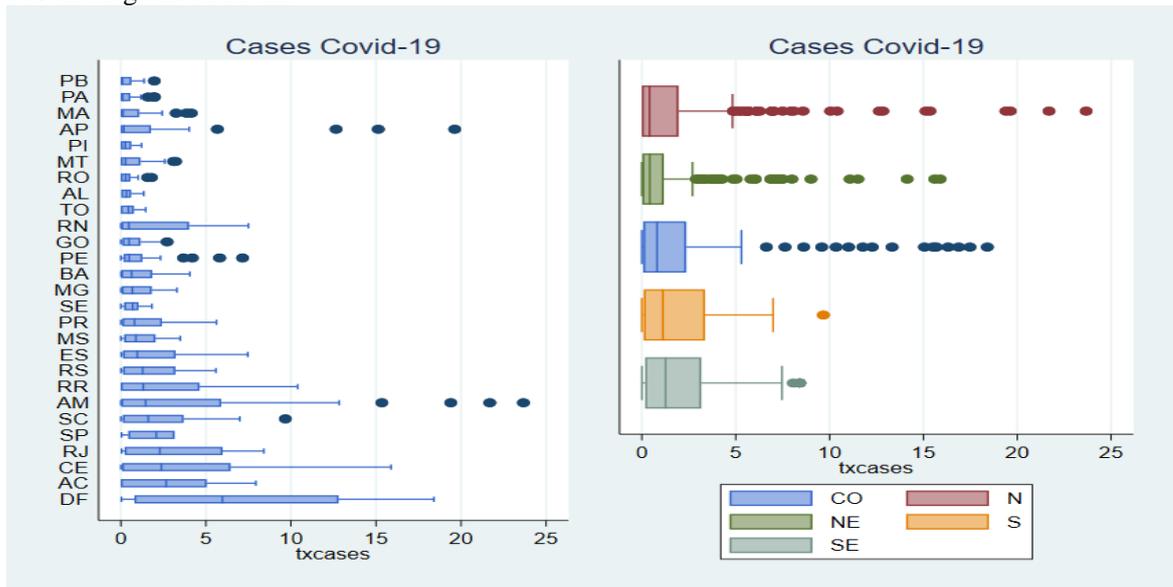


Figure 4 shows the dispersion of COVID-19 daily incidence rates within each state and between states, with the same being done for the regions of the country. Some states in the northeastern region, such as the states of Paraíba (PB), Alagoas (AL), Piauí (PI), Tocantins (TO) and Sergipe (SE), had lower COVID-19 dissemination rates and lower variability compared to other states within the analyzed period.

Figure 4- Distribution of the daily prevalence rates of COVID-19 from March 10 to April 10, 2020, in the states and regions of Brazil.



Conversely, the state of Amazonas (AM), in the northern region, presented a greater variability in COVID-19 prevalence rates and one of the highest rates among states. The southeastern states of São Paulo (SP), Rio de Janeiro (RJ), Espírito Santo (ES) and Minas Gerais (MG) presented high COVID-19 prevalence rates, but their values were approximately constant from March 10 to April 10.

Additionally, in Figure 4, it can be seen (to the right of the figure) that the midwestern and northern regions had great variation in their COVID-19 dissemination rates, followed by the northeastern region. The southern (S) and southeastern (SE) regions had more constant rates over time.

Table 2 presents the variables used in the econometric exercise. The average amount of sunlight in the states of Brazil is 5.75 hours. The average temperature and relative humidity are 26.67° C and 77%, respectively. The number of states that used a policy to restrict the movement of people was, on average, 69.6%, while adherence to social isolation by the population was, on average, of the order of 44.8%.

Table 2. Descriptive statistics of the variables.

VARIABLES	(1) N	(2) Mean	(3) SD	(4) Min.	(5) Max.
Sunh	864	5.759	3.132	0	11.20
Tmean	864	26.67	2.801	12.25	31.55
Humi	864	77.00	8.553	56	97
Lifeexp	864	74.71	2.504	70.90	79.40
Pop (1000)	864	7,783	9,084	605.76	45,920
Older	864	7.563	2.495	0.500	12.50
Income	864	1,238	468.0	635	2,685
Lockdown	864	0.696	0.460	0	1
Govwin	864	0.593	0.492	0	1
Analf	864	0.254	0.0613	0.120	0.360
Sii	864	44.88	9.227	25.70	72.80
Txcases	864	1.799	3.096	0	23.67
pflight	864	210.5	390.0	0	1,514
Txheart	864	2.367	1.030	0.918	4.554
Txhiper	864	0.603	0.558	0.0501	2.344
Txresp	864	46.65	12.04	25.50	69.56

3.2 Spatial Econometric Model.

Estimations of the association between COVID-19 prevalence rates and climate characteristics, socioeconomic variables, the profile of health conditions and their spatial interactions in the Brazilian states were carried out for a period of 32 days through *generalized least squares* (GLS) estimation since it is a long panel with a long period of time and high number of observations, which can generate a serial correlation of the first order of the error term. This estimation process still allows for errors to be heteroscedastic and us to control the existence of contemporary correlation, that is, *correlation between cross-sections*, which implies $E(\mu_{it}, \mu_{jt}) = \sigma_{ij}$ (Cameron; Trivedi, 2009; Hoechle, 2007; Wooldridge, 2002). The correlation between cross sections arises due to the existence of unobserved components that end up creating interdependence between the observation units and makes the estimators of fixed and random effects unsuitable (Pesaran, 2004; Hoyos; Sarafidis, 2006). The panel data model is given in equation (1):

$$y_{it} = clima_{it}\beta + x'_{it}\gamma + a_i + \mu_{it} \quad (1)$$

where y_{it} is the COVID-19 prevalence rate in state i on day t . $clima_{it}$ is the vector of climate variables, such as the effective amount of sunlight without cloud interference, the average

temperature and the relative humidity of the air in state i on day t . x'_{it} is the vector of the other covariates used as controls. a_i is the set of variables not observed invariant in time, and μ_{it} is the random error term.

Considering the existence of first-order autoregressive effects, the error term in equation (1) is represented by

$$\mu_{it} = \rho\mu_{i,t-1} + \varepsilon_{it} \quad (2)$$

Given the above, the GLS estimator is given by

$$\hat{\beta}_{GLS} = (X'\hat{\Omega}X)^{-1}X'\hat{\Omega}^{-1}y \quad (3)$$

$$\widehat{Var}(\hat{\beta}_{GLS}) = (X'\hat{\Omega}^{-1}X)^{-1} \quad (4)$$

and the matrix can be written as Ω , where

$$\Omega = \Sigma_{m \times m} \otimes I_{T \times T} \quad (5)$$

and $\hat{\Omega}$ can be obtained by replacing $\hat{\Sigma}$ in Σ given the following calculation:

$$\hat{\Sigma}_{i,j} = \frac{\hat{\mu}_i' \hat{\mu}_j}{T} \quad (6)$$

To better specify the econometric model and solve possible problems of spatially omitted variables, space models were used to capture the influence of space on the estimates of the proposed parameters. Thus, to measure the *spillover effect* of COVID-19 prevalence rates, a *spatial autoregressive model* (SAR) was used, which measured the overflow effect of COVID-19 prevalence rates beyond state borders:

$$y_{it} = \text{clima}_{it}\beta + x'_{it}\gamma + \rho WY_t + a_i + \mu_{it} \quad (7)$$

where Wy_{it} is the prevalence rates of COVID-19 in the states neighboring state i on day t , and W is the spatial weighting matrix that captures the interaction between regions with common borders.

The effect of space on the econometric estimates can be captured from the spatial lags of the independent variables of the regression model. In this case, the *spillover effect* should be controlled by the SLX spatial model.

$$y_{it} = clima_{it}\beta + x'_{it}\gamma + WX_t\delta + \alpha_i + \mu_{it} \quad (8)$$

To control the *spillover* effect of the COVID-19 prevalence rate, and the variables, the regression model used is the *spatial Durbin model* (SDM) since it makes it possible to incorporate several characteristics of the behavior of variables through space in econometric modeling (Elhorst, 2010, 2011; Guliyev, 2020).

$$y_{it} = clima_{it}\beta + x'_{it}\gamma + \rho WY_t + WX_t\delta + \alpha_i + \mu_{it} \quad (9)$$

4. RESULTS AND DISCUSSION

4.1 Results

To determine the estimation method of the models, we performed preliminary statistical tests. The first test was the Breusch and Pagan Lagrange multiplier test to determine whether, due to the structure of the data, it would be better to use the ordinary least squares method or methods for longitudinal data. The result rejected the null hypothesis at the 0.1% level, indicating that OLS estimation is biased.

Another test was the Woodridge test for the existence of a serial correlation of order 1 in terms of regression error since the data used in this research were considered long panel data, with a period of time greater than the number of observations ($T > N$). Here, the null hypothesis of no serial correlation was rejected at the 1% level.

The Pesaran test was also performed to detect contemporary correlations (correlations between *cross-sections*), which may imply heteroscedastic errors and biased estimators. In this test, the hypothesis that there was no correlation between cross-sections was rejected at the level of 0.1%. In this case, the model estimation had to be done by *generalized least squares* (GLS) regression.

To verify the presence of spatial correlation in the data, Moran's I test was performed under the null hypothesis of no spatial correlation in the data. This hypothesis was also rejected

at the significance level of 0.1%, indicating that the spatial characteristics of Brazilian states could determine the contagion rate of COVID-19 and should be included in the regression model to prevent problems of spatial variable bias.

Table 2 shows the results of econometric exercises regarding the estimation of spatial models for the panel data. To test the hypotheses raised about the factors that affect COVID-19 dissemination, the regression model given in equation (1) is estimated in column (1). In columns (2), (3) and (4), the spatial characteristics are included, and the SAR models are estimated, where the effect of the spatial *spillover of the dependent variable*, SLX, was controlled, the spatial lag of the *independent variables* as controls and the SDM were used, and the effects of the spatial lags of the dependent and independent *variables* were controlled, respectively.

The results obtained in all models show a negative correlation between the 14-day moving average of *sunlight (sun14m)* and the prevalence rate of COVID-19, indicating that states with a higher incidence of sunlight have lower COVID-19 dissemination rates. This same result is found for the moving averages of 11 and 7 days of sunlight incidence (*SUN11M* and *SUN07M*, respectively). All results were statistically significant at 0.1% ($p\text{-value} < 0.001$)

Table 3. Estimation of the models for the panel data and their spatial versions for the daily prevalence rates of COVID-19 in the Brazilian states from March 10 to April 10, 2020.

Independent variable	Dependent variable: <i>txcases</i>			
	(1) GLS	(2) Sar	(3) SLX	(4) SDM
Moving Average of 14 days				
Sun14m	-0.0831*** (-15.70)	-0.0841*** (-15.85)	-0.0917*** (-17.33)	-0.101*** (-24.24)
Humi14m	0.0253*** (14.56)	0.0250*** (14.56)	0.00186 (0.96)	0.00194 (1.42)
Tmean14m	-0.129*** (-18.53)	-0.132*** (-18.93)	-0.0196* (-2.54)	-0.0255*** (-3.85)
Moving Average of 11 days				
Sun11m	-0.0624*** (-20.18)	-0.0598*** (-18.15)	-0.0550*** (-16.48)	-0.0522*** (-14.05)
Humi11m	0.00259* (2.09)	0.00278* (2.23)	-0.00625*** (-5.07)	-0.00546*** (-3.88)
Tmean11m	-0.102*** (-16.53)	-0.100*** (-16.06)	-0.0357*** (-7.63)	-0.0446*** (-8.29)
Moving Average of 7 days				
Sun07m	-0.0226*** (-15.10)	-0.0210*** (-14.09)	-0.0171*** (-8.92)	-0.0169*** (-10.27)

Humi07m	0.000456 (0.68)	0.00118 (1.77)	-0.00491*** (-6.42)	-0.00397*** (-5.42)
Tmean07m	-0.0462*** (-18.20)	-0.0439*** (-17.43)	-0.00528 (-1.34)	-0.00483 (-1.30)
Political Controls	yes	yes	yes	yes
Socioeconomic Controls	yes	yes	yes	yes
Health Profile Controls	yes	yes	yes	yes
Spatial Controls	no	yes	yes	yes
Fixed Effects Region	no	no	no	yes
N	864	864	864	864
	Moving Average of 14 days	Moving Average of 11 days	Moving Average of 7 days	
Lagrange ^{to}	121.62***	93.23***	78.97***	
Wooldridge ^B	598.32***	589.51***	599.19***	
Pesaran ^C	38.80***	45.65***	48.04***	
Moran ^d	0.245***	0.327***	0.377***	

Note: [i] the total number of states includes the Federal District. [a] the Breusch-Pagan Lagrange test, where the null hypothesis is that OLS produces more consistent estimators. [b] the Wooldridge test, where the null hypothesis is that there is no serial correlation of the error terms. [c] the Pesaran test, where the null hypothesis is that there is noncorrelation between cross-sections. [d] the Moran index, where the hypothesis is null and void and there is no spatial correlation in the data. [ii] t-statistics are in parentheses; [iii] **, and *** indicate statistical significance at the 5% and 1% levels, respectively.

A negative effect was also found in all proposed models for the moving averages of 14, 11 and 7 days of average temperature (*tmean14m*, *tmean11m* and *tmean07m*, respectively), on the incidence rates of COVID-19, indicating that states with higher temperature levels had lower COVID-19 dissemination rates. Here, the results were also statistically significant at the 0.1% level ($p\text{-value} < 0.001$).

Conversely, the moving averages of 11 and 7 days of relative humidity (*hum11m* and *hum07m*, respectively) were negative and statistically significant ($p\text{-value} < 0.001$) only in the SLX model and the SDM (columns (3) and (4)), indicating that when controlling for the effects of socioeconomic characteristics, states with higher relative humidity experienced a decrease in COVID-19 dissemination rates. However, these results were not observed for the moving average of 14 days of relative humidity.

In the spatial models, the covariates used directly affect the dependent variable in a given observation unit i and indirectly affect the dependent variable of all observation units contiguous to unit i , and the sum of these effects results in the total effect (Lesage; Pace, 2009). The results of the direct, indirect and total marginal effects are presented in Table 3 below.

Table 4 shows the results of the direct, indirect and total marginal effects of the moving averages of the covariates of the SDM for COVID-19 prevalence rates. The analysis of marginal effects suggests that a 1% increase in the hours in which a state was exposed to sunlight generates, on average, a reduction in the total effect of the rates of confirmed cases of COVID-19 of 0.16% considering the moving average of 11 days and 0.07% considering the moving average of 7 days. That is, increasing exposure to sunlight by one hour (which corresponds to a 20% increase in the Brazilian average) leads to a reduction in the average number of cases per 10,000 inhabitants of 5.58%, 8.93% and 3.9%.

Additionally, in Table 4, the total marginal effects of the moving averages of relative humidity indicate that a 1% increase in relative humidity leads to a reduction in the prevalence rate of COVID-19 of 0.049% for a moving average of 11 days and 0.027% for a moving average of 7 days, indicating that states with higher relative humidity levels have lower rates of COVID-19 dissemination.

The results of the total marginal effects of the average temperature in the Brazilian states show that increases of 1% in the moving averages of 14, 11 and 7 days reduce the incidence rates of COVID-19 by 0.32%, 0.22% and 0.06%, respectively, indicating that higher average temperature levels reduce COVID-19 incidence rates in Brazilian states.

Table 4. Direct, indirect and total marginal effects of the variables of interest in the SDM on the daily prevalence rates of COVID-19 in the Brazilian states.

	Direct effects	Indirect effects	Total effects
Moving Average of 14 days			
Sun14m	-0.101***	-0.00243	-0.10343
humi14m	0.00194	0.00949**	0.01143
Tmean14m	-0.0255***	-0.295***	-0.3205***
Moving Average of 11 days			
Sun11m	-0.0522***	-0.116***	-0.1682***
humi11m	-0.00546***	-0.0441***	-0.04956***
Tmean11m	-0.0446***	-0.182***	-0.2266***
Moving Average of 07 days			
Sun07m	-0.0169***	-0.0619***	-0.0788***
humi07m	-0.00397***	-0.0235***	-0.02747***
Tmean07m	-0.00483	-0.0650***	-0.06983***

Note: [i] the total number of states includes the Federal District. [ii] **, and *** indicate statistical significance at the 5% and 1% levels, respectively.

4.2 Discussion

Brazil is a country of continental dimensions and the largest country in South America. Nevertheless, this country has accentuated climatic differences between its regions, which are composed of areas of the mountain range, coast, Atlantic Forest, among others. Thus, Brazil has under its territory the various types of climates where the main ones are: equatorial, tropical, semi-arid, high altitude tropical, Atlantic tropical and subtropical (Palialol et al., 2020). Thus, the investigation of the influence of climatic factors on COVID-19 cases in Brazilian states proved to be relevant due to the uneven way in which SARS-CoV-2 has been spreading through space (Candido et al., 2020).

Working with Brazil, we have developed several studies to explain the behaviour of this disease in the country (Ajzenman, Cavalcanti and Da Mata, 2020; Nicoletis et al., 2021; Mariane et al., 2020; Candido et al., 2020), however, none of them focused on climate issues.

The period covered by this research, March 10 to April 10, 2020, corresponds to the initial phase of the pandemic, where there were not many non-pharmaceutical interventions, restricting economic activity and social interaction. This allowed us to investigate the impact of exogenous climate variations on the rate of dissemination of COVID-19. In addition, it was at the beginning of March that the dissemination of SARS-CoV-2 started to occur locally, that is, it began to have contamination of residents within the Brazilian territory and between states.

To analyze the influence of climate on the spread of COVID-19, moving averages of 14, 11 and 7 days of climate variables were used to better capture the effects of these variables on the current incidence rates of COVID-19. since there is an incubation period of SARS-CoV-2 and the manifestation of symptoms of COVID-19 (Lauer, 2020; Paez et al., 2020).

The climatic conditions of the states proved to be an important exogenous source to explain the incidence rates of COVID-19, as the results obtained showed that states that reach higher temperature levels and have a higher incidence of sunlight manage to have a reduction in the rate of prevalence of COVID-19. These results corroborate other findings in the literature such as Palialol et al. (2020), Tobías and Molina (2020), Araneda et al. (2021), Chen et al. (2021) and Wang et al. (2020).

A result contrary to the one found for the sunlight incidence variable can be seen in Paez et al. (2020) who found a positive effect of the incidence of sunlight on the prevalence rates of COVID-19 and attributed such effect to interference from other factors such as possible lockdown decrees that reduced the circulation of people and their exposure to the sun.

In this research, different moving averages of climate variables were used to capture the effects of past exposure to the period of COVID-19 contagion. The results showed that the

shorter the average exposure time to sunlight, the lower its impact on COVID-19 rates and its reducing impact on COVID-19 was verified in all tested models. Relative air humidity and average temperature are also part of the list of variables that influence COVID-19 rates, indicating that wetter places have a lower prevalence of COVID-19 (Wang et al., 2020), but the impact of this variable was not statistically significant for the 14-day moving average. States with higher temperatures also have a lower incidence of COVID-19, since the capacity of SARS-CoV-2 to remain active decreases when temperatures reach more than 38°C and relative humidity is greater than 95% (Jaakkola et al., 2014; Chan et al., 2011).

Social and economic characteristics and the profile of health conditions in the regions have determined the speed of dissemination of COVID-19. We sought to control these characteristics here, as they have shown to be relevant influences in determining the factors that influence COVID-19 contagion. These characteristics determine the degree of vulnerability of locations to the pandemic and the measures they adopt to contain the spread of SARS-CoV2 (Noy et. al., 2020; Snyder; Parks, 2020; Ying-Ying et al., 2020). Initially, the fixed-effects panel model was estimated so that it was possible to capture the effect of non-variant factors over time, but there was no statistical significance of the variables used due to the presence of correlation between the cross-sections, which implies heteroscedasticity of the errors and increased variance of the estimators, thus compromising the statistical significance of the estimated parameters for not being efficient (PESARAN, 2004; HOYOS; SARAFIDIS, 2006), making it necessary to estimate the models by GLS.

The current numbers referring to COVID-19 are attributed, in many cases, to the decisions of the political leaders of the localities (Allcott et al., 2020; Gadarian et al., 2021). In this way, we tried to control the effect of political decisions in the regression models proposed in this research. Social isolation policies have been recommended as an effective way to prevent the uncontrolled spread of COVID-19 and the collapse of the health system (Gatto et al., 2020; Toda, 2020), because, as shown by Gatto et al. (2020), the dissemination rates of COVID-19 grow exponentially over the days, which entails measures of social isolation to curb the spread of contagion. These controls were in all models in line with Ajzenman, Cavalcanti and Da Mata (2020) and Mariani, Gagete-Miranda and Retzl (2020).

Another relevant factor in the dissemination of COVID-19 was the degree of connection that one location has with others, leading to a spillover effect of the virus that causes COVID-19 between regions (Guliyev, 2020). In this case, geographic proximity can be a determining factor to explain the dynamics of the dissemination of COVID-19 and its non-inclusion in

statistical models implies a bias of the omitted spatial variable, making parameter estimates biased and inconsistent (Lesage; Pace, 2009; Anselin, 1988, 2003). In addition, the connection between places may not only be delimited by common geographic borders, as with the use of an airplane, but travel between countries can also take only a few minutes or hours, causing the dissemination of SARS-CoV-2 to occur faster way (Snyder; Parks, 2020; Nicoletis et al., 2021).

Social isolation policies alone cannot be a determining factor for the decrease in the prevalence of COVID-19 (Candido et al., 2020), requiring a combination of actions based on several other factors that also influence rate dynamics related to COVID-19, such as climatic and geographic factors so that the final result in the fight against SARS-CoV-2 is maximized. The results obtained in this research can help the policymaker to better understand how the idiosyncratic characteristics of the localities can influence the dynamics of the COVID-19 rates in space. In this way, public resources and efforts for the eradication of COVID-19 can be directed to a certain state that has favorable climatic conditions that are less favorable to the decrease in the prevalence rate of COVID-19.

5. CONCLUSIONS

This virus COVID-19 spread rapidly around the world, causing disease and leading to millions of deaths within a few months. Since then, several researchers have sought to determine which factors are capable of inhibiting the spread of the virus as well as COVID-19 incidence rates.

This research aimed to contribute to the literature by measuring the dynamic and spatial effects of COVID-19 dissemination rates, showing how these rates can be correlated throughout space and how climate variables can influence the spatiotemporal dynamics of COVID-19 in the Brazilian states. More specifically, we sought to measure the impact of climate variables such as hours of effective sunlight without cloud interference, temperature and relative humidity on COVID-19 prevalence rates in the Brazilian states from March 10 to April 10, 2020, due to the predominantly exogenous nature of these variables. Spatial models were used for the panel data, including spatial interactions between states.

We also tried to control for the effect of other sets of variables that as shown in several empirical studies, may affect COVID-19 prevalence rates. These variables, such as socioeconomic variables, aimed at controlling the effects of the idiosyncratic economic characteristics of the states; health profile variables, aimed at controlling the effect of health

conditions on COVID-19 prevalence rates; and political scenario variables because several studies have shown that government actions, such as decrees of social distancing, have impacts on the current statistics related to COVID-19, in addition to region fixed effects.

Preliminarily, several statistical tests were performed with the objective of choosing the most appropriate method for estimating the econometric models, given the nature of the data. Thus, the test of the multipliers of Breusch and Pagan Lagrange was resumed, where the hypothesis that OLS estimators would be more consistent was rejected. The Woodridge test, where the hypothesis of no serial correlation of the error terms, and the Pesaran test, rejected the hypothesis of noncontemporary correlation. Finally, Moran's I index rejected the null hypothesis of no spatial correlation in the data.

Therefore, the models posed by GLS were estimated, making use of the influences of spatial lags and fixed regression effects. The results showed that climate variables were significant in explaining the incidence of COVID-19 in the Brazilian states. The moving averages of these variables were used for periods of 14, 11 and 7 days due to the incubation time of COVID-19 and the time it takes for COVID-19 symptoms to manifest. It has been shown that the incidence of sunlight has a negative impact on COVID-19 prevalence rates, reducing the rate of contamination in states that have longer periods of sunlight probably by reducing the propensity for people to crowd indoors, so minimizing the risk of contagion.

The relative humidity and mean temperature were also significant to explain COVID-19 prevalence rates in the Brazilian states, both having a negative impact, which implies a reduction in the incidence of COVID-19 in the states because SARS-CoV-2 loses its ability to remain active in places with higher temperature and humidity levels.

The spatial lags of the covariates used in the spatial regression models were also significant in explaining COVID-19 prevalence rates in the Brazilian states, showing that climate factors not only affect COVID-19 prevalence rates in the states where they occur but also indirectly affect the rates related to COVID-19 in nearby states.

The results suggest that inter-regional policies to combat COVID-19 should be adopted taking into account the environmental characteristics of the localities, with states with a lower incidence of sunlight, lower temperature and lower relative humidity channeling resources for formulation and adoption of policies to combat the spread of SARS-CoV-2 as a way to save lives and reduce the impacts of the pandemic on the economy and on the health of the population. In this sense, social distancing rules and reinforced containment controls could be

reintroduced in winter and in areas with a higher transmission rate of the new coronavirus as found in this and other studies around the world.

References

Ajzenman, N.; Cavalcanti, T.; Da Mata, D. (2020) More Than Words: Leaders' Speech and Risky Behavior during a Pandemic (April 22, 2020). Available at SSRN: <https://ssrn.com/abstract=3582908> or <http://dx.doi.org/10.2139/ssrn.3582908>

Allcott, H.; Boxell, A.; Conway, J.; Gentzkow, M.; Thaler, M.; Yang, D. (2020) Polarization and public health: partisan differences in social distancing during the coronavirus pandemic. **Journal of Public Economics**.

Anselin, Luc. (1988) **Spatial Econometrics: methods and models**. Kluwer Academic Publishers.

_____. (2003) Spatial Externalities, Spatial Multipliers, and Spatial Econometrics. **International Regional Science Review**, v.26, n. 2, p.153–166.

Araneda, F.; Yáñez, A.; Núñez, D.; Boyero, L.; Tonin, A.; Cornejo, A.; Urbina, M.; Díaz, M.; Muñoz, G.; Esse, C. (2021) Environmental determinants of COVID-19 transmission across a wide climatic gradient in Chile. **Scientific Reports**. <https://doi.org/10.1038/s41598-021-89213-4>.

Ascani, A., Faggian, A.; Montresor, S. (2021) The geography of COVID-19 and the structure of local economies: The case of Italy. **Journal of Regional Science**, 61(2), 407-441.

Baker, R.; Yang, W.; Vecchi, G.; Metcalf, C.; Grenfell, B. (2020) Susceptible supply limits the role of climate in the early SARS-CoV-2 pandemic. **Science**.

Barrot, J.; Grassi, B.; Sauvagnat, J. (2020) Sectoral effects of social distancing. **Covid Economics**. Issue 3.

Borjas, G. (2020) Demographic determinants of testing incidence and Covid-19 infections in New York City neighbourhoods. **Covid Economics**.

Candido, D.; Claro, M.; Jesus, J.; Souza, W.; Moreira, F.; Dellicour, S.; Mellan, T.; Plessis, L. Pereira, R.; Sales, F.; Manuli, M.; Thézé, J. Almeida, L.; Menezes, M.; Voloch, C.; Fumagalli, M.; Coletti, T. (2020) Evolution and epidemic spread of SARS-CoV-2 in Brazil. **Science** 369, 1255–1260.

Chan, K. H.; Malik Peiris, J. S.; Lam, S. Y.; Poon, L. L. M.; Yuen, K. Y.; Seto, W. H. (2011). "The Effects of Temperature and Relative Humidity on the Viability of the SARS Coronavirus." **Advances in Virology**. <https://doi.org/10.1155/2011/734690>.

Chen, S.; Prettner, K.; Kuhn, M.; Geldsetzer, M.; Wang, C.; Bärnighausen, T.; Bloom, D. (2021) Climate and the spread of COVID-19. **Scientific Reports**, 11, 9042.

D'adamo, H.; Yoshikawa; T. Ouslander, J. (2020) Coronavirus Disease 2019 in Geriatrics and Long-Term Care: The ABCDs of COVID-19. **Journal of the American Geriatrics Society**.

Elhorst, J. P. (2010), **Spatial Panel Data Models**, Vol. C.2, Springer, chapter 2, pp. 377–407.

- Elhorst, J. P. (2011), 'Dynamic spatial panels: models, methods, and inferences', **Journal of Geographical Systems** 14, 5–28.
- Gatto, M.; Bertuzzob, E.; Maria, L.; Miccolid, S.; Carraro, L.; Casagrandia, R.; Rinaldo, A. (2020) Spread and dynamics of the COVID-19 epidemic in Italy: Effects of emergency containment measures. **PNAS** May 12, 2020 117 (19). <https://doi.org/10.1073/pnas.2004978117>.
- Gadarian, S.; Goodman, S.; Pepinsky, T. (2021) Partisanship, Health Behavior, and Policy Attitudes in the Early Stages of the COVID-19 Pandemic. **PLoS ONE**.
- Guliyev, H. (2020) Determining the spatial effects of COVID-19 using the spatial panel data model. **Spatial statistics**.
- Hoechle, D. (2007) Robust standard errors for panel regressions with cross-sectional dependence. **Stata Journal** 7: 281–312.
- Jaakkola, K.; Saukkoriipi, A.; Jokelainen, J.; Juvonen, R.; Kauppila, J.; Vainio, O.; Ziegler, T.; Rönkkö, E.; Jaakkola, J.; Ikäheimo, T. (2014) Decline in temperature and humidity increases the occurrence of influenza in cold climate. **Environmental Health**.
- Lesage, J.P.; Pace, R. K. (2009) **Introduction to Spatial Econometrics**. Chapman and Hall/CRC Press.
- Mariani, L.; Miranda, J.; Retzl, P. (2020) Words can hurt: How political communication can change the pace of an epidemic. **Covid Economics**. Issue 12.
- C. Merow; Urban, M. (2020) Seasonality and uncertainty in global COVID-19 growth rates. **PNAS** vol. 117 | no. 44.
- Nicolelis, M.; Raimundo, R.; Peixoto, P.; Andreazzi, C. (2021) The impact of super-spreader cities, highways, and intensive care availability in the early stages of the COVID-19 epidemic in Brazil. **Scientific Reports**.
- Noy, I.; Doan, N.; Ferrarini, B.; Park, D. (2020) Measuring the economic risk of Covid-19. **Global Policy**. Volume11, Issue4, September 2020, Pages 413-423.
- Paliolol, B.; Pereda, P.; Azzoni, C. Does weather influence COVID-19 transmission? (2020) **Regional Science Policy & Practice**.
- Paez, A.; Lopez, F.; Menezes, T.; Cavalcanti, R.; Pita, M. (2020) A Spatio-Temporal Analysis of the Environmental Correlates of COVID-19. Incidence in Spain. **Geographical Analysis**.
- Pesaran, M. H. (2004) General diagnostic tests for cross section dependence in panels. University of Cambridge, Faculty of Economics, **Cambridge Working Papers in Economics** No. 0435.
- Porsse, A.; Sousa, K.; Carvalho, T.; Vale, V. (2020) The economic impacts of COVID-19 in Brazil based on an interregional CGE approach. **Regional Science Policy and Practice**.
- Scafetta, N. (2020) Distribution of the SARS-CoV-2 Pandemic and Its Monthly Forecast Based on Seasonal Climate Patterns. **International Journal of Environmental Research and Public Health**, 17;17(10):3493. doi: 10.3390/ijerph17103493.

Snyder, B.; Parks, V. (2020) Spatial Variation in Socio-ecological Vulnerability to COVID-19 in the Contiguous United States. **Health & Place**.

Tobías, A. (2020) Evaluation of the lockdowns for the SARS-CoV-2 epidemic in Italy and Spain after one month follow up. **Science of the Total Environment**.

Tobías, A.; Molina, T. (2020) Is temperature reducing the transmission of COVID-19? **Environmental Research**.

Toda, A. (2020) Susceptible-Infected-Recovered (SIR) Dynamics of COVID-19 and Economic Impact. arXiv:2003.11221 [q-bio.PE].

Wang, J.; Tang, K.; Feng, K.; Lv, W.; Chen, K.; Wang, F. (2021) Impact of temperature and relative humidity on the transmission of COVID-19: a modelling study in China and the United States. **BMJ Open**.

Wooldridge, J. (2002) **Econometric Analysis of Cross Section and Panel Data**. Cambridge, MA: MIT Press.

Ying-Ying, Z.; Yi-Tong, M.; Jin-Ying, Z.; Xiang, X. (2020) Covid-19 and the cardiovascular system. **Nature Review Cardiologist**. <https://doi.org/10.1038/s41569-020-0360-5>.