Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”

Os impactos do desmatamento na incidência de malária na Amazônia: uma análise espacial

Augusto Seabra Santos

Dissertação apresentada para obtenção do título de Mestre em Ciências. Área de concentração: Economia Aplicada

Piracicaba
2016

Augusto Seabra Santos
Bacharel em Ciências Econômicas

Os impactos do desmatamento na incidência de malária na Amazônia: uma análise espacial

Orientador:
Prof. Dr. **ALEXANDRE NUNES DE ALMEIDA**

Dissertação apresentada para obtenção do título de Mestre em Ciências. Área de concentração: Economia Aplicada

Piracicaba
2016

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Santos, Augusto Seabra

Os impactos do desmatamento na incidência de malária na Amazônia: uma análise espacial / Augusto Seabra Santos. - - Piracicaba, 2016.

117 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura “Luiz de Queiroz”.

1. Malária 2. Desmatamento 3. Indicadores socioeconômicos 4. Econometria Espacial I. Título

DEDICATÓRIA

Se não sabes, aprende. Se já sabes, ensina

Confúcio

Dedico a Claudia

AGRADECIMENTOS

A minha mãe, Claudia, pelos conselhos, amizade, compreensão e por tudo que tem feito, sem medir esforços. A razão da existência deste trabalho se deve a senhora.

Ao meu pai, Helder, pelos conselhos e amizade.

Aos meus avós maternos e paternos, Antônio e Nadege, José e Izabel.

A toda minha família, tios e primos e ao Gilberto.

A minha amada, Marina, pelo carinho, amor, paciência e, acima de tudo, amizade.

Ao meu orientador, Alexandre Almeida, pelos conselhos, contribuições e por acreditar integralmente nas minhas capacidades de desenvolver o trabalho.

Aos professores do exame de qualificação, André Chagas, Carlos Azzoni e Humberto Spolador, que teceram comentários primordiais para a qualidade do trabalho.

Aos professores que participaram do meu processo de formação tanto no bacharelado, quanto no mestrado.

Aos funcionários do Programa de Pós Graduação em Economia Aplicada.

Aos amigos de república, André, Gustavo, Henrique, Leandro, Pedro, Rafael e Tiago, pelo convívio e pela amizade.

Aos amigos conquistados durante o mestrado, Diego, Josimar e Pedro, pela amizade e pelas discussões filosóficas acerca da ciência.

Aos amigos de longa data, Antônio Márcio, Emmanuel, Geraldo, Gustavo, Iago, Kássio, Marcos Paulo, Mateus, Pedro Paulo e Thiago Pereira, pela amizade que me acompanha a anos.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico -CNPq, pelo apoio financeiro em forma de bolsa de estudos.

Em geral, agradeço a todos que contribuíram direta e indiretamente para a conclusão deste trabalho.

SUMÁRIO

RESUMO 7
ABSTRACT 8
LISTA DE FIGURAS 9
LISTA DE TABELAS 10
1. INTRODUÇÃO 13
1.1. Objetivos 15
1.2.1. Objetivo Geral 15
1.2.2. Objetivo Específico 15
2. REVISÃO BIBLIOGRÁFICA 17
2.1. Malária, Desmatamento e Meio Ambiente 20
2.2. Malária, Desenvolvimento Econômico e Desenvolvimento Agrícola 23
3. DADOS 27
4. METODOLOGIA 33
4.1. Análise Exploratória de Dados Espaciais (AEDE) 33
4.2. Matriz de Ponderação Espacial 36
4.3. Dados em Painel 39
4.4. Dados em Painel Espacial 42
4.4.1. Estimação do Modelo de Defasagem Espacial de Efeitos Fixos - SAR 43
4.4.2. Estimação do Modelo de Erro Espacial de Efeitos Fixos – SEM 45
4.4.3. Efeitos *Spillovers* 47
4.4.4. Escolha do Modelo Espacial 51
4.5. Estratégia Empírica 54
5. RESULTADOS E DISCUSSÃO 57
5.1. Análise Exploratória de Dados Espaciais da Incidência de Malária 57
5.2. Procedimentos para a Escolha do Modelo e da Matriz Espacial 62
5.3. Resultados da Estimação do Modelo SDEM 67
5.4. Checagem de Robustez dos Resultados 75

5.4.1. Resultados da Estimação dos Modelos Econométricos de Dados em Painel 75
5.4.2. Resultados da Estimação dos Modelos Espaciais 79
5.4.3. Modelos Econométricos Espaciais sem *lag* 86
5.4.4. Checagem de Robustez para o Desmatamento 90
5.5. Diretrizes de Políticas Públicas 93
6. CONCLUSÃO 97
REFERÊNCIAS 101
APÊNDICE 106
ANEXOS 109

RESUMO

OS IMPACTOS DO DESMATAMENTO NA INCIDÊNCIA DE MALÁRIA NA AMAZÔNIA: UMA ANÁLISE ESPACIAL

O objetivo deste estudo foi analisar a relação dos casos de malária com o desmatamento nos municípios da Amazônia Legal, entre os anos de 2003 e 2012. A pesquisa também intenta contribuir para a literatura ao realizar uma análise econométrica espacial, viabilizando capturar efeitos *spillovers* das variáveis em estudo sobre a incidência de malária na região. Primeiramente, evidenciou-se que os casos de malária na região da Amazônia Legal não são distribuídos aleatoriamente entre os municípios, ou seja, a doença é correlacionada espacialmente. Também foram encontrados indícios de que municípios com altos índices parasitários anuais de malária, estão rodeados de outros municípios que também apresentam alta incidência de paludismo. Em relação às estimações econométricas, foram encontradas evidências de que o desmatamento possui uma correlação estatística com os casos de paludismo, onde, áreas de até 425 Km^2 de mata derrubada possuem uma relação positiva com os casos da doença, enquanto áreas desmatadas acima de 425 Km^2 possuem relação negativa com contaminação por malária. Não obstante, o estudo também encontrou uma relação positiva dos dispêndios municipais *per capita* com saúde com os casos da doença. Já os gastos municipais com habitação e o efetivo bovino municipal tiveram efeitos negativos em relação à doença. Ademais, não foram encontradas evidências de que a área de soja e de que demais culturas agrícolas possam afetar a dinâmica de infecção por malária. Já o Produto Interno Bruto municipal gerou resultados inconclusivos. Para aferir a robustez das estimativas, o estudo também realiza um exercício de comparação dos resultados obtidos a partir de diversos modelos de dados de painel, tanto convencionais, quanto espaciais, atualmente usados pela literatura.

Palavras-chave: Malária; Desmatamento; Indicadores socioeconômicos; Econometria espacial

ABSTRACT

IMPACTS OF DEFORESTATION IN THE INCIDENCE OF MALARIA IN BRAZILIAN AMAZON: THE SPATIAL ANALISYS

The aim of this study was to analyze the relationship of cases of malaria with deforestation in the municipalities of the Amazon, between 2003 and 2012. The research also intends to contribute to the literature through of spatial econometrics models, enabling capture effects spillovers of several socio economic determinants on incidence of malaria in the region. First, it became clear that the cases of malaria in the Amazon region are not randomly distributed among the municipalities, meaning that the disease is spatially correlated. It was also found evidence that municipalities with higher annual rates of malaria parasites are surrounded by other municipalities that also have a higher incidence of malaria. Regarding to the econometrics estimates, it was found evidence that deforestation is strongly statistically correlated with malaria cases, where areas of up to 425 km^2 of loss os forest cover has a positive relationship with the cases of the disease, while deforested areas above 425 km^2 have negative relationship with contamination malaria. Notwithstanding, the study also found a positive relationship between health public expenditures with cases of the disease. Housing public expenditures ans cattle heard have shown negative relationships with malaria infection. Moreover, no evidence was found that the soybean area and that other crops can affect the dynamics of malaria infection. Finally, municipal GDP generated inconclusive results. To assess the robustness of the estimates, the study also performed a comparison from multiple panel data models, both conventional well as spatial, currently used in the literature.

Keywords: Malaria; Deforestation; Socioeconomics indicators; Spatial econometrics

LISTA DE FIGURAS

Figura 1. Evolução dos casos clínicos de malária e do desmatamento 19
Figura 2. Índice Parasitário Anual de Malária. 2003 – 2009 – 2012. 31
Figura 3. Mapa de Densidade de Kernel. 2003 – 2009 – 2012 32
Figura 4. Diagrama de Dispersão de Moran 36
Figura 5. Dispersão de Moran Local para os casos Malária . 2003 – 2009 – 2012 59
Figura 6. Mapa da Estatística de *I* de Moran Local para os casos Malária. 2003 – 2009 – 2012 61
Figura 7. Índice Parasitário Anual de Malária 110
Figura 8. Mapa da estatística I de Moran Local para os casos de Malária 111

LISTA DE TABELAS

Tabela 1. Descrição das variáveis. 27
Tabela 2. Estatísticas descritivas 28
Tabela 3. Efeitos diretos e indiretos para os modelos espaciais 50
Tabela 4. Sinais previamente esperados 55
Tabela 5. Estatística *I* de Moran para os casos de malária 54
Tabela 6. Estatística *c* de Geary para os casos de malária 58
Tabela 7. Teste LR entre os modelos com *lag* e sem *lag* 62
Tabela 8. Testes LM-ERR, LM-LAG e LM-SARAR com a matriz Queen. 63
Tabela 9. Testes LM-ERR, LM-LAG e LM-SARAR com a matriz com raio de 300Km 63
Tabela 10. Testes LM-ERR, LM-LAG e LM-SARAR com a matriz de distância inversa. . . . 63
Tabela 11. Testes LM-ERR, LM-LAG e LM-SARAR com a matriz de KNN5 64
Tabela 12. Teste LR entre os modelos espaciais 64
Tabela 13. AIC para os modelos espaciais. 65
Tabela 14. Procedimentos para a escolha da matriz de pesos espaciais 66
Tabela 15. Efeitos diretos, indiretos e totais para o modelo SDEM 68
Tabela 16. Coeficientes estimados para os modelos de dados em painel 78
Tabela 17. Efeitos diretos dos modelos econométricos espaciais 83
Tabela 18. Efeitos indiretos dos modelos econométricos espaciais. 84
Tabela 19. Efeitos totais dos modelos econométricos espaciais 85
Tabela 20. Efeitos diretos e indiretos para os modelos econométricos espaciais sem *lag* 88
Tabela 21. Efeitos totais para os modelos econométricos espaciais sem *lag* 89
Tabela 22. Checagem de robustez para a área desmatada 92
Tabela 23. Estatística *I* de Moran para o desmatamento 112
Tabela 24. Estatística *c* de Geary para o desmatamento 112
Tabela 25. Estatística *I* de Moran para o percentual de floresta 113
Tabela 26. Estatística *c* de Geary para o percentual de floresta 113
Tabela 27. Estatística *I* de Moran para a densidade populacional 113
Tabela 28. Estatística *c* de Geary para a densidade populacional 114
Tabela 29. Estatística *I* de Moran para os dispêndios com saúde 114
Tabela 30. Estatística *c* de Geary para os dispêndios com saúde 114

Tabela 31. Estatística *I* de Moran para os dispêndios com habitação. 115
Tabela 32. Estatística *c* de Geary para os dispêndios com habitação. 115
Tabela 33. Estatística *I* de Moran para o PIB 115
Tabela 34. Estatística *c* de Geary para o PIB 116
Tabela 35. Estatística *I* de Moran para o efetivo bovino 116
Tabela 36. Estatística *c* de Geary para o efetivo bovino 116
Tabela 37. Estatística *I* de Moran para a área plantada de soja. 117
Tabela 38. Estatística *c* de Geary para a área plantada de soja 117
Tabela 39. Estatística *I* de Moran para a área plantada das demais culturas 117
Tabela 40. Estatística *c* de Geary para a área plantada das demais culturas 118

1. INTRODUÇÃO

A malária, em uma década, foi responsável por cerca de 3,8 milhões de casos clínicos no Brasil, gerando a necessidade de articulações nas políticas de saúde e despendendo milhões de reais dos cofres públicos para o tratamento e controle dessa doença. No Brasil, quase a totalidade dos casos (acima de 99%) concentram-se na região da Floresta Amazônica[1] , sendo três espécies de protozoários associados à malária em seres humanos no país: *P.vivax*, *P. falciparum* e *P. malariae*. O mosquito vetor transmissor mais comum na região é o *Anopheles darlingi*, sendo os vetores *An. deaneorum*, *An. marajoara* e *An. janconnae* menos comuns, mas também com capacidade de transmissão do protozoário (MS, 2015).

Os custos do paludismo vão muito além de despesas hospitalares no tratamento e de prevenção da doença. Os sintomas causados pela infecção podem gerar efeitos negativos sobre a produtividade no trabalho dos adultos, acarretando assim um custo econômico que pode ser um potencial entrave ao desenvolvimento nas regiões de risco de contaminação (CUTLER et al., 2010). No entanto, o efeito mais nocivo da presença da malária está principalmente entre as crianças, comprometendo seu desenvolvimento físico e cognitivo, diminuindo sua capacidade de ter um avanço escolar significativo (DUFFY; DESOWITZ, 2001; LUCAS, 2010).

Além da educação e da produtividade, outros custos econômicos da malária podem ser citados, como os impactos no comércio, migração para áreas não endêmicas, menor atividade turística e diminuição do investimento direto estrangeiro (SACHS; MALANEY, 2002). Deste modo, compreender como ocorre a dinâmica de infecção da malária é de suma importância para o desenvolvimento regional dos locais endêmicos e norteia-se como objetivo principal do presente trabalho.

Desmatamento, agricultura, extração madeireira, mineração e migração são atividades que podem criar um ambiente propício para a proliferação do mosquito *Anopheles darlingi*, o principal vetor transmissor da malária no Brasil (HAHN et al., 2014). As quatro primeiras atividades possuem a característica de transformar a floresta Amazônica, gerando potenciais mudanças no microclima da região modificada, mudanças na biodiversidade, incluindo a extinção dos predadores naturais do mosquito, além de maiores espaços

[1]No Brasil, a floresta Amazônica está presente nos estados do Acre, Amapá, Amazonas, Pará, Rondônia, Roraima e partes do Maranhão, Tocantins e Mato Grosso.

para a reprodução do vetor (BAUCH et al., 2014). Já a migração para a região endêmica faz com que pessoas não imunes à doença sejam expostas à ação do mosquito, aumentando, assim, a incidência da infecção[2] (MARQUES, 1987). Além disto, existem evidências que o aquecimento global e o El Niño também podem propiciar condições ideais para a proliferação do mosquito hospedeiro, gerando aumentos no índice parasitário de malária (SACHS; MALANEY, 2002; BOSELLO; ROSON; TOL, 2006).

Desta forma, a malária na Amazônia não pode ser estudada apenas em termos médicos e biológicos, sendo que as relações entre meio ambiente, agricultura, demografia, condições socioeconômicas e políticas públicas são de suma importância para a compreensão do fenômeno da propagação da malária (SINGER; CASTRO, 2001). É neste sentido que este estudo busca analisar os efeitos do desmatamento na incidência de malária na região da Amazônia brasileira. Ademais, o artigo também incorpora outros elementos como os gastos públicos com habitação e saúde, desenvolvimento agropecuário e crescimento econômico, que podem contribuir na política pública de saúde para a erradicação do paludismo.

Toda a análise proposta será empreendida levando em conta a distribuição da doença no espaço. Deste modo, o trabalho possui a capacidade de não só verificar os efeitos médios locais das covariadas, mas também possui o potencial de compreender a ocorrência de efeitos *spillovers*. A análise econométrica espacial deste problema a níveis municipais, até a data presente, traz uma nova abordagem na literatura científica sobre a epidemia de paludismo, almejando colaborar na formulação de políticas públicas de saúde mais especificas e direcionadas de combate a malária.

Entre os principais resultados, evidenciou-se que o desmatamento possui uma relação estatística com os casos de malária, onde, nas fases iniciais de derrubada da mata, aumenta-se os casos de malária e, nas fases mais avançadas de desflorestamento (acima de 425 Km^2), ocorre relação negativa com os casos de paludismo. Também houveram indícios de que os gastos municipais com saúde aumentam as estatísticas da doença, reflexo da maior capacidade de detecção. Os gastos municipais com habitação e o efetivo bovino tiveram um impacto negativo nos casos de paludismo. Ademais, a densidade populacional, o PIB, a área plantada de soja e a área plantada de demais culturas tiveram resultados inconclusivos acerca das relações com a infecção.

Além desta introdução, este trabalho é composto por mais quatro seções.

[2]Ressalta-se que indígenas e moradores (adultos) da região endêmica geralmente desenvolvem imunidade a doenças parasitárias (PATZ et al., 2000; SACHS; MALANEY, 2002).

A segunda apresenta a revisão da literatura sobre o tema, ao passo que a terceira seção é dedicada ao detalhamento da metodologia utilizada. Os resultados são apresentados e discutidos na quarta seção, enquanto que na quinta são tecidas as considerações finais ao trabalho.

1.1. Objetivos

1.1.1. Objetivo Geral

A pesquisa intenta buscar a relação entre desmatamento e casos de malária na Amazônia Brasileira. Ademais, objetiva-se também verificar a relação entre crescimento econômico, desenvolvimento agrícola e gastos municipais com habitação e saúde com os casos de paludismo na região.

1.1.2. Objetivo Específico

Especificamente, a pesquisa tem como objetivo estimar uma regressão de dados em painel espacial, sendo 757 unidades cross-section (municípios da região amazônica brasileira), com um horizonte temporal de 10 anos (2003 a 2012), analisando os efeitos diretos e indiretos do desmatamento, desenvolvimento agrícola, crescimento econômico e gastos municipais na incidência de malária.

2. REVISÃO BIBLIOGRÁFICA

Atualmente, cerca de metade da população mundial vive em áreas de risco de infecção por malária, totalizando 3,2 bilhões de pessoas em situação de alerta. A cada ano surgem de 300 a 500 milhões de novos casos da doença, levando a três milhões de óbitos por ano. Aproximadamente 90% dos casos são transmitidos na África Subsaariana, sendo que as crianças são mais vulneráveis a contrair a doença (SACHS; MALANEY, 2002; WHO, 2016).

No Brasil, a malária começou a ter notoriedade após a migração em massa para a região amazônica durante a segunda guerra mundial, época em que ocorreu a corrida pela extração da borracha, levando a óbito cerca de 27 mil pessoas que trabalhavam nas seringueiras. De 1945 até o início da década de setenta houve uma queda na incidência da doença devido o uso do inseticida DDT, chegando a 52,5 mil casos em 1970 (SINGER; CASTRO, 2001)

Cabe ressaltar que, na década de sessenta, o governo brasileiro criou a Campanha de Erradicação de Malária (CEM), que consistia na aplicação intradomiciliar de *diclorodifeniltricloroetano* (DDT), conjuntamente com o uso de drogas anti-maláricas que visavam o esgotamento das fontes de infecção. A CEM teve um papel fundamental para a erradicação do paludismo nas regiões brasileiras do Nordeste, Centro-Oeste, Sudeste e Sul. Embora esta estratégia foi eficaz nas regiões citadas, na região da Amazônia tal intervenção não obteve a mesma eficácia no que tange a erradicação. O insucesso do CEM na Amazônia pode estar atrelado às características climáticas locais, ausência de superfícies borrifáveis nos domicílios da região, resistência do *P. falciparum* aos antimaláricos, alta incidência de grupos humanos expostos ao vetor, ausência de serviços de saúde permanente e condições sociais inadequadas (LOIOLA; SILVA; TAUIL, 2002).

Apesar de relativo insucesso do CEM, evidenciou-se um decréscimo dos casos da doença até o final da década de setenta. No início da década de oitenta, a região amazônica passou por uma grande transformação induzida pelo programa de colonização, gerando uma massiva migração para a região, além de surgimento da mineração e construção de estradas, abrindo caminhos a locais antes inacessíveis. Esta transformação estrutural fez com que os casos de malária tivessem um aumento expressivo, passando a 200 mil casos em 1982 e 500 mil em 1988 (SINGER; CASTRO, 2001).

Em 1989, o Ministério da Saúde criou o Programa de Controle da Malária na Bacia Amazônica (PCMAM), mas somente a partir de 1993 o PCMAM conseguiu executar 100% dos recursos alocados. Desta forma, o controle da infecção é ampliado na Amazônia com a criação de laboratórios para diagnóstico e tratamento da doença e melhoria na captação de recursos humanos, como médicos e equipes técnicas que auxiliam no combate à malária. O PCMAM impactou em redução de mortalidade da doença (7 mortes a cada 100 mil habitantes em 1988 contra 1,8 mortes a cada 100 mil habitantes em 1995) e também reduziu a incidência do paludismo no período de vigência do programa. Após o término do PCMAM, a incidência de malária tornou a elevar na região, passando de 440 mil casos em 1996 para 630 mil em 1999 (LOIOLA; SILVA; TAUIL, 2002).

Visando o retorno da redução dos casos de paludismo, o governo brasileiro lançou, em 2000, o Plano e Intensificação das Ações de Controle da Malária na Amazônia Legal (PIACM), caracterizado por maior integração com setores paralelos a área de saúde, como o Ministério do Meio Ambiente, e também caracterizado pela descentralização das ações, englobando os Estados e municípios no programa. O PIACM teve certa efetividade, visto que, de 1999 a 2001 ocorreu uma redução de cerca de 40% nos casos de malária, com 380 mil casos em 2001 (LOIOLA; SILVA; TAUIL, 2002).

Após o término do PIACM os casos de malária voltaram a aumentar na Amazônia, onde, em 2005, o número de casos de paludismo chegou a 590 mil casos, sendo este o ápice da incidência malária no século XXI em território brasileiro. De 2006 a 2015 ocorreu uma diminuição dos casos da infecção, sendo confirmados 230 mil casos em 2012 e 130 mil em 2015. A mortalidade da doença caiu em 89% de 2000 a 2015 (MS, 2015).

Paralelamente em que ocorreram as diminuições na incidência de malária no século XXI, houve também um processo significativo de diminuição do desmatamento da floresta amazônica, sugerindo haver uma forte correlação entre desmatamento e a incidência de casos da doença na região. Em 2001, foram desmatados mais de 18 mil Km^2, ao passo de que em 2004 ocorreu a derrubada de 27 mil Km^2 da floresta Amazônica. No ano 2005 houve uma inflexão na tendência de desmatamento, chegando em 2015 com apenas 5,8 mil Km^2 desmatados. Boa parte da diminuição do desmatamento deve-se ao programa governamental PPCDAm (Plano de Prevenção e Controle do Desmatamento na Amazônia Legal), iniciado em 2004, que aumentou fiscalização nos municípios com altas taxas de desmatamento (ASSUNÇÃO; GANDOU; ROCHA, 2012). A Figura 1 mostra a evolução

do desmatamento e dos casos clínicos de malária na Amazônia, de 2003 a 2012.

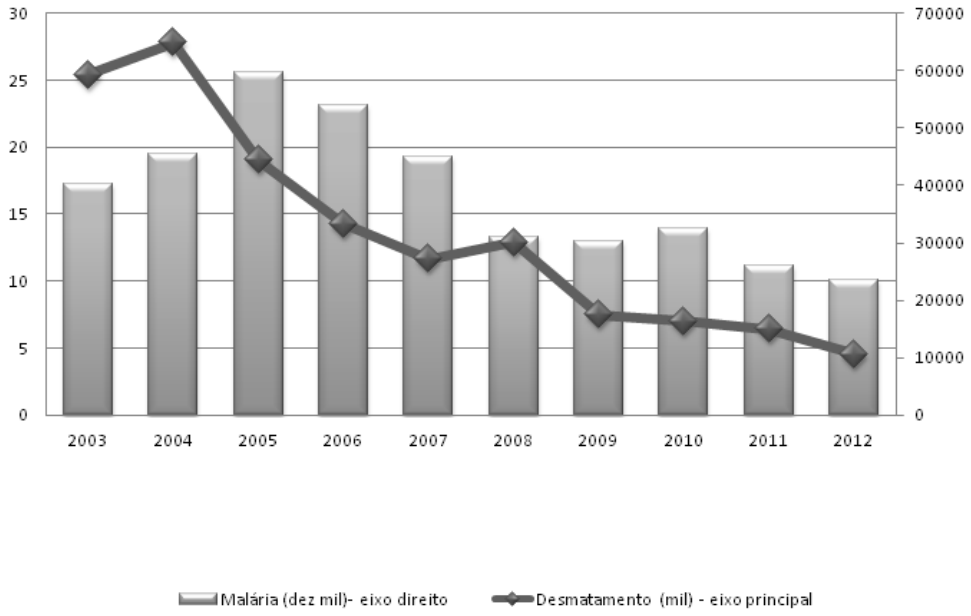

Figura 1. Evolução dos casos clínicos de malária e do desmatamento.
Fonte: Elaboração própria com os dados disponibilizados pelo PRODES e pelo Ministério da Saúde.

2.1. Malária, desmatamento e meio ambiente

Áreas na região de florestas tropicais possuem condições ideais para a reprodução dos insetos devido às altas temperaturas, grandes volumes de precipitação e umidade relativa do ar elevada. O *Anopheles darlingi*, na região amazônica, é encontrado mais frequentemente nas margens das florestas ("franjas florestais"), pois, na floresta densa e intacta, as condições para a reprodução são dificilmente encontradas. Deste modo, cada mudança ambiental, seja ela através de fenômenos naturais ou antropogênicos, possui o poder de mudar o balanço ecológico local, podendo afetar a dinâmica de transmissão de parasitas, propiciando, assim, condições para a proliferação do vetor transmissor da malária.

Uma mudança ambiental que pode ser determinante na dinâmica de infecção por malária é o desmatamento. A derrubada da mata nativa, geralmente, amplia regiões de "franjas florestais", que por sua vez possuem condições propícias para a proliferação dos *Anophelinos*. O desflorestamento também aumenta o contato de seres humanos com animais silvestres, que podem ser hospedeiros intermediários do *Plasmodium*. Ademais, o desmatamento pode causar potenciais mudanças no microclima da região modificada e eliminar predadores naturais dos vetores transmissores (PATZ et al., 2000; SINGER; CASTRO, 2001; BAUCH et al., 2014).

No âmbito científico existem trabalhos que documentam a relação entre desmatamento e casos de malária. Vittor et al. (2006) realizou uma pesquisa no sentido de verificar a incidência do mosquito *Anopheles darlingi* em áreas de degradação de florestas tropicais no Peru. Os autores encontraram evidências de que existem uma incidência do mosquito em áreas desmatadas 278 maior do que a taxa encontrada em áreas de floresta preservada.

Garg (2014) propôs, através de microdados coletados do censo de vilarejos promovido pela *Badan Pusat Statistik*, um estudo entre a incidência de malária e desmatamento na Indonésia. O autor, por meio de um *logit*, encontrou evidências de que o desmatamento pode explicar mais de um milhão de casos de paludismo. Além disso, Garg (2014) estimou que um aumento de 1000 ha desmatados em um distrito pode propiciar um aumento de casos de malária na ordem de 2% a 7,2%, culminando em 45 mil a 162 mil casos adicionais da infecção.

Visando buscar a relação entre pertubação da floresta e incidência de malária, Wayant et al. (2010) utiliza a análise de séries temporais. Por meio da técnica de trans-

formada de Fourrier, os autores evidenciaram uma relação entre mudança na cobertura da terra, principalmente a relação entre conversão de áreas florestais para áreas não-florestais, com a incidência de malária no Paraguai.

Para o Brasil, Junior, Mation e Sakowski (2015), por meio da regressão de Poisson, encontraram que o desmatamento, não só atual, mas também defasado, possui relação com a incidência de malária. Os resultados encontrados pelos autores, indicam que, para cada 1% de área desmatada, pode ocorrer um incremento de 23% nas taxas de incidência de malária.

Assim como Junior, Mation e Sakowski (2015), Terrazas et al. (2015) e Achcar et al. (2011) também encontraram relações entre desmatamento e incidência de malária no Brasil. Terrazas et al. (2015), por meio de uma regressão linear múltipla, encontraram que a média anual da taxa de desmatamento, na Amazônia brasileira, possui relação positiva com a incidência de malária na região. Já Achcar et al. (2011), utilizando métodos bayesianos de regressão espaço-temporais de Poisson, também reforçam que o desflorestamento na Amazônia é um fator importante para a predição da malária no Brasil. Esta relação também é confirmada por Bauch et al. (2014), que utilizando a metodologia de regressão quantílica e tendo como foco a análise dos municípios da Amazônia brasileira, encontraram uma relação negativa entre áreas de proteção ambiental e incidência de malária.

Em consonância com Garg (2014) e Junior, Mation e Sakowski (2015) , Olson et al. (2010) também encontraram evidências de que o desmatamento pode acarretar em um aumento dos casos de malária no município de Mâncio Lima, localizado no Estado do Acre. Tal inferência foi possibilitada através de uma regressão binomial negativa, concluindo que o risco de malária aumentou, aproximadamente, 50% em distritos do município quando 4% da área eram submetidas a desmatamento, no período 1997-2000. Já Parente, Souza e Ribeiro (2012), encontraram padrões semelhantes entre aumento do desmatamento e aumento do índice parasitário de malária nos municípios de Anajás, Itaituba, Santana do Araguaia e Viseu, todos localizados no Estado do Pará.

Hahn et al. (2014) encontraram, por meio de uma regressão binomial negativa, evidências empíricas de que a relação entre incidência malária e desmatamento varia dependendo da escala escolhida para o estudo. Em uma análise de amplitude municipal, a relação entre malária e desmatamento não foi estatisticamente significativa na região Amazônica Brasileira, sendo que as estradas, queimadas e extração seletiva de madeira

foram mais representativos do que nível real de perturbação da floresta.

Por outro lado, o desmatamento, via derrubada em larga escala, pode influenciar negativamente os casos de paludismo, de modo que ocorra um aumento da distância entre "franjas florestais" e os centros urbanos. O desmatamento em larga escala também pode incorrer na total derrubada da floresta, que, por sua vez, diminui a capacidade de gerar condições ideais para os vetores transmissores do paludismo (VALLE; CLARK, 2013).

Valle e Clark (2013) encontraram resultados divergentes sobre o tema. Os autores constataram que cidades perto de áreas protegidas tendem a ter maior incidência de malária do que as cidades mais distantes. Desta forma, os autores concluíram que evitar 10% do desmatamento pode resultar em um aumento médio de duas vezes na incidência de malária até 2050. Os resultados de Valle e Clark (2013) sugerem que locais de florestas que são submetidos ao total desmatamento podem ser isentos de casos da doença, visto que, localidades sem reserva de floresta são menos suscetíveis a ocorrer uma epidemia de paludismo.

Até a data presente, são escassos os trabalhos na literatura científica que incluem na estimação da regressão a relação espacial entre meio ambiente e malária. Olson et al. (2010) argumentam que existem associações dos padrões de incidência de malária e de desmatamento ao longo do espaço, ao invés de uma tendência de incidência de malária e do desmatamento ao longo do tempo. Hahn et al. (2014) sugere que o desmatamento tende a ser espacialmente agrupado dentro dos municípios, tornando-o difícil de igualar os níveis de desmatamento e incidência da malária através das fronteiras municipais. Deste modo, fica clara a importância de compilar técnicas de regressão espacial para o tema, reafirmando a importância no contexto científico do presente artigo, visando fortalecer o dimensionamento das políticas públicas para a região.

2.2. Malária, desenvolvimento econômico e desenvolvimento agrícola

Como mencionado na seção anterior, a malária e o desenvolvimento socioeconômico podem estar interligados por relações causais bidirecionais. Tanto a malária pode ser a propulsora de alterações nos índices de crescimento e desenvolvimento econômico, como o contrário, sendo que o crescimento, desenvolvimento e atividades econômicas podem alterar a dinâmica de infecção por malária.

Doenças têm gerado um debate nas ciências econômicas sobre seu poder de delimitar o desenvolvimento econômico. Acemoglu e Johnson (2007) encontraram fracas evidências de que os baixos índices de desenvolvimento das nações estejam associados ao panorama local de saúde. Já Bloom e Sachs (1998) afirmam que as condições de saúde podem explicar parte da diferença entre as taxas de crescimento na África e as taxas de crescimento nos demais países.

A relação da malária com educação e produtividade também é bem documentada no âmbito científico. Segundo Barlow (1967), o paludismo gera três efeitos aos seres humanos que podem ser um entrave à força de trabalho em locais endêmicos. O primeiro é a debilidade, que está atrelada à baixa produtividade da mão-de-obra local. Já a morbidade, causada pela doença, gera uma diminuição temporária da força de trabalho. Por fim, no caso mais extremo da infecção, altos índices de mortalidade tendem a diminuir, permanentemente, a força de trabalho em localidades onde existem epidemias de malária.

A malária também pode ter efeitos sobre a educação de crianças. Durante a gravidez, a infecção pode gerar anemia, afetando o desenvolvimento físico e cognitivo do feto, assim diminuindo a probabilidade da criança ter um sucesso escolar. Além disto, contrair a infecção durante a infância pode causar sintomas ao longo da vida, diminuindo a capacidade de aprendizagem. O paludismo também pode gerar o afastamento da criança na escola por um longo período, interrompendo o processo de formação escolar (LUCAS, 2010; DUFFY; DESOWITZ, 2001). Neste sentido, Lucas (2010) encontra uma relação positiva entre a erradicação da malária e melhorias na educação no Paraguai e na Sri Lanka, sendo que a cada diminuição de 10 pontos percentuais na incidência de malária leva a um aumento de 0,1 anos de escolaridade e um aumento na probabilidade de alfabetização de 1 a 2 pontos percentuais.

Diferentemente de Lucas (2010), Cutler et al. (2010) não encontra evidências de um efeito da erradicação da malária na melhoria da educação na Índia. Entretanto, o estudo encontrou evidências de que crianças expostas ao programa de erradicação da malária tinham um maior consumo domiciliar quando adultos, sendo que este maior consumo pode ser fruto de ganhos de produtividade após o programa de erradicação. Todavia, não se comprova que a erradicação da malária foi um dos principais motores para o crescimento.

Em relação ao crescimento econômico, Barlow (1967) encontrou evidências de que a erradicação do paludismo, no Sri Lanka, pode ter um efeito benéfico sobre a economia no curto prazo, via redução de debilidade e morbidade. Todavia, os benefícios econômico da erradicação da infecção no longo prazo não são claros, visto que o extermínio da doença pode ocasionar um *boom* populacional, gerando efeitos indesejáveis à economia do país.

Apesar de a malária poder afetar o desenvolvimento e crescimento econômico, a relação contrária também pode ser observada. Locais mais desenvolvidos tendem a ter uma melhor vantagem na erradicação da malária. Um exemplo disso é a erradicação do paludismo nos Estados Unidos, Espanha, Itália e Grécia nas décadas de 30 e 50, resultados de desenvolvimento socioeconômico e intensiva política de saúde para o extermínio da doença. Apesar do sucesso destes países, desenvolvimento e crescimento econômico não são, por si só, suficientes para a erradicação da infecção, vide Omã e Emirados Árabes Unidos, que possuem alto PIB *per capita*, mas não conseguiram sucesso na erradicação da doença (SACHS; MALANEY, 2002). Deste modo, a combinação de boas práticas ambientais e desenvolvimento socioeconômico podem ser efetivos para o controle da epidemia de malária.

No sentido de verificar a relação entre incidência de malária e desenvolvimento socioeconômico no Brasil, Terrazas et al. (2015) encontraram evidências, através de uma regressão linear, de que o Índice de Desenvolvimento Humano (IDH) possui relação negativa com a incidência de malária na Amazônia. Já Junior, Mation e Sakowski (2015) analisa separadamente os componentes do IDH, indicando que somente o IDH-educação possui relação negativa com os casos de paludismo. Ademais, Junior, Mation e Sakowski (2015) não encontra a relação entre índice parasitário de malária e IDH-longevidade, IDH-renda e quantidade de pessoas atendidas pelo programa "bolsa família".

Apesar de existir evidências de que o desenvolvimento econômico pode ser capaz melhorar as condições sociais para o combate à doença, Castilla e Sawyer (1993)

argumentam que melhores condições econômicas nas áreas endêmicas podem levar à maior migração para a região, aumentando as estatísticas de casos de contaminação por malária. Isto ocorre devido ao fato de que pessoas sem a imunidade à doença migrem para áreas endêmicas, assim, contraindo a infecção. A mesma lógica não pode sem empregada para os indígenas e moradores locais (adultos) da região, que geralmente desenvolvem imunidade doenças parasitárias (MARQUES, 1987; SACHS; MALANEY, 2002; PATZ et al., 2000; BAUCH et al., 2014).

O desenvolvimento agropecuário também é alvo de constantes estudos a cerca da sua relação com a incidência de malária. São documentadas diferentes interações entre culturas agrícolas e o paludismo, visto que cada vetor possui sua peculiaridade na reprodução e condições de sobrevivência. Yasuoka e Levins (2007) investigam como certas culturas podem influenciar a incidência de malária. Os autores listaram a cana-de-açúcar, borracha, chá e cacau como culturas positivamente correlacionas com a incidência do paludismo em diversas localidades. Já o café possui divergências sobre seu potencial efeito a cerca da incidência da infecção, enquanto o cultivo de mandioca é negativamente relacionado com casos da doença.

Segundo Wielgoz et al. (2012), o cultivo de milho é identificado como uma cultura que contribui para aumentos nos índices parasitários de malária. Kebede et al. (2005), por meio de uma regressão de Poisson, encontrou evidências, em 21 aldeias no noroeste da Etiópia, de que o cultivo de milho está correlacionado com a incidência de malária, sendo esta relação explicada pelo fato de que alguns vetores, em sua forma larval, se alimentam do pólen do milho.

A atividade agrícola irrigada, em geral, também pode estar correlacionada com um aumento de casos de paludismo. Segundo Amerasinghe e Ariyasena (1990), corpos de água podem aparecer como resquícios da irrigação, propiciando ambientes ideais para a reprodução de certos vetores. Desta forma, a produção orizícola, que utiliza intensa irrigação, pode criar ambientes propícios à reprodução do vetor, fazendo com que sua época de reprodução seja prolongada (YASUOKA; LEVINS, 2007).

A relação entre pecuária bovina e paludismo também é alvo de estudo entre os cientistas. Wielgoz et al. (2012) disserta que o efeito da criação de gado na incidência da infecção pode ser distinto entre os diferentes vetores e também entre as diferentes práticas pecuárias. O sangue do animal pode servir de alimento para o vetor, podendo aumentar a

quantidade de insetos devido à abundância de alimentos, elevando o risco da doença para os seres humanos. Contrariamente, para alguns vetores, o sangue gado pode ser preferível ao sangue humano, diminuindo os casos da doença. Além disto, as distâncias geográficas entre a criação de gado e aglomerados urbanos podem determinar tal correlação.

Além do desenvolvimento econômico e agrícola, outros fatores econômicos também podem influenciar a dinâmica de infecção por malária. Hahn et al. (2014) mostram que a construção de estradas na região amazônica e a extração madeireira possuem o poder de aumentar o risco de malária em um município. Olson et al. (2010) argumentam que a indústria da aqüicultura local pode ser correlacionado com os padrões de incidência de malária. Já Marques (1987) encontra relação entre mineração e assentamentos agrícolas com os casos de malária no Brasil.

Singer e Castro (2001) indicam que as condições de moradia, tanto em relação à infraestrutura, quanto em relação à localização, pode ser um ponto crucial no combate à infecção por malária, fato este que evidencia que a política de habitação pode ter um papel importante no combate à doença. Sobre intervenções das políticas de saúde, Cohen e Dupas (2010) sugerem que a distribuição gratuita de mosquiteiros tratados com inseticida possui capacidade de redução nos casos de paludismo no Quênia, fortalecendo a teoria de que políticas públicas de saúde podem ter influência sobre a infecção por malária.

Tendo em vista que fenômenos econômicos possuem a capacidade de influenciar a dinâmica de transmissão da malária, esta pesquisa visa também buscar a relação do desmatamento, do desenvolvimento agrícola, dos gastos governamentais municipais com habitação e saúde com a incidência de malária na Amazônia brasileira. Além disto, analisa-se como o crescimento econômico pode influenciar nos casos da doença. Assim, este artigo multidisciplinar torna-se uma contribuição para o planejamento de politicas públicas de controle da malária, buscando esclarecer as relações entre malária, meio ambiente, agricultura e economia no Brasil.

3. DADOS

Os dados utilizados para a análise compõem um painel balanceado, formando observações anuais para 757 municípios inseridos na Amazônia Legal [3], para o período que compreende de 2003 a 2012, resultando em 7570 observações para cada variável do estudo. A Tabela 1 apresenta a definição das variáveis utilizadas no modelo, ao passo de que a Tabela 2 apresenta as estatísticas descritivas das variáveis utilizadas e suas respectivas fontes.

Tabela 1. Descrição das variáveis

Variável	**Descrição**
$Malaria$	Casos confirmados de malária a cada mil habitantes
$Desm$	Área desmatada ente o ano t e $t-1$, em Km^2
$Desm_{t-1}$	Área desmatada ente o ano $t-1$ e $t-2$, em Km^2
$Desm_{t-2}$	Área desmatada ente o ano $t-2$ e $t-3$, em Km^2
$Desm^2$	Área desmatada ente o ano t e $t-1$, em Km^2 ao quadrado
$Flor$	Percentual de floresta na área do município, em Km^2
$Denspop$	Densidade populacional
$Saude$	Gastos públicos municipais com saúde *per capita* a preços de 2012
$Saude_{t-1}$	Gastos públicos municipais com saúde *per capita* a preços de 2012 em $t-1$
$Saude_{t-2}$	Gastos públicos municipais com saúde *per capita* a preços de 2012 em $t-2$
Hab	Gastos públicos municipais com habitação *per capita* a preços de 2012
PIB	Produto Interno Bruto municipal (mil reais) a preços de 2012
PIB_{t-1}	Produto Interno Bruto municipal (mil reais) a preços de 2012 em $t-1$
PIB_{t-2}	Produto Interno Bruto municipal (mil reais) a preços de 2012 em $t-2$
$Gado$	Efetivo bovino municipal
$Gado_{t-1}$	Efetivo bovino municipal em $t-1$
$Gado_{t-2}$	Efetivo bovino municipal em $t-2$
$Soja$	Área plantada de soja no município, em Km^2
$Soja_{t-1}$	Área plantada de soja no município, em Km^2 em $t-1$
$Soja_{t-2}$	Área plantada de soja no município, em Km^2 em $t-2$
$Outcult$	Área plantada de algodão, arroz, cacau, café, cana, milho e mandioca, em Km^2

Fonte: Resultados da pesquisa.

O número de casos de malária foi obtido junto ao Ministério da Saúde que unificou duas bases de dados, do Sistema de Informações do Programa Nacional de Controle da Malária (Sismal), que reporta as ocorrências no ano de 2003 e a base de dados do Sistema de Informação de Vigilância Epidemiológica (Sivep-malária), no qual são registrados os casos de malária na região amazônica, a partir de 2003[4]. A contagem de casos de paludismo se dá pelo número de exames positivos em cada município, sendo que, desta forma, pode ocorrer superestimação do número de casos (o número de casos é computado por exame

[3] Os municípios de Ipiranga do Norte e Itanhangá, localizados no Estado do Mato Grosso, foram excluídos pelo fato de que, ambos, foram emancipados somente no ano de 2005.

[4] As informações sobre os casos de malária na região Amazônica foram obtidos através do Portal e-sic, assim, disponibilizados pelo Mistério da Saúde

Tabela 2. Estatísticas Descritivas

Var	Obs	Média	DP	Mín	Máx
$Malaria$	7570	20,9062	138,555	0	10579,06
$Desm$	7570	18,3479	60,8935	0	1407,8
$Desm_{t-2}$	7570	27,4637	89,2615	0	1808,6
$Desm_{t-1}$	7570	21,1091	66,3426	0	1407,8
$Desm^2$	7570	4044,17	43866	0	1981901
$Flor$	7570	27,2584	30,1236	0	99,05
$Denspop$	7570	23,1004	125,13	0,00282	2732,497
$Saude$	7570	331,881	3241,29	0	281735,82
$Saude_{t-1}$	7570	313,854	2750,66	0	238952,8
$Saude_{t-2}$	7570	304,261	3050,53	0	258413,5
Hab	7570	106,221	151,812	0	5243,323
PIB	7570	384339	2097583	6174,58	5,57e+072
PIB_{t-1}	7570	365032	2024131	5895,49	5,57e+07
PIB_{t-2}	7570	344763	1928633	5554,2	5,57e+07
$Gado$	7570	97496,6	144714	0	2312493
$Gado_{t-1}$	7570	93966.4	138586	0	2162570
$Gado_{t-2}$	7570	90140.4	132801	0	2022366
$Soja$	7570	84,1171	392,367	0	6106,7
$Soja_{t-1}$	7570	79,6701	381,008	0	6002,46
$Soja_{t-1}$	7570	75,0351	367,633	0	5966,58
$Outcult$	7570	70,7443	175,402	0	3001

Fonte: Resultados da pesquisa.

positivo e não por indivíduo infectado, assim, se um indivíduo fizer mais de um exame para a doença, ocorrerá dupla contagem desse mesmo infectado) e subestimação (visto que a capacidade de reportar um exame positivo vem da capacidade do município ter condições técnicas-laboratoriais adequadas para a sua detecção).

A área que mede o desflorestamento e o percentual municipal de estoque de floresta foram obtidas através do INPE (Instituto Nacional de Pesquisas Espaciais). São construídos mapas digitais através do satélite Landsat TM, que possui resolução espacial de 120 x 120 metros, gerando assim, "pixels" para cada município. Após a criação dos "pixels", este é convertido[5] em quilômetros quadrados, chegando na estimativa de desmatamento anual e a área total de floresta, ambas utilizadas no estudo (PRODES, 2016). O desmatamento também pode ser entendido como $F_{t-1} - F_t$, em que F é o estoque de floresta. Deste modo, desmatamento anual é a diferença entre o estoque de floresta no tempo $t-1$ e no tempo t.

O Produto Interno Bruto (PIB) é originário do Sistema IBGE de Recuperação

[5]A fórmula de conversão de "pixels" para Km^2 é $Areakm2 = (NrPixel * (120^2))/1000000$ (PRODES,2016).

Automática (SIDRA), atualizado para valores de 2012 pelo deflator IGP-DI, disponível no banco de dados do IPEA DATA. O efetivo bovino (gado) também foi obtido junto ao SIDRA, a partir da Pesquisa Pecuária Municipal.

No que tange os gastos públicos municipais com habitação e saúde, foram coletados na base de dados do IPEA DATA, que por sua vez reuniu e organizou as estatísticas do Tesouro Nacional. A exemplo do PIB, tais variáveis também tiveram seus valores atualizados para preços de 2012 por meio do IGP-DI. Já as áreas plantadas de algodão, arroz, cacau, café, cana, milho, mandioca e soja foram obtidas junto ao IPEA DATA, que por sua vez, coletou tais estatísticas do Ministério da Agricultura Indústria e Comércio. Ressalta-se que, como as estatísticas os gastos municipais e as áreas plantadas das variadas culturas estão disponíveis até o ano de 2010, foi realizado uma interpolação linear até no ano de 2012, com o objetivo de proporcionar maiores informações na análise.

A incidência de malária a cada mil habitantes possui uma peculiaridade em três municípios (Rodrigues Alves e Mâncio Lima em 2006 e Anajás em 2009), pois a incidência de malária foi maior que a população residente. Esta anomalia pode acontecer devido à forma de preenchimento do prontuário médico, que relata o local de infecção da malária e não o local de residência do paciente. Desta forma, turistas, trabalhadores temporários e população flutuante podem causar esta anomalia associada aos dados anuais de incidência de malária. Outra explicação para tal anomalia é a possível superestimação dos casos, visto que, se um indivíduo infectado fizer o exame de detecção de paludismo mais de uma vez, ocorrerá uma repetição na contagem dos casos.

Outra peculiaridade nas estatísticas são municípios que não reportam corretamente seus gastos para o tesouro nacional, assim, computando dispêndios iguais a zero, no que tange os gastos com habitação e saúde. Vale ressaltar que poucas observações tiveram tais distúrbios, não comprometendo a análise proposta.

O número de casos de malária (exames positivos) anual a cada mil pessoas também é chamado de Índice Parasitário Anual de Malária (IPA), em que se estima o risco de ocorrência de malária (ou o risco de ser picado por um mosquito fêmea *Anophelino* infectado por um protozoário do gênero *Plasmodium*) em uma população, no intervalo de um ano. O IPA possui três classificações para as regiões de risco, onde de 0 a 10 são regiões que possuem um grau de risco de contaminação *baixo*, de 10 a 50 são regiões que possuem um grau *médio* de risco de contaminação, enquanto regiões com o grau considerado *alto*

possuem um IPA maior que 50 (DATASUS, 2012).

A Figura 2 mostra a evolução espacial do Índice Parasitário Anual de Malária, para os anos de 2003, 2009 e 2012[6], nos municípios selecionados no estudo. Quanto mais escuro o município, maior o IPA, agrupados em quatro *clusters*, sendo eles, os municípios com nenhum registro da doença no ano, municípios com *baixo* risco de contaminação (>0 a 10), municípios com *médio* risco de contaminação (>10 a 50) e municípios de *alto* risco de contaminação (>50).

Percebe-se, de acordo com a Figura 2, que o Estado que apresentou a maior diminuição dos casos de malária foi o Mato Grosso, onde, principalmente, a região leste do Estado apresentou significativas quedas de 2003 a 2012, sendo que alguns municípios passaram de um IPA alto para a não observação de casos de paludismo. Os municípios localizados no Estado de Rondônia, oeste dos Estados do Maranhão e do Tocantins, norte de Roraima e leste do Pará também apresentaram queda nos casos de malária *per capita*. Já os municípios Amapaenses continuaram com o IPA praticamente inalterado ao longo da década analisada. Na contra-mão da tendência de queda do IPA na região Amazônica, o Estado do Amazonas e o Noroeste do Acre apresentaram uma maior incidência, ao longo da década, de municípios com o risco *alto* de contaminação de malária, como é apresentado um mapa de densidade de Kernel, na Figura 3[7].

[6] A evolução espacial do IPA, de 2003 a 2012, é apresentada no anexo (Página 117).

[7] Um mapa de densidade de Kernel (também chamado de mapa de "temperatura"), faz a interpolação espacial das densidades de Kernel estimadas. Ressalta-se que é utilizado um estimador de Kernel Quártico. Para maiores informações sobre a utilização de estimadores de Kernel em mapas, ver (WALLER, 2004).

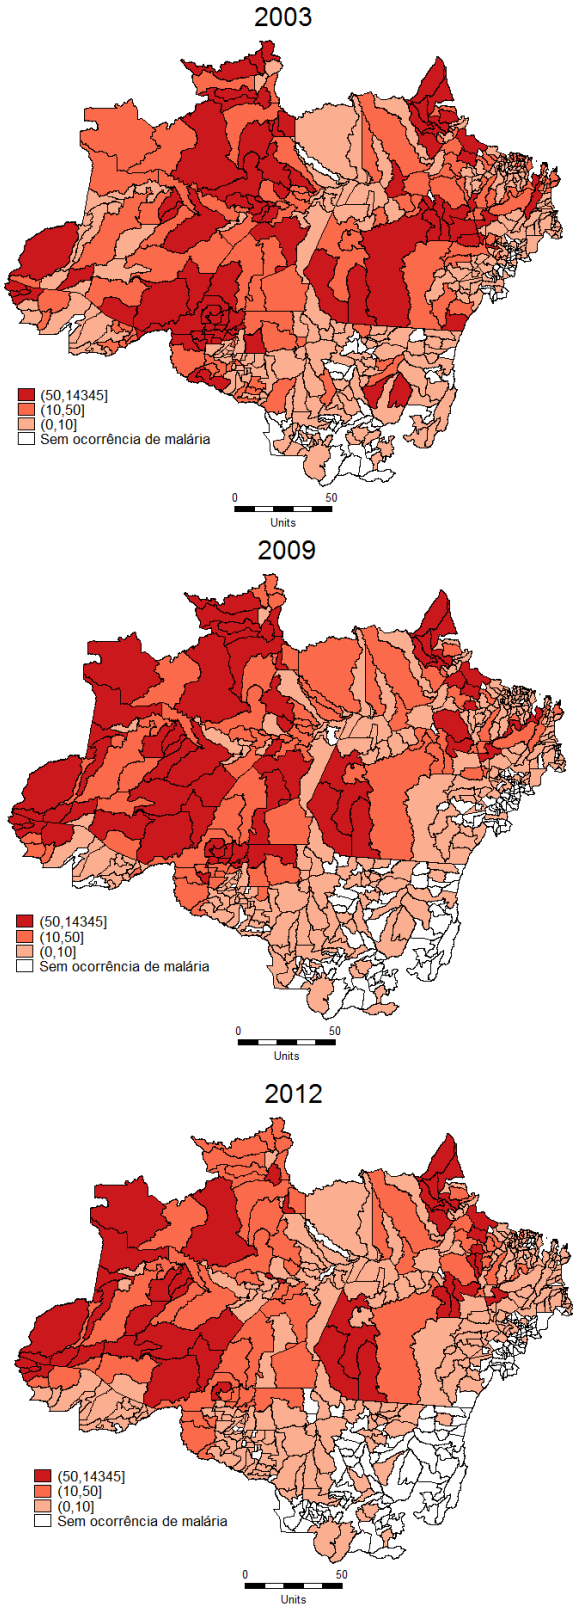

Figura 2. Índice Parasitário Anual de Malária. 2003 - 2009- 2012.
Fonte: Elaboração própria com os dados disponibilizados pela SIVEP. Software: Stata 12.0

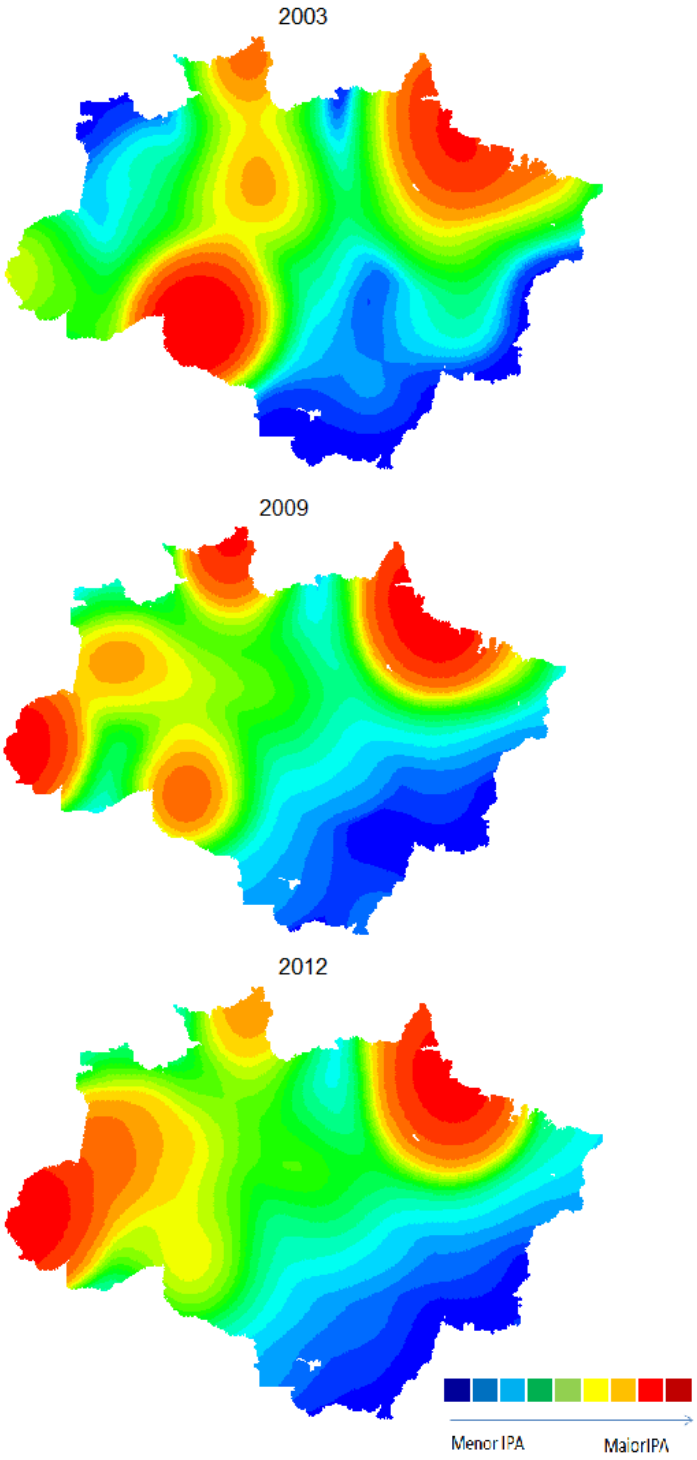

Figura 3. Mapa de Densidade de Kernel. 2003 - 2007 - 2012.
Fonte: Elaboração própria com os dados disponibilizados pela SIVEP. Software: Stata 12.0

4. METODOLOGIA

4.1. Análise Exploratória de Dados Espaciais (AEDE)

A metodologia AEDE, segundo Almeida (2012) possui o objetivo de descrever e visualizar distribuições espaciais, identificando *outliers* e *clusters* espaciais. Esta técnica é essencial para a modelagem econométrica-espacial.

De acordo com Almeida (2012), o primeiro passo é testar a hipótese da aleatoriedade dos dados, ou seja, testar se não ocorre a dependência espacial entre as unidades espaciais. Caso a hipótese da aleatoriedade seja rejeitada, é de suma importância prosseguir com uma estimação econométrica-espacial. Para a realização de tal inferência é necessário estimar um coeficiente de correlação espacial, que, segundo Almeida (2012), é construído como a razão de uma medida de autocovariância e uma medida de variação total das observações. Neste trabalho são estimados dois coeficientes de autocorrelação global, a estatística I de Moran e a estatística c de Geary.

A estatística I de Moran pode ser expressa como

$$I = \frac{n}{S_0} \frac{z'\mathbf{W}z}{z'z} \tag{1}$$

onde, $z = (Y - \bar{Y})$, em que Y é o vetor de observações, $\bar{Y}$ é o valor correspondente à média de Y, assim, z é o desvio de Y em relação à média. Ademais, n é o número de unidades espaciais, $\mathbf{W}$ é a matriz de pesos espaciais apresentada na próxima seção e S_0 é a soma de todos os elementos de $\mathbf{W}$. Como, utilizar-se-á uma matriz de ponderação espacial normalizada na linha, tem-se que $S_0 = n$. Deste modo, a estatística I de Moran a ser calculada é apresentada como

$$I = \frac{z'\mathbf{W}z}{z'z}. \tag{2}$$

Sendo que, o valor do operador de esperança da estatística I de Moran pode ser expresso como:

$$E(I) = -\frac{1}{n-1} \tag{3}$$

onde,

$$\begin{cases} H_0: & \text{aleatoriedade espacial} \\ H_a: & \text{dependência espacial.} \end{cases}$$

Segundo Almeida (2012), O I de Moran não é centrado em 0, mas à medida que o número de unidades espaciais aumentam, a estatística I tende a ser centrada em 0. Ou seja,

$$\lim_{n\to\infty} E(I) = \lim_{n\to\infty} -\frac{1}{n-1} = 0.$$

Caso o valor de I de Moran seja positivo, ocorre similaridade, ou seja, os valores de Y em uma região tendem a serem diretamente proporcional aos valos de Y em seus vizinhos. Caso o valor do I de Moran seja negativo, ocorre dissimilaridade, ou seja, os valores de Y em uma região tendem a serem inversamente proporcional aos valos de Y em seus vizinhos (ALMEIDA, 2012).

Já o coeficiente de autocorrelação espacial c de Geary pode ser expresso como:

$$c = \left(\frac{n-1}{2S_0}\right)\frac{z'\mathbf{W}z}{z'z} \tag{4}$$

em que $E(c) = 1$, ou seja, a estatística c de Geary é centrada em 1 e está compreendida entre 0 e 2, sob a hipótese nula de aleatoriedade. Se $c \leq 1$, ocorre autocorrelação espacial positiva, onde, de modo análogo, caso $c \geq 1$ ocorre autocorrelação espacial global negativa (ALMEIDA, 2012).

Além das estatística de autocorrelação espacial global, se faz necessária a estimação de coeficientes de autocorrelação espacial local. Deste modo, utiliza-se a estatística I de Moran local, também conhecido como LISA (*Local Indicator of Spatial Association*). Segundo Almeida (2012), este coeficiente deve obedecer a dois critérios. O primeiro preco-

niza que deve haver capacidade de indicar *clusters* espaciais estatisticamente significativos. O segundo critério diz respeito à propriedade de que o somatório dos indicadores locais deve ser proporcional ao indicador de autocorrelação espacial global. O I de Moran local pode ser definido como (ANSELIN, 1995)

$$I_i = \frac{Z_i' \mathbf{W} Z_j}{S_0 \frac{Z_i' Z_i}{n}} \tag{5}$$

Segundo Anselin (1995), se $I_i \geq 0$, os *clusters* tendem a ser diretamente proporcionais aos valores de Y em seus vizinhos. Paradoxalmente, caso $I \leq 0$, os *clusters* tendem a ser inversamente proporcional aos valos de Y em seus vizinhos. Caso $I = 0$, observa-se ausência de *clusters*.

Com o intuito de facilitar a visualização da autocorrelação espacial local, é apresentado o diagrama de dispersão de Moran e um mapa de autocorrelação espacial, representado pela Figura 4. Segundo Almeida (2012), o diagrama de dispersão de Moran é um gráfico, onde em seu eixo vertical representa a defasagem espacial e o eixo horizontal o valor da variável. A estatística I_i é o coeficiente angular.

No primeiro quadrante (Q1) representa observações com valores altos e com vizinhos igualmente tendo altos valores (Alto-Alto). Já no quarto quadrante (Q4), são representadas as observações com valores altos e vizinhos com valores baixos (Alto-Baixo), ao passo de que o quadrante três (Q3) representa as observações e seus vizinhos (Baixo-Baixo), ambos com valores baixos. Por fim, o segundo quadrante (Q2) representa observações com valores baixos e seus vizinhos com valores altos (Baixo-Alto).

O mapa de dispersão de Moran segue a mesma lógica do diagrama de dispersão de Moran, representando os *clusters* significativos em um arranjo espacial. Deste modo, serão computados no mapa a representação dos municípios referentes ao diagrama de dispersão, ou seja, serão agrupados de acordo com o quadrante da Figura 4.

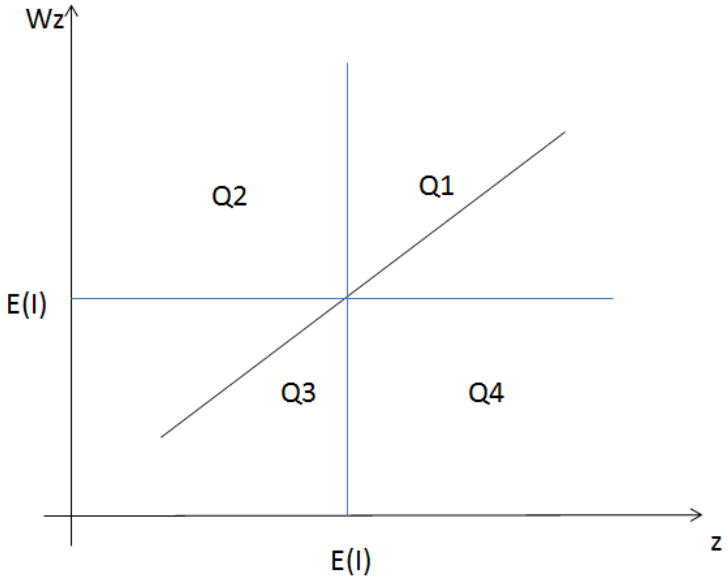

Figura 4. Diagrama de Dispersão de Moran
Fonte: Elaboração própria.

4.2. Matriz de Ponderação Espacial

Para a estimação de modelos espaciais é necessário a utilização de uma matriz de ponderação espacial (a matriz **W**, incluída nas equações de dados em painel espacial). Segundo Almeida (2012), esta matriz representa um arranjo espacial das interações consequentes do fenômeno em análise, sendo que regiões mais conectadas possuem maiores interações do que regiões não conectadas. Para o caso de dados em painel espacial, a matriz **W** necessariamente deve ser constante no tempo, o que ocorre para matrizes de proximidade geográfica. Neste estudo, utiliza-se, como candidatos, a matriz queen, a matriz de distância inversa total, a matriz de distância inversa com corte de 300km[8] e a matriz de distância inversa de 5 vizinhos mais próximos. Tais matrizes são, respectivamente especificadas por,

$$w_{ij}(Q) = \begin{cases} 1, & \text{se j é um município contíguo} \\ 0, & \text{se j não é um município contíguo} \end{cases}$$

$$w_{ij}(DIT) = \frac{1}{d_{ij}^{v}}, \quad \text{onde} \quad d_{ij}^{v} \quad \text{é a distância entre os municípios i e j}$$

[8]O corte de 300Km é realizado devido às características municipais da região, onde, esta é a distância em que nenhum município é computado como uma "ilha".

$$w_{ij}(DI300) = \begin{cases} \frac{1}{d_{ij}^{v}}, & \text{se } d_{ij} \leq 300Km \\ 0, & \text{se } d_{ij} > 300Km \end{cases}$$

$$w_{ij}(KNN5) = \begin{cases} \frac{1}{d_{ij}^{v}}, & \text{se j é um dos 5 vizinhos mais próximos} \\ 0, & \text{se j não é um dos 5 vizinhos mais próximos} \end{cases} \quad (6)$$

No contexto de estudo, a análise espacial torna-se de suma importância, visto que o vetor transmissor da malária mais comum no Brasil, o *A. darlingi*, pode se deslocar até 7,2 km em nove dias (CHARLWOOD, 1989), que pode se tornar bem maior, tendo em vista que o estudo possui um período anual. Por fim, as matrizes utilizadas foram normalizadas (linha) utilizando a seguinte fórmula (ALMEIDA, 2012):

$$w_{ij}^{*}(.) = \frac{w_{ij}(.)}{\sum_{j} w_{ij}(.)} \quad (7)$$

Segundo Almeida (2012), a normalização da matriz **W** possui duas vantagens. A primeira é a limitação de um número finito das somas das linhas e das colunas da matriz **W**. A segunda é que a matriz **W** normalizada permite a interpretação média dos valores da variável nos vizinhos para a defasagem espacial. Além disto, uma matriz de ponderação espacial normalizada possui a característica de ser assimétrica, assim, a influência que uma unidade cross-section exerce sobre o seu vizinho não é similar à influência do vizinho sobre a determinada unidade cross-section.

A escolha da matriz de pesos espaciais seguirá os procedimentos expostos por Almeida (2012), Kooijman (1976), Getis e Aldstadt (2004) e Stakhovych e Bijmolt (2009). Segundo Almeida (2012) e Kooijman (1976), a matriz de pesos espaciais deve maximizar o valor da estatística I de Moran. Deste modo, a seleção ocorre em três etapas. A primeira é estimar o modelo de regressão linear simples. A segunda etapa consiste em extrair os resíduos de tal regressão. Por fim, aplica-se a estatística I de Moran para os resíduos da regressão estimada, escolhendo a matriz que gerar o maior valor de I.

Já Getis e Aldstadt (2004) e Stakhovych e Bijmolt (2009) propõem a seleção

de uma matriz que resulta em um bom desempenho do modelo espacial. Deste modo, este processo consiste em estimar o modelo espacial proposto (ou aquele indicado pelos testes de Multiplicador de Lagrange) com cada matriz candidata, escolhendo, assim, a matriz de pesos espacias que gerar o menor valor do critério de informação de Akaike (AIC), a ser descrito adiante.

4.3. Dados em Painel

Para captar a relação entre malária, desmatamento, desenvolvimento agrícola, crescimento econômico e gastos governamentais, foi construída uma estrutura de dados em painel, contendo 757 unidades cross-section e um horizonte temporal de 10 anos, de 2003 a 2012, compondo 7570 observações. A escolha desta estrutura se deve ao fato de que quaisquer variáveis omitidas, desde que sejam invariantes no tempo, não afetarão as propriedades desejáveis da regressão, assim, contornando o problema do viés da variável omitida. Um exemplo de variável que possui tais características (variável explicativa importante, mas invariante no tempo) é a altitude, que pode influenciar na incidência do Anopheles (BØDKER et al., 2003). Deste modo, a estrutura de dados em painel permitirá que tal regressor seja omitido sem que a regressão se torne viesada e inconsistente, fazendo com que estimativas convirjam ao verdadeiro parâmetro populacional.

Ademais, a ferramenta de dados em painel possui a vantagem de conciliar os dados em unidades cross-section e séries de tempo, adquirindo maiores informações sobre o fenômeno em estudo e, consequentemente, aumentando os graus de liberdade, aumentando, assim, a eficiência da estimação e diminuindo o problema de alta colinearidade. O modelo geral na abordagem dos dados em painel pode ser representado como (GREENE, 2012):

$$y_{it} = \alpha_i + x_{it}'\beta + \mu_i + \varepsilon_{it}, \quad i = 1, 2, ..., N \quad t = 1, 2, ..., T \tag{8}$$

onde i indica a unidade cross-section e t o período temporal, x_{it} é um regressor, sendo um vetor $1 \times n$ observações, β é um coeficiente de vetor $k \times 1$, μ_i é o efeito não observado variando por indivíduo e ε_{it} são os desvios idiossincráticos da regressão. Na metodologia dos dados em painel, destacam-se as abordagens de efeito fixo e efeito aleatório. A primeira considera que a heterogeneidade (μ_i) está correlacionada com os regressores, enquanto a segunda pressupõe que não existe tal correlação (GREENE, 2012). Para testar a correlação entre as variáveis explicativas observadas e o os efeitos não observados, usualmente se utiliza na literatura o teste de Hausman (1978), que, para o modelo proposto no artigo, indicou que uso dos efeitos fixos é mais apropriado ($\chi^2 = 61,18$), ou seja, os efeitos não observados estão correlacionados de alguma forma com as variáveis explicativas, $E(c_i x_{it}) \neq 0$.

Segundo Greene (2012), em modelos de painel são assumidas as seguintes

propriedades:

1) Linearidade nos parâmetros:

$y_i = \alpha_i + x_{i1}\beta_1 + x_{i2}\beta_2 + ... + x_{ik}\beta_k + \varepsilon_i$

2) Posto completo (ou ausência de multicolinearidade perfeita):

$Posto[E(x_{it}{}'x_{it})] = K$

3) Exogeneidade estrita das variáveis dependentes:

$E(\varepsilon_i \mid x_{i1}, x_{i2}, ..., x_{ik}, \mu_i) = 0$

4) Homocedasticidade:

$E(\varepsilon_{it}\varepsilon_{it}{}' \mid x_i, \mu_i) = \sigma_\varepsilon^2 I_T$

5) Ausência de autocorrelação:

$E(\varepsilon_i\varepsilon_j) = 0, \quad \forall\ i \neq j$

6) Independência entre as unidades cross-section: As unidades cross-section são obtidas de amostras aleatórias.

Para maiores detalhes sobre processo de estimação de modelos de efeitos fixos vide Apêndice A. As especificações propostas são apresentadas na seção 4.4.

4.4. Dados em Painel Espacial

Embora os modelos de dados em painel possuam vantagens, é de suma importância ficar atento as suas pressuposições iniciais, que se não atendidas, podem levar a problemas na inferência dos parâmetros. Deste modo, modelos convencionais de dados em painel são rodeados da pressuposição de que as unidades cross-section não estão correlacionadas, ou seja, elas são obtidas a partir de amostras aleatórias (ALMEIDA, 2012). Tal pressuposição pode ser satisfeita quando as unidades em estudos são retiradas de amostras aleatórias de indivíduos ou empresas. Entretanto, esta pressuposição pode não ser satisfeita quando o objeto de análise são unidades espaciais, como acontece com a variável dependente deste estudo, que está distribuída entre os municípios (ALMEIDA, 2012).

Outra pressuposição inicial dos modelos de dados em painel é de que os resíduos não sejam autocorrelacionados entre as unidades cross-section, ou seja, $E(\varepsilon_i \varepsilon_j) = 0, \quad \forall\, i \neq j$. Tal pressuposição, também, pode não ser satisfeita quando os dados possuem alguma característica espacial, gerando um viés na estimação do modelo, visto que a matriz de variância e covariância das estimativas não seja representada por uma matriz diagonal. Assim, a introdução dos componentes espaciais são recomendados quando é comprovada a dependência espacial, podendo ser observada a partir da estatística I de Moran (1948), c de Geary (1954) e G de Otis (1992) (ALMEIDA, 2012). Deste modo, a inclusão de componentes espaciais se torna necessário no sentido de manter as estimativas não viesadas e consistentes, convergindo para o verdadeiro parâmetro populacional.

Em modelos de dados em painel podem ser acoplados componentes espaciais quando ocorrem a dependência e heterogeneidade espacial. A dependência espacial é representada no modelo a partir da introdução da variável dependente defasada espacialmente (caracterizado como Modelo de Lag Espacial) ou a introdução de um processo autorregressivo espacial no termo de erro (Modelo de Erro Espacial) (ELHORST, 2003).

Partindo de um modelo espacial geral, para dados em painel, tem-se,

$$Y_{it} = \alpha_i + \mathbf{W}Y_{it}\delta + \mu_i + X_{it}\beta + \mathbf{W}X_{it}\theta + u_{it}; \quad u_{it} = \mathbf{W}u_{it}\lambda + \varepsilon_{it} \tag{9}$$

onde, $\mathbf{W}$ é uma matriz $nt \times nt$ de ponderação espacial, λ é o coeficiente de correlação espacial, δ é o coeficiente espacial autorregressivo e θ é o coeficiente da defasagem espacial

de cada variável explicativa. A partir da inserção de restrições no modelo espacial geral (equação 9) é possível se obter qualquer modelo espacial.

Caso $\lambda = 0$, obtém-se o modelo SDM (*Modelo Espacial de Durbin*), denotado por:

$$Y_{it} = \alpha_i + \mathbf{W}Y_{it}\delta + \mu_i + X_{it}\beta + \mathbf{W}X_{it}\theta + \varepsilon_{it}. \tag{10}$$

Se $\delta = 0$, obtém-se o modelo SDEM (*Modelo de Erro Espacial de Durbin*), que é expresso por:

$$Y_{it} = \alpha_i + \mu_i + X_{it}\beta + \mathbf{W}X_{it}\theta + u_{it}; \quad u_{it} = \mathbf{W}u_{it}\lambda + \varepsilon_{it}. \tag{11}$$

Por outro lado, caso $\theta = 0$, origina-se o modelo SAC (*Modelo de Erro e Defasagem Espacial*), denotado por:

$$Y_{it} = \alpha_i + \mathbf{W}Y_{it}\delta + \mu_i + X_{it}\beta + u_{it}; \quad u_{it} = \mathbf{W}u_{it}\lambda + \varepsilon_{it}. \tag{12}$$

Os modelos SAR (*Modelo de Defasagem Espacial*) e SEM (*Modelo de Erro Espacial*), são originados do modelo SAC (equação 12), quando $\lambda = 0$ e $\delta = 0$, respectivamente, sendo expressos por:

$$Y_{it} = \alpha_i + \mathbf{W}Y_{it}\delta + \mu_i + X_{it}\beta + \varepsilon_{it} \tag{13}$$

$$Y_{it} = \alpha_i + \mu_i + X_{it}\beta + u_{it}; \quad u_{it} = \mathbf{W}u_{it}\lambda + \varepsilon_{it}. \tag{14}$$

Por fim, obtém-se o modelo SLX[4] (*Modelo Espacial Cross-regressivo*) a partir

[4]A estimação dos modelos SEM, SAR, SAC, SDEM E SDM é realizada pelo método da quase-máxima verossimilhança. Já o modelo SLX é estimado via MQO, visto que este modelo não possui opção de estimação no software utilizado. Uma das vantagens da estimação por máxima verossimilhança, dado

da imposição de que, dado o modelo geral, $\delta = 0$ e $\lambda = 0$, sendo denotado por:

$$Y_{it} = \alpha_i + \mu_i + X_{it}\beta + \mathbf{W}X_{it}\theta + \varepsilon_{it}. \tag{15}$$

Percebe-se que se forem impostas restrições, ante o modelo geral espacial, de que $\delta = 0$, $\theta = 0$ e $\lambda = 0$, obtém-se o modelo clássico de dados em painel. Cabe ressaltar que os modelos SAR e SAC, são modelos de alcance global, enquanto os modelos SLX e SDEM são de alcance local e o SDM é um modelo de alcance global e local.

4.4.1. Estimação do Modelo de Defasagem Espacial de Efeitos Fixos - SAR

O modelo SAR, especificado na equação (13), incorpora o lag espacial da variável dependente:

$$Y_{it} = \alpha_i + \mathbf{W}Y_{it}\delta + \mu_i + X_{it}\beta + \varepsilon_{it}.$$

Segundo Elhorst (2013), a incorporação de $\mathbf{W}Y_{it}$ (variável dependente defasada espacialmente), pode gerar duas complicações. A primeira é a disruptura do pressuposto da exogeneidade estrita, de que $E[(\sum_j w_{ij}y_{jt})\varepsilon_{it}] = 0$. A segunda complicação é de que a dependência espacial entre as observações a cada período temporal pode afetar as estimações de efeito fixo.

Com o intuito de corrigir as complicações citadas, o modelo SAR é estimado via Máxima Verossimilhança, contabilizando a endogeneidade. O log da função de Máxima Verossimilhança é expresso por (ELHORST, 2013):

$$\begin{aligned} logL &= \frac{-NT}{2}log(2\pi\sigma^2) + Tlog \mid \mathbf{I}_N - \delta\mathbf{W} \mid - \\ &- \frac{1}{2\sigma^2}\sum_{i=1}^{N}\sum_{t=1}^{T}\left(y_{it} - \delta\sum_{j=1}^{N}w_{ij}y_{jt} - x_{it}\beta - \mu_i\right)^2 \end{aligned} \tag{16}$$

onde, $Tlog \mid \mathbf{I}_N - \delta\mathbf{W} \mid$ é o jacobiano da transformação de ε para y, por conta da endoge-

que a distribuição das variáveis segue a normalidade, é que regressores endógenos não fazem com que as estimativas sejam inconsistentes (WOOLDRIDGE, 2010).

neidade em questão (ANSELIN, 2013; ELHORST, 2013). Realizando a derivada parcial de μ_i, obtém-se (ELHORST, 2013):

$$\frac{\partial logL}{\partial \mu_i} = \frac{1}{\sigma^2} \sum_{t=1}^{T} \left(y_{it} - \delta \sum_{j=1}^{N} w_{ij} y_{jt} - x_{it}\beta - \mu_i \right) = 0. \tag{17}$$

Rearranjando a equação (17), obtem-se μ_i,

$$\mu_i = \frac{1}{T} \sum_{t=1}^{T} \left(y_{it} - \delta \sum_{j=1}^{N} w_{ij} y_{jt} - x_{it}\beta \right). \tag{18}$$

Substituindo μ_i, obtido na equação (18) na equação (16) e rearranjando, obtém-se (ELHORST, 2013):

$$\begin{aligned} logL &= \frac{-NT}{2} log(2\pi\sigma^2) + Tlog \mid \mathbf{I}_N - \delta \mathbf{W} \mid - \\ &- \frac{1}{2\sigma^2} \sum_{i=1}^{N} \sum_{t=1}^{T} \left(y_{it}^* - \delta \left[\sum_{j=1}^{N} w_{ij} y_{jt} \right]^* - x_{it}^* \beta \right)^2 \end{aligned} \tag{19}$$

onde,

$$y_{it}^* = y_{it} - \frac{1}{T} \sum_{t=1}^{T} y_{it} \tag{20}$$

$$x_{it}^* = x_{it} - \frac{1}{T} \sum_{t=1}^{T} x_{it}. \tag{21}$$

Deste modo, pode-se estimar β, σ^2 *e* δ a equação (19) por Máxima Verossimilhança similarmente à estimação de dados cross-section. Segundo Elhorst (2013), o procedimento de estimação se ancora em três passos. O primeiro é empilhar as observações para se obter um vetor y_{it}^* e $(I_T \otimes \mathbf{W}) y_{it}^*$ de $NT \times 1$ observações e uma matriz $NT \times k$ para x^* (ELHORST, 2013). O segundo procedimento é obter δ a partir da função de máxima verossimilhança concentrada (ELHORST, 2003).

$$logL = C - \frac{NT}{2} log[(e_0^* - \delta e_1^*)'(e_0^* - \delta e_1^*)] + Tlog \mid \mathbf{I}_N - \delta \mathbf{W} \mid \tag{22}$$

em que C é uma constante não dependente de δ, e_0^* e e_1^* são os resíduos dos coeficientes estimados por OLS de b_0^* e b_1^* de y^* e $(\mathbf{I}_T \otimes \mathbf{W})y^*$, respectivamente, em x^*. De acordo com Elhorst (2013), se a função de máxima verossimilhança concentrada (equação 22) é côncava em δ, existirá uma solução numérica única.

O terceiro e último passo é obter os coeficiente β e σ^2 dada a estimação numérica de δ (ELHORST, 2013). Desta forma, obtém-se:

$$\begin{aligned} \beta &= b_0^* - \delta b_1^* \\ &= (x^{*\prime} x^*)^{-1} x^{*\prime} [y^* - \delta (I_T \otimes \mathbf{W}) y^*] \end{aligned} \tag{23}$$

$$\sigma^2 = \frac{1}{NT} (e_0^* - \delta e_1^*)'(e_0^* - \delta e_1^*). \tag{24}$$

Por fim, dado os erros padrão e o t-valor, computa-se a matriz de variância assintótica dos parâmetros,

$$Asy.Var(\beta, \delta, \sigma^2) = \begin{bmatrix} \frac{x^{*\prime} x^*}{\sigma^2} & 0 & 0 \\ \frac{x^{*\prime}(\mathbf{I}_T \otimes \mathbf{W}) x^* \beta}{\sigma^2} & T.tr(\tilde{\mathbf{W}}\tilde{\mathbf{W}} + \tilde{\mathbf{W}}'\tilde{\mathbf{W}}) + \frac{\beta' x^{*\prime}(\mathbf{I}_T \otimes \tilde{\mathbf{W}}'\tilde{\mathbf{W}}) x^* \beta}{\sigma^2} & 0 \\ 0 & \frac{T}{\sigma^2} tr(\tilde{\mathbf{W}}) & \frac{NT}{2\sigma^4} \end{bmatrix}^{-1} \tag{25}$$

onde, $\tilde{\mathbf{W}} = \mathbf{W}(\mathbf{I}_N - \delta \mathbf{W})^{-1}$. Cabe ressaltar que o procedimento de estimação do modelo SDM (equação 10) é semelhante ao apresentado, havendo diferenças somente no tocante à inserção das variáveis defasadas.

4.4.2. Estimação do Modelo de Erro Espacial de Efeitos Fixos - SEM

O modelo SEM (*Modelo de Erro Espacial*), especificado pela equação (14), incorpora o termo de erro defasado espacialmente, sendo expresso como:

$$Y_{it} = \mu_i + X_{it}\beta + u_{it}; \quad u_{it} = \mathbf{W}u_{it}\lambda + \varepsilon_{it}.$$

Segundo Elhorst (2013), pode-se estimar os coeficientes β, λ e σ^2 do modelo SEM, por Máxima Verossimilhança, semelhantemente à estimação de dados cross-section, alterando somente o número que observações, ou seja, de N para NT observações. Deste modo, a função de máxima verossimilhança para o modelo SEM pode ser denotada como:

$$\begin{aligned} logL &= -\frac{NT}{2}log(2\pi\sigma^2) + Tlog \mid \mathbf{I}_N - \lambda\mathbf{W} \mid - \\ &- \frac{1}{2\sigma^2}\sum_{i=1}^{N}\sum_{j=1}^{T}\left\{ y_{it}^{*} - \lambda\left[\sum_{j=1}^{N} w_{ij}y_j t\right]^{*} - \left(x_{it} - \lambda\left[\sum_{j=1}^{N} w_{ij}x_j t\right]^{*}\right)\beta\right\}^2 . \end{aligned} \quad (26)$$

Dado o valor numérico de λ, obtém-se β e σ^2 a partir da maximização da equação (26) (ELHORST, 2013),

$$\beta = \left(X^{**\prime}X^{**}\right)^{-1}\left(X^{**\prime}Y^{**}\right) \quad (27)$$

$$\sigma^2 = \frac{e(\lambda)'e(\lambda)}{NT} \quad (28)$$

onde,

$$X^{**} = X^{*} - \lambda(\mathbf{I}_T \otimes \mathbf{W})X^{*} \quad (29)$$

$$Y^{**} = Y^{*} - \lambda(\mathbf{I}_T \otimes \mathbf{W})Y^{*} \quad (30)$$

$$e(\lambda) = Y^{**} - X^{**}\beta. \quad (31)$$

A estimativa de λ resulta da maximização da função de máxima verossimilhança concentrada de λ, dada por (ELHORST, 2013):

$$logL \;=\; -\frac{NT}{2} log\left[e(\lambda)'e(\lambda)\right] + Tlog \mid I_N - \lambda W \mid . \tag{32}$$

O último procedimento é estimar a hetorogeneidade μ_i, dado por,

$$\mu_i = \frac{1}{T}\sum_{t=1}^{T}\left(y_{it} - x_{it}\beta\right). \tag{33}$$

Por fim, a matriz de variância assintótica pode ser expressa como (ELHORST, 2013):

$$Asy.Var(\beta, \lambda, \sigma^2) = \begin{bmatrix} \frac{x^{*\prime}x^*}{\sigma^2} & 0 & 0 \\ 0 & T.tr(\tilde{\mathbf{W}}\tilde{\mathbf{W}} + \tilde{\mathbf{W}}'\tilde{\mathbf{W}}) & 0 \\ 0 & \frac{T}{\sigma^2}tr(\tilde{\mathbf{W}}) & \frac{NT}{2\sigma^4} \end{bmatrix}^{-1} \tag{34}$$

onde, $\tilde{\mathbf{W}} = \mathbf{W}(\mathbf{I}_N - \lambda\mathbf{W})^{-1}$. Ressalta-se que que o procedimento de estimação do modelo SDEM (equação 11) é semelhante ao apresentado, havendo diferenças somente no tocante à inserção das variáveis defasadas.

4.4.3. Efeitos *Spillovers*

A utilização de modelos espaciais permite aos pesquisadores que obtenham as magnitudes empíricas dos efeitos *spillovers* (ELHORST, 2003). Estes efeitos, na abordagem dos modelos econométricos padrão, não são possíveis de se obter, visto que tais modelos impõem a restrição de que os *spillovers* espaciais são iguais a zero, reafirmando a pressuposição de que as unidades cross-section são independentes (VEGA; ELHORST, 2013). Vale ressaltar que, apesar do modelo SEM ser um modelo espacial, este não possui a característica de gerar efeitos *spillovers*, dado que só existe a introdução do componente espacial no termo de erro, alterando, ante os modelos de painel clássico, somente a matriz de variância e covariância (LESAGE; PACE, 2008).

Os efeitos diretos e indiretos possuem diferenças entre cada modelo. As diferenças entre os modelos se origina no alcance de cada modelo, se dividindo entre modelos de alcance global, local e global e local. Os modelos de alcance global possuem interpretações

diferentes dos efeitos diretos e indiretos em vista aos modelos de alcance local. Para modelos de alcance global, uma alteração na variável explicativa em qualquer local vai ser transmitida a todos os outros locais na sequência da matriz $\mathbf{W}$, gerando efeitos feedback, oriundos de impactos que se deslocam entre as unidades vizinhas e que voltam para a unidade inicial, geradora do impacto (VEGA; ELHORST, 2013).

Em modelos de alcance local, os efeitos diretos e indiretos ocorrem em outros locais sem ocorrer à sequência na matriz $\mathbf{W}$, ou seja, estes efeitos não são transmitidos a todos os locais. Paradoxalmente aos modelos de alcance global, os modelos locais não possuem o efeito feedback (ANSELIN, 2013; LESAGE; PACE, 2008; VEGA; ELHORST, 2013).

Os efeitos diretos e indiretos podem ser obtidos através da matriz de esperança em relação à k-ésima variável explicativa. Para o modelo SAR, obtém-se a forma reduzida a partir da equação (13):

$$\begin{aligned} Y_{it} &= \mathbf{W}Y_{it}\delta + \mu_i + X_{it}\beta + \varepsilon_{it} \\ Y_{it} - \mathbf{W}Y_{it}\delta &= X_{it}\beta + \mu_i + \varepsilon_{it} \\ (\mathbf{I}_T - \delta\mathbf{W})Y_{it} &= X_{it}\beta + \mu_i + \varepsilon_{it} \\ Y_{it} &= (I_T - \delta\mathbf{W})^{-1}X_{it}\beta + (\mathbf{I}_T - \delta\mathbf{W})^{-1}\mu_i + (\mathbf{I}_T - \delta\mathbf{W})^{-1}\varepsilon_{it}. \end{aligned} \tag{35}$$

Deste modo, a matriz de esperança pode ser expressa como:

$$\left[\frac{\partial E(Y)}{\partial X_{1K}} \quad \ldots \quad \frac{\partial E(Y)}{\partial X_{NK}}\right] = (\mathbf{I}_T - \delta\mathbf{W})^{-1}\beta_K. \tag{36}$$

Assim, os elementos diagonais da matriz de $E(Y)$ (equação 36) são os efeitos diretos do modelo SAR, enquanto os elementos não-diagonais são os efeitos indiretos. O procedimento é semelhante para os modelos SDM e SAC, acrescentando somente as variáveis explicativas defasadas espacialmente no primeiro e o termo de erro defasado para o segundo.

Para o modelo SDM,

$$Y_{it} = \mathbf{W}Y_{it}\delta + \mu_i + X_{it}\beta + \mathbf{W}X_{it}\theta + \varepsilon_{it}$$
$$Y_{it} - \mathbf{W}Y_{it}\delta = X_{it}\beta + \mathbf{W}X_{it}\theta + \mu_i + \varepsilon_{it}$$
$$(\mathbf{I}_T - \delta\mathbf{W})Y_{it} = X_{it}\beta + \mathbf{W}X_{it}\theta + \mu_i + \varepsilon_{it}$$

$$Y_{it} = (\mathbf{I}_T - \delta\mathbf{W})^{-1}X_{it}\beta + (\mathbf{I}_T - \delta\mathbf{W})^{-1}\mathbf{W}X_{it}\theta + (\mathbf{I}_T - \delta\mathbf{W})^{-1}\mu_i + (\mathbf{I}_T - \delta\mathbf{W})^{-1}\varepsilon_{it}. \quad (37)$$

A matriz de esperança do modelo SDM pode ser expressa como:

$$\left[\frac{\partial E(Y)}{\partial X_{1K}} \quad \cdots \quad \frac{\partial E(Y)}{\partial X_{NK}}\right] = (\mathbf{I}_T - \delta\mathbf{W})^{-1}\left[\beta_K\mathbf{I} + \mathbf{W}\theta\right]. \quad (38)$$

Para o modelo SAC,

$$\begin{aligned} Y_{it} &= \mathbf{W}Y_{it}\delta + \mu_i + X_{it}\beta + \mathbf{W}u_{it}\lambda + \varepsilon_{it} \\ Y_{it} - \mathbf{W}Y_{it}\delta &= X_{it}\beta + \mu_i + \mathbf{W}u_{it}\lambda + \varepsilon_{it} \\ (\mathbf{I}_T - \delta\mathbf{W})Y_{it} &= X_{it}\beta + \mu_i + \mathbf{W}u_{it}\lambda + \varepsilon_{it} \\ Y_{it} &= (\mathbf{I}_T - \delta\mathbf{W})^{-1}X_{it}\beta + (\mathbf{I}_T - \delta\mathbf{W})^{-1}\mu_i + (\mathbf{I}_T - \delta\mathbf{W})\mathbf{W}u_{it}\lambda + \\ &+ (\mathbf{I}_T - \delta\mathbf{W})^{-1}\varepsilon_{it}. \end{aligned} \quad (39)$$

A matriz de esperança do modelo SAC pode ser expressa como:

$$\left[\frac{\partial E(Y)}{\partial X_{1K}} \quad \cdots \quad \frac{\partial E(Y)}{\partial X_{NK}}\right] = (\mathbf{I}_T - \delta\mathbf{W})^{-1}\beta_K. \quad (40)$$

Assim, os elementos diagonais das matrizes de $E(Y)$ (equações 38 e 40) são os efeitos diretos do modelo SAR e SAC, respectivamente , ao passo de que os elementos não-diagonais são os efeitos indiretos. Já para os modelos locais, SEM, SDEM e SLX, os efeitos diretos e indiretos não possuem o efeito feedback, sendo, β_K os efeitos direto e $\mathbf{W}\theta_k$ os efeitos indiretos (para SDEM e SLX).

Desta forma, para o modelo SEM,

$$\left[\frac{\partial E(Y)}{\partial X_{1K}} \quad \dots \quad \frac{\partial E(Y)}{\partial X_{NK}}\right] = \beta_K. \tag{41}$$

E para os modelos SDEM e SLX,

$$\left[\frac{\partial E(Y)}{\partial X_{1K}} \quad \dots \quad \frac{\partial E(Y)}{\partial X_{NK}}\right] = \beta_K \mathbf{I} + \mathbf{W}\theta_K. \tag{42}$$

Sintetizando, os efeitos diretos e indiretos (*spillovers*) de cada modelo são apresentados na Tabela 3. Para cada matriz, a diagonal principal são os efeitos diretos, ou seja, o efeito de uma mudança de uma variável explicativa em uma sobre a variável dependente na mesma localidade, sem qualquer efeito transbordamento (VEGA; ELHORST, 2013). Já os elementos não diagonais são os efeitos *spillovers*, ou seja, os efeitos transbordamentos.

Tabela 3. Efeitos diretos e indiretos para os modelos espaciais.

Modelo	**Efeito Direto**	**Efeito Indireto**	**Alcance**
OLS/SEM	β_K	0	
SAR/SAC	Elementos diagonais de $(\mathbf{I}_T - \delta\mathbf{W})^{-1}\beta_K$	Elementos não diagonais de $(\mathbf{I}_T - \delta\mathbf{W})^{-1}\beta_K$	Global
SLX/SDEM	β_K	θ_K	Local
SDM	Elementos diagonais de $(\mathbf{I}_T - \delta\mathbf{W})^{-1}[\beta_K\mathbf{I} + \mathbf{W}\theta]$	Elementos não diagonais de $(\mathbf{I}_T - \delta\mathbf{W})^{-1}[\beta_K\mathbf{I} + \mathbf{W}\theta]$	Global/Local

Fonte: Adaptado de Vega e Elhorst (2013).

4.4.4. Escolha do Modelo Espacial

Com o intuito de verificar a validade do uso de modelos espaciais ante os modelos de dados em painel não espaciais, utilizar-se-á os testes de Wald (W), Razão de Verossimilhança (LR) e Multiplicador de Lagrange (LM), propostos por Anselin (2013). Tais testes são baseados nas propriedades ótimas do estimador de máxima verossimilhança, seguindo a normalidade assintótica dos estimadores (ANSELIN, 2013). De acordo com Anselin (2013), os testes W, LR e LM são assintoticamente equivalentes. Já para amostras finitas os testes seguem o seguinte padrão, $W \geq LR \geq LM$.

O teste de Wald, utiliza-se os parâmetros do modelo restrito (mais simples) e do modelo irrestrito (mais complexo). O teste de Wald é dado por,

$$W = g'[\mathbf{G}'\mathbf{V}\mathbf{G}]^{-1}g \tag{43}$$

onde, g é um vetor $q \times 1$ dos resultados quando são impostos restrições nos parâmetros estimados por máxima verossimilhança, $\mathbf{G}$ é a matriz das derivadas parciais $\frac{\partial g(theta)}{\partial \theta}$ e V é a matriz de variância assintótica estimada. O teste de Wald utiliza a estatística χ^2 com q (número de restrições) graus de liberdade. A rejeição do teste W indica a utilização do modelo irrestrito.

O teste LR consistem em comparar o modelo mais simples, ou seja, o modelo restrito (no caso, o modelo OLS) com o modelo mais complexo, ou seja, o modelo irrestrito (no caso, os modelos espaciais). Desta forma, especifica-se o teste LR como,

$$LR = 2[L(\theta) - L(\theta_R)] \tag{44}$$

onde, $L(\theta)$ é o log de máxima verossimilhança do modelo irrestrito e $L(\theta_R)$ é o log de máxima verossimilhança do modelo restrito. O teste de Razão de Máxima Verossimilhança segue uma estatística χ^2 com q graus de liberdade, onde, a rejeição de H_0 indica a utilização do modelo irrestrito (ANSELIN, 2013).

Já o teste LM, diferentemente dos testes W e LR, não utiliza as estatísticas do modelo mais abrangente, sendo necessária somente a estimação do modelo mais restrito. O teste LM é expresso como,

$$LM = d_R^v \mathbf{I}(\theta_R)^{-1} d_R \tag{45}$$

onde, d_R é o vetor de escores do modelo restrito e $\mathbf{I}(\theta_R)$ é a matriz de informação. Tal estatística segue distribuição χ^2 com q graus de liberdade (ANSELIN, 2013).

A estatística LM é a base para as estatísticas LM-ERR, LM-LAG e LM-SAR, diferenciando-se somente do parâmetro testado.[9] Surge também as estatísticas LM-SDM e LM-SDEM, diferenciando das estatísticas anteriores no que tange o modelo restrito, onde, o modelo restrito para LM-ERR, LM-LAG e LM-SAR é o OLS e o modelo restrito para LM-SDM e LM-SDEM é o modelo SLX (ANSELIN, 2013). Segundo Elhorst (2003), os testes LM-ERR (LM_λ) e LM-LAG (LM_ρ) são especificados por,

$$LM_\lambda = \frac{\left[e^T(\mathbf{I}_T \otimes \mathbf{W})e/\widehat{\sigma}^2\right]^2}{T \times T_W} \tag{46}$$

$$LM_\rho = \frac{\left[e^T(\mathbf{I}_T \otimes \mathbf{W})\mathbf{Y}/\widehat{\sigma}^2\right]^2}{J} \tag{47}$$

onde,

$$J = \frac{1}{\sigma^2}\left[\left((\mathbf{I}_T \otimes \mathbf{W})\mathbf{X}\widehat{\beta}\right)^T \left(\mathbf{I}_{NT} - \mathbf{X}(\mathbf{X}^T\mathbf{X})^{-1}\mathbf{X}^T\right)(\mathbf{I}_T \otimes \mathbf{W})\mathbf{X}\widehat{\beta} + TT_w\sigma^2\right]$$

$$T_W = tr\left(\mathbf{WW} + \mathbf{W}^T\mathbf{W}\right).$$

Para o LM-ERR, LM-LAG, LM-SDM e LM-SDEM calcula-se também a versão robusta, levando em contra possíveis problemas de especificação (ANSELIN, 2013). Elhorst (2003), mostra que os testes LM robustos podem ser expressos como,

[9] A hipótese nula do LM-ERR é $\lambda = 0$, enquanto a hipótese nula do LM-LAG é $\rho = 0$. Por fim, a hipótese nula do LM-SAC é $\lambda = \rho = 0$.

$$LM_{\lambda}^{*} = \frac{\left[e^{T}(\mathbf{I}_{T} \otimes \mathbf{W})e/\widehat{\sigma}^{2} - TT_{W}/J \times e^{T}(\mathbf{I}_{T} \otimes \mathbf{W})\mathbf{Y}/\widehat{\sigma}^{2}\right]^{2}}{TT_{W}\left[1 - TT_{W}/J\right]} \tag{48}$$

$$LM_{\rho}^{*} = \frac{\left[e^{T}(\mathbf{I}_{T} \otimes \mathbf{W})\mathbf{Y}/\widehat{\sigma}^{2} - e^{T}(\mathbf{I}_{T} \otimes \mathbf{W})e/\widehat{\sigma}^{2}\right]^{2}}{J - TT_{W}}. \tag{49}$$

Os testes LR e LM, além de comparar os modelos espaciais com os modelos não espaciais, também são bons indicadores de qual modelo espacial se adapta melhor ao problema proposto. O teste LR permite ao pesquisador comparar modelos "aninhados", ou seja, modelos que podem ser comparados, como o SAR com o SAC e com o SDM e o SEM com o SAC e com o SDEM. Já o procedimento de seleção do teste LM consiste na escolha do modelo que prover a maior estatística χ^2, comparando os testes LM-ERR com o LM-LAG e o LM-SDEM com o LM-SDM (ELHORST, 2013).

Outro critério de seleção de modelos espaciais é o Critério de Informação de Akaike (AIC), que revela o modelo melhor ajustado aos dados. O AIC é calculado como,

$$AIC = 2k - L(\theta) \tag{50}$$

onde, k é o número de parâmetros do modelo e $L(\theta)$ é o log de máxima verossimilhança do modelo estimado. Deste modo, o estudo utilizar-se-á, como critério de seleção do modelo espacial, os testes LR, LM e o Critério de Informação de Akaike.

4.5. Estratégia Empírica

Com o intuito de avaliar o impacto do desmatamento, crescimento econômico, desenvolvimento agrícola e gastos municipais na incidência de malária estima-se duas equações centrais. A primeira equação (equação 51) estima o modelo com as variáveis sem defasagem. A segunda equação (equação 52) incorpora possíveis variáveis defasadas no modelo central.

$$\begin{aligned} Malaria_{it} &= \beta_1 Desm_{it} + \beta_2 Desm_{it}^2 + \beta_3 Denspop_{it} + \beta_4 Saude_{it} + \beta_5 Hab_{it} + \\ &+ \beta_6 PIB_{it} + \beta_7 Soja_{it} + \beta_8 Gado_{it} + \beta_9 Outcult_{it} + \beta_{10} Flor_{it} + \varepsilon_{it} \end{aligned} \quad (51)$$

$$\begin{aligned} Malaria_{it} &= \beta_1 Desm_{it} + \beta_2 Desm(t-1)_{it} + \beta_3 Desm(t-2)_{it} + \beta_4 Desm_{it}^2 + \\ &+ \beta_5 Denspop_{it} + \beta_6 Saude_{it} + \beta_7 Saude(t-1)_{it} + \beta_8 Saude(t-2)_{it} + \\ &+ \beta_9 Hab_{it} + \beta_{10} PIB_{it} + +\beta_{11} PIB(t-1)_{it} + \beta_{12} PIB(t-2)_{it} + \\ &+ \beta_{13} Soja_{it} + \beta_{14} Soja(t-1)_{it} + \beta_{15} Soja(t-2)_{it} + \beta_{16} Gado_{it} + \\ &+ \beta_{17} Gado(t-1)_{it} + \beta_{18} Gado(t-2)_{it} + \beta_{19} Outcult_{it} + \\ &+ \beta_{20} Flor_{it} + \varepsilon_{it} \end{aligned} \quad (52)$$

O intuito de criar defasagens nas variáveis de desmatamento, soja e gado decorre das características de interação de cada variável. A relação entre desmatamento e malária pode ocorrer através de áreas desmatadas em anos anteriores ao da contaminação (JUNIOR; MATION; SAKOWSKI, 2015). Já o efetivo bovino e o plantio de soja, de acordo com Faria e Almeida (2015) são variáveis muito correlacionadas com o desmatamento. Devido o tempo de preparação da terra (para a inserção do gado e da soja) após a derrubada da mata nativa, decidiu-se defasar também estas covariadas[10].

Já a defasagem do Produto Interno Bruto ocorre devido a simultaneidade, como já abordado no tópico 2.2, criando uma endogeneidade no modelo proposto. A estratégia de defasar as variáveis explicativas que possuem simultaneidade com a variável dependente é usada na literatura econômica, como em Baccini e Urperlainen (2014).

[10]Utiliza-se somente duas defasagens evitando a perda de graus de liberdade.

Deste modo, as equações 51 e 52 são as especificações de principal interesse desse estudo. Adapta-se tais modelos gerais para modelos de dados em painel e dados em painel espacial. A escolha entre o melhor modelo é realizado através de uma série de testes, especificados durante a seção metodológica.

A partir dos estudos citados na seção de revisão bibliográfica, os coeficientes das equações 51 e 52 possuem sinais previamente esperados. A Tabela 4 apresenta o direcionamento do possível efeito esperado, assim como um breve resumo sobre o mecanismo de infecção por paludismo.

Tabela 4. Sinais previamente esperados

Variável	**Sinal**	**Mecanismo de infecção**
$Desm$	+	Aumento de franjas florestais e melhores condições para propagação do vetor
$Desm_{t-1}$	+	Aumento de franjas florestais e melhores condições para propagação do vetor
$Desm_{t-2}$	+	Aumento de franjas florestais e melhores condições para propagação do vetor
$Desm^2$	+/-	Mesmos mecanismos de $Desm$ / excesso de degradação
$Flor$	+	Municípios endêmicos estão geralmente localizados em áreas florestais
$Denspop$	+	Maior quantidade de pessoas expostas à ação do mosquito
$Saude$	+/-	Maiores recursos para o combate ao vetor / Aumentos da detecção da doença
$Saude_{t-1}$	+/-	Maiores recursos para o combate ao vetor / Aumentos da detecção da doença
$Saude_{t-2}$	+/-	Maiores recursos para o combate ao vetor / Aumentos da detecção da doença
Hab	-	Melhores condições de moradia, que aumentam as proteções contra o vetor
PIB	-	Maior aporte de recursos para o combate da doença
PIB_{t-1}	-	Maior aporte de recursos para o combate da doença
PIB_{t-2}	-	Maior aporte de recursos para o combate da doença
$Gado$	+/-	Aumento do desmatamento / *zooprofilaxis* e *paddies paradox*
$Gado_{t-1}$	+/-	Aumento do desmatamento / *zooprofilaxis* e *paddies paradox*
$Gado_{t-2}$	+/-	Aumento do desmatamento / *zooprofilaxis* e *paddies paradox*
$Soja$	+/-	Aumento do desmatamento / *paddies paradox*
$Soja_{t-1}$	+/-	Aumento do desmatamento / *paddies paradox*
$Soja_{t-2}$	+/-	Aumento do desmatamento / *paddies paradox*
$Outcult$	+/-	Aumento do desmatamento / *paddies paradox*

Fonte: Resultados da pesquisa.

5. RESULTADOS E DISCUSSÃO

5.1. Análise Exploratória dos Dados Espaciais da Incidência de Malária

Conforme apresentado no item 4.1, a análise exploratória de dados espaciais possui a finalidade de visualizar as relações espaciais. Torna-se necessário, antes da estimação econométrica espacial de dados em painel, testar a hipótese de aleatoriedade, que caso seja rejeitada, recomenda-se a utilização de componentes espaciais na regressão. As Tabelas 5 e 6 representam os valores das estatísticas I de Moran e c de Geary para os casos de malária em todos os anos empreendidos na análise [11].

Tabela 5. Estatística I de Moran para os casos de malária

Ano	I	E(I)	sd(I)	z	p-valor
2003	0,554	$-0,001$	0,022	25,367	0,000
2004	0,519	$-0,001$	0,022	23,687	0,000
2005	0,533	$-0,001$	0,022	24,284	0,000
2006	0,583	$-0,001$	0,021	27,626	0,000
2007	0,587	$-0,001$	0,022	26,542	0,000
2008	0,005	$-0,001$	0,003	1,735	0,041
2009	0,346	$-0,001$	0,020	17,039	0,000
2010	0,297	$-0,001$	0,021	14,175	0,000
2011	0,323	$-0,001$	0,021	15,414	0,000
2012	0,383	$-0,001$	0,020	18,87	0,000

Fonte: Resultados da pesquisa.

De acordo com a Tabela 5, em todos os anos, de 2003 a 2012, a estatística I de Moran indicou a rejeição da hipótese de aleatoriedade (95% de confiança) dos casos de incidência de malária a cada mil habitantes, indicando que existem evidências de correlação espacial global. Também infere-se que na totalidade do período temporal em análise, a incidência de malária apresentou autocorrelação global positiva. Observa-se também que o valor do I de Moran apresenta sucessivas quedas a partir de 2008.

Já na Tabela 6, apresenta-se a estatística c de Geary, que assim como a estatística I de Moran, apresentada na Tabela 5, indica a rejeição da hipótese de aleatoriedade dos casos de incidência de malária a cada mil habitantes. A estatística c de Geary também indicou a presença de autocorrelação espacial positiva para os casos de malária na Amazônia, com exceção do ano de 2008, que apresentou aleatoriedade dos casos de malária.

[11] Para as demais variáveis utilizadas no estudo, as estatísticas I de Moran e c de Geary são apresentadas no anexo (páginas 119 - 125).

Tabela 6. Estatística c de Geary para os casos de malária

Ano	c	E(c)	sd(c)	z	p-valor
2003	0,438	1,000	0,055	$-10,256$	0,000
2004	0,430	1,000	0,051	$-11,133$	0,000
2005	0,409	1,000	0,050	$-11,708$	0,000
2006	0,339	1,000	0,076	$-8,750$	0,000
2007	0,358	1,000	0,044	$-14,743$	0,000
2008	0,905	1,000	0,206	$-0,464$	0,321
2009	0,688	1,000	0,091	$-3,423$	0,000
2010	0,724	1,000	0,077	$-3,566$	0,000
2011	0,699	1,000	0,078	$-3,836$	0,000
2012	0,646	1,000	0,091	$-3,868$	0,000

Fonte: Resultados da pesquisa.

O diagrama de dispersão de Moran para os casos de malária é apresentado na Figura 5, para os anos de 2003, 2009 e 2012, respectivamente. Este diagrama possui a característica de criar uma representação gráfica para os valores da estatística I de Moran local. Observa-se que maior parte dos municípios estão entorno do valor zero, em 2003, 2007 e 2012. Para os anos de 2003 e 2007, destacam-se uma gama de municípios localizados no primeiro quadrante (ver Figura 4), indicando que estes municípios possuem valores altos de incidência de malária acompanhados de altos valores nos seus vizinhos. Já no ano de 2012 ocorre uma diminuição de municípios no primeiro quadrante.

Para facilitar a visualização dos valores da estatística I de Moran local associados a cada município, apresentados no diagrama de dispersão (Figura 5), utiliza-se a ferramenta de representação em mapa, representado pela Figura 6. Os mapas estão ordenados para os anos de 2003, 2009 e 2012[12], respectivamente.

No ano de 2003 observa-se cinco locais de concentração de valores "Alto-Alto" do I de Moran local. Estes locais estão no Oeste de Roraima e Norte do Amazonas, Amapá, Sudoeste do Pará, Leste do Pará e na fronteira entre Amazonas e Rondônia, sendo esta localidade como a maior incidência de municípios como altos valores da estatística I de Moran local. Não existiram ocorrência de valores "Alto-Baixo", "Baixo-Alto" e "Baixo-Baixo" significativos.

Já no ano de 2009 houve uma expansão de valores "Alto-Alto" na incidência de paludismo nos Estados do Amazonas, Acre, Amapá, Rondônia e Roraima, ao passo que houve uma retração destes valores no Estado do Pará. Em 2009 não foram observadas

[12]Apresenta-se no anexo os mapas de I de Moran local para a totalidade dos anos analisados no estudo (página 118)

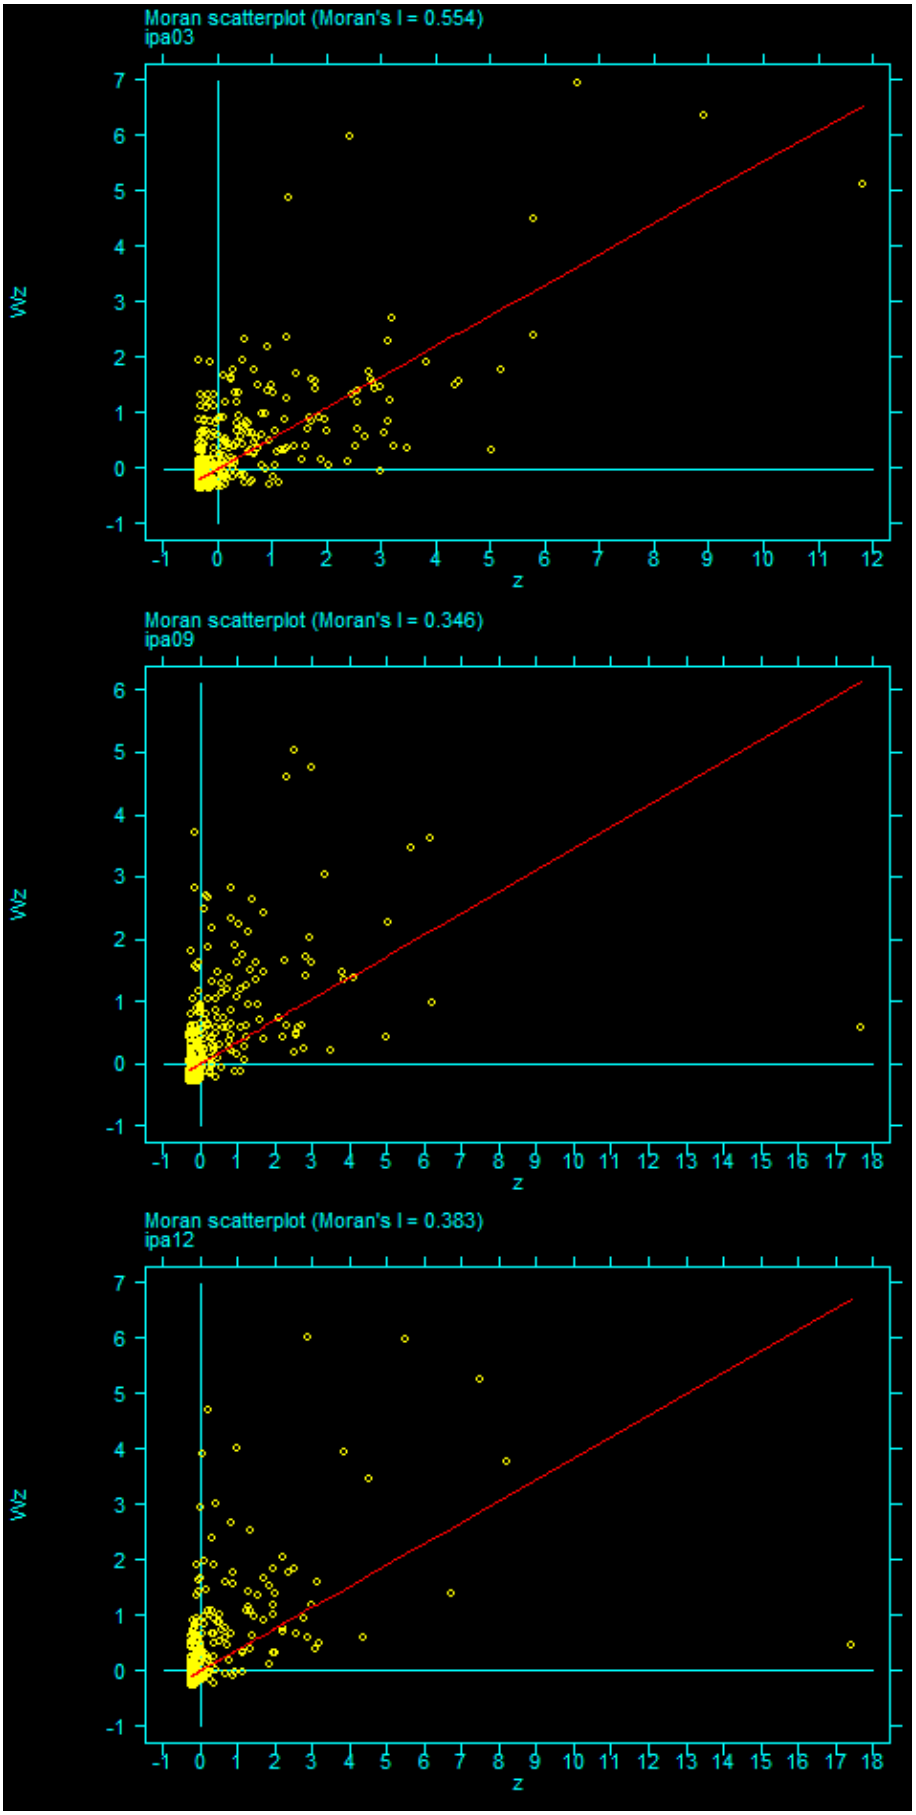

Figura 5. Dispersão de Moran Local para os casos de malária em 2003, 2007 e 2012
Fonte: Resultados da pesquisa. Software: Stata 12.0

localidades com valores “Alto-Baixo”, “Baixo-Alto” e “Baixo-Baixo” significativos.

Já no ano de 2012, houve uma retração nos municípios com valores “Alto-Alto” de I de Moran local, em relação a 2009. Destaca-se que houve um agrupamento de municípios com valores “Alto-Alto” entre o Noroeste do Acre e o Oeste e Sudoeste de Amazonas. Ademais, não foram observadas localidade com valores “Alto-Baixo”, “Baixo-Alto” e “Baixo-Baixo” significativos.

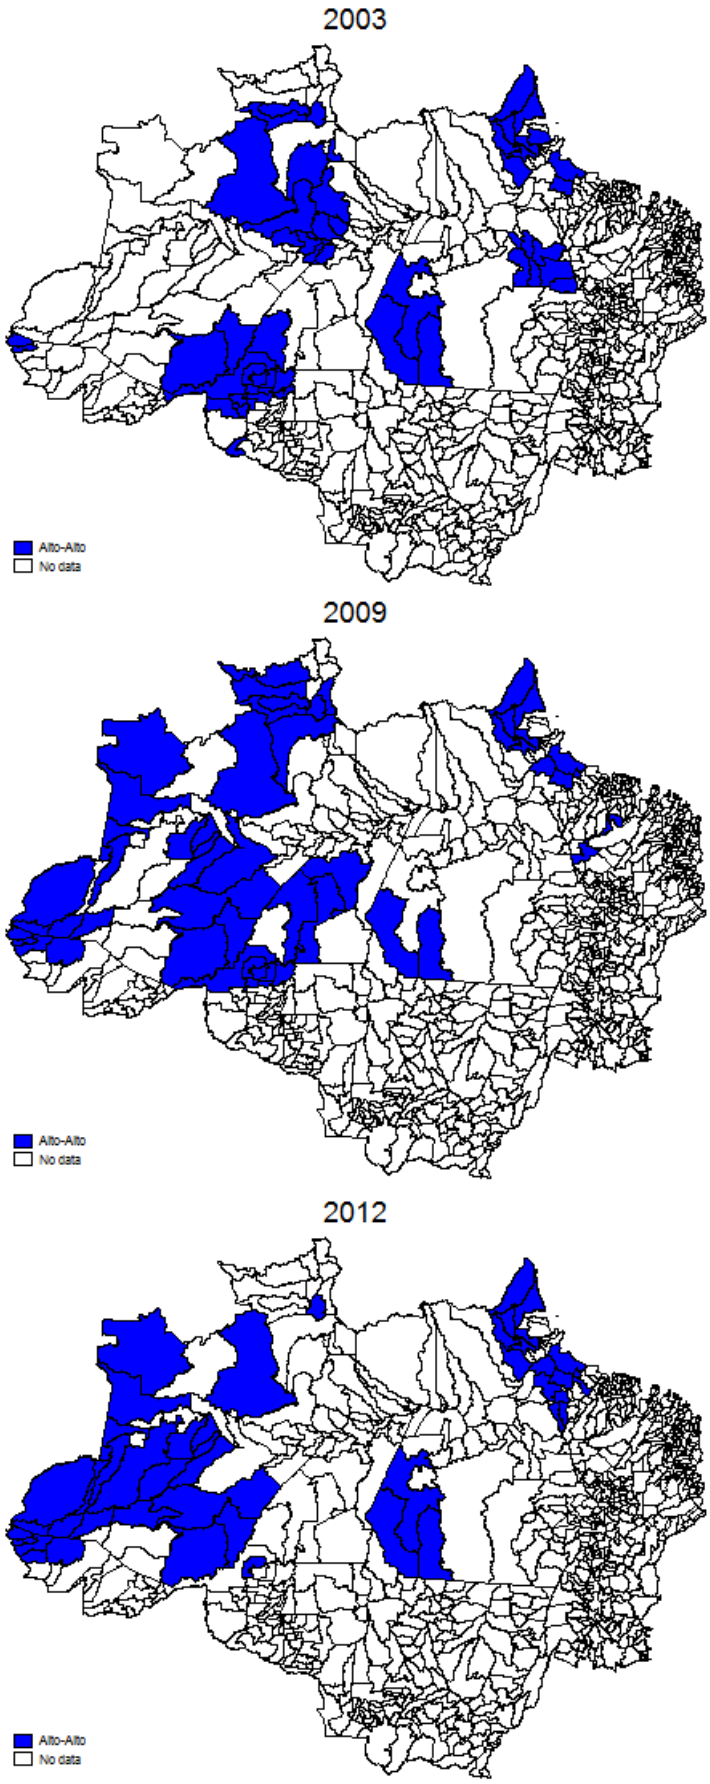

Figura 6. Mapa da estatística I de Moran Local para os casos de malária em 2003, 2007 e 2012

Fonte: Resultados da pesquisa. Software: Stata 12.0

5.2. Procedimentos para a Escolha do Modelo e da Matriz Espacial

Conforme indicado nas seções 4.1.1 e 4.3.4, para auxiliar na escolha da matriz de pesos espaciais e no modelo a ser estimado, é necessário a realização de certos procedimentos. Para a escolha do modelo são realizados os testes LR e LM e o critério de informação de Akaike, ao passo que para a escolha da matriz são observados a estatística I de Moran para os resíduos do modelo sem efeitos espaciais e o critério de informação de Akaike do modelo espacial escolhido.

Antes de se realizar os testes pretendidos, confronta-se, através da Razão de Verossimilhança (LR), as equações 51 e 52, ou seja, confronta-se o modelo sem lag nas variáveis explicativas e o modelo que contém defasagem temporal em algumas variáveis independentes. Observa-se, perante a Tabela 7, que em todos os modelos espaciais, o modelo que incorpora as variáveis defasadas é preferível ao modelo que não as incorpora. Desta forma, os demais testes serão feitos utilizando a equação 52.

Tabela 7. Teste LR entre os modelos com lag e sem lag

	χ^2	p-valor
SEM x SEM_LAG	68,47	0,000
SAR X SAR_LAG	106,97	0,000
SAC X SAC_LAG	68,19	0,000
SDM X SDM_LAG	98,85	0,000
SDEM X SDEM_LAG	91,06	0,000
SLX X SLX_LAG	178,74	0,000

Fonte: Resultados da pesquisa.

Como suporte para a seleção do modelo espacial, as Tabelas 8,9,10 e 11 expõe os testes LM realizados. Cabe ressaltar que os testes LM-SEM, LM-SAR, LM-SAC, LM-SEM (robusto) e LM-SAR (robusto) são realizados com o modelo restrito sendo o OLS, enquanto os testes LM-SDEM, LM-SDM, LM-SDEM (robusto) e LM-SDM (robusto) são realizados em vista do modelo restrito SLX.

De acordo com as Tabelas 8, 9, 10 e 11, em todas as matrizes e especificações testadas, os testes indicam o uso de modelos espacias ante modelos mais simples, ou seja, os modelos que não levam em consideração os efeitos espaciais. A exceção entre os testes foi o LM-SAR (robusto), que indicou a não rejeição da hipótese de que o coeficiente espacial autorregressivo é igual a 0. Em relação à escolha dos modelos espaciais, a partir dos testes de Multiplicador de Lagrange robustos, infere-se que os modelos de erros espaciais possuem

Tabela 8. Testes LM-ERR, LM-LAG e LM-SARAR com a matriz Queen

	MODELO LAG			**MODELO SEM LAG**		
	χ^2	**df**	**p-valor**	χ^2	**df**	**p-valor**
$LM_\lambda(SEM)$	710,04	1	0,0000	712,54	1	0,0000
$LM_\rho(SAR)$	292,32	1	0,0000	296,35	1	0,0000
$LM^*_\lambda(SEM)$	417,82	1	0,0000	416,31	1	0,0000
$LM^*_\rho(SAR)$	0,1030	1	0,7483	0,131	1	0,7183
$LM(SARAR)$	710,14	2	0,0000	712,67	2	0,0000
$LM_\lambda(SDEM)$	84,925	1	0,0000	82,494	1	0,0000
$LM_\rho(SDM)$	50,066	1	0,0000	50,399	1	0,0000
$LM^*_\lambda(SDEM)$	39,159	1	0,0000	36,852	1	0,0000
$LM^*_\rho(SDM)$	4,2991	1	0,0381	4,7564	1	0,0292

Fonte: Resultados da pesquisa.

Tabela 9. Testes LM-ERR, LM-LAG e LM-SARAR com a matriz de distância inversa

		MODELO LAG			**MODELO SEM LAG**		
		χ^2	**df**	**p-valor**	χ^2	**df**	**p-valor**
	$LM_\lambda(SEM)$	2373,4	1	0,0000	2351,1	1	0,0000
	$LM_\rho(SAR)$	1151,5	1	0,0000	1167,6	1	0,0000
	$LM^*_\lambda(SEM)$	1222	1	0,0000	1183,9	1	0,0000
com raio de 300 Km	$LM^*_\rho(SAR)$	0,1767	1	0,6743	0,4205	1	0,5167
	$LM(SARAR)$	2373,5	2	0,0000	2351,5	2	0,0000
	$LM_\lambda(SDEM)$	303,17	1	0,0000	286,15	1	0,0000
	$LM_\rho(SDM)$	184,25	1	0,0000	179,33	1	0,0000
	$LM^*_\lambda(SDEM)$	132,41	1	0,0000	121,16	1	0,0000
	$LM^*_\rho(SDM)$	13,488	1	0,0002	14,335	1	0,0001

Fonte: Resultados da pesquisa.

Tabela 10. Testes LM-ERR, LM-LAG e LM-SARAR com a matriz de distância inversa

	MODELO LAG			**MODELO SEM LAG**		
	χ^2	**df**	**p-valor**	χ^2	**df**	**p-valor**
$LM_\lambda(SEM)$	8957	1	0,0000	8947,7	1	0,0000
$LM_\rho(SAR)$	3228,6	1	0,0000	3276	1	0,0000
$LM^*_\lambda(SEM)$	5736,8	1	0,0000	5679,8	1	0,0000
$LM^*_\rho(SAR)$	8,318	1	0,0039	8,1243	1	0,0044
$LM(SARAR)$	8965,3	2	0,0000	8955,8	2	0,0000
$LM_\lambda(SDEM)$	491,27	1	0,0000	461,61	1	0,0000
$LM_\rho(SDM)$	249,62	1	0,0000	240,85	1	0,0000
$LM^*_\lambda(SDEM)$	290,97	1	0,0000	269,95	1	0,0000
$LM^*_\rho(SDM)$	49,327	1	0,0002	49,192	1	0,0001

Fonte: Resultados da pesquisa.

Tabela 11. Testes LM-ERR, LM-LAG e LM-SARAR com a matriz de cinco vizinhos mais próximos

	MODELO LAG			**MODELO SEM LAG**		
	χ^2	**df**	**p-valor**	χ^2	**df**	**p-valor**
$LM_\lambda(SEM)$	1090,2	1	0,0000	1082,2	1	0,0000
$LM_\rho(SAR)$	298,5	1	0,0000	300,26	1	0,0000
$LM_\lambda(SEM)$	791,79	1	0,0000	782,05	1	0,0000
$LM^*_\rho(SAR)$	0,0379	1	0,8456	0,0600	1	0,8065
$LM(SARAR)$	1090,3	2	0,0000	1082,3	2	0,0000
$LM_\lambda(SDEM)$	195	1	0,0000	187,36	1	0,0000
$LM_\rho(SDM)$	71,428	1	0,0000	69,831	1	0,0000
$LM^*_\lambda(SDEM)$	127,78	1	0,0000	121,8	1	0,0000
$LM^*_\rho(SDM)$	4,2067	1	0,0403	4,266	1	0,0389

Fonte: Resultados da pesquisa.

uma maior estatística do teste, onde (LM-SEM (robusto) > LM-SAR (robusto) e LM-SDEM (robusto) > LM-SDM (robusto)), sendo preferíveis aos modelos que incorporam os coeficientes autorregressivos. Desta forma, de acordo com os testes de Multiplicador de Lagrange, indica-se o uso dos modelos SEM e SDEM para estimar os impactos das covariadas sobre a incidência de malária, tanto no modelo com *lag* em certas variáveis dependentes (equação 52), quanto no modelo sem a defasagem temporal (equação 51) e também em todas as matrizes de pesos espaciais.

Outro teste que pode auxiliar na escolha dos modelos espacias é o teste de Razão de Verossimilhança (LR). A Tabela 12 mostra os testes LR para modelos espaciais que se "aninham", ou seja, para modelos espaciais que são comparáveis.

Tabela 12. Teste LR entre os modelos espaciais

	LAG		SEM LAG	
	χ^2	p-valor	χ^2	p-valor
SAR X SAC	2107,41	0,0000	2146,18	0,0000
SEM X SAC	1,73	0,1881	2,01	0,1558
SAR X SDM	2270,27	0,0000	2278,39	0,0000
SEM X SDM	164,60	0,0000	134,22	0,0000
SAR X SDEM	2221,34	0,0000	2237,24	0,0000
SEM X SDEM	115,67	0,0000	93,08	0,0000

Fonte: Resultados da pesquisa.

De acordo com a Tabela 12, o modelo SAC é preferível ao modelo SAR, mas o modelo SEM é preferível ao modelo SAC. Por outro lado, o modelo SDM é preferível aos modelos SAR e SEM, enquanto o modelo SDEM também é preferível aos modelos SEM e SAR. Percebe-se que o teste LR possui a capacidade de confrontar os modelos SEM e SDEM, que não é possível no teste LM. Particularmente, o modelo SDEM é preferível ao

modelo SEM, sanando a lacuna deixada no teste LM (que indicou os modelos SEM e o SDEM como candidatos, mas não os comparou). Deste modo, infere-se, de acordo com os testes LM e LR, que o modelo SDEM é o modelo mais adequado para estimar os impactos do desmatamento na incidência de malária, na região da Amazônia brasileira.

Uma das restrições do teste LR é a impossibilidade de comparar modelos não comparáveis, como o modelo SDEM e SDM (ELHORST, 2013). Desta forma, um outro procedimento para a escolha do modelo espacial é a comparação do Critério de Informação de Akaike (AIC), que é exposto na Tabela 13.

Tabela 13. AIC para os modelos espaciais

Modelo	AIC (modelo com lag)	AIC (modelo sem lag)
SEM	74220,3	74268,8
SAR	76446	76472,9
SAC	74340,6	74328,8
SDEM	74144,6	74195,7
SDM	74215,7	74214,6
SLX	76684,4	76823,1

Fonte: Resultados da pesquisa.

Em ambos os modelos (com *lag* e sem *lag*) o modelo de erro de Durbin possui o menor valor de AIC, ou seja, é o modelo que melhor se ajusta aos dados, segundo o Critério de Informação de Akaike. Desta forma, em todos os testes realizados a fim de estabelecer o modelo espacial que mais se ajusta aos dados disponíveis, o modelo de erro de Durbin (SDEM) é indicado, sendo este utilizado no resultado principal deste estudo. Os demais modelos são expostos na seção 5.4.2, confrontando seus resultados com o modelo SDEM.

Por fim, para estabelecer a estimação dos modelos espaciais, é necessário definir a matriz de pesos espaciais que melhor se ajusta aos dados. Na literatura, dois procedimentos são indicados (ver seção 4.1.1). O primeiro é a escolha da matriz com a maior estatística I de Moran, aplicada aos resíduos do modelo de efeitos fixos não espacial e o segundo é a verificação da matriz que gera o melhor ajuste no modelo, conforme o Critério de Informação de Akaike.

Conforme descrito na seção 4.1.1, quatro matrizes foram escolhidas como postulantes. De acordo com a Tabela 14, em ambos os procedimentos, a matriz Queen de contiguidade[13] foi indicada como a matriz que melhor se ajusta aos dados.

[13]A matriz Queen considera como vizinhos todos os municípios que fazem fronteira com o município de destino.

Tabela 14. Procedimentos para a escolha da matriz de pesos espaciais

Matriz	**AIC**	***I* de Moran**
Queen	74144,6	0,4109
Distância inversa total	74936,77	0,1021
Corte de 300km	74612,12	0,3327
5 vizinhos mais próximos	74961,94	0,3754

Fonte: Resultados da pesquisa.

Sintetizando, de acordo com os testes realizados, indica-se a utilização do modelo de erro espacial de Durbin, o modelo SDEM. Ademais, os procedimentos para a escolha da matriz de pesos espaciais indicaram a utilização de uma matriz Queen de contiguidade. Deste modo, os resultados são obtidos a partir do modelo SDEM com uma matriz Queen. As estimações dos demais modelos e das demais matrizes são apresentadas na seção 5.4.

5.3. Resultados da Estimação do Modelo SDEM

A partir da constatação de autocorrelação espacial global e local, por meio das estatísticas de I de Moran e c de Geary, em todos os anos, para a incidência de malária, indicou-se o uso de modelos econométricos espaciais, a fim de corrigir possíveis vieses gerados por modelos que não levam em consideração os componentes espaciais. Constatou-se também que o modelo que mais se ajusta ao problema proposto é o modelo de erro espacial de Durbin, assim como a matriz de peso espaciais mais adequada é a matriz Queen de contiguidade. Desta forma, os resultados apresentados são estimados a partir da equação 53.

$$
\begin{aligned}
Malaria_{it} &= \alpha + \beta_1 Desm_{it} + \beta_2 Desm(t-1)_{it} + \beta_3 Desm(t-2)_{it} + \\
&+ \beta_4 Desm^2_{it} + \beta_5 Denspop_{it} + \beta_6 Saude_{it} + \beta_7 Saude(t-1)_{it} + \\
&+ \beta_8 Saude(t-2)_{it} + \beta_9 Hab_{it} + \beta_{10} PIB_{it} + \beta_{11} PIB(t-1)_{it} + \\
&+ \beta_{12} PIB(t-2)_{it} + \beta_{12} PIB(t-2)_{it} + \beta_{13} Soja_{it} + \beta_{14} Soja(t-1)_{it} + \\
&+ \beta_{15} Soja(t-2)_{it} + \beta_{16} Gado_{it} + \beta_{17} Gado(t-1)_{it} + \beta_{18} Gado(t-2)_{it} + \\
&+ \beta_{19} Outcult_{it} + \beta_{20} Flor_{it} + \theta_1 \mathbf{W} Desm_{it} + \theta_2 \mathbf{W} Desm(t-1)_{it} + \\
&+ \theta_3 \mathbf{W} Desm(t-2)_{it} + \theta_4 \mathbf{W} Desm^2_{it} + \theta_5 \mathbf{W} Denspop_{it} + \theta_6 \mathbf{W} Saude_{it} + \\
&+ \theta_7 \mathbf{W} Saude(t-1)_{it} + \theta_8 \mathbf{W} Saude(t-2)_{it} + \theta_9 \mathbf{W} Hab_{it} + \theta_{10} \mathbf{W} PIB_{it} + \\
&+ \theta_{11} \mathbf{W} PIB(t-1)_{it} + \theta_{12} \mathbf{W} PIB(t-2)_{it} + \theta_{12} \mathbf{W} PIB(t-2)_{it} + \theta_{13} \mathbf{W} Soja_{it} + \\
&+ \theta_{14} \mathbf{W} Soja(t-1)_{it} + \theta_{15} \mathbf{W} Soja(t-2)_{it} + \theta_{16} \mathbf{W} Gado_{it} + \theta_{17} \mathbf{W} Gado(t-1)_{it} + \\
&+ \theta_{18} \mathbf{W} Gado(t-2)_{it} + \theta_{19} \mathbf{W} Outcult_{it} + \theta_{20} \mathbf{W} Flor_{it} + \mu_i + \\
&+ \lambda \mathbf{W} u_{it} + \varepsilon_{it}. \qquad (53)
\end{aligned}
$$

Onde, α é o intercepto, μ_i é a heterogeneidade, $\lambda \mathbf{W} u_{it}$ é o componente de erro espacial e ε_{it} são os desvios idiossincráticos da regressão. De acordo com a Tabela 3, β_1 a β_{20} são os coeficientes que representam os efeitos diretos, ou seja, o efeito das variáveis nos municípios correspondentes, enquanto θ_1 a θ_{20} são os coeficientes que representam os efeitos indiretos (*spillovers*), também conhecidos como efeitos de transbordamento. Ademais, estima-se o efeito total, que é a soma dos efeitos diretos e indiretos. Os coeficientes estimados do modelo SDEM, utilizando uma matriz Queen de contiguidade, estão representados na Tabela 15.

Tabela 15. Efeito diretos diretos, indiretos e totais para o modelo SDEM

	Efeito Direto	Efeito indireto	Efeito Total
$Desm$	0,0850***	0,0333	0,1183*
	(0,0228)	(0,0459)	(0,0687)
$Desm_{t-1}$	-0,0008	0,0642*	0,0634
	(0,0135)	(0,0290)	(0,0425)
$Desm_{t-2}$	-0,0027	0,0234	0,0207
	(0,0082)	(0,0148)	(0,0229)
$Desm^2$	-0,0001***	1,50e-05	-0,0001
	(2,23e-05)	(4,24e-05)	(6,47e-05)
$Flor$	0,4096***	-0,3120	0,0971
	(0,0925)	(0,1881)	(0,2805)
$Denspop$	-0,0163	0,1990	0,1827
	(0,0700)	(0,1641)	(0,2340)
$Saude$	0,0225***	0,0061	0,0286***
	(0,0024)	(0,0049)	(0,0073)
$Saude_{t-1}$	0,0173***	-0,0069	0,0104
	(0,0028)	(0,0056)	(0,0084)
$Saude_{t-2}$	0,0006	0.0007	0,0013
	(0,0006)	(0,0022)	(0,0028)
Hab	-0,0062	-0,0316**	-0,0378***
	(0,0040)	(0,0106)	(0,0146)
PIB	-2,26e-07	-6,40e-06	-6,63e-06
	(1,98e-06)	(5,59e-06)	(7,57e-06)
PIB_{t-1}	8,02e-07	-3,58e-07	4,44e-07
	(2,71e-06)	(7,72e-06)	(1,04e-06)
PIB_{t-2}	2,82e-06	-1,65e-05*	-1,368e-06
	(2,49e-06)	(6,89e-06)	(9,38e-06)
$Soja$	0,0017	0,0088	0,0105
	(0,0110)	(0,0268)	(0,0378)
$Soja_{t-1}$	-0,0012	-0,0011	-0,0023
	(0,0137)	(0,0340)	(0,0477)
$Soja_{t-2}$	-0,0011	0,0188	0,0177
	(0,0099)	(0,0232)	(0,0331)
$Gado$	-5,28e-05*	-5,50e-06	-7,83e-05
	(2,36e-05)	(5,55e-05)	(7,91e-05)
$Gado_{t-1}$	-3,07e-05	5,52e-05	2,45e-05
	(3,02e-05)	(7,23e-05)	(0,0001)
$Gado_{t-2}$	-3,12e-05	-0,0001**	-0,0001**
	(2,40e-05)	(5,41e-05)	(7,81e-05)
$Outcult$	0,0067	-0,0032	0,0034
	(0,0053)	(0,0128)	(0,0181)
λ		0,6920***	
		(0,0108)	

Fonte: Resultados da pesquisa. *** p < 0,001; ** p < 0,01; * p < 0,05. Erro padrão entre parênteses.

Os resultados estimados indicam que a cada cem km^2 (ou dez mil hectares) acrescidos de mata amazônica desmatada aumenta, em média, 8,5 casos de malária a cada mil habitantes, no próprio município. Constata-se que existe uma consonância com os trabalhos de Garg (2014), Junior, Mation e Sakowski (2015) e Olson et al. (2010), chegando à um denominador comum de que existem evidências que o desmatamento possui influência positiva sobre a dinâmica de transmissão da doença. Em relação ao trabalho de Garg (2014) - que estimou um aumento de 2% a 7% nos casos da doença quando ocorre desmatamento de mil hectares na Indonésia - houve disparidades no que tange à magnitude do impacto do desmatamento sobre a incidência do paludismo, podendo ser explicada pela possível diferença entre o vetor dominante na Indonésia, vegetação, solo, clima, dinâmica de habitação e atividades nas bordas das florestas.

Os resultados indicaram que, estatisticamente, as áreas desmatadas nos dois anos anteriores não possuem efeitos diretos sobre os casos de paludismo. Desta forma, encontra-se evidências de que somente o desmatamento recente possui efeito direto na incidência de malária. Estes resultados são distintos das conclusões de Junior, Mation e Sakowski (2015), que encontraram evidências de que o desmatamento, de até dois anos defasados, afeta os casos de malária na Amazônia, mas, em contra partida, convergem com os resultados de Olson et al. (2010) que também não encontraram indícios de que o desmatamento se relaciona temporalmente com os casos de paludismo. Tais resultados divergentes podem ocorrer devido a utilização de métodos e especificações diferentes, visto que, no estudo de Junior, Mation e Sakowski (2015) utiliza-se uma regressão de Poisson sem o controle espacial, tendo também controles diferentes.

Além do efeito direto, observa-se que existe um efeito transbordamento do desmatamento defasado de um ano, ou seja, a derrubada de cem km^2 de floresta em um município no tempo $t-1$, gera um aumento, em média, de 6,4 casos de malária a cada mil habitantes nos municípios vizinhos, no ano t. Portanto, encontra-se evidências de que o desmatamento defasado de um ano possui um potencial efeito transbordamento na incidência municipal de paludismo. Este efeito pode estar relacionado com a capacidade de migração do vetor, o *A. darlingi*, que possui um raio de deslocamento de até 7,2 km em nove dias (CHARLWOOD, 1989), propiciando uma perpetuação do efeito do desmatamento sobre os casos da infecção nos municípios contíguos. O efeito transbordamento também pode estar correlacionado com o desmatamento próximo à fronteira municipal, gerando um

maior acesso do vetor à população dos municípios adjacentes.

O efeito total do desmatamento pode ser obtido somando-se os efeitos diretos e indiretos. Deste modo, estima-se um efeito total de um aumento de 11,8 casos de malária a cada mil habitantes, no ano t quando 100 km^2 são desmatados, no mesmo período t. A relação positiva entre os casos de paludismo e desmatamento pode ser explicada pelas mudanças no meio ambiente, gerando condições propícias à reprodução vetor, além de potenciais mudanças no microclima da região modificada e a eliminação de predadores naturais dos vetores transmissores (BAUCH et al., 2014). Ademais, não houveram efeitos totais significativos para as variáveis que representam o desmatamento defasado em um e dois anos.

Adicionalmente ao desmatamento nos anos t, $t-1$ e $t-2$, também estimou-se o termo quadrático desmatamento. O intuito de elevar a variável desmatamento ao quadrado deve-se à captação da relação entre malária e desmatamento nos maiores quantis de áreas desmatadas. Desta forma, elevar tal covariada ao quadrado gera uma estimação do desflorestamento com peso maior para maiores áreas desmatadas. De acordo com o modelo estimado, quando coloca-se maior peso para maiores áreas submetidas ao desflorestamento, o efeito direto do desmatamento sobre a malária passa a ser negativo. Este resultado evidencia que o desmatamento não atua de forma linear sobre os casos de malária, sugerindo haver um ponto inflexão de acordo com que a área desmatada aumenta. Tal ponto de inflexão pode ser calculado derivando a equação 53 em relação ao $Desm$. Deste modo, $\frac{\partial Malaria_{it}}{\partial Desm} = \beta_1 + 2(\beta_2 Desm) = 0$. Assim, o ponto de inflexão calculado é de 425 Km^2, que é próximo à área desmatada pertencente a Juara (MT) no ano de 2005. Destaca-se ainda que somente 32 municípios tiveram uma área desmatada maior ou igual a 425 Km^2.

O motivo de um desmatamento em larga escala afetar negativamente os casos de malária é o excesso de degradação da floresta causado por grandes quantidades desmatadas[14] (MALHI et al., 2008). No Brasil, a malária ocorre, geralmente, em áreas cobertas pela floresta amazônica, onde as condições são mais propícias à sua ocorrência (VITTOR et al., 2009). Assim, a total degradação da floresta pode ter um efeito negativo sobre a epidemia de paludismo. Desta forma, o estudo encontra evidências de que o efeito direto do desmatamento depende da escala em que ocorre. Ademais, não foram evidenciados efeitos

[14]A degradação total da floresta amazônica elimina as áreas de "franjas florestais", que possuem condições ideais para a proliferação do mosquito, além de eliminar hospedeiros intermediários do *Plasmodium*, dificultando a disseminação da doença (SAUL, 2003; VITTOR et al., 2006).

spillovers e efeitos totais para o desmatamento em larga escala.

O percentual de floresta em relação a área municipal, inserida na equação 53, reafirma a teoria de que, no Brasil, a incidência de malária ocorre em municípios que estão inseridos em áreas cobertas pela floresta amazônica. Evidencia-se que, a cada 10% da área municipal coberta por floresta aumenta, em média, 4,096 casos de malária a cada mil habitantes, em relação ao efeito direto. No que tange o efeito indireto, tal evidência não é encontrada. O efeito total do percentual de floresta em relação a área municipal também não é estatisticamente significante, em decorrência de que os efeitos diretos e indiretos possuírem sinais divergentes, tornando o efeito total estatisticamente igual a zero.

Em relação aos gastos municipais com saúde e saneamento, as estimativas se mostraram contrárias ao sinal esperado. Inicialmente, esperava-se que os gastos com saúde e saneamento propiciassem a diminuição dos casos de paludismo, via políticas de erradicação do vetor, principalmente no que tange os gastos com saneamento básico (COHEN; DUPAS, 2010). Porém, evidencia-se que a cada R$100 *per capita* dispendidos com saúde e saneamento, no período t, aumenta, em média, 2,25 casos de malária a cada mil habitantes, no período t, em relação aos efeitos diretos. Constata-se também que o dispêndio com tais gastos no ano anterior também possuem efeitos sobre os casos de malária no período temporal atual. Deste modo, a cada cem reais *per capita* gastos com saúde e saneamento, em $t-1$ aumenta, em média, 1,73 casos de paludismo a cada mil habitantes, em t, em relação aos efeitos diretos.

A relação positiva entre gastos municipais com saúde e saneamento básico e incidência de paludismo pode ser explicada pelo aumento da capacidade de detecção da doença. Uma hipótese é que para um município reportar os casos de malária deve-se ocorrer capacidade técnica-laboratorial para tal, de modo que, municípios que possuem melhores infra-estrutura laboratoriais, tendem a ter uma melhor capacidade de reportar todos os casos de paludismo ocorridos em seu domínio. Desta forma, os dispêndios com saúde e saneamento podem atuar na melhoria e ampliação dos laboratórios com capacidade de diagnóstico da infecção, aumentando, assim, as estatísticas da ocorrência da doença. Cabe ressaltar que, os gastos com saúde e saneamento não possuem a capacidade de aumentar o risco de infecção, mas sim, aumenta a diagnosticação, aumentando as estatísticas municipais da doença.

Não foram observados efeitos indiretos para os dispêndios com saúde e sane-

amento básico, gerando indícios de que tais gastos só possuem a capacidade de aumentar a eficiência de detecção da doença no próprio município de origem dos dispêndios. Ademais, só foram observados efeitos totais significativos para os gastos com saúde no período t.

Outra categoria de gastos municipais que possuem a capacidade de combater a epidemia por malária, são os gastos municipais com habitação. Segundo Singer e Castro (2001) é primordial adequar às condições de moradia, via instalação de telas mosquiteiras e melhores condições de saneamento urbano, para que haja redução dos casos de paludismo. Em relação ao efeito direto, apesar de o sinal esperado ser consonante com a literatura, este não apresentou significância estatística. Porém, no que tange os efeitos *spillovers*, a cada cem reais *per capita* dispendidos com habitação, diminui, em média, 3,16 casos de paludismo nos municípios contíguos. O motivo de os gastos com habitação possuírem efeitos diretos não estatisticamente significativos e efeitos indiretos significativos não são claros, porém, presume-se que tais dispêndios possam dificultar a proliferação do mosquito transmissor, diminuindo a incidência de vetores que possam migrar para os municípios vizinhos. Ademais, em relação ao efeito total, a cada cem reais *per capita* gastos com habitação, diminui, em média, 3,78 casos de paludismo.

A exemplo dos gastos com habitação, o Produto Interno Bruto municipal não gerou efeitos diretos significativos, porém, houve evidências de efeitos *spillovers*. Em relação aos efeitos diretos, no período t, o PIB possui efeitos negativos sobre a incidência da doença, porém não estatisticamente significativo. Já nos períodos $t-1$ e $t-2$, o PIB apresentou efeitos positivos, no que concerne os efeitos diretos, sobre os casos da doença, mas também não significativos. Tais resultados expõe uma instabilidade dos coeficientes, podendo ser reflexo de "forças" opostas atuando sobre o PIB, como maiores recursos destinados para a erradicação do paludismo (efeito negativo) e maior migração para áreas endêmicas (efeito posito) (CASTILLA; SAWYER, 1993). Outra hipótese é de que o PIB não possui influência sobre os casos da doença, mas sim, os casos de malária possuem capacidade de afetar negativamente a renda (SACHS; MALANEY, 2002).

Embora o PIB não possua efeitos diretos significativos sobre os casos de malária, evidencia-se um efeito negativo do PIB com duas defasagens, em relação ao efeito transbordamento. Deste modo, assim como os gastos com habitação, uma maior renda municipal pode ser crucial para a implementação de políticas que visam a redução do paludismo, dificultando a proliferação e consequentemente a migração do vetor, assim, benefici-

ando os municípios contíguos. Ademais, não foram encontrados efeitos totais significativos para o Produto Interno Bruto.

Em relação ao desenvolvimento agropecuário, somente na pecuária bovina foi evidenciada uma relação com os casos de paludismo. As variáveis que representam a área plantada de soja e de demais culturas (como o arroz, a cana e o milho), não possuíram coeficientes significativos. Foram encontradas evidências de que o efetivo bovino possui uma relação negativa com a incidência do paludismo, tanto em relação ao efeito direto, quanto em relação ao efeito *spillover*.

No que tange o efeito direto, a cada mil cabeças de gado, no tempo t, em um município, diminui, em média, 0,05 casos de malária a cada mil habitantes, no período t, no próprio município. Os efeitos diretos para o efetivo bovino defasados não tiveram significância estatística. Porém, no que diz respeito aos efeitos *spillovers*, somente o estoque bovino com duas defasagens possuem efeitos sobre os municípios vizinhos. Desta forma, a cada mil cabeças de gado em um município, no período $t-2$, diminui, em média, 0,1 casos de malária a cada mil habitantes nos municípios contíguos, no período t. Já no que concerne aos efeitos totais, somente o rebanho defasado em dois períodos possui coeficientes significativos.

Uma explicação para esta relação negativa se deve ao fato de que, para alguns vetores, o sangue do gado é preferível ao sangue humano, esta ação é conhecida como *Zoo-prophylaxis*, ou seja, o desvio de insetos patogênicos de humanos para animais (SAUL, 2003; WIELGOZ et al., 2012). Alternativamente, no Brasil, a pecuária possui características de ser uma atividade de capital intensivo, fazendo com que a relação negativa entre rebanho e casos de malária seja um caso *paddies paradox*, onde o desenvolvimento agrícola resulta em um aumento de renda para a comunidade, aumentando também a capacidade de proteção contra o vetor transmissor da doença (ASENSO-OKYERE et al., 2009).

Apesar da existência de evidências que a criação de gado contribui para a diminuição da malária, deve-se ficar atento à correlação entre atividade pecuária e desmatamento, dado que a criação de gado é visto como um determinante importante do desmatamento na Amazônia (FARIA; ALMEIDA, 2015). Deste modo, revela-se uma limitação deste artigo, que não possui embasamento para estimar o efeito da conversão de matas nativas em pastagens nos casos de malária. A relação da criação de gado com massivo desmatamento pode ser uma justificativa alternativa para o sinal negativo do coeficiente,

em razão de que a introdução de pastagens possui a capacidade de alterar bruscamente o ecossistema local, podendo até aumentar a distância entre floresta e população.

O coeficiente de erro espacial λ apresentou o valor de $0,6920$, estatisticamente significativo. Este coeficiente indica uma autocorrelação espacial positiva de algum efeito espacial não incluso no modelo, ou seja, um choque sobre determinado município provoca efeitos semelhantes nos municípios contíguos. Fatores climáticos podem ser um exemplo de tais choques, visto que a sua ocorrência possui capacidade de alterar a dinâmica de transmissão do paludismo, abrangendo as regiões não aleatoriamente. Desta forma, o modelo de erro espacial de Durbin, o SDEM, possui a capacidade de controlar os efeitos espacias não modelados, através do coeficiente de erro espacial, λ.

Ademais, as variáveis que representam a densidade populacional, plantio de soja e o plantio das demais culturas representativas da região não exerceram efeitos sobre os casos de malária. Em relação à densidade populacional, era esperado que quanto maior a concentração de pessoas em áreas endêmicas, maior a quantidade de casos de malária reportados, porém, não foram observados efeitos significativos para a densidade populacional. O motivo da não significância pode ser o efeito diverso de tal covariada, pois, enquanto a maior densidade populacional pode expor mais pessoas à picada do *Anophelino*, a mesma pode indicar maior urbanização, que, por sua vez, pode aumentar a distância entre a população e as franjas florestais, diminuindo a exposição ao vetor transmissor da infecção.

A não significância dos coeficientes que representam o plantio de soja e de outras culturas também podem estar atrelados aos efeitos diversos das variáveis. Enquanto o plantio de soja e de outras culturas, por ser uma atividade que, geralmente, utiliza a irrigação, pode gerar um ambiente propício à reprodução do vetor, gerando efeito positivo sobre a incidência do paludismo, pode também gerar renda à população, aumentando a capacidade de proteção contra o mosquito, gerando um efeito negativo nos casos da doença, conhecido como *paddies paradox* (ASENSO-OKYERE et al., 2009). Desta forma, expõe-se uma incapacidade do estudo, cujo os efeitos diversos da atividade agrícola não puderam ser desagregados, sendo indicada tal desagregação para estudos futuros.

5.4. Checagem de Robustez dos Resultados

5.4.1. Resultados da estimação dos modelos econométricos de dados em painel

Com o objetivo de verificar a robustez das estimativas dos resultados apresentados na seção anterior, confronta-se o modelo SDEM, estimado na seção 5.3, com os coeficientes estimados de modelos de painéis convencionais, sendo eles o *pooled*, o modelo de efeito aleatório e o modelo de efeito fixo (Tabela 16). Frisa-se que, embora o artigo apresente os coeficientes estimados dos três modelos, o teste de Breusch e Pagan indicou o uso de moldelos que controlam a heterogeneidade ($\chi^2 = 9778,31$), enquanto o teste de Hausman indicou que a heterogeneidade está correlacionada ($\chi^2 = 61,18$) com as variáveis dependentes do modelo. Deste modo, pelos testes realizados, indica-se que o modelo de efeitos fixos é o mais apropriado para a inferência.

Em relação ao coeficiente que representa o desmatamento, houve significância na totalidade dos modelos apresentados na Tabela 16, de modo que, os coeficientes estimados para o desmatamento se diferiram somente na terceira casa decimal. Destaca-se que os coeficientes estimados variaram de $0,1221$ a $0,1250$. Em relação ao modelo SDEM (equação 52), também ocorreu a convergência dos coeficientes que representam o efeito do desmatamento sobre a incidência de paludismo. Desta forma, em relação o modelo SDEM e de dados em painel, os coeficientes estimados variaram de $0,1183$ a $0,1250$[15].

Nos modelos de efeito aleatório e de efeito fixo houve significância do coeficiente que representa o desmatamento defasado em um ano, ao passo de que, nos modelos *pooled* e SDEM, não é observada a significância de tal coeficiente. Os coeficientes do desmatamento defasado em um ano variaram de $0,0477$ a $0,328$. Apesar de o desmatamento em $t-1$, no que tange o efeito total, não ser significativo no modelo SDEM, tal coeficiente é estatisticamente significativo no que diz respeito o efeito *spillover*, que possui coeficiente estimado de $0,0642$ (ver Tabela 15), convergindo com os coeficientes estimados dos modelos de efeito fixo e aleatório. Ademais, o desmatamento com duas defasagens só foi significativo no modelo espacial de efeito aleatório, não tendo significância nos modelos *pooled*, efeito fixo e no modelo de erro de Durbin (SDEM).

No que concerne ao termo quadrático do desmatamento, houve a convergência

[15]Frisa-se que, com o intuito de comparar modelos não espacias com modelos espaciais, utiliza-se os efeitos totais do modelo espacial para confrontá-los com os modelos convencionais de dados em painel (ELHORST, 2013).

do coeficiente estimado em todos os modelos, sendo este $-0,0001$. Ressalta-se que somente no modelo SDEM este coeficiente não foi significativo, mas, em contrapartida, o termo quadrático é significativo no que tange o efeito direto do modelo SDEM. Semelhantemente ao termo quadrático, o percentual de floresta sobre a área municipal também é significativo nos modelos *pooled*, efeito aleatório e efeito fixo e, apesar do efeito total do moledo SDEM não ser significativo, o coeficiente estimado do efeito direto do percentual de floresta possui significância estatística $(0,4096)$, convergindo para os parâmetros estimados dos modelos convencionais de dados em painel.

De acordo com a Tabela 16, na totalidade dos modelos apresentados, os gastos *per capita* com saúde apresentaram concordância e convergência. Desta forma, os coeficientes estimados variaram de $0,0225$ a $0,0286$. Já os gastos com saúde defasados em um ano foram significativos nos modelos *pooled*, efeito aleatório e efeito fixo, sendo, em relação ao modelo SDEM, somente estatisticamente significativo no efeito direto.

Em relação aos gastos municipais com habitação *per capita*, houve convergência em todos os modelos apresentados na Tabela 16. Estimou-se que, a cada cem reais gastos com habitação, reduz, em média, de $0,94$ a $3,78$ casos de malária na região amazônica.

No que tange as variáveis agrícolas, a soja defasada em um e dois anos e o gado com *lag* de um ano não foram significativos em nenhum modelo estimado. Enquanto a variável que representa a soja no ano corrente e a área plantada de outras culturas só foram significativas no modelo *pooled*, o efetivo bovino no ano corrente só foi significativo no modelo de efeitos fixos. A única variável agrícola que foi significativa em todos os modelos propostos foi a variável que representa o efetivo bovino com defasagem de dois anos, tendo coeficiente estimado entre $-0,0001$ e $-0,00008$.

Em resumo, houveram divergências, de todos os modelos convencionais de dados em painel com o modelo SDEM, nos parâmetros de três variáveis, sendo elas, desmatamento ao quadrado, percentual de floresta na área municipal e gastos municipais com saúde *per capita* defasados em um ano. Tais divergências não ocorrem se considerar a significância dos efeitos diretos e indiretos isolados, visto que, o termo quadrático, o percentual de floresta e os gastos com saúde em $t-1$ possuem efeitos diretos significativos, no modelo SDEM. Estes resultados reforçam que os coeficientes estimados do modelo SDEM, apresentado na seção 5.3, convergem com os modelos convecionais de dados em painel, evidenciando que as estimações tendem a convergir para o verdadeiro parâmetro populacional.

Particularmente, percebe-se uma semelhança entre o modelo de efeito fixo (Tabela 16) e o modelo de erro espacial de efeito fixo -SEM- (Tabela 17). Esta semelhança é esperada pelo fato de que, no modelo SEM, ocorre somente a inclusão do erro espacial defasado, divergindo do modelo clássico de efeito fixo somente no que diz respeito à matriz de variância e covariância (ELHORST, 2013).

Tabela 16. Coeficientes estimados para os modelos de dados em painel

	POOLED	**RE**	**FE**	**SDEM**
$Desm$	0,1221***	0,1250***	0,1232***	0,1183*
	(0,0286)	(0,0225)	(0,0240)	(0,0687)
$Desm_{t-1}$	0,0283	0,0477**	0,0328*	0,0634
	(0,0193)	(0,0139)	(0,0149)	(0,0425)
$Desm_{t-2}$	0,0138	0,0160*	0,0126	0,0207
	(0,0107)	(0,0077)	(0,0078)	(0,0229)
$Desm^2$	-0,0001***	-0,0001***	-0,0001***	-0,0001
	(2,91e-05)	(2,46e-05)	(2,55e-05)	(6,47e-05)
$Flor$	0,8724***	0,7440***	0,4323***	0,0971
	(0,0254)	(0,0486)	(0,0843)	(0,2805)
$Denspop$	-0,0089	-0,0116	-0,0325	0,1827
	(0,0059)	(0,0140)	(0,0771)	(0,2340)
$Saude$	0,0281***	0,0230***	0,0225***	0,0286***
	(0,0031)	(0,0021)	(0,0021)	(0,0073)
$Saude_{t-1}$	0,0109**	0,0164***	0,0168***	0,0104
	(0,0036)	(0,0025)	(0,0025)	0,0013
$Saude_{t-2}$	0,0006	0,0009	0,0010	0,0013
	(0,0010)	(0,0007)	(0,0007)	(0,0028)
Hab	-0,0266***	-0,0119**	-0,0094*	-0,0378***
	(0,0053)	(0,0045)	(0,0046)	(0,0146)
PIB	-1,19e-07	4,09e-07	1,33e-07	-6,63e-06
	(3,27e-06)	(2,33e-07)	(2,40e-07)	(7,57e-06)
PIB_{t-1}	-6,02e-07	-2,70e-07	7,04e-09	4,44e-07
	(4,83e-06)	(3,30e-06)	(3,31e-06)	(1,04e-06)
PIB_{t-2}	1,10e-07	-1,19e-06	-2,18e-06	-1,368e-06
	(3,84e-07)	(2,82e-06)	(3,01e-06)	(9,38e-06)
$Soja$	-0,0379*	-0,0112	0,0073	0,0105
	(0,0159)	(0,0116)	(0,0128)	(0,0378)
$Soja_{t-1}$	0,0075	-0,0009	0,0040	-0,0023
	(0,0232)	(0,0159)	(0,0159)	(0,0477)
$Soja_{t-2}$	0,0302	0,0103	0,0079	0,0177
	(0,0159)	(0,0112)	(0,0113)	(0,0331)
$Gado$	1,64e-05	-2,43e-05	-7,07e-05*	-7,83e-05
	(3,59e-05)	(2,56e-05)	(2,77e-05)	(7,91e-05)
$Gado_{t-1}$	7,38e-06	1,57e-05	5,58e-06	2,45e-05
	(5,24e-05)	(3,58e-05)	(3,57e-05)	(0,0001)
$Gado_{t-2}$	-9,17e-05*	-8,21e-05**	-0,0001***	-0,0001**
	(3,69e-05)	(2,60e-05)	(2,74e-05)	(7,81e-05)
$Outcult$	-0,0162*	-0,0060	-0,0024	0,0034
	(0,00660)	(0,0061)	(0,0063)	(0,0181)
R^2 *within*	0,8062	0,8962	0,8968	0,9006
R^2 *between*		0,4913	0,3672	0,1822
R^2 *overall*		0,8044	0,7748	0,7195
Breush-Pagan		9778,31		
Hausman		61,18		

Fonte: Resultados da pesquisa. *** p < 0,01; ** p < 0,05; * p < 0,10. Erro padrão entre parênteses.

5.4.2. Resultado da estimação dos modelos espaciais

Paralelamente à seção 5.4.1, confronta-se os resultados do modelo SDEM, apresentado na seção 5.3, com os demais modelos espaciais, especificados na seção metodológica 4.3. A comparação dos coeficientes estimados entre os variados modelos espaciais, surge da necessidade do pesquisador observar a variação dos coeficientes de interesse em diferentes metodologias. Nas Tabelas 17 e 18 estão apresentados os efeitos diretos e indiretos, respectivamente, dos modelos descritos, ao passo de que a Tabela 19 apresenta os efeitos totais, o R^2 *within, beetwen* e *overall*, além do teste de Wald (com o modelo de efeitos fixos não espacial como modelo restrito), o teste de razão de verossimilhança (LR, com o modelo de efeitos fixos não espacial como modelo restrito) e o Critério de Informação de Akaike (AIC).

Os coeficientes que representam os impactos do desmatamento convergiram na totalidade dos modelos propostos, em relação aos efeitos diretos (Tabela 17). Os coeficientes do desmatamento, no período presente, foram todos significativos, variando entre $0,0820$ e $0,128$. Em relação ao desmatamento defasado em um e dois anos, com exceção do modelo SAR (que apresentou um coeficiente estimado de $0,0154$ para o desmatamento defasado em dois anos), os modelos não estimaram coeficientes estatisticamente significativos. Já para os efeitos indiretos (Tabela 18), os modelos não convergiram em resultados. Destaca-se que, somente no modelo SAC, não se obteve significância para o desmatamento, levando em conta as defasagens e o valor presente. Deste modo, os modelos SDEM $(0,0642)$, SDM $(0,1110)$ e SLX $(0,070)$ indicaram que o desmatamento possui um efeito *spillover* somente na defasagem de um ano, ao passo de que o modelo SAR indica efeitos transbordamentos no período presente (com valor $0,0347$) e em $t-2$ $(0,0041)$.

Em relação aos efeitos totais dos desmatamentos em t, $t-1$ e $t-2$, somente no modelo SLX não apresentou coeficientes significativos. O coeficiente estimado do desmatamento em t, apresentou significância nos modelos SEM, SDEM, SAR e SAC, variando de $0,1040$ a $0,1630$, ou seja, a cada 100 Km de mata derrubada, aumenta, em média, de $10,4$ a $16,3$ casos de paludismo na Amazônia Legal. Já para o desmatamento em $t-1$ só foi significativo no modelo SDM, ao passo que o desmatamento em $t-2$ é significativo somente no modelo SAR.

O coeficiente estimado para o termo quadrático do desmatamento apresentou estabilidade entre os modelos, no que tange o efeito direto, apresentando o valor $-0,0001$

em todos os modelos econométricos espaciais. Já no que concerne aos efeitos *spillovers*, somente houve significância no modelo SAR, com o coeficiente estimado em $-0,0000396$, ao passo de que nos efeitos totais somente os modelos SEM, SAR e SAC possuíram coeficientes significativos, variando entre $-0,0002$ e $-0,0001$.

Similarmente ao termo quadrático do desmatamento, o percentual de floresta em relação a área municipal teve convergência dos parâmetros no que diz respeito aos efeitos diretos ($0,3409$ a $0,4255$), mas, em relação aos efeitos indiretos, somente o modelo SAR teve o parâmetro significativo ($0,0970$). Nos efeitos totais, os modelos que apresentaram o coeficiente estatisticamente significativos foram, SEM, SAR e SAC ($0,4561$ a $0,4190$).

Os coeficientes que representam os dispêndios municipais *per capita* com saúde obtiveram estabilidade entre os modelos espaciais. No que tange ao efeito direto, os gastos com saúde em t e $t-1$ foram significativos em todos os modelos espaciais, ao passo que, os gastos com saúde em $t-2$ não foi estatisticamente significativo em todos os modelos. Desta forma, a cada cem reais gastos com saúde no período presente, aumenta a capacidade de detecção da doença, em média, de $2,14$ a $2,31$ casos de malária, no próprio município. Similarmente, a cada cem reais gastos com saúde no período $t-1$, aumenta a capacidade de detecção da doença, em média, de $1,66$ a $1,85$ casos de malária, no próprio município de origem dos dispêndios. Contrariamente aos efeitos diretos, somente no modelo SAR houveram coeficientes significativos para os dispêndios municipais com saúde, nos períodos t (0,0062) e em $t-1$ ($0,0045$), no que tange aos efeitos *spillovers*. Já em relação aos efeitos totais, os gastos com saúde no período presente foi significativo em todos os modelos espaciais estimados, tendo o coeficiente no intervalo de $0,0214$ a $0,0359$. Os dispêndios saúde defasado em um ano obteve coeficientes significativos, para os efeitos totais, somente nos modelos SEM, SAR e SAC, enquanto os dispêndios com saúde defasado em dois anos não apresentou coeficientes significativos em nenhum modelo espacial estimado.

O outro componente de gastos municipais analisado no estudo é o dispêndio *per capita* com habitação. No seu efeito direto, somente os modelos SAR e SDM apresentaram coeficientes estimados significativos. Já no que concerne ao efeito *spillover*, somente o modelo SAC não apresentou significância para o parâmetro dos dispêndios habitacionais, assim, variando, nos demais modelos, de $-0,0784$ a $-0,0026$. Por fim, os efeitos totais só foram significativos nos modelos espaciais SDEM, SAR, SDM e SLX, variando entre $-0,0866$ e $-0,0124$.

Em relação aos coeficientes estimados do efetivo de rebanho bovino no período t, houve convergência na totalidade dos modelos, no que tange aos efeitos diretos, onde o coeficiente estimado varia entre $-5,94e-05$ e $-4,90e-05$, ao passo de que o efetivo bovino em $t-1$ não possui significância em nenhum modelo espacial e, em $t-2$, somente no modelo SAR, em relação ao efeitos diretos. Já em relação ao efeito indireto, nenhum modelo apresentou coeficiente significativo para o rebanho no período t, ao passo que somente o modelo SLX apresentou significância para o efetivo bovino com uma defasagem temporal, enquanto os modelos SDEM, SAR e SLX apresentaram coeficientes significativos para o parâmetro associado a defasagem de dois ano do efetivo bovino, variando entre $-0,0002$ e $-2,70e-06$. No tocante ao efeito total, enquanto os modelos SEM, SAR e SAC apresentaram coeficientes significativos para o rebanho em t, os modelos SDEM, SAR, SDM e SLX revelaram coeficientes significativos para o número de cabeças de gado em $t-2$, frisando que o rebanho em $t-1$ não apresentou nenhum coeficiente significativo.

Ademais, os coeficientes estimados da densidade populacional, do PIB em t, $t-1$ e $t-2$, da área plantada de soja em t, $t-1$ e $t-2$ e a área plantada das demais culturas não foram, em sua maioria, estatisticamente significativos, tanto em relação ao efeito direto, quanto aos efeitos indiretos e totais. As exceções, no tocante à significância, é o efeito indireto e total da densidade populacional nos modelos SDM e SLX, o efeito direto do PIB em $t-2$ nos modelos SEM e SAC, o efeito indireto do PIB em $t-2$ nos modelos SDEM, SAR e SLX, os efeitos totais do PIB em $t-2$ nos modelos SEM, SDM, SAC e SLX[16] e o efeito indireto para as demais culturas no modelo SLX. A área plantada de soja, em todas as defasagens, não foram estatisticamente significativas em nenhum modelo espacial estimado.

Na Tabela 19, também estão apresentados o coeficiente de correlação espacial (λ) e o coeficiente espacial autorregressivo (δ). O coeficiente de correlação espacial foi significativo em todos os modelos de erro espacial (SEM, SAC e SDEM), enquanto o coeficiente espacial autorregressivo obteve significância nos modelos de lag espacial SAR e SDM, mas não significativo no modelo SAC. A não significância do coeficiente espacial autorregressivo no modelo SAC pode ser responsável pelas estimativas não significativas em todos os parâmetros de efeito indireto (ver Seção 4.3.3), limitando a análise deste modelo espacial. Ademais, o coeficiente de correlação espacial foi estimado entre $0,696$ e $0,722$, ao

[16] Apesar da significância em quatro modelos, os efeitos totais do PIB defasado duas vezes no tempo são inconclusivos, divergindo em relação ao sinal do coeficiente entre os modelos espaciais estimados.

passo que o coeficiente espacial autorregressivo foi estimado entre $0,222$ e $0,691$.

Em relação ao grau de ajustamento do dados, percebe-se um R^2 *within* elevado em todos os modelos, variando de $0,8870$ a $0,9008$, enquanto o R^2 *between* variou de $0,0548$ a $0,4091$ e o R^2 *overall* esteve no intervalo entre $0,6349$ e $0,7839$. Por fim, os valores da estatística χ^2 para os testes de Wald e LR indicaram que os modelos espaciais são preferíveis aos modelos restritos (sem os componentes espaciais), ao passo que o valor do critério AIC reforça a escolha do modelo espacial de Durbin, o modelo SDEM.

Sintetizando, ocorreu a convergência dos coeficientes estimados para diversos modelos espaciais, ante o modelo SDEM. Os coeficientes que foram significativos e, majoritariamente, convergiram com os coeficientes estimados do modelo SDEM, foram o desmatamento em t (efeito direto e total), desmatamento em $t-1$ (efeito indireto), desmatamento ao quadrado (efeito direto), percentual de floresta em relação a área municipal (efeito direto), dispêndios municipais com saúde *per capita* em t (efeito direto e total) e em $t-1$ (efeito direto), gastos municipais com habitação *per capita* (efeito indireto e total), efetivo bovino em t (efeito direto) e em $t-2$ (efeito indireto e total).

Desta forma, as estimativas dos modelos espaciais sugerem uma convergência, na sua maior parte, com os coeficientes estimados do modelo SDEM, gerando maior convicção na inferência dos parâmetros do modelo SDEM. Também evidenciou-se que os modelos apresentados possuem boa qualidade de ajustamento dos dados, além da constatação de que, no caso do estudo da incidência de malária, os modelos espaciais são preferíveis aos modelos de dados em painel convencionais, via testes de Wald e LR (além do teste LM, apresentado no tópico 5.2).

Tabela 17. Efeitos diretos dos modelos econométricos espaciais

	SEM	SDEM	SAR	SDM	SAC	SLX
$Desm$	0,1043***	0,0850***	0,1283***	0,0781***	0,102***	0,0820***
	(0,0216)	(0,0228)	(0,0185)	(0,0201)	(0,0184)	(0,0299)
$Desm_{t-1}$	-0,0051	-0,0008	0,0215	0,0010	-0,0041	-0,0046
	(0,0135)	(0,0135)	(0,0151)	(0,0148)	(0,0150)	(0,0181)
$Desm_{t-2}$	-0,0045	-0,0027	0,0154*	-0,0041	-0,0045	-0,0007
	(0,0082)	(0,0082)	(0,0076)	(0,0085)	(0,0088)	(0,0111)
$Desm^2$	-0,0001***	-0,0001***	-0,0001***	-0,0001***	-0,0001***	-0,0001***
	(1,94e-05)	(2,23e-05)	(2,29e-05)	(2,07e-05)	(1,94e-05)	(2,75e-05)
$Flor$	0,4238***	0,4093***	0,3591***	0,3861***	0,4255***	0,3403**
	(0,0918)	(0,0925)	(0,0742)	(0,0887)	(0,0887)	(0,1305)
$Denspop$	-0,0630	-0,0163	-0,0254	0,0280	-0,0483	-0,0127
	(0,0693)	(0,0700)	(0,0667)	(0,0665)	(0,0664)	(0,0930)
$Saude$	0,0214***	0,0225***	0,0230***	0,0233***	0,0218***	0,0231***
	(0,0024)	(0,0024)	(0,0020)	(0,0025)	(0,0025)	(0,0034)
$Saude_{t-1}$	0,0185***	0,0173***	0,0166***	0,0166***	0,0178***	0,0165***
	(0,0028)	(0,0028)	(0,0023)	(0,0029)	(0,0029)	(0,0039)
$Saude_{t-2}$	0,0005	0,0006	0,00100	0,0003	0,0005	0,0005
	(0,0005)	(0,0006)	(0,0007)	(0,0007)	(0,0005)	(0,0007)
Hab	0,0004	-0,0062	-0,0097***	-0,0082**	0,00012	-0,0074
	(0,0034)	(0,0040)	(0,0038)	(0,0037)	(0,0030)	(0,0046)
PIB	7,57e-07	-2,26e-07	2,49 e-07	-5,76e-08	7,03 e-07	1,02 e-06
	(1,74e-06)	(1,98e-06)	(2,16e-06)	(1,78e-06)	(1,74e-06)	(2,36e-05)
PIB_{t-1}	3,22e-07	8,02e-07	5,62e-08	4,40e-07	4,55e-07	7,24e-07
	(2,43e-06)	(2,49e-06)	(2,71e-06)	(2,46e-06)	(2,42e-06)	(3,28e-05)
PIB_{t-2}	6,43e-06**	2,82e-06	-4,58e-07	-1,53e-06	6,24e-06**	-1,05e-06
	(2,19e-06)	(2,49e-06)	(2,71e-06)	(2,23e-06)	(2,18e-06)	(2,96e-06)
$Soja$	-0,0012	0,0017	0,0063	0,0016	-0,0015	0,0017
	(0,0102)	(0,0110)	(0,0124)	(0,0122)	(0,0110)	(0,0135)
$Soja_{t-1}$	0,0010	-0,0012	0,0014	-0,0037	-0,0015	-0,0018
	(0,0122)	(0,0137)	(0,0146)	(0,0135)	(0,0122)	(0,0163)
$Soja_{t-2}$	-0,0043	-0,00113	0,0085	0,0032	-0,0016	5,50e-05
	(0,0092)	(0,0099)	(0,0090)	(0,0085)	(0,0080)	(0,0123)
$Gado$	-4,90e-05*	-5,28e-05*	-5,94e-05*	-5,70e-05*	-5,26e-05*	-5,70e-05*
	(2,19e-05)	(2,36e-05)	(2,49e-05)	(2,19e-05)	(2,18e-05)	(2,91e-05)
$Gado_{t-1}$	-4,25e-05	-3,07e-05	2,88e-06	-3,02e-05	-4,11e-05	-2,04e-05
	(2,78e-05)	(3,02e-05)	(3,21e-05)	(2,79e-05)	(2,77e-05)	(3,70e-05)
$Gado_{t-2}$	-2,11e-05	-3,12e-05	-9,99e-05***	-2,32e-05	-1,86e-05	-3,53e-05
	(2,27e-05)	(2,40e-05)	(2,46e-05)	(2,27e-05)	(2,27e-05)	(3,01e-05)
$Outcult$	0,0072	0,0067	0,0044	0,0061	0,0073	0,0042
	(0,0049)	(0,0053)	(0,0055)	(0,0051)	(0,0047)	(0,0065)

Fonte: Resultados da pesquisa. *** p < 0,01; ** p < 0,05; * p < 0,10. Erro padrão entre parênteses.

Tabela 18. Efeitos indiretos dos modelos econométricos espaciais

	SEM	SDEM	SAR	SDM	SAC	SLX
$Desm$		0,0333	0,0347***	-0,0392	-0,0014	-0,0291
		(0,0459)	(0,0054)	(0,0760)	(0,0010)	(0,0430)
$Desm_{t-1}$		0,0642*	0,0058	0,1110*	5,58e-05	0,0707*
		(0,0290)	(0,0040)	(0,0481)	(0,0003)	(0,0278)
$Desm_{t-2}$		0,0234	0,0041**	0,0196	6,94e-05	0,0101
		(0,0148)	(0,0021)	(0,0247)	(0,0001)	(0,0135)
$Desm^2$		1,50e-05	-3,96e-05***	0,0001	1,99e-06	5,96e-05
		(4,24e-05)	(5,98e-06)	(8,86e-05)	(1,42e-06)	(3,95e-05)
$Flor$		-0,3116	0,0970***	-0,4880	-0,0061	-0,0674
		(0,1881)	(0,0206)	(0,2912)	(0,0045)	(0,1761)
$Denspop$		0,1990	-0,0069	0,6601**	0,0006	0,4401**
		(0,1641)	(0,0180)	(0,2962)	(0,0013)	(0,1480)
$Saude$		0,0061	0,00623***	0,0126	-0,0003	0,0050
		(0,0049)	(0,0006)	(0,0077)	(0,0002)	(0,0043)
$Saude_{t-1}$		-0,0069	0,0045***	-0,0117	-0,0002	-0,0059
		(0,0056)	(0,0007)	(0,0075)	(0,0002)	(0,0048)
$Saude_{t-2}$		0,0008	0,0003	-0,0009	-7,15e-06	0,0009
		(0,0022)	(0,0002)	(0,0047)	(1,06e-05)	(0,0018)
Hab		-0,0316***	-0,0026***	-0,0784***	9,00e-07	-0,0459***
		(0,0106)	(0,0010)	(0,0219)	(5,51e-05)	(0,0096)
PIB		-6,40e-06	6,28e-08	-7,64e-06	-1,28e-08	-3,29e-06
		(5,59e-06)	(6,15e-07)	(1,30e-05)	(3,33e-08)	(5,48e-06)
PIB_{t-1}		-3,58e-07	1,70e-08	-5,11e-06	-7,36e-09	-6,27e-06
		(7,72e-06)	(7,95e-07)	(1,75e-05)	(4,54e-08)	(7,52e-06)
PIB_{t-2}		-1,65e-05*	-1,19e-07	-5,69e-05***	-8,53e-08	-3,92e-05***
		(6,89e-06)	(7,19e-07)	(1,57e-05)	(7,17e-08)	(6,63e-06)
$Soja$		0,0088	0,0017	0,0309	1,79e-05	0,0309
		(0,0268)	(0,0033)	(0,0501)	(0,0002)	(0,0229)
$Soja_{t-1}$		-0,0011	0,00041	-0,0037	2,11e-05	-0,0024
		(0,0340)	(0,0039)	(0,0625)	(0,0002)	(0,0289)
$Soja_{t-2}$		0,0188	0,0023	0,0472	1,96e-05	0,0377*
		(0,0232)	(0,0024)	(0,0408)	(0,0001)	(0,0198)
$Gado$		-2,55e-06	-1,61e-05**	-5,78e-05	7,66e-07	-2,49e-05
		(5,55e-05)	(7,27e-06)	(0,0001)	(6,95e-07)	(4,85e-05)
$Gado_{t-1}$		5,52e-05	7,65e-07	0,0001	5,51e-07	0,0001
		(7,23e-06)	(9,21e-06)	(0,0001)	(5,82e-07)	(6,35e-05)
$Gado_{t-2}$		-0,0001*	-2,70e-06***	-0,0002	2,78e-07	-0,0002**
		(5,41e-05)	(6,57e-06)	(9,94e-05)	(4,05e-07)	(4,69e-05)
$Outcult$		-0,0032	0,0012	-0,0133	-0,0001	-0,0220*
		(0,0128)	(0,0015)	(0,0222)	(0,0001)	(0,0112)

Fonte: Resultados da pesquisa. *** p < 0,01; ** p < 0,05; * p < 0,10. Erro padrão entre parênteses.

Tabela 19. Efeitos totais dos modelos econométricos espaciais

	SEM	SDEM	SAR	SDM	SAC	SLX
Desm	0,1040***	0,1183**	0,1630***	0,0389	0,1011***	0,0529
	(0,0216)	(0,0687)	(0,0237)	(0,0846)	(0,0183)	(0,0729)
$Desm_{t-1}$	-0,0051	0,0634	0,0273	0,1122**	-0,0041	0,0661
	(0,0135)	(0,0425)	(0,0191)	(0,0504)	(0,0148)	(0,0459)
$Desm_{t-2}$	-0,0045	0,02068	0,0195**	0,0155	-0,0044	0,0093
	(0,0082)	(0,02297)	(0,0097)	(0,0249)	(0,0087)	(0,0246)
$Desm^2$	-0,0001***	-0,0001	-0,0002***	-0,0001	-0,0001***	-0,0001
	(1,94e-05)	(6,47e-05)	(2,67e-05)	(0,0001)	(1,75e-05)	(6,70e-05)
Flor	0,4242***	0,0971	0,4561***	-0,1021	0,4190***	0,2726
	(0,0918)	(0,2805)	(0,0944)	(0,2861)	(0,0874)	(0,3060)
Denspop	-0,0630	0,1827	-0,0323	0,6881**	-0,0477	0,4273*
	(0,0693)	(0,2340)	(0,0847)	(0,3103)	(0,0654)	(0,2410)
Saude	0,0214***	0,0286***	0,0293***	0,0359***	0,0215***	0,0281***
	(0,0024)	(0,0073)	(0,0025)	(0,0079)	(0,0024)	(0,0077)
$Saude_{t-1}$	0,0185***	0,0104	0,0211***	0,0049	0,0176***	0,0105
	(0,0028)	(0,0084)	(0,0030)	(0,0077)	(0,0029)	(0,0087)
$Saude_{t-2}$	0,0005	0,0013	0,00127	-0,0006	0,0004	0,0014
	(0,0005)	(0,0028)	(0,0008)	(0,0051)	(0,0005)	(0,0025)
Hab	0,00039	-0,0378***	-0,0124***	-0,0866***	0,0001	-0,0533***
	(0,0034)	(0,0146)	(0,0048)	(0,0242)	(0,0029)	(0,0142)
PIB	7,57e-07	-6,63e-06	3,12e-07	-7,70e-06	6,90e-07	-2,27e-06
	(1,74e-06)	(7,57e-06)	(2,89e-06)	(1,48e-05)	(1,78e-06)	(7,84e-06)
PIB_{t-1}	3,22e-07	4,44e-07	7,32e-08	-4,67e-06	4,48e-06	-5,55e-06
	(2,43e-06)	-1.04E-03	(3,75e-06)	(1,94e-05)	(2,34e-05)	(1,08e-05)
PIB_{t-2}	6,43e-06***	-1.37E-03	-5,77e-07	-5,58e-05**	6,15e-06***	-4,02e-05***
	(2,19e-06)	(9,38e-06)	(3,39e-06)	(1,72e-05)	(2,13e-06)	9,59e-06
Soja	-0,0012	0,0105	0,0080	0,0325	-0,0015	0,0326
	(0,0102)	(0,0378)	(0,0158)	(0,0569)	(0,0108)	(0,0364)
$Soja_{t-1}$	0,0010	-0,0023	0,0019	-0,0073	-0,0014	-0,0042
	(0,0122)	(0,0477)	(0,0186)	(0,0693)	(0,0120)	(0,0452)
$Soja_{t-2}$	-0,00431	0,0177	0,0107	0,0504	-0,0016	0,0377
	(0,0092)	(0,0331)	(0,0114)	(0,0443)	(0,0079)	(0,0321)
Gado	-4,90e-05*	-7,83e-05	-7,55e-05*	-0,0001	-5,18e-05*	-8,19e-05
	(2,19e-05)	(7,91e-05)	(3,42e-05)	(0,0001)	(2,28e-05)	(7,76e-05)
$Gado_{t-1}$	-4,25e-05	2,45e-05	3,65e-05	7,83e-5	-4,06e-05	8,96e-05
	(2,78e-05)	(0,0001)	(4,30e-05)	(0,0002)	(2,84e-05)	(0,0001)
$Gado_{t-2}$	-2,11e-05	-0,0001***	-0,0001***	-0,0002	-1,84e-05	-0,0002***
	(2,27e-05)	(7,81e-05)	(3,03e-05)	(0,0001)	(2,13e-05)	(7,70e-05)
Outcult	0,0072	0,0034	0,0056	-0,0072	0,0072	-0,0178
	(0,0049)	(0,0181)	(0,0071)	(0,0245)	(0,0046)	(0,0177)
λ	0,715***	0,692***			0,722***	
	(0,0102)	(0,0108)			(0,0114)	
δ			0,220***	0,686***	-0,0140	
			(0,00794)	(0,0107)	(0,0106)	
R^2 *within*	0,8948	0,9006	0,8891	0,9034	0,8948	0,9021
R^2 *between*	0,3758	0,1822	0,3730	0,0397	0,3744	0,0809
R^2 *overall*	0,7763	0,7195	0,7707	0,6152	0,7759	0,6438
Wald	4920,31	4143,56	771,11	4134,04	5061,16	
LR	2869,29	2984,95	765,59	3033,88	2871,01	443,19
AIC	74220,3	74144,6	76446,0	74215,7	74340,6	76684,4

Fonte: Resultados da pesquisa. *** p < 0,01; ** p < 0,05; * p < 0,10. Erro padrão entre parênteses.

5.4.3. Modelos econométricos espaciais sem *lag*

De acordo com a Seção 4.4, propõe-se também a estimação de um modelo (equação 51) sem a defasagem temporal no desmatamento, gastos com saúde, PIB, área plantada de soja e efetivo bovino. Embora, a partir dos testes LR (seção 5.2, Tabela 7), os modelos espaciais com a defasagem se mostraram mais adequados ao problema estudado, apresenta-se nesta seção, a fim de checar as estimativas dos parâmetros, os modelos espaciais sem o *lag* em determinadas variáveis dependentes. De acordo com as Tabelas 20 e 21, houveram concordâncias entre os modelos com a defasagem e sem a defasagem. Todas as variáveis significativas nos modelos espaciais com *lag* (Tabelas 17, 18 e 19), também se mostraram significativas nos modelos sem a defasagem.

Em ambas especificações, o desmatamento foi significativo nos modelos espaciais, no que se refere ao efeito direto. Para a especificação sem *lag*, houveram evidências de efeitos *spillovers* para o desmatamento, o que só aconteceu no desmatamento em $t-1$ na especificação com a defasagem. Desta forma, levando em consideração todas as defasagens da especificação com *lag*, existem evidências de efeitos direto, indireto e total para o desmatamento.

Os gastos municipais com saúde *per capita*, assim como a área desmatada, convergiu entre as especificações. Em relação à especificação sem as defasagens, existe uma superestimação dos gastos com saúde em relação à especificação apresentada na seção anterior, sendo que, a explicação provável para esta anomalia, é a contabilização do efeito no ano anterior (significativo no modelo com *lags*) não incluído na especificação. A exemplo da seção anterior, também evidencia-se efeitos totais para os dispêndios com saúde.

O Produto Interno Bruto também apresenta-se de forma inconclusiva na especificação sem a defasagem temporal. Os valores deste coeficiente estimado variam entre valores positivos e negativos, em ambas as especificações, nos efeitos diretos e totais, indicando instabilidade dos coeficientes estimados para variável. Somente no que tange o efeito indireto, o PIB se mostrou estável, com valores negativos. Desta forma, o Produto Interno Bruto revelou-se inconclusivo em ambas especificações.

A exemplo da área desmatada e dos gastos com saúde, os parâmetros da área plantada de soja e do efetivo bovino também convergiram entre as especificações. Enquanto a área plantada de soja, nas duas especificações e em todos os efeitos, não teve parâmetros significativos, o efetivo bovino teve efeitos diretos, indiretos e totais significativos em ambas

as especificações.

A diferença entre as duas especificações, no que tange as variáveis defasadas na especificação com *lag* (Desm, Saude, PIB, Soja e Gado), está apenas no período em que ocorre o impacto. Por questões de limitações, a especificação sem o *lag* indica as variáveis que possuem impacto sobre o paludismo, enquanto a especificação com a defasagem temporal desagrega tais impactos por período temporal.

As demais variáveis (que não sofreram defasagens na especificação com *lag*) também convergiram entre as duas especificações. Enquanto o termo quadrático do desmatamento se mostrou significante (efeitos direto e total), majoritariamente entre os modelos, o percentual de área florestal em relação a área municipal também se mostrou significante (efeitos diretos) nos modelos espaciais sem *lag*, convergindo com a especificação com defasagens. Ademais, os dispêndios municipais *per capita* com habitação, a densidade populacional e a área das demais culturas também convergiram com tais parâmetros da especificação com *lag*.

Desta forma, como não ocorre discrepâncias entre as especificações, no que tange as variáveis em nível (em t), a especificação com *lags* torna-se mais atraente. A grande vantagem da especificação que incorpora variáveis com lag, além da possibilidade de controlar a endogeneidade oriunda da simultaneidade, é o maior detalhe sobre os impactos das variáveis dependentes, podendo observar a relação destas sobre os casos de paludismo durante o tempo.

Tabela 20. Efeitos diretos e indiretos para os modelos econométricos espaciais sem *lag*

	SEM	SDEM		SAR		SDM		SAC		SLX	
	ED	ED	EI	ED	EI	ED	EI	ED	EI	ED	EI
Desm	0,1081***	0,0929***	0,0818*	0,1610***	0,0439***	0,0867***	0,0613	0,1061***	-0,0015	0,0874***	0,0395
	(0,0211)	(0,0222)	(0,0427)	(0,0172)	(0,0050)	(0,0188)	(0,0664)	(0,0179)	(0,0011)	(0,0293)	(0,0384)
$Desm^2$	-0,0001***	-0,0001***	2,24e-05	-0,0001***	-3,90e-05***	-0,0001***	9,93e-05	-0,0001***	1,92e-06	-0,0001***	5,83e-05
	(1,94e-05)	(2,23e-05)	(4,20e-05)	(2,32e-05)	(6,43e-06)	(2,25e-05)	(8,33e-05)	(1,94e-05)	(1,37e-06)	(2,75e-05)	(3,86e-05)
Flor	0,4252***	0,4181***	-0,2721	0,3841***	0,1051***	0,3880***	-0,4163	0,4232***	-0,00592	0,3431***	-0,0440
	(0,0922)	(0,0930)	(0,1890)	(0,0798)	(0,0222)	(0,0960)	(0,2742)	(0,0951)	(0,00423)	(0,132)	(0,1785)
Denspop	-0,0504	-0,0058	0,1831	-0,0409	-0,0112	0,0287	0,5990**	-0,0460	0,0006	0,0039	0,3881***
	(0,0696)	(0,0704)	(0,1650)	(0,0759)	(0,0208)	(0,0738)	(0,3052)	(0,0750)	(0,0013)	(0,0938)	(0,1490)
Saude	0,0375***	0,0377***	0,0010**	0,0382***	0,0104***	0,0377***	0,0017*	0,0374***	-0,0005	0,0377***	0,0009**
	(0,0001)	(0,0001)	(0,0004)	(0,0001)	(0,0005)	(0,0001)	(0,0009)	(0,0001)	(0,0003)	(0,0002)	(0,0004)
Hab	-0,0019	-0,0095**	-0,0385***	-0,0177***	-0,0048***	-0,0097***	-0,0831***	-0,0012	2,03e-05	-0,0121***	-0,0623***
	(0,0034)	(0,0039)	(0,0103)	(0,0040)	(0,0011)	(0,0037)	(0,0175)	(0,0033)	(5,72e-05)	(0,0046)	(0,0087)
PIB	5,13e-06***	2,04e-05*	-1,85e-05***	-1,92e-07	-5,05e-08	-1,03e-07	-5,50e-05***	5,31e-06***	-7,34e-08	5,55e-07	-3,76e-05***
	(9,11e-07)	(1,04e-05)	(2,86e-06)	(1,14e-06)	(3,16e-07)	(1,14e-06)	(6,83e-06)	(9,13e-07)	(5,19e-08)	(1,24e-06)	(2,75e-06)
Soja	-0,0026	-2,01e-05	0,0215	0,0109	0,0029	0,0021	0,0650*	-0,0027	3,38e-05	0,0005	0,0520***
	(0,0074)	(0,0077)	(0,0184)	(0,0085)	(0,0023)	(0,0079)	(0,0350)	(0,0077)	(0,0001)	(0,0097)	(0,0160)
Gado	-8,20e-05***	-9,01e-05***	-8,05e-05**	-0,0001***	-3,22e-05***	-8,80e-05***	-0,0001*	-8,18e-05***	1,12e-06	-9,20e-05***	-6,73e-05**
	(1,60e-05)	(1,68e-05)	(3,86e-05)	(1,88e-05)	(5,32e-06)	(1,71e-05)	(6,64e-05)	(1,72e-06)	(8,41e-07)	(2,13e-05)	(3,31e-05)
Outcult	0,0062	0,0061	-0,0024	0,0037	0,0010	0,0053	-0,0084	0,0057	-7,87e-05	0,0047	-0,0157
	(0,0048)	(0,0052)	(0,0127)	(0,0052)	(0,0014)	(0,0049)	(0,0242)	(0,0045)	(9,71e-05)	(0,0065)	(0,0110)

Fonte: Resultados da pesquisa. *** p < 0,01; ** p < 0,05; * p < 0,10. Erro padrão entre parênteses.

Tabela 21. Efeitos totais para o modelo econométrico espacial sem *lag*

	SEM	SDEM	SAR	SDM	SAC	SLX
Desm	0,1081***	0,1747***	0,205***	0,148**	0,104***	0,1269***
	(0,0211)	(0,0649)	(0,0219)	(0,0719)	(0,0177)	(0,0677)
$Desm^2$	-0,0001***	-9,06e-05	-0,0002***	-4,53e-06	-0,0001***	-5,57e-05
	(1,94e-05)	(6,43e-05)	(2,94e-05)	(9,53e-05)	(1,91e-05)	(6,61e-05)
Flor	0,4252***	0,1462	0,489***	-0,0271	0,4177***	0,2992
	(0,0922)	(0,2822)	(0,102)	(0,269)	(0,0937)	(0,3101)
Denspop	-0,0504	0,1772	-0,0521	0,6270**	-0,0454	0,3919
	(0,0696)	(0,2354)	(0,0968)	(0,3161)	(0,0741)	(0,2428)
Saude	0,0375***	0,0387***	0,0486***	0,0395***	0,0369***	0,0387***
	(0,0001)	(0,0006)	(0,0005)	(0,0010)	(0,0004)	(0,0006)
Hab	-0,0019	-0,0479***	-0,0226***	-0,0928***	-0,0012	-0,0744***
	(0,0034)	(0,0142)	(0,0051)	(0,0195)	(0,0033)	(0,0132)
PIB	5,13e-06***	-1,65e-05	-2,42e-07	-5,51e-05***	5,24e-06***	-3,71e-05***
	(9,11e-07)	(3,90e-06)	(1,46e-06)	(7,57e-06)	(9,05e-07)	(3,99e-06)
Soja	-0,0026	0,0215	0,0138	0,0671*	-0,00269	0,0525***
	(0,0074)	(0,0261)	(0,0109)	(0,0377)	(0,0076)	(0,0258)
Gado	-8,20e-05***	-0,0002***	-0,0001***	-0,0002***	-8,07e-05***	-0,0002***
	(1,60e-05)	(5,54e-05)	(2,39e-05)	(7,10e-05)	(1,70e-05)	(5,44e-05)
Outcult	0,0062	0,0037	0,0048	-0,0030	0,0056	-0,0110
	(0,0048)	(0,0179)	(0,0066)	(0,0268)	(0,0044)	(0,0175)
λ	0,714***	0,696***			0,722***	
	(0,0102)	(0,0106)			(0,0113)	
δ			0,222***	0,691***	-0,0151	
			(0,0079)	(0,0105)	(0,0106)	
R2 within	0,8939	0,8987	0,8870	0,9008	0,8938	0,8998
R^2 *between*	0,4091	0,2098	0,4078	0,0548	0,4078	0,1088
R^2 *overall*	0,7839	0,7308	0,7782	0,6349	0,7836	0,6706
Wald	4941,23	4296,48	774,01	4300,15	5090,10	
LR	2870,19	2963,27	726,03	3004,42	2872,21	333,84
AIC	74268,8	74195,7	76472,9	74214,6	74328,8	76823,1

Fonte: Resultados da pesquisa. *** p < 0,01; ** p < 0,05; * p < 0,10. Erro padrão entre parênteses.

5.4.4. Checagem de robustez para o desmatamento

O último procedimento adotado para verificar a robustez das estimativas é verificar a variação dos impactos das variáveis de interesse (no caso o dematamento e o desmatamento ao quadrado, no que tange os efeitos diretos) conforme são inseridos os variados controles na equação. Além da estimação com diferentes controles, este estudo também realizou a estimação dos modelos espaciais com diferentes matrizes de pesos, como a matriz queen, distância inversa total, cinco vizinhos mais próximos e distância inversa com raio de 300Km.

Conforme a Tabela 22, a área desmatada e seu termo quadrático revelaram coeficientes estimados estáveis em diversas especificações estimadas. O desmatamento variou de $0,0601$ a $0,1479$, ou seja, a cada cem quilômetros quadrados desmatados, aumenta, em média, de $6,01$ a $14,79$ casos de malária a cada mil habitantes. O termo quadrático do desmatamento também revelou-se bastante estável, variando de $-0,0002$ a $-0,0001$.

Na primeira especificação, estima-se somente os casos de malária levando em conta o desmatamento, sem qualquer controle ou componente espacial, evidenciando um parâmetro de $0,1479$ para a área desmatada. Na segunda especificação, insere-se, ante a primeira, o termo quadrático do desmatamento e o componente de erro espacial, assim, estimando um parâmetro de $0,1189$ para o desmatamento e $-0,0002$ para o termo quadrático. Quando insere-se as variáveis econômicas e agrícolas (terceira e quarta especificações), os parâmetros do desmatamento apresentam os valores $0,1332$ e $0,1080$.

O lag no desmatamento é inserido na quinta especificação, revelando um coeficiente $0,1081$ para a área desmatada, sendo esta especificação, o modelo SEM, apresentado na seção 5.4.2. Já os efeitos *spillovers* são inseridos na sexta especificação, sendo esta, equivalente ao modelo SDEM apresentado nos resultados (seção 5.3), onde, desta forma, o coeficiente do desmatamento apresenta o valor $0,0850$. Na sétima especificação, utiliza-se o controle temporal, aplicando *dummies* de tempo, apresentando valor $0,0809$ para o desmatamento.

Cabe ressaltar que, da especificação dois a sete, utiliza-se a matriz *queen*, indicada na seção 5.2. Na especificação 8, utiliza-se a matriz de cinco vizinhos mais próximos, evidenciando um parâmetro com o valor $0,0601$. Nas últimas especificações, 9 e 10, utiliza-se matrizes do tipo distância inversa, sendo a especificação 9 com uma matriz de distância inversa total e a na especificação 10 uma matriz de distância inversa com raio de

300Km. Nas especificações 9 e 10, os coeficientes estimados para o desmatamento foram $0,0719$ e $0,0769$. No que tange o termo quadrático da área desmatada, nas especificações 3, 4, 5, 6, 7, 8, 9 e 10, o coeficiente estimado foi o mesmo, com valor de $-0,0001$.

Ademais, infere-se que, apesar do valor do coeficiente estimado do desmatamento diminua a cada introdução de controles, este se apresenta estável, indicando a convergência para o parâmetro populacional. Ressalta-se também a grande estabilidade do coeficiente estimado do termo quadrático, que se apresentou com o mesmo valor em oito especificações. Desta forma, esta seção agrega mais confiabilidade à inferência da variável de interesse.

Tabela 22. Checagem de robustez para a área desmatada

	1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**
$Desm$	0,1479***	0,1189***	0,1332***	0,1080***	0,1081***	0,0850***	0,0809***	0,0601***	0,0719***	0,0769***
	(0,0261)	(0,0642)	(0,0206)	(0,0211)	(0,0215)	(0,0228)	(0,0228)	(0,0243)	(0,0257)	(0,0235)
$Desm^2$	Não	-0,0002***	-0,0001***	-0,0001***	-0,0001***	-0,0001***	-0,0001***	-0,0001***	-0,0001***	-0,0001***
		(7,37e-05)	(1,91e-05)	(1,94e-05)	(1,94e-05)	(2,23e-05)	(2,24e-05)	(2,26e-05)	(2,39e-05)	(2,24e-05)
Erro Espacial	Não	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Var. Econômicas	Não	Não	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Var. Agropecuárias	Não	Não	Não	Sim	Sim	Sim	Sim	Sim	Sim	Sim
Lag desmatamento	Não	Não	Não	Não	Sim	Sim	Sim	Sim	Sim	Sim
Efeito Spillover	Não	Não	Não	Não	Não	Sim	Sim	Sim	Sim	Sim
Controle tempo	Não	Não	Não	Não	Não	Não	Sim	Sim	Sim	Sim
Matriz Queen		X	X	X	X	X	X			
Matriz Knn(5)								X		
Matriz Dist_inv									X	
Matriz 300km										X

Fonte: Resultados da pesquisa. *** p < 0,01; ** p < 0,05; * p < 0,10. Erro padrão entre parênteses.

5.5. Diretrizes de Políticas Públicas

O estudo intentou contribuir para a melhor compreensão das externalidades de atividades econômicas sobre a incidência de malária. Para isso, foram estimados uma série de modelos econométricos de dados em painel, visando a obtenção de impactos das covariadas sobre os casos de paludismo. Após a estimação e checagem de tais impactos, surge a necessidade de direcionamentos de políticas que visam a erradicação da doença, com base nos resultados encontrados no estudo.

De acordo com o World Health Organization (WHO), entre 2003 e 2012, o Brasil reportou, em média, aproximadamente 72 milhões de dólares dispendidos com a malária[17], que representa um custo[18] aproximado médio de US$ 144,00 por pessoa infectada no país. Além do custo direto para o combate e tratamento da malária, o país pode sofrer custos indiretos da doença como, a diminuição do crescimento econômico, quedas de produtividade e escolaridade da população, impactos no comércio, migração para áreas não endêmicas, menor atividade turística e diminuição do investimento direto estrangeiro (SACHS; MALANEY, 2002; CUTLER et al., 2010; LUCAS, 2010). Desta forma, os esforços para a erradicação da malária podem ser importantes no sentido de promoção do desenvolvimento regional, visto a diminuição dos gastos públicos em saúde e o maior crescimento econômico, da produtividade e da escolaridade nos locais endêmicos.

Considerando os modelos estimados nas seções 5.4.1 e 5.4.2 (modelos *pooled*, efeito aleatório, efeito fixo, SEM efeito fixo, SDEM efeito fixo, SAR efeito fixo, SDM efeito fixo, SAC efeito fixo e SLX efeito fixo), foram encontradas relações entre desmatamento, percentual de floresta em relação a área municipal, dispêndios municipais *per capita* com saúde e habitação e efetivo bovino com os casos de malária a cada mil habitantes. Desta forma, o estudo contribui para as políticas públicas de saúde, indicando as atividades econômicas que podem afetar a dinâmica por infecção de malária.

Os resultados estimados não encontraram relações entra a densidade populacional, área plantada de soja e área plantada de demais culturas com os casos de paludismo. Já o Produto Interno Bruto gerou estimativas inconclusivas, de modo que as estimações entre os diferentes modelos não convergiram entre si, impossibilitando qualquer conclusão e direcionamentos políticos sobre o efeito PIB nos casos da doença.

[17]Estes gastos com a doença não são discriminados, dificultando uma análise de custo-benefício de erradicação da doença no país.

[18]Este custo inclui desde a prevenção até o tratamento da doença.

Foram encontradas evidências de que o desflorestamento de cem Km^2, nos municípios situados na região da Amazônia legal, possui um efeito direto de um aumento, em média, de $7,81$ a $12,83$ casos de paludismo a cada mil habitantes. Além do efeito direto, foram encontrados efeitos *spillovers* do desmatamento defasado em um ano nos municípios vizinhos. Desta forma, segundo as estimativas realizadas, a cada aumento de cem quilômetros quadrados no desmatamento em um município em $t-1$, aumenta, em média, de $6,42$ a $11,1$ casos de malária a cada mil habitantes, nos municípios contíguos.

O estudo também revelou que a relação entre desmatamento e malária não é linear, visto que altos índices de derrubada da mata podem incorrer em extrema degradação, assim, aumentando a distância entre população e "franjas florestais". Assim, estimou-se que um desmatamento acima de 425 Km^2 contribui para a diminuição dos casos de paludismo, possivelmente via degradação da floresta, que, por motivos ecológicos e climáticos, não se revela a melhor forma de reduzir os casos da doença.

Desta forma, o estudo gerou evidências de que o desmatamento possui a capacidade de influenciar a quantidade de pacientes infectados por malária, não só no próprio município onde ocorreu a derrubada da mata, mas também nos municípios contíguos. Esta constatação orienta as políticas públicas no sentido de que o combate ao desmatamento pode ser crucial nos esforços de erradicação do paludismo e, também, expõe a necessidade de uma ação conjunta entre os municípios para o combate à doença, visto a presença de efeitos *spillovers*. Assim, programas que visam a contenção da mata desmatada, como o PPCDAm, possuem o poder de também se tornarem instrumentos de políticas públicas de saúde para a erradicação do paludismo.

Ademais, os resultados estimados revelaram mais um efeito de externalidades da prática do desmatamento, que além da geração de gases de efeito estufa e perda de biodiversidade, pode também afetar a população na propagação da malária, que por sua vez, pode ser um entrave ao crescimento e desenvolvimento econômico na áreas endêmicas (SACHS; MALANEY, 2002; MALHI et al., 2008; JUNIOR; MATION; SAKOWSKI, 2015). Assim, este estudo também contribui para a quantificação das externalidades do desmatamento.

Outra contribuição deste estudo na formulação de políticas públicas de saúde é a constatação de que quanto maior os dispêndios municipais *per capita* com saúde, maior a estatística da doença no município. Este resultado pode expor que o aumento dos gastos

com saúde contribuem para a melhor detecção da doença nos municípios, sendo de suma importância no mapeamento e apoio aos pacientes infectados. Por outro lado, estes resultados indicam a ineficiência dos gastos com saúde na prevenção da doença, evidenciando que o destino de tais dispêndios são, em sua maioria, para o tratamento e não para a prevenção da doença. Assim, recomenda-se o aumento do aporte financeiro para a saúde, além de uma maior eficiência destes gastos para a prevenção da malária.

Os gastos municipais *per capita* com habitação também se mostraram efetivos no combate da epidemia por paludismo. Os dispêndios com habitação podem ser importantes no sentido de diminuir o contato dos moradores da região de risco com o mosquito transmissor. As condições de moradia, tanto em relação à infraestrutura, quanto em relação à localização, podem ser um ponto crucial no combate à infecção por malária, além da distribuição e instalação de mosquiteiros tratados com inseticida (SINGER; CASTRO, 2001; COHEN; DUPAS, 2010). Desta forma, também recomenda-se o investimento em moradias nas regiões endêmicas, com o intuito de reduzir os casos de paludismo.

Os resultados também contribuíram no sentido de revelar que os municípios que possuem maiores casos da doença na Amazônia Legal, são municípios que possuem um alto percentual de floresta em sua área. Estes resultados contribuem para a formulação das políticas no mapeamento de áreas onde a epidemia tem maiores probabilidades de ocorrer.

Embora o estudo revela uma relação negativa entre o efetivo bovino e os casos da infecção, não fica claro como esta relação é estabelecida. Entre os possíveis mecanismos de transmissão candidatos a explicar tal relação são, a *Zooprophylaxis* e a excessiva degradação ambiental causada pela introdução de rebanhos em áreas desmatadas. Desta forma, estes resultados precisam ser melhores avaliados (como a estimação da relação de áreas florestais convertidas em pastagens com o paludismo) para que ocorra a indicação de políticas públicas.

6. CONCLUSÃO

O objetivo deste estudo foi buscar evidências de como o paludismo possui relações com diversas atividades econômicas, que por sua vez possuem a capacidade de alterar o meio ambiente, podendo gerar condições propícias ou hostis à proliferação do vetor transmissor da malária. Especificamente, foi estimada a relação dos casos de paludismo com o desmatamento, crescimento econômico, desenvolvimento agrícola e gastos públicos municipais. O artigo também contribui para a literatura ao realizar uma análise econométrica-espacial, viabilizando a apreciação de efeitos *spillovers* municipais das variáveis em estudo sobre a incidência de malária.

Precedentemente à estimação econométrica, o estudo realizou uma análise exploratória dos dados espacias. Os casos de paludismo na Amazônia Brasileira possui indícios, por meio das estatísticas I de Moran e c de Geary, que de não são distribuídos aleatoriamente entre os municípios, ou seja, os casos da doença possuem correlações espaciais globais entre os municípios. Também constatou-se que altos índices parasitários anuais de malária estão rodeados de outros municípios que também apresentam alta incidência de paludismo, por meio da estatística I de Moran local.

Foram encontrados indícios de que o desmatamento da floresta amazônica contribui para a propagação dos casos de malária. Estima-se que a cada 100 Km^2 de mata nativa desmatada, em t, aumentam-se, em média, $7,81$ a $12,83$ internações por paludismo a cada mil habitantes, no próprio município onde ocorreu o desmatamento. O desmatamento localizado em certo município em $t-1$ também possui influência sobre os casos de paludismo nos municípios vizinhos, em t, sendo que, cem Km^2 de desmatamento, em $t-1$, geram um efeito *spillover* de incremento da doença na ordem de $6,42$ a $11,1$ casos a cada mil habitantes, em t. Assim, o efeito total de cem Km^2 de desmatamento aumenta de $10,4$ a $16,3$ casos de infecção por malária, a cada mil habitantes. Deste modo, este artigo expõe que a prática do desmatamento causa externalidades além da perda de biodiversidade e emissões de gases de efeito estufa, afetando também a população no que tange a epidemia de malária.

O estudo também corrobora com a literatura no que se refere à linearidade da área desmatada com os casos de paludismo. Nos modelos estimados, existiram evidências de que, a partir de 425 Km^2 de mata derrubada no município, ocorre uma inflexão do impacto

sobre os casos de malária, passando a afetar negativamente os casos da doença. Deste modo, encontra-se indícios de que extrema degradação ambiental pode alterar bruscamente a composição do bioma regional, extinguindo até mesmo os casos de paludismo.

A estimação do percentual de floresta na área municipal corrobora com a não linearidade do desmatamento. Constatou-se, a partir do percentual de floresta no município, que municípios que possuem mais floresta em sua área estão mais propensos a sofrerem surtos da doença. Deste modo, quando existe a prática de massivo desmatamento, esta composição é alterada, podendo diminuir os casos da doença.

No tocante sobre os gastos municipais, foram evidenciados efeitos diretos para os dispêndios *per capita* com saúde em t e $t-1$, com a capacidade de aumentar a detecção da doença, assim, tendo uma associação positiva com os casos da infecção. Os gastos *per capita* com habitação tiveram um relação negativa com os casos de paludismo, no que se refere aos efeitos transbordamento e total.

Tendo em vista o desenvolvimento agropecuário, os resultados estimados indicaram que o efetivo total de bovinos possui relação negativa com a malária, enquanto as demais culturas e a área plantada de soja não possuíram efeitos sobre os casos de malária. A justificativa dos efeitos negativos da atividade pecuária pode ser reflexo da *Zooprophylaxis*, em que ocorre o desvio de insetos patogênicos de humanos para animais (SAUL, 2003). Também, a criação de gado pode levar a ocorrência de *paddies paradox*, onde um aumento da quantidade de vetores não necessariamente aumenta os casos de malária, em que aumento da renda proveniente da pecuária pode elevar a capacidade de proteção contra o vetor (ASENSO-OKYERE et al., 2009). Uma explicação alternativa para a relação negativa desta atividade está na capacidade de transformação do meio ambiente, promovido pelas pastagens, sendo capaz de aumentar a distância entre floresta e população.

Deste modo, este estudo contribui para a formulação de políticas públicas de saúde no combate ao paludismo, indicando como diversas atividades econômicas afetam a dinâmica de infecção por malária. Este trabalho também colabora com a literatura no sentido de mostrar a importância de se realizar estimativas espaciais a cerca da incidência de malária, evidenciando que estimativas que não levam em conta os efeitos *spillovers* podem subestimar os efeitos das atividades, como o desmatamento, na incidência da doença. A importância de contabilizar os efeitos transbordamentos ocorre devido à capacidade de migração do vetor, que chega a se movimentar em até 7km a cada nove dias (CHARLWOOD,

1989). Assim, conclui-se que a estimação espacial é de suma importância para o fenômeno em estudo.

Ademais, este trabalho deixa uma lacuna no destino do uso da terra desmatada, como a substituição de terras nativas para terras agrícolas possui influência sobre os casos da doença, como por exemplo, a verificação da conversão de florestas em pastagens. Deste modo, indica-se, para trabalhos futuros, a associação entre os casos de paludismo e os diferentes destinos da área desmatada.

REFERÊNCIAS

ACEMOGLU, Daron; JOHNSON, Simon. Disease and development: The effect of life expectancy on economic growth. **Journal of Political Economy**, v. 116, n. 6, p. 925–985, 2007.

ACHCAR, Jorge Alberto; MARTINEZ, Edson Zangiacomi; SOUZA, Aparecida Doniseti Pires de; TACHIBANA, Vilma Mayumi; ; FLORES, Edilson Ferreira. Use of poisson spatiotemporal regression models for the Brazilian Amazon forest: malaria count data. **Revista da Sociedade Brasileira de Medicina Tropical**, v. 44, n. 6, p. 749 - 754, 2011.

ALMEIDA, Eduardo Simões. **Econometria Espacial Aplicada**. Campinas,SP: Editora Alínea. Campinas, SP, 2012.

AMERASINGHE, FP; ARIYASENA, TG. Larval survey of surface water-breeding mosquitoes during irrigation development in the Mahaweli project, Sri Lanka. **Journal of Medical Entomology**, v. 27, n. 5, p. 789 - 802, 1990.

ANSELIN, Luc. Local indicators of spatial association - lisa. **Geographical Analisys**, v. 27, n. 2, p. 93–115, 1995.

ANSELIN, L. **Spatial Econometrics: Methods and Models**. [S.l.]: Springer Netherlands, 2013.

ASENSO-OKYERE, Kwadwo; ASANTE, Felix A.; TAREKEGN, Jifar; ADAM, Kwaw S. The linkages between agriculture and malaria. **International Food Policy Research Institue**, 2009. Discussion Paper 00861. Disponível em: <http://ebrary.ifpri.org/cdm/ref/collection/p15738coll2/id/29795>.

ASSUNÇÃO, Juliano; GANDOU, Clarissa C.; ROCHA, Rudi. Deforestation slowdown in the legal amazon: Prices or policies? **Climate Policy Initiative**, 2012. Disponível em: <http://climatepolicyinitiative.org/wp-content/uploads/2012/03/Deforestation-Prices-or-Policies-Working-Paper.pdf>.

BACCINI, Leonardo; URPERLAINEN, Johanes. International institutions and domestic politics: Can preferential trading agreements help leaders promote economic reform? **Journal of Politics**, v. 76, n. 1, p. 195 – 214, 2014.

BARLOW, Robin. The economic effects of malaria erradication. **American Economic Review**, v. 57, n. 2, p. 130 - 148, 1967. Disponível em: <http://www.jstor.org/stable/1821615>.

BAUCH, Simone C.; BIRKENBACH, Anna M.; PATTANAYAK, Subhrendu K.; SILLS, Erin O. Public health impacts of ecosystem change in the Brazilian Amazon. **Proceedings of the National Academy of the United States of America (PNAS)**, v. 112, n. 24, p. 7414 - 7419, 2014.

BLOOM, David E.;; SACHS, Jeffrey D. Geography, demography, and economic growth in Africa. **Brookings Papers on Economic Activity**, v. 2, p. 207 - 295, 1998.

BØDKER, R; AKIDA, J; D, Shayo; W, Kisinza; HA, Msangeni; EM, Pedersen; SW, Lindsay. Relationship between altitude and intensity of malaria transmission in the Usambara Mountains, Tanzania. **Journal of Medical Entomology**, v. 40, n. 5, p. 706–717, 2003.

BOSELLO, Francesco; ROSON, Roberto; TOL, Richard S.J. Economic-wide estimates of the implications of climate change: Human health. **Ecological Economics**, v. 58, n. 3, p. 579–591, 2006.

CASTILLA, Rogelio E. Fernandez; SAWYER, Diana Oya. Malaria rates and fate: a socioeconomic study of malaria in Brazil. **Social Science & Medicine**, v. 37, n. 9, p. 1137 - 1145, 1993.

CHARLWOOD, Jacques D.and W. A. Alecrim. Capture-recapture studies with the South American malaria vector Anopheles darlingi, root. **Annals of tropical Medicine and Parasitology**, v. 86, n. 6, p. 569–576., 1989.

COHEN, Jessica; DUPAS, Pascaline. Free distribution or cost-sharing? evidence from a randomized malaria prevention experiment. **Quarterly Journal of Economics**, v. 125, n. 1, p. 1–45, 2010.

CUTLER, David; FUNG, Winnie; KREMER, Michael; SINGHAL, Monica; VOGL, Tom. Early-life malaria exposure and adult outcomes: Evidence from malaria eradication in India. **American Economic Journal: Applied Economics**, v. 2, n. 2, p. 72–94, 2010.

DATASUS. Indicadores e dados básicos. **IDB**, 2012. Disponível em: <http://tabnet.datasus.gov.br/cgi/idb2012/matriz.htm>.

DUFFY, Patrick E.; DESOWITZ, Robert S. Pregnancy malaria throughout history: Dangerous labors. In: _____. [S.l.]: Harwood Academic Pub, 2001. cap. Malaria in Pregnancy: Deadly Parasite, Susceptible Host, p. 1–27.

ELHORST, J.Paul. Specification and estimation of spatial panel data models. **International Regional Science Review**, v. 26, n. 3, p. 224–268, 2003.

ELHORST, J Paul. **Spatial Econometrics**. [S.l.]: Springer, 2013. ISBN 3642403395.

FARIA, Weslem Rodrigues; ALMEIDA, Alexandre Nunes. Relationship between openness to trade and deforestation: Empirical evidence from the Brazilian Amazon. **Ecological Economics**, v. 121, p. 85–97, 2015.

GARG, Teevrat. Public health effects of natural resource degradation: evidence from deforestation in Indonesia. **Agricultural and Applied Economics Association, Annual Meeting, July 27-29, 2014, Minneapolis, Minnesota**, 2014.

GETIS, Arthur; ALDSTADT, Jared. Constructing the spatial weights matrix using a local statistic. **Geographical Analysis**, Wiley-Blackwell, v. 36, n. 2, p. 90–104, jul 2004.

GREENE, William H. **Econometric Analysis**. [S.l.]: ADDISON WESLEY PUB CO INC, 2012. ISBN 0131395386.

HAHN, M. B.; R.E., Gangnon; C., Barcellos; G.P., Asner; J.A., Patz. Influence of deforestation, logging, and fire on malaria in the Brazilian Amazon. **PLoS ONE**, v. 9, n. 1, 2014.

JUNIOR, Nilo Luiz Saccaro; MATION, Lucas Ferreira; SAKOWSKI, Patrícia Alessandra Morita. Impacto do desmatamento sobre a incidência de doenças na Amazônia. **Texto para a discussão 2142 (Instituto de Pesquisa Econômica Aplicada)**, 2015.

KEBEDE, Asnakew; MCCANN, James C.; KISZEWSKI, Anthony E.; YE-EBIYO, Yemane. New evidence of the effects of agro-ecologic change on malaria transmission. **America Journal of Tropical Medicine and Hygiene**, v. 73, n. 4, p. 676 - 680, 2005.

KOOIJMAN, S. A. L. M. Some remarks on the statistical analysis of grids especially with respect to ecology. **Annals of Systems Research**, v. 5, p. 113 – 132, 1976.

LESAGE, James; PACE, Robert Kelley. **Introduction to Spatial Econometrics**. [S.l.]: Taylor & Francis Ltd, 2008. ISBN 142006424X.

LOIOLA, Carlos Cat ao Prates; SILVA, C. J. Mangabeira da; TAUIL, Pedro Luiz. Controle da malária no Brasil: 1965 a 2001. **Revista Panamericana de Salud Publica**, v. 11, n. 4, p. 235 - 244, 2002.

LUCAS, Adrienne M. Malaria eradication and educational attainment: Evidence from Paraguay and Sri Lanka. **American Economic Journal: Applied Economics**, v. 2, n. 2, p. 46–71, 2010.

MALHI, Y.; ROBERTS, J. T.; BETTS, R. A.; KILLEEN, T. J.; LI, W.; NOBRE, C. A. Climate change, deforestation, and the fate of the Amazon. **Science**, American Association for the Advancement of Science (AAAS), v. 319, n. 5860, p. 169–172, jan 2008.

MARQUES, Agostinho Cruz. Human migration and the spread of malaria in Brazil. **Parasitology Today**, v. 3, n. 6, p. 166 - 170, 1987.

MS. Portal da saúde. **Ministério da saúde**, 2015. Disponível em: <http://portalsaude.saude.gov.br/index.php/o-ministerio/principal/leia-mais-o-ministerio/662-secretaria-svs/vigilancia-de-a-a-z/malaria/11783-publicacoes-malaria.>.

OLSON, Sarah H.; GANGNON, Ronald; SILVEIRA, Guilherme Abbad; PATZ, Jonathan A. Deforestation and malaria in Mâncio lima county, Brazil. **Emerging Infectious Diseases**, v. 16, n. 7, p. 1108–1115, 2010.

PARENTE, Andressa Tavares; SOUZA, Everaldo Barreiros de; RIBEIRO, João Batista Miranda. A ocorrência de malária em quatro municípios do estado do Pará, de 1988 a 2005, e sua relação com o desmatamento. **Acta Amazonica**, v. 42, n. 1, 2012.

PATZ, Jonathan A.; GRACZYK, Thaddeus K.; GELLER, Nina; VITTOR, Amy Y. Effects of environmental change on emerging parasitic diseases. **International Journal for Parasitology**, v. 30, n. 12-13, p. 1395–1405, 2000.

PRODES. Coordenação geral de observação da terra. **OBT - INPE**, 2016. Disponível em: <www.obt.inpe.br/prodes>.

SACHS, Jeffrey; MALANEY, Pia. The economic and social burden of malaria. **Nature**, v. 415, p. 680–685, 2002.

SAUL, Allan. Zooprophylaxis or zoopotentiation: The outcome of introducing animals on vector transmission is highly dependent on the mosquito mortality while searching. **Malaria Journal**, v. 2, n. 32, p. 01–18, 2003.

SINGER, Burton H.; CASTRO, Marcia Caldas de. Agricultural colonization and malaria on the Amazon frontier. **Annals of the New York Academy of Sciences**, v. 954, p. 184 - 222, 2001.

STAKHOVYCH, Stanislav; BIJMOLT, Tammo H.A. Specification of spatial models: A simulation study on weights matrices. **Papers in Regional Science**, Wiley-Blackwell, v. 88, n. 2, p. 389–408, jun 2009. Disponível em: <h>.

TERRAZAS, Wagner Cosme Morhy; SAMPAIO, Vanderson de Souza; CASTRO, Daniel Barros de; PINTO, Rosemary Costa; ALBUQUERQUE, Bernardino Cláudio de; SADAHIRO, Megumi; PASSOS, Ricardo Augusto dos; ; BRAGA, José Ueleres. Deforestation, drainage network, indigenous status, and geographical differences of malaria in the state of Amazonas. **Malaria Journal**, v. 14, n. 379, 2015.

VALLE, D.; CLARK, J. Conservation efforts may increase malaria burden in the Brazilian Amazon. **PLoS ONE**, v. 8, n. 3, 2013.

VEGA, Solmaria Halleck; ELHORST, J. Paul. On spatial econometric models, spillover effects, and w. **53rd ERSA Palermo, August 27-31, 2013**, 2013. Disponível em: <http://www-sre.wu.ac.at/ersa/ersaconfs/ersa13/ERSA2013_paper_00222.pdf>.

VITTOR, AMY Yomiko; GILMAN, Robert H.; TIELSCH, James; VIDRO, Gregory; SHIELDS, Tim; SÁNCHEZ-LOZANO, Wagner; PINEDO, Viviana V.; PATZ, Jonathan A. The effect of deforestation on the human-biting rate of anopheles darlingi, the primary vector of falciparum malaria in the Peruvian Amazon. **The American Journal of Tropical Medicine and Hygiene**, v. 74, n. 1, p. 3 - 11, 2006.

VITTOR, Amy Y.; PAN, William; GILMAN, Robert H.; TIELSCH, James; GLASS, Gregory; SHIELDS, Tim; SÁNCHEZ-LOZANO, Wagner; PINEDO, Viviana V.; SALAS-COBOS, Erit; FLORES, Silvia; PATZ, Jonathan A. Linking deforestation to malaria in the Amazon: Characterization of the breeding habitat of the principal malaria vector, Anopheles darlingi. **America Journal of Tropical Medicine and Hygiene**, v. 81, n. 1, p. 5 - 12, 2009.

WALLER, Carol A. Gotway Lance A. **Applied Spatial Statistics for Public Health Data**. [S.l.]: JOHN WILEY & SONS INC, 2004. ISBN 0471387711.

WAYANT, NM; MALDONADO, D; ARIAS, A Rojas de; NO, B Cousi GOODIN, DG. Correlation between normalized difference vegetation index and malaria in a subtropical rain forest undergoing rapid anthropogenic alteration. **Geospatial Health**, v. 4, n. 2, p. 179 - 190, 2010.

WHO. World health organization. 2016. Disponível em: <http://www.who.int/mediacentre/factsheets/fs094>.

WIELGOZ, Benjamin; MANGHENI, Margaret; TSEGAI, Daniel; RINGLER, Claudia. Malaria and agriculture. **International Food Policy Research Institue: Discussion Paper 01232**, 2012. Disponível em: <http://reliefweb.int/sites/reliefweb.int/files/resources/Malaria%20and%20Agriculture.pdf>.

WOOLDRIDGE, Jeffrey M. **Econometric Analysis of Cross Section and Panel Data**. [S.l.]: The MIT Press, 2010. ISBN 0262232588.

YASUOKA, J.; LEVINS, R. Impact of deforestation and agricultural development on anopheline ecology and malaria epidemiology. **America Journal of Tropical Medicine and Hygiene**, v. 76, n. 3, p. 450 – 460, 2007.

APÊNDICE

APÊNDICE A.

De acordo com Greene (2012), como, nos modelos de efeito fixo, a heterogeneidade é correlacionada com as variáveis explicativas, tem-se que $E(\mu_i \mid X_i) = f(X_i)$. Deste modo, como a média condicional é a mesma em todos os períodos, a equação 8 pode ser reescrita como (GREENE, 2012):

$$\begin{aligned} y_{it} &= x_{it}'\beta + f(X_i) + \varepsilon_{it} + [\mu_i - f(X_i)] \\ &= x_{it}'\beta + \alpha_i + \varepsilon_{it} + [\mu_i - f(X_i)] \end{aligned} \tag{54}$$

Como $[\mu_i - f(X_i)]$ não está correlacionado com X_i, a equação (54) pode ser reescrita como (GREENE, 2012):

$$y_{it} = x_{it}'\beta + \iota\alpha_i + \varepsilon_{it} \tag{55}$$

Onde, ι é um vetor de um, $T \times 1$. A equação (55) pode ser reescrita na forma matricial:

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} \beta + \begin{bmatrix} \iota & 0 & \dots & 0 \\ 0 & \iota & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \iota \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_n \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_k \end{bmatrix} \tag{56}$$

Simplificando, onde d_i é uma variável binária associada a unidade cross-section i:

$$y = \begin{bmatrix} X & d_1 & d_2 & \dots & d_n \end{bmatrix} \begin{bmatrix} \beta \\ \alpha \end{bmatrix} + \varepsilon \tag{57}$$

Considerando $D = \begin{bmatrix} d_1 & d_2 & \dots & d_n \end{bmatrix}$, uma matriz n$T$xn, pode-se reescrever a equação (57) como (GREENE, 2012):

$$y = D\alpha + X\beta + \varepsilon \tag{58}$$

A equação (58) é um modelo de variáveis dummie, sendo estimado por mínimos quadrados da variável dummie. Deste modo, segue-se uma estimação de um modelo

de regressão clássica, onde $(x'x)b = (x'y)$. No caso, para equação (58), tem-se

$$\begin{bmatrix} D' \\ X' \end{bmatrix} \begin{bmatrix} D' & X' \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} D' \\ X' \end{bmatrix} y \tag{59}$$

Resolvendo a equação (59), encontra-se os coeficiente a e b:

$$a = \begin{bmatrix} D' & D \end{bmatrix}^{-1} D'(y - Xb) \tag{60}$$

$$b = \begin{bmatrix} X' & M_d & X \end{bmatrix}^{-1} \begin{bmatrix} X' & M_d & y \end{bmatrix} \tag{61}$$

Onde,

$$M_d = I - D(D'D)^{-1}D' \tag{62}$$

Na forma matricial, verifica-se que M_d possui colunas ortogonais (GREENE, 2012):

$$M_d = \begin{bmatrix} M^0 & 0 & \dots & 0 \\ 0 & M^0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & M^0 \end{bmatrix} \tag{63}$$

Em que,

$$M^0 = I_T - \frac{1}{T}\iota\iota' \tag{64}$$

Transformando $X^* = M_d X$ e $Y^* = M_d y$, tem-se a estimação de b por Mínimos Quadrados (GREENE, 2012):

$$b = (X^{*\prime}X^*)^{-1}(X^{*\prime}Y^*) \tag{65}$$

Segundo Greene (2012), a matriz de covariância assintótica para b pode ser expressa como,

$$\begin{aligned} Est.Asy.Var(b) &= \sigma^2[X'M_dX]^{-1} \\ &= \sigma^2\left(S_{XX}^{WITHIN}\right)^{-1} \end{aligned} \tag{66}$$

Sendo que,

$$\sigma^2 = \frac{(Y^* - X^*\beta)'(Y^* - X^*\beta)}{nT - n - k} \tag{67}$$

Desta forma, tem-se a matriz de variância assintótica (GREENE, 2012):

$$Asy.Var(\beta, \sigma^2) = \begin{bmatrix} \frac{1}{\sigma^2}X^{*\prime}X^* & 0 \\ 0 & \frac{nT-n-k}{2\sigma^2} \end{bmatrix} \tag{68}$$

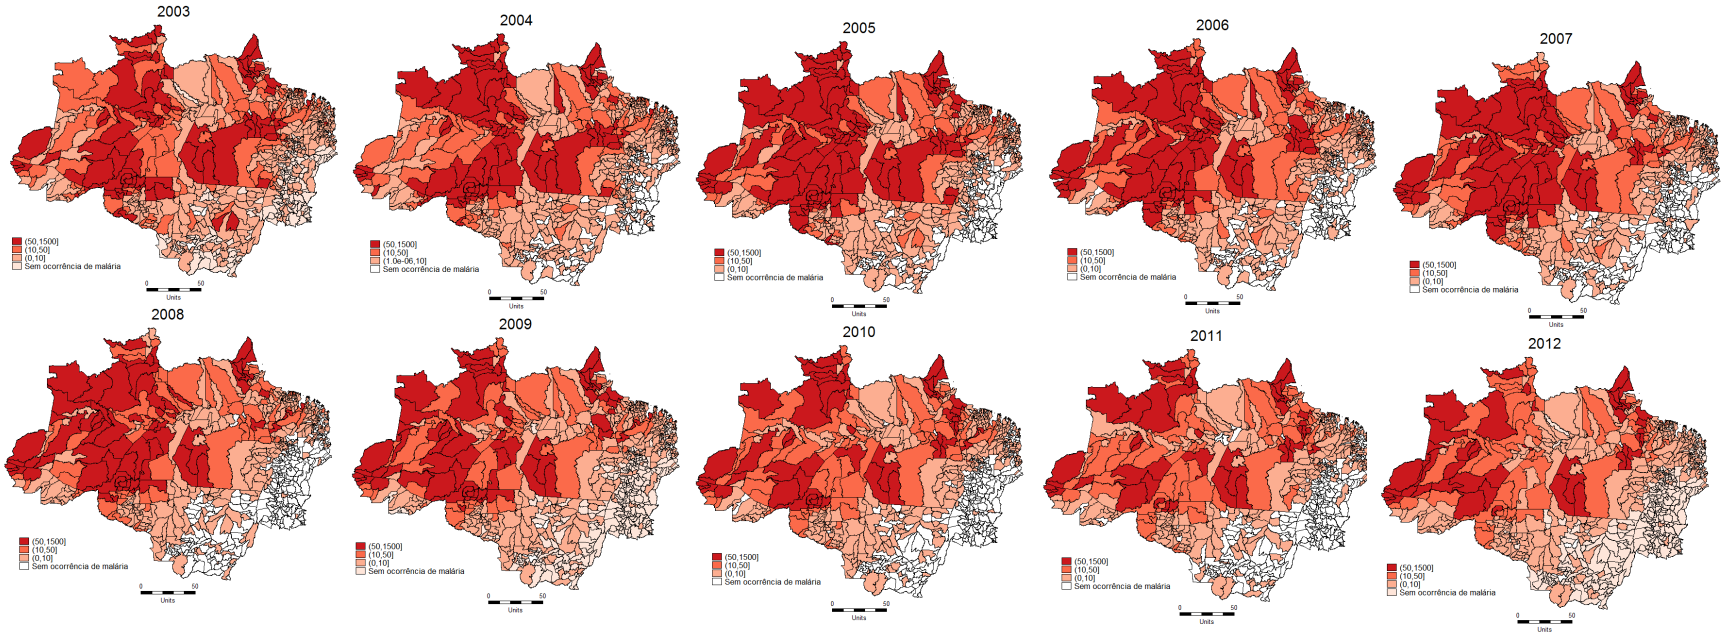

Figura 7. Índice Parasitário Anual de Malária. 2003 - 2012
Fonte: Elaboração própria com os dados disponibilizados pela SIVEP. Software: Stata 12.0

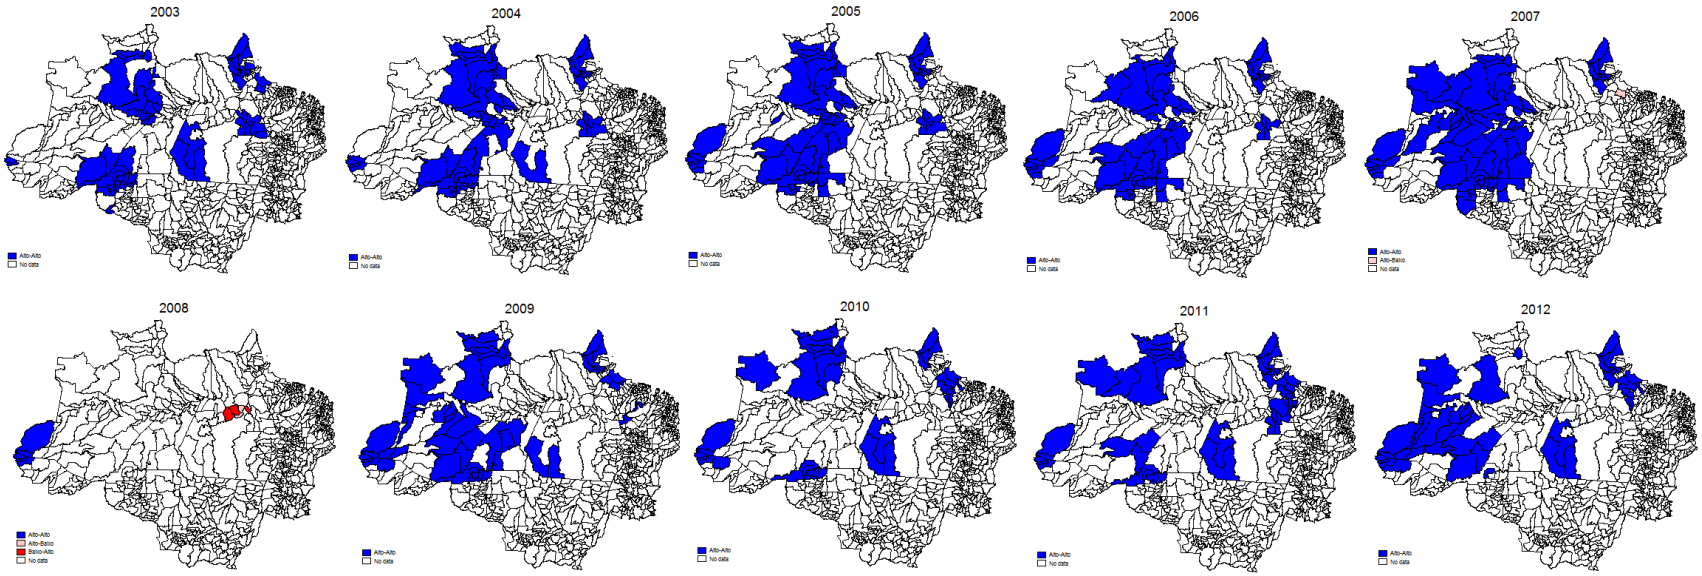

Figura 8. Mapa da estatística I de Moran Local para os casos de malária. 2003 - 2012
Fonte: Resultados da pesquisa. Software: Stata 12.0

Tabela 23. Estatística I de Moran para o Desmatamento

Ano	**I**	**E(I)**	**DP(I)**	**z**	**p-valor**
2003	0,507	-0,001	0,022	23,399	0,000
2004	0,489	-0,001	0,022	22,396	0,000
2005	0,458	-0,001	0,021	21,902	0,000
2006	0,410	-0,001	0,021	19,730	0,000
2007	0,430	-0,001	0,02	21,046	0,000
2008	0,423	-0,001	0,021	20,026	0,000
2009	0,359	-0,001	0,021	17,360	0,000
2010	0,409	-0,001	0,021	19,393	0,000
2011	0,465	-0,001	0,021	21,901	0,000
2012	0,452	-0,001	0,021	21,085	0,000

Fonte: Resultados da pesquisa.

Tabela 24. Estatística c de Geary para o Desmatamento

Ano	**c**	**E(c)**	**DP(c)**	**z**	**p-valor**
2003	0,665	1,000	0,059	-5,637	0,000
2004	0,729	1,000	0,054	-5,018	0,000
2005	0,831	1,000	0,079	-2,143	0,016
2006	0,919	1,000	0,082	-0,978	0,164
2007	0,907	1,000	0,089	-1,043	0,148
2008	0,872	1,000	0,075	-1,716	0,043
2009	1,015	1,000	0,084	0,177	0,430
2010	0,860	1,000	0,075	-1,858	0,032
2011	0,843	1,000	0,072	-2,175	0,015
2012	0,908	1,000	0,067	-1,389	0,082

Fonte: Resultados da pesquisa.

Tabela 25. Estatística I de Moran para o percentual de Floresta

Ano	**I**	**E(I)**	**DP(I)**	**z**	**p-valor**
2003	0,855	-0,001	0,023	38,013	0,000
2004	0,855	-0,001	0,023	38,015	0,000
2005	0,855	-0,001	0,023	38,033	0,000
2006	0,854	-0,001	0,023	37,964	0,000
2007	0,842	-0,001	0,023	37,439	0,000
2008	0,849	-0,001	0,023	37,752	0,000
2009	0,833	-0,001	0,023	37,033	0,000
2010	0,838	-0,001	0,023	37,252	0,000
2011	0,846	-0,001	0,023	37,618	0,000
2012	0,843	-0,001	0,023	37,481	0,000

Fonte: Resultados da pesquisa.

Tabela 26. Estatística c de Geary para o percentual de Floresta

Ano	**c**	**E(c)**	**DP(c)**	**z**	**p-valor**
2003	0,156	1,000	0,024	-35,15	0,000
2004	0,156	1,000	0,024	-34,99	0,000
2005	0,157	1,000	0,024	-34,844	0,000
2006	0,157	1,000	0,024	-34,463	0,000
2007	0,172	1,000	0,025	-33,793	0,000
2008	0,164	1,000	0,024	-34,207	0,000
2009	0,181	1,000	0,024	-33,554	0,000
2010	0,173	1,000	0,025	-33,345	0,000
2011	0,167	1,000	0,025	-33,609	0,000
2012	0,168	1,000	0,025	-33,72	0,000

Fonte: Resultados da pesquisa.

Tabela 27. Estatística I de Moran para a densidade populacional

Ano	**I**	**E(I)**	**DP(I)**	**z**	**p-valor**
2003	0,331	-0,001	0,018	18,389	0,000
2004	0,333	-0,001	0,018	18,597	0,000
2005	0,333	-0,001	0,018	18,661	0,000
2006	0,334	-0,001	0,018	18,743	0,000
2007	0,337	-0,001	0,018	18,95	0,000
2008	0,367	-0,001	0,018	19,94	0,000
2009	0,341	-0,001	0,018	19,181	0,000
2010	0,364	-0,001	0,018	19,789	0,000
2011	0,365	-0,001	0,018	19,868	0,000
2012	0,367	-0,001	0,018	19,94	0,000

Fonte: Resultados da pesquisa.

Tabela 28. Estatística c de Geary para a densidade populacional

Ano	c	E(c)	DP(c)	z	p-valor
2003	0,636	1,000	0,126	-2,89	0,002
2004	0,630	1,000	0,127	-2,91	0,002
2005	0,628	1,000	0,127	-2,92	0,002
2006	0,625	1,000	0,128	-2,929	0,002
2007	0,622	1,000	0,129	-2,939	0,002
2008	0,597	1,000	0,121	-3,338	0,000
2009	0,616	1,000	0,128	-2,996	0,001
2010	0,601	1,000	0,121	-3,29	0,001
2011	0,599	1,000	0,121	-3,315	0,000
2012	0,597	1,000	0,121	-3,338	0,000

Fonte: Resultados da pesquisa.

Tabela 29. Estatística I de Moran para os dispêndios com saúde

Ano	I	E(I)	DP(I)	z	p-valor
2003	0,259	-0,001	0,022	11,678	0,000
2004	0,266	-0,001	0,022	12,036	0,000
2005	0,389	-0,001	0,022	17,393	0,000
2006	0,288	-0,001	0,022	12,903	0,000
2007	0,299	-0,001	0,022	13,506	0,000
2008	-0,002	-0,001	0,001	-0,767	0,222
2009	0,381	-0,001	0,022	17,043	0,000
2010	0,498	-0,001	0,022	22,610	0,000
2011	0,389	-0,001	0,022	17,396	0,000
2012	0,419	-0,001	0,022	18,733	0,000

Fonte: Resultados da pesquisa.

Tabela 30. Estatística c de Geary para os dispêndios com saúde

Ano	c	E(c)	DP(c)	z	p-valor
2003	0,683	1,000	0,038	-8,267	0,000
2004	0,686	1,000	0,041	-7,616	0,000
2005	0,567	1,000	0,031	-14,184	0,000
2006	0,666	1,000	0,029	-11,350	0,000
2007	0,637	1,000	0,040	-9,075	0,000
2008	0,910	1,000	0,208	-0,432	0,333
2009	0,572	1,000	0,031	-13,762	0,000
2010	0,488	1,000	0,047	-10,942	0,000
2011	0,566	1,000	0,029	-15,122	0,000
2012	0,541	1,000	0,030	-15,511	0,000

Fonte: Resultados da pesquisa.

Tabela 31. Estatística I de Moran para os dispêndios com habitação

Ano	I	E(I)	DP(I)	z	p-valor
2003	0,177	-0,001	0,022	8,043	0,000
2004	0,178	-0,001	0,022	8,141	0,000
2005	0,072	-0,001	0,019	3,948	0,000
2006	0,148	-0,001	0,022	6,691	0,000
2007	0,191	-0,001	0,022	8,603	0,000
2008	0,045	-0,001	0,018	2,661	0,004
2009	0,153	-0,001	0,022	6,970	0,000
2010	0,498	-0,001	0,022	22,61	0,000
2011	0,162	-0,001	0,022	7,316	0,000
2012	0,185	-0,001	0,022	8,333	0,000

Fonte: Resultados da pesquisa.

Tabela 32. Estatística c de Geary para os dispêndios com habitação

Ano	c	E(c)	DP(c)	z	p-valor
2003	0,776	1,000	0,043	-5,244	0,000
2004	0,745	1,000	0,051	-5,039	0,000
2005	0,854	1,000	0,120	-1,212	0,113
2006	0,776	1,000	0,041	-5,496	0,000
2007	0,766	1,000	0,037	-6,379	0,000
2008	0,901	1,000	0,132	-0,746	0,228
2009	0,828	1,000	0,044	-3,920	0,000
2010	0,488	1,000	0,047	-10,942	0,000
2011	0,766	1,000	0,035	-6,665	0,000
2012	0,751	1,000	0,036	-6,938	0,000

Fonte: Resultados da pesquisa.

Tabela 33. Estatística I de Moran para o PIB

Ano	I	E(I)	DP(I)	z	p-valor
2003	0,049	-0,001	0,031	1,640	0,051
2004	0,053	-0,001	0,031	1,760	0,039
2005	0,045	-0,001	0,031	1,543	0,061
2006	0,050	-0,001	0,031	1,673	0,047
2007	0,049	-0,001	0,030	1,677	0,047
2008	0,061	-0,001	0,031	2,022	0,022
2009	0,052	-0,001	0,030	1,821	0,034
2010	0,064	-0,001	0,029	2,238	0,013
2011	0,056	-0,001	0,030	1,930	0,027
2012	0,049	-0,001	0,029	1,737	0,041

Fonte: Resultados da pesquisa.

Tabela 34. Estatística c de Geary para o PIB

Ano	**c**	**E(c)**	**DP(c)**	**z**	**p-valor**
2003	1,022	1,000	0,171	0,127	0,450
2004	1,018	1,000	0,170	0,104	0,458
2005	1,030	1,000	0,172	0,177	0,430
2006	1,005	1,000	0,170	0,028	0,489
2007	0,993	1,000	0,174	-0,043	0,483
2008	0,995	1,000	0,168	-0,031	0,488
2009	1,060	1,000	0,180	0,330	0,371
2010	1,052	1,000	0,181	0,288	0,387
2011	1,050	1,000	0,177	0,284	0,388
2012	1,066	1,000	0,183	0,361	0,359

Fonte: Resultados da pesquisa.

Tabela 35. Estatística I de Moran para o efetivo bovino

Ano	**I**	**E(I)**	**DP(I)**	**z**	**p-valor**
2003	0,506	-0,001	0,022	22,820	0,000
2004	0,542	-0,001	0,022	24,477	0,000
2005	0,547	-0,001	0,022	24,696	0,000
2006	0,539	-0,001	0,022	24,378	0,000
2007	0,528	-0,001	0,022	23,972	0,000
2008	0,525	-0,001	0,022	23,934	0,000
2009	0,527	-0,001	0,022	24,043	0,000
2010	0,534	-0,001	0,022	24,366	0,000
2011	0,533	-0,001	0,022	24,358	0,000
2012	0,525	-0,001	0,022	24,037	0,000

Fonte: Resultados da pesquisa.

Tabela 36. Estatística c de Geary para o efetivo bovino

Ano	**c**	**E(c)**	**DP(c)**	**z**	**p-valor**
2003	0,674	1,000	0,042	-7,767	0,000
2004	0,641	1,000	0,043	-8,389	0,000
2005	0,635	1,000	0,043	-8,516	0,000
2006	0,642	1,000	0,044	-8,17	0,000
2007	0,665	1,000	0,048	-6,928	0,000
2008	0,680	1,000	0,052	-6,19	0,000
2009	0,671	1,000	0,052	-6,338	0,000
2010	0,672	1,000	0,052	-6,283	0,000
2011	0,673	1,000	0,053	-6,144	0,000
2012	0,679	1,000	0,054	-5,973	0,000

Fonte: Resultados da pesquisa.

Tabela 37. Estatística I de Moran para a área plantada de soja

Ano	I	E(I)	DP(I)	z	p-valor
2003	0,516	-0,001	0,021	24,610	0,000
2004	0,553	-0,001	0,021	26,044	0,000
2005	0,546	-0,001	0,021	25,676	0,000
2006	0,546	-0,001	0,021	25,862	0,000
2007	0,539	-0,001	0,021	25,584	0,000
2008	0,569	-0,001	0,021	26,882	0,000
2009	0,560	-0,001	0,021	26,497	0,000
2010	0,560	-0,001	0,021	26,497	0,000
2011	0,568	-0,001	0,021	26,724	0,000
2012	0,572	-0,001	0,021	26,806	0,000

Fonte: Resultados da pesquisa.

Tabela 38. Estatística c de Geary para a área plantada de soja

Ano	c	E(c)	DP(c)	z	p-valor
2003	0,565	1,000	0,078	-5,586	0,000
2004	0,525	1,000	0,072	-6,633	0,000
2005	0,543	1,000	0,071	-6,416	0,000
2006	0,538	1,000	0,075	-6,182	0,000
2007	0,554	1,000	0,076	-5,884	0,000
2008	0,522	1,000	0,074	-6,480	0,000
2009	0,529	1,000	0,074	-6,367	0,000
2010	0,529	1,000	0,074	-6,367	0,000
2011	0,521	1,000	0,072	-6,657	0,000
2012	0,515	1,000	0,069	-7,006	0,000

Fonte: Resultados da pesquisa.

Tabela 39. Estatística I de Moran para a área plantada das demais culturas

Ano	I	E(I)	DP(I)	z	p-valor
2003	0,508	-0,001	0,022	23,415	0,000
2004	0,545	-0,001	0,022	24,985	0,000
2005	0,493	-0,001	0,022	22,527	0,000
2006	0,445	-0,001	0,022	20,559	0,000
2007	0,476	-0,001	0,021	22,335	0,000
2008	0,491	-0,001	0,021	23,038	0,000
2009	0,484	-0,001	0,022	22,472	0,000
2010	0,483	-0,001	0,022	22,453	0,000
2011	0,483	-0,001	0,022	22,501	0,000
2012	0,329	-0,001	0,022	15,117	0,000

Fonte: Resultados da pesquisa.

Tabela 40. Estatística c de Geary para a área plantada das demais culturas

Ano	**I**	**E(I)**	**DP(I)**	**z**	**p-valor**
2003	0,500	1,000	0,059	-8,462	0,000
2004	0,508	1,000	0,056	-8,824	0,000
2005	0,531	1,000	0,053	-8,791	0,000
2006	0,561	1,000	0,060	-7,3	0,000
2007	0,568	1,000	0,070	-6,157	0,000
2008	0,553	1,000	0,070	-6,388	0,000
2009	0,542	1,000	0,064	-7,152	0,000
2010	0,542	1,000	0,064	-7,157	0,000
2011	0,546	1,000	0,066	-6,934	0,000
2012	0,764	1,000	0,056	-4,22	0,000

Fonte: Resultados da pesquisa.