



Desempenho eleitoral dos candidatos a presidente do PT e PSDB em 2014:

**o que explica a votação dos principais partidos
nos municípios, variáveis políticas ou sociais?¹**

Emerson Urizzi Cervi

ecervi7@gmail.com

Universidade Federal do Paraná

Jaqueline Kleine Buckstegge

jaqueline.buckstegge@gmail.com

Universidade Federal do Paraná

ÁREA TEMÁTICA

Grupo de Investigación en Análisis Espacial en América Latina

ESPACIO ALACIP – PANEL 4

Geografia eleitoral brasileira: eleições presidenciais

Coordinador: Gláucio Soares (IESP/UERJ – Brasil)

¹ Trabajo preparado para su presentación en el VIII Congreso Latinoamericano de Ciencia Política, organizado por la Asociación Latinoamericana de Ciencia Política (ALACIP). Pontificia Universidad Católica del Perú, Lima, 22 al 24 de julio de 2015.

**Desempenho eleitoral dos candidatos a presidente do PT e PSDB em 2014:
o que explica a votação dos principais partidos nos municípios, variáveis políticas ou
sociais?**

Resumo: As eleições gerais de 2014 no Brasil reuniram 230 milhões de eleitores em 5,6 mil municípios para eleger representantes aos cargos de presidente, governador e senador, com votos majoritários; e deputado federal e estadual, em disputas proporcionais. O *paper* discute a associação entre votos em diferentes cargos, controlada pela distribuição espacial, em duas dimensões distintas: política e social. A pergunta é: no município, o desempenho eleitoral do partido *incumbent* e do desafiante a presidente da república pode ser explicado pelas mesmas variáveis? A dimensão política relaciona o desempenho dos dois partidos, em participação percentual no total de votos de legenda para deputado federal e o percentual de votos no partido para presidente. A dimensão social associa a diferença do Índice de Desenvolvimento Humano Municipal (IDH-M) entre 2000 e 2010 com o desempenho dos candidatos à presidência. Utiliza-se técnicas de regressão espacial para identificar que tipo de variável independente (política ou social) explica mais as votações para presidente do PT e PSDB nos municípios. Também verifica-se o grau de vizinhança do desempenho dos candidatos à presidência em função da região do País. A hipótese é que a votação para presidente do PT (*incumbent*) associa-se de forma positiva à variável social em consequência dos resultados das políticas públicas. Já a votação do PSDB para presidente está mais associada aos votos de legenda do partido nos municípios, indicando maior importância da estrutura partidária nos municípios para explicar o desempenho eleitoral do partido de oposição à presidência da república.

Palavras-chave: dependência espacial; eleições 2014; PT e PSDB; IDH-M

**Electoral performance of PT and PSDB presidential candidates in 2014:
which explains the vote of the main parties in the municipalities, political or social
variables?**

Abstract: *The general elections of 2014 in Brazil gathered 230 million voters in 5,561 cities to elect representatives to the offices of president, governor and senator, through majoritarian vote; and state and federal legislative representatives, in proportional system. The paper discusses the association between the vote in different positions, controlled by spatial distribution, in two different dimensions: political and social. The focus of the paper is: in city level, presidential electoral performance of the incumbent party and its respective main challenger can be explained by the same variables? The political dimension relates the performance of the two parties, as a percentage stake of the total of party votes for congressional representative and the percentage of presidential votes that the same party received. The social dimension is measured by the association in the difference of the City's Human Development Index (IDH-M), between 2000 and 2010, and the performance of presidential candidates. The paper uses spatial regression techniques to identify what kind of independent variable (political or social) has more explanatory power in presidential elections between the two main parties in the competition (PT and PSDB), within city level. The degree of neighborhood in the presidential candidate performance is also verified, controlled by region of the country. The hypothesis is that the presidential vote of PT (incumbent) is associated positively to the social variable dimension as a result of the results of public policies. On the other hand, PSDB's presidential vote is more closely associated with party vote in city level, indicating greater importance of cities' party structure on the explanation of electoral performance, when opposition party for in a presidential competition.*

Keywords: *spatial dependence; 2014's election; PT and PSDB; City's Human Development Index*

***Desempeño electoral de los candidatos a la presidencia del PT y PSDB en 2014:
¿Lo que explica el voto de los principales partidos en los municipios, las variables políticas o
sociales?***

Resumen: Las elecciones generales de 2014 en Brasil reunieron 230 millones de votantes en 5.561 municipios para elegir a los representantes en los cargos de presidente, gobernador y senador, con mayoría de votos; y los representantes legislativos a nivel federal y estatal, en las disputas proporcionales. El paper analiza la relación entre votos en diferentes posiciones, controlada por la distribución espacial, en dos dimensiones: política y social. La pregunta es: en el municipio, el desempeño electoral presidencial del partido en el poder y de su desafiante puede ser explicado por las mismas variables? La dimensión política se relaciona a el rendimiento de los dos partidos, como un porcentaje de participación de lo voto en leyenda para el congresista y el porcentaje de votos del partido a la presidencia. La dimensión social es asociada con la diferencia de Índice de Desarrollo Humano Municipal (IDH-M), entre 2000 y 2010, con la actuación de los candidatos presidenciales. El paper utiliza técnicas de regresión espacial para identificar qué tipo de variable independiente (político o social) explica más los resultados para presidente obtenidos por PT y PSDB en los municipios. También se verificó el grado de vecindad en el desempeño de los candidatos presidenciales, dependiendo de la región del país. La hipótesis es que el voto para presidente del PT (incumbent) se asocia positivamente a la variable social como consecuencia de los resultados de las políticas públicas. Por otro lado, la votación presidencial del PSDB está más estrechamente asociada con el voto en leyenda a nivel municipal, lo que indica una mayor importancia de la estructura del partido en los municipios para explicar el desempeño electoral del partido de la oposición a la presidencia.

Palabras clave: dependencia espacial; las elecciones de 2014; PT y PSDB; IDH-M

1. INTRODUÇÃO

O *paper* aborda a dupla questão da associação espacial e explicação para a variação de voto a partir de variáveis políticas e sociais. O objeto é o desempenho eleitoral, medido em percentual de votos por município, dos dois principais partidos em 2014, o PT e o PSDB, na disputa pela presidência do Brasil. O PT, no governo, conseguiu a reeleição da presidente Dilma Rousseff no segundo turno, após vencer por uma diferença de apenas 1% de votos o candidato do PSDB, senador Aécio Neves. Com isso, o PT consegue manter-se no governo pelo quarto mandato consecutivo (dois de Lula e dois de Dilma Rousseff), tendo em todas as disputas como segundo colocado o candidato do PSDB - seu principal adversário político-eleitoral. A hipótese é de que apenas variáveis institucionais não são suficientes para explicar o desempenho desses dois partidos nas eleições. A explicação deve começar pela estrutura dos partidos, entendida como a capilaridade do PT e PSDB nas regiões brasileiras e a forma como ambos conseguem tirar proveito das estruturas de siglas médias e pequenas do sistema partidário brasileiro. Mas, além das variáveis tais institucionais, o que ajuda a garantir a manutenção da força eleitoral do PT é o desempenho que teve no governo do País. O resultado de políticas implementadas pelos três governos petistas, refletido diretamente no desempenho de seus candidatos à presidência, é o que espera-se contribuir para a explicação da manutenção da polarização entre as duas siglas.

O objetivo do *paper* é testar uma variável explicativa em cada dimensão para o desempenho espacial na eleição presidencial: desenvolvimento econômico (social) e desempenho partidário (político), ambas em nível municipal. A hipótese a ser aferida é de que o candidato à reeleição tende a apresentar melhor desempenho em áreas com resultados mais positivos de políticas públicas (explicação social) e o candidato da oposição tende a ter votação espacialmente associada com maior estruturação partidária local (explicação política). Desde a ampliação dos programas sociais dos governos do Partido dos Trabalhadores, boa parte dos trabalhos sobre comportamento eleitoral buscam compreender como se relaciona, por um lado, a identificação partidária tradicional ao próprio PT, e, por outro, o foco nos benefícios das políticas públicas de distribuição de renda, principalmente através do Programa Bolsa Família (Guarnieri, 2014; Kerkauy, 2011; Marzagão, 2013; Nicolau, 2014; Peixoto & Rennó, 2011; Rennó & Cabello, 2010; Soares; Terron, 2008; Terron; Soares, 2010). Para isso, considera-se a possibilidade de associação entre crescimento do IDH e maior percentual de votos PT. No caso, o percentual de votos no partido do mandatário cresce conforme aumenta a diferença do IDH-M no período, enquanto o percentual de votos na oposição (PSDB), tenderia a diminuir no mesmo movimento do desenvolvimento humano.

Em 1948, o sociólogo norte-americano Joseph Campbell propôs um conjunto de variáveis políticas e econômicas para explicar o desempenho dos partidos em disputas presidenciais nos Estados Unidos (Gelman & King, 1993). Adota-se a proposta de Campbell como ponto de partida para a análise do desempenho do PT e PSDB no Brasil em 2014, agregando a análise de dependência espacial. A variável dependente aqui é o percentual de votos obtidos pelo PT e PSDB na eleição presidencial de 2014. A unidade de análise é o município.

Em democracias multipartidárias como a brasileira, o desempenho dos partidos em eleições não depende apenas das condições relativas diretamente ao desempenho do governo nacional. Há um viés de responsividade eleitoral identificado por King (1990) que considera o desempenho dos partidos para o legislativo e o desempenho em eleições regionais para explicar o sucesso eleitoral em disputas nacionais. Isso porque os sistemas de representação política são fundados tanto da representação local quanto na nacional. Assim, partidos que conseguem fazer a integração entre a política local e a nacional

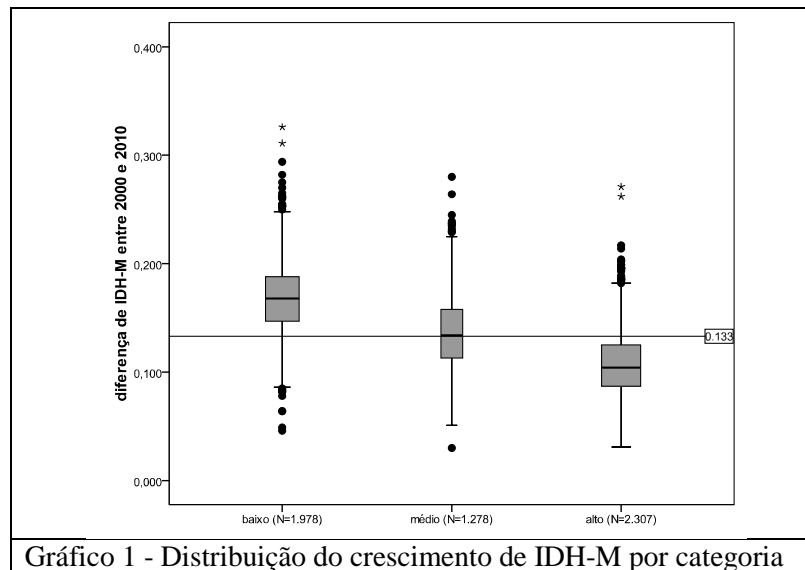
apresentam melhores condições para desempenhos positivos em disputas presidenciais. Nesta lógica, há duas teses concorrentes. Uma é a de que os partidos estruturados politicamente nos estados conseguem replicar o bom desempenho nas disputas nacionais. Nesse caso, haveria uma coincidência no desempenho dos partidos para presidência e para o congresso nacional. A outra é que os partidos apresentam desempenhos eleitorais distintos para disputas majoritárias e proporcionais. Nesse caso, a especialização do partido em disputas nacionais majoritárias independeria da estruturação regional do mesmo.

A segunda dimensão explicativa proposta pelo *paper*, a socioeconômica regional, também é relevante para explicar a polarização nas disputas presidenciais. Sua hipótese para o sucesso político-eleitoral é que a melhoria de vida dos eleitores é recompensada com votos ao partido governante. Em termos do IDH nacional, que incorpora indicadores econômicos, de educação e de saúde pública, seu aprimoramento é realizado através da efetivação de políticas públicas em regiões menos desenvolvidas. Como no Brasil há uma centralização de recursos para políticas públicas na esfera federal (Boschi, 2004), pode-se pensar que a diferença no IDH em um período pode gerar algum ganho eleitoral para o partido governante. Não se pretende com isso defender que o IDH é o melhor preditor de votação e, muito menos, que seja a única variável explicativa para o desempenho dos partidos. O objetivo é usar uma variável que não seja político-partidária para testar os comportamentos de PT e PSDB. Como a unidade de análise espacial é o município, utiliza-se o IDH-M, que mede o índice de desenvolvimento humano em cada um dos 5,6 municípios brasileiros.

Os modelos usados para testar a associação espacial consideram como variável dependente os percentuais de voto no PT e PSDB por município no 1º e 2º turnos de 2014. Como variáveis independentes, utiliza-se a diferença do IDH-M por município entre 2000 e 2010 (para indicar a associação não-política) e a participação percentual do PT do PSDB nos votos de legenda para deputado federal em cada município no primeiro turno de 2014 (para indicar associação política). O texto está dividido em mais três partes. Na próxima, apresenta-se o modelo e os métodos, com breve apresentação do contexto das variáveis. Depois, analisa-se os resultados encontrados e, por fim, apresenta-se algumas conclusões a respeito do experimento analítico realizado.

2. CONTEXTO, MODELO E MÉTODOS

Para compreender melhor o contexto social das eleições brasileiras de 2014, a partir da variáveis independente selecionada pelo *paper*, o Gráfico 1 demonstra as distribuições dos crescimentos de IDH-M nos municípios brasileiros entre 2000 e 2010 por categoria de IDH-M (alto, médio ou baixo) no último ano de análise. A partir dele é possível perceber que os municípios de mais baixo IDH-M apresentaram os maiores crescimentos médios no período analisado, com quedas nos municípios de IDH-M médio e nos que pertencem à categoria alto.



A mediana do crescimento de IDH-M no Brasil foi de 0,133 na década. Excetuando os outliers, na categoria de IDH-M baixo o município com menor crescimento apresentou 0,097 de diferença entre 2000 e 2010, contra apenas 0,035 no município da categoria IDH-M alto com menor crescimento no período. Já os maiores crescimento ficaram na categoria de IDH-M baixo, com 0,255, excetuando os *outliers*, contra um crescimento máximo de 0,197 para os municípios com IDH-M alto. Como as categorias de agrupamento do índice apresentam relação inversa ao crescimento, com menor crescimento em municípios que já apresentam IDH-M alto, a variável da dimensão social inserida no modelo apresenta uma associação inversa ao grau de desenvolvimento do município. Ou seja, municípios com menor IDH-M foram os que apresentaram as maiores diferenças e, portanto, pela hipótese são, geograficamente, onde mais se sentiram os efeitos positivos das políticas públicas, tendendo a apresentar maiores percentuais de voto ao mandatário. Já os municípios com IDH-M mais alto foram os que apresentaram as menores diferenças de crescimento, estando assim associados com a diferença positiva em percentual de votos ao candidato governante à presidência. Ainda que não tenha sido testada a associação do IDH-M com os percentuais de voto, as distribuições de crescimento mostram que as unidades espaciais de análise (municípios) apresentam alguma regularidade em relação ao desenvolvimento humano, pois os menos desenvolvidos tiveram maior crescimento, em média, no período.

A segunda variável explicativa do modelo é de caráter político-partidário: percentual de votos de legenda para deputado federal no município. Utiliza-se como *proxy* os votos de legenda por ser uma variável que indica a força política de um partido em determinado espaço geográfico. Quanto mais votos de legenda um partido recebe em determinado município, maior é o enraizamento dele nesse espaço, pois os eleitores optam por destinar o voto à legenda e não a um candidato específico. Opta-se por usar os votos de legenda para deputado federal por ser cargo legislativo de esfera nacional, aproximando-o da presidência da república. Os dois partidos apresentaram percentuais de votos de legenda muito próximos. Em 2014, para deputado federal, o PT apresentou média de 19,9% do total de votos de legenda nos municípios, contra 20,4% de votos de legenda do PSDB. Ou seja, os dois partidos somaram mais de 40% dos votos de legenda para deputado federal naquele ano.

Antes de testar a associação espacial, será verificada a existência de correlação linear simples (*Pearson*) entre as variáveis que compõem o modelo de análise. As

correlações bivariadas apenas indicaram a associação entre duas das variáveis incluídas e servem como uma primeira aproximação ao modelo - ainda sem considerar a dependência espacial. Os resultados da Tabela 1 mostram alta correlação entre a diferença de IDH-M e os percentuais de voto no PT e no PSDB nos dois turnos eleitorais. Ainda, os coeficientes são positivos para PT e negativos para PSDB, indicando que os percentuais de voto no PT tendem a crescer em municípios onde houve maior diferença de IDH-M e os percentuais do PSDB tendem a ser mais altos em municípios com menor diferença de IDH-M. Todos os coeficientes ficaram acima de $\pm 60\%$ para a correlação entre as variáveis.

Tabela 1 - Correlação linear de Pearson entre as variáveis inseridas no modelo

Variável	% Pres. 1T (PT)	% Pres. 1T (PSDB)	% Pres. 2T (PT)	% Pres. 2T (PSDB)
Diferença IDH-M (2000 e 2010)	0,637** (0,000)	-0,602** (0,000)	0,621** (0,000)	-0,614** (0,000)
% Voto Legenda Dep. Fed. (PT)	0,041** (0,000)	-0,003 (0,000)	-0,006 (0,000)	0,004 (0,000)
% Voto Legenda Dep. Fed. (PSDB)	-0,536** (0,000)	0,552** (0,000)	-0,516** (0,000)	0,528** (0,000)

Fonte: Autores

A correlação com os percentuais de votos de legenda para deputado federal do PSDB também foi alta, tanto para voto em presidente do PSDB quanto para voto em presidente do PT, nos dois turnos. No caso de votos a presidente do PT os coeficientes foram negativos, indicando que em municípios com percentuais mais altos de votos de legenda no PSDB, a candidata do PT tendeu a percentuais menores de voto nos dois turnos. Já o candidato do PSDB à presidência tendeu a mais sucesso em municípios que detinham mais votos em legenda para seu partido nas eleições de deputado federal. Todos os coeficientes de correlação com percentual de participação de votos de legenda do PSDB no município ficaram acima de $\pm 50\%$. Até aqui, as correlações apresentam-se conforme esperado, com associação positiva entre desenvolvimento econômico e votos no candidato à presidência do partido *incumbent* e associação positiva entre votos de legenda para deputado federal do partido de oposição e votos para seu respectivo candidato presidencial. Além disso, a variável de estruturação política do partido do governo (PT) foi a que apresentou os menores coeficientes de correlação com os percentuais de votos para presidência - mesmo considerando os votos do próprio partido. A correlação entre participação do PT em votos de legenda para deputado federal no município e percentual de votos para presidência no PT foi de 4,1%, muito abaixo dos coeficientes anteriores. Todas as demais correlações apresentaram coeficientes abaixo de 1%. Isso demonstra uma baixa associação entre percentual de votos de legenda do PT no município e distribuição de votos para presidência no mesmo espaço, o que ajuda a reforçar a hipótese de que a associação de voto presidencial no partido mandatário não é tanto forte com variáveis político-partidárias (aqui representada pelos votos de legenda para deputado federal), mas sim com o resultado de políticas públicas (aqui representada pela diferença de IDH-M).

Identificadas as associações diretas entre as variáveis, o próximo passo é incluir a dependência espacial nas análises, pois considera-se a existência de um "contágio por vizinhança" tanto das variáveis dependentes (votos para presidente) como para as variáveis explicativas (IDH-M e votos de legenda para deputado federal). Para isso,

utiliza-se o coeficiente I de Moran, que é derivado da correlação de Pearson, como uma primeira aproximação descritiva da associação espacial entre variáveis. Assim como a correlação de Pearson, o I de Moran varia de -1 a +1. Quanto mais próximo de -1, mais forte é a associação espacial negativa e mais para +1 cresce a força da correlação no mesmo sentido. Os valores próximos de zero indicam ausência de correlação espacial. O índice I de Moran é usado de forma exploratória para medir possível dependência espacial e seu coeficiente equivale ao da regressão linear, indicando a inclusão da reta de regressão em um ambiente com autocorrelação espacial. Como o modelo trabalha com mais de 5,6 mil municípios, o número de vizinhanças é suficientemente alto para utilizar o I de Moran. Em caso de baixo número de unidades vizinhas, o melhor coeficiente é o G de Geary. Para os casos em que não há autocorrelação espacial, o mais indicado é usar o modelo de regressão linear. Portanto, testa-se a existência de autocorrelação espacial pelo I de Moran antes de aplicar o modelo de regressão espacial.

A melhor forma para identificar a autocorrelação espacial é a partir dos resíduos do I de Moran (*I Moran error*). Se os resíduos forem estatisticamente significativos, há presença de autocorrelação espacial e, portanto, pode-se usar modelos regressivos espaciais para explicar as variações. Os resultados do teste de resíduos para o modelo utilizado aqui são apresentados na tabela 2 a seguir. Uma vez identificada a dependência espacial, o passo seguinte é encontrar o melhor modelo autoregressivo espacial para explicar o fenômeno analisado. Existem dois modelos principais, o de erros espaciais e o de *lag* espacial, ambos descritos pela Figura 1, na sessão de Resultados.

A diferença entre eles diz respeito aos efeitos das variáveis dependentes entre unidades espaciais distintas. A seleção do melhor modelo a ser usado é baseada em valores de máxima verossimilhança dos modelos. O paper apresenta tais análises na Tabela 4, na sessão de Resultados. Previamente, é preciso considerar que, assim como qualquer modelo regressivo, o de autoregressão espacial não precisa respeitar os três pressupostos clássicos da regressão: (i) erros normais com média zero; (ii) homoqueadasticidade na distribuição dos erros; e (iii) erros não relacionados. Os testes de quebra de pressupostos são apresentados na Tabela 3.

Todo modelo espacial autoregressivo (SAR, sigla em inglês) considera que as observações em unidades vizinhas podem ajudar a explicar a variação de um valor qualquer em uma unidade espacial em relação às demais. Por definição, trata-se de um modelo onde as variáveis explicativas possuem dependência espacial com a variável explicada. Por exemplo, os votos para um partido em determinado município, entre outras coisas, podem ser explicados pelos votos obtidos no município vizinho. A função matemática do modelo SAR é a seguinte:

$$y = \rho W_1 y + X\beta + \varepsilon$$

Considera-se Y a variável dependente; X a(s) variável(is) independente(s); β o coeficiente de regressão; e ε representa os erros aleatórios com média zero. Até aqui, todos os componentes da função são os mesmos de uma regressão clássica. No caso de existência espacial são acrescentados à função o W , que é a matriz de vizinhança ou ponderação espacial, e o ρ que é o coeficiente espacial autoregressivo. Em geral, SAR é o modelo que melhor explica quando há dependência espacial. (Rego e Pena, 2012). No entanto, é importante levar em conta o número de parâmetros independentes inseridos em funções espaciais nos modelos. Para cada nova variável em modelo de regressão, acrescenta-se um parâmetro. Por isso a recomendação técnica é sempre ser o mais "econômico" possível no número de variáveis explicativas em um modelo SAR, pois quanto mais parâmetros forem acrescentados ao modelo, mais distante ele fica da

essência do fenômeno que queremos estudar. No próximo tópico apresentam-se os resultados dos modelos SAR para desempenho do PT e PSDB nos dois turnos eleitorais, utilizando as duas variáveis explicativas propostas: IDH-M e participação do partido no percentual de votos de legenda no município para deputado federal.

3. RESULTADOS

Como não há garantias de que os modelos georegressivos são os melhores para a análise, primeiramente é preciso identificar se há associação geográfica entre a variável dependente e as variáveis explicativas (Anselin, 1988). Aqui, utiliza-se o teste de "erro do I de Moran" para identificar dependência espacial para os modelos explicativos do PT e PSDB, considerando os dois turnos da eleição presidencial de 2014. Entende-se dependência espacial quando o valor encontrado em determinada unidade depende em parte dos valores identificados em seus vizinhos. Os resultados são apresentados na Tabela 2 e todos os coeficientes mostram-se significativos, com poucas diferenças entre eles. Isso significa que, para os dois partidos, em ambos turnos, há dependência espacial entre o percentual de votos para o candidato à presidência do partido e as variáveis explicativas. A maior dependência espacial fica com PSDB, no primeiro turno, com coeficiente de 0,692 de erro de I de Moran. O menor é do PT, também no primeiro turno, com 0,576. Com isso, descarta-se a realização de regressão linear múltipla e se avança para a problematização de se as variáveis explicativas podem ser usadas, juntas, no modelo e qual o melhor tipo de regressão espacial para as análises propostas.

Tabela 2 - Teste de resíduos de I de Moran para modelos explicativos do PT e PSDB

Teste	Turno	PT	PSDB
<i>I Moran error</i>	1	0,576 (0,000)	0,692 (0,000)
	2	0,596 (0,000)	0,661 (0,000)

Fonte: Autores

Uma vez definida a dependência espacial é preciso identificar se o modelo não quebra os pressupostos da não colinearidade e da distribuição normal dos erros. Se as variáveis independentes apresentarem variação colinear, isso quebra o pressuposto da independência das observações e impede a leitura dos resultados de um teste de regressão (Anselin, 1988). Ainda, os erros também não podem apresentar tendência ou qualquer tipo de associação, pois geraria um comportamento de heteroquedasticidade dos resíduos, inviabilizando também a análise do teste de regressão. O teste de colinearidade entre variáveis explicativas para dados geoespaciais é baseado em análises de curtose e estabelece como limite crítico o valor de 20,0 unidades. Se os resultados ficarem abaixo desse limite, não há colinearidade entre as variáveis explicativas. Em complemento, o teste de normalidade de erros usado pelo trabalho é o de Jarque-bera, que segue os mesmos princípios de testes, com limite crítico para significância estatística em 0,050. Os resultados da Tabela 3 mostram que o modelo não é colinear e apresenta normalidade da distribuição de erros. O coeficiente de multicolinearidade fica em 9,59 para os modelos do PT e em 9,93 para os dos PSDB. Aqui, a colinearidade é a mesma no primeiro e segundo turnos porque as variáveis explicativas são as mesmas nos dois casos. O teste de Jarque-bera também indica que para os quatro modelos os erros se distribuem sem uma tendência, ou seja, as duas variáveis podem ser usadas no modelo de regressão espacial para identificar os efeitos dos votos de legenda e da diferença de IDH-M para explicar as variações dos percentuais de votos para presidente do Brasil em 2014.

Tabela 3 - Testes de colinearidade e normalidade de erros para os modelos SAR

Modelo	Turno	Multicolinearidade	Normalidade dos erros (Jarque-bera)
PT	1	9,59	17,625 (0,000)
	2		21,261 (0,000)
PSDB	1	9,93	198,130 (0,000)
	2		43,249 (0,000)

Fonte: Autores

Vencidas as etapas de identificação da dependência espacial e das análises de colinearidade e distribuição de erros, é preciso estabelecer qual o melhor modelo regressivo espacial para delimitar as características do fenômeno estudado. Existem dois grandes modelos de dependência espacial, como exposto pela Figura 1. O primeiro é o de "error spatial", onde as diferenças ou os termos de erros entre diferentes unidades espaciais estão correlacionados. No entanto, o valor da variável explicativa X_i de uma unidade espacial tem efeitos sobre a variável dependente Y , mas não está associada à explicativa X_j da unidade espacial vizinha. O segundo modelo é do "lag spatial", onde a variável X_i de uma unidade vizinha, além de interferir na variável Y da unidade analisada também sobre influência da variável X_j da unidade vizinha. Aqui, quando ocorre um "retardo" espacial, percebe-se múltiplas associações, conforme quadros a seguir (Anselin, 1988).

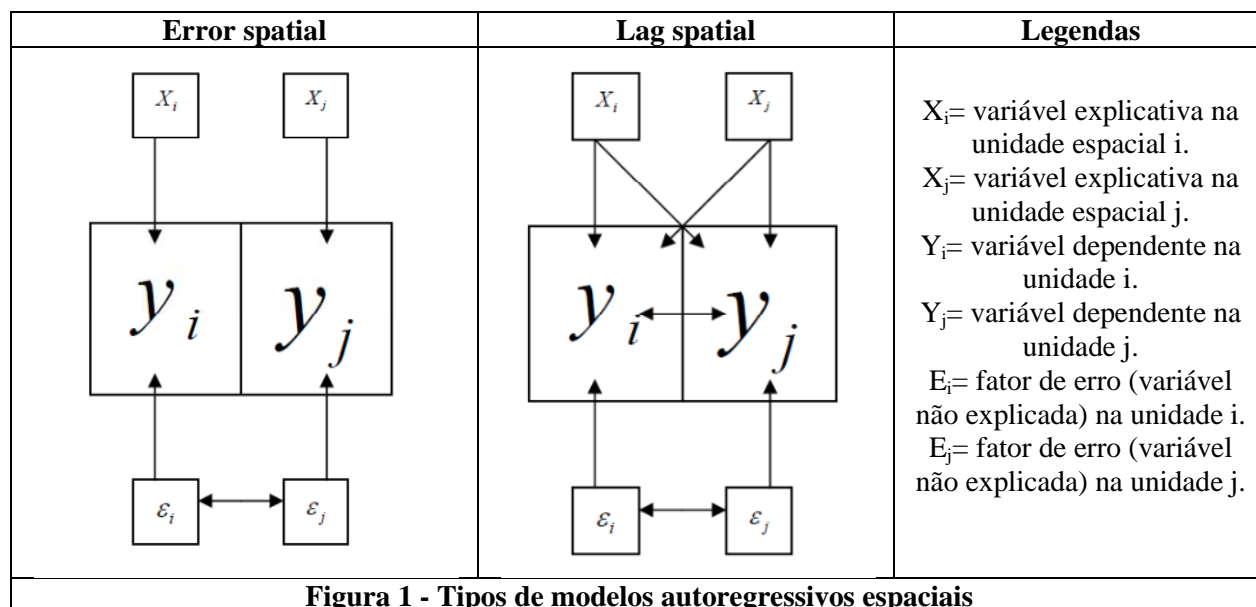


Figura 1 - Tipos de modelos autoregressivos espaciais

Fonte: Anselin, 1988

A melhor maneira de escolha do modelo é considerar o tipo de variável e como elas se relacionam com a teoria utilizada. Quando tal decisão não é possível através da teoria - como o caso analisado pelo presente trabalho - existem alguns coeficientes que podem ser utilizados para definir o melhor modelo explicativo. O caso analisado não possibilita tal delimitação prévia pois uma variável independente pode ter influência sobre a dependente de maneira isolada ou associada à outra explicativa, ou seja, o desenvolvimento do município na última década (IDH-M) não apenas pode interferir nos percentuais de voto para presidente, como também pode explicar as variações de votos de legenda, pois a literatura mostra que votos de legenda tendem a estar associados com eleitores com maior

desenvolvimento econômico e cultural. Dadas tais características, opta-se por usar os indicadores estatísticos para definir o modelo de análise. São comparados três coeficientes. O primeiro é o *log likelihood*, que está presente como função padrão dos modelos básicos de regressão e sustenta-se na hipótese de normalidade das distribuições de variáveis. Quanto maior o *log likelihood*, melhor é o modelo. O segundo é o critério Schwarz, que tem a mesma função do anterior, porém, com valores analisados no sentido oposto. Quanto menor o valor, mas adequado é o modelo. Por fim, o coeficiente de determinação (r^2), que identifica quão ajustado está o modelo para identificar a determinação do conjunto de variáveis explicativas sobre a variação da variável dependente.

A Tabela 4 mostra os resultados dos três indicadores para os modelos analíticos do desempenho do PT e PSDB nos dois turnos eleitorais. Percebe-se uma proximidade grande de valores entre eles, com *error spatial* mostrando-se um pouco melhor no *log likelihood* e Schwarz para os modelos do PT e *lag spatial* um pouco mais ajustado para os modelos do PSDB nos dois turnos. Como o objetivo é comparar os efeitos das variáveis dependentes sobre as votações dos dois partidos, opta-se por usar o mesmo modelo para os dois partidos e considera-se o coeficiente de determinação (r^2) para defini-lo melhor (Anselin, 1988). No caso, o *error spatial* mostrou um coeficiente de determinação superior ao do *lag spatial* nos quatro casos. Assim, escolhe-se o modelo de erro espacial, que considera tanto o efeito da variável dependente sobre a variável independente da vizinhança, quanto o efeito conjunto de outra variável explicativa sobre a mesma unidade de análise.

Tabela 4 - Indicadores dos modelos "lag" e "erro" espacial

Turno	Modelos	PT			PSDB		
		r^2	<i>Log likelihood</i>	Critério Schwarz	r^2	<i>Log likelihood</i>	Critério Schwarz
1	<i>Lag spatial</i>	0,835	-19.556,9	39.148,3	0,854	-18.908,1	37.850,6
	<i>Error spatial</i>	0,841	-19.627,6	39.281,1	0,872	-18.670,3	37.366,5
2	<i>Lag spatial</i>	0,832	-19.227,5	38.463,1	0,830	-19.287,0	38.608,5
	<i>Error spatial</i>	0,840	-19.252,6	38.531,1	0,845	-19.154,7	38.335,3

Fonte: Autores

Identificado o melhor modelo de regressão com dependência espacial (por erro espacial), pode-se, finalmente, verificar os efeitos individuais das variáveis independentes na explicação do desempenho eleitoral dos candidatos a presidente pelo PT e PSDB por município brasileiro em 2014. A tabela 5 sumariza as principais informações das variáveis para explicar a variação espacial dos percentuais de voto a presidente (todas as estatísticas dos quatro modelos estão nos anexos ao final do texto). Os modelos incluem a estatística *Lambda*, que é um coeficiente adicional dos erros espacialmente correlacionados. A *Lambda* dos quatro modelos (PT e PSDB, no primeiro e segundo turnos) é significativa indicado alta correlação espacial dos erros. Como os valores são muito próximos, variando de 120,572 no 2º turno do PSDB até 138,360 do primeiro turno do mesmo partido, isso significa que os erros espaciais são muito próximos entre todos os casos.

Tabela 5 - Principais estatísticas dos Modelos SAR para PT e PSDB no 1º e 2º turnos

	Estatísticas	PT			PSDB		
		Coef.	Z	p	Coef.	Z	p
1º Turno	Dif. IDH-M	88,501	23,748	0,000	-33,071	-10,571	0,000
	%Vot.Leg.Fed.	0,386	22,424	0,000	0,462	32,173	0,000
	Lambda	0,884	130,106	0,000	0,894	138,360	0,000
	Estatísticas	PT			PSDB		
		Coef.	Z	p	Coef.	Z	p
2º Turno	Dif. IDH-M	70,781	20,349	0,000	-49,434	-14,372	0,000
	%Vot.Leg.Fed.	0,355	22,065	0,000	0,398	25,500	0,000
	Lambda	0,889	133,899	0,000	0,872	120,572	0,000

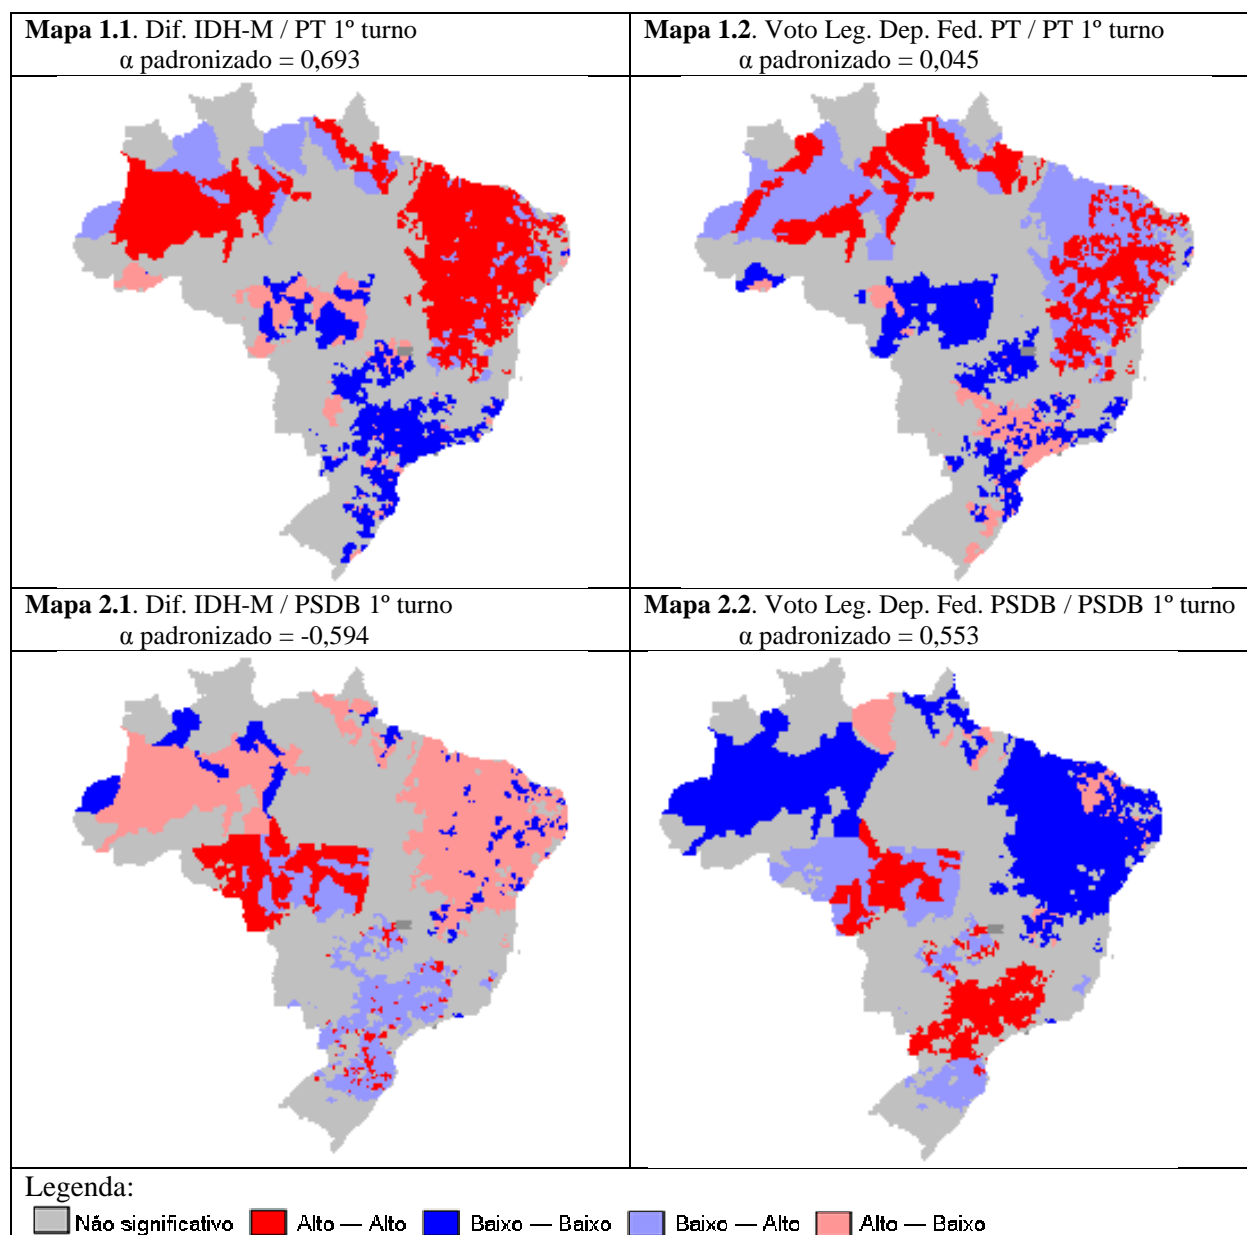
Fonte: Autores

No entanto, as estatísticas individuais mostram diferenças entre os modelos. A estatística Z é o valor padronizado do modelo, portanto, podendo ser usada para comparar efeitos de variáveis de distintas dimensões, como é o nosso caso: desenvolvimento humano e votos de legenda. Como esperado, a diferença do IDH-M apresenta associação positiva com voto no PT e negativa com voto no PSDB. O Z para diferença de IDH-M e voto no PT no 1º turno é de 23,748, caindo para 20,349 no 2º turno. Já o coeficiente Z de IDH-M do PSDB no primeiro turno é de -10,571, indicando associação inversa, ou seja, quanto maior a diferença de IDH, menor tende a ser o percentual de votos no PSDB no município. E no segundo turno o efeito cresce ainda mais, passando a Z de -14,372. Isso indica que nos dois turnos o PSDB tendeu a ter mais votos em municípios com menor diferença de IDH, mas a tendência aumentou no segundo turno, quando comparado ao desempenho do partido no primeiro turno.

Quanto à associação com o percentual de votos de legenda, os modelos também apresentam resultados esperados, com associações positivas nos quatro modelos. Porém, as associações do partido de oposição, PSDB, foram superiores ao do partido mandatário. A associação mais forte encontrada nos modelos comparados são do PSDB no primeiro turno, com Z de 32,173. No segundo turno o coeficiente caiu para 25,500, ainda assim superior aos dois coeficientes encontrados para a associação com votos do PT, que foram de 22,424 e 22,065, respectivamente para primeiro e segundo turno.

Para completar a informação de associação espacial, utiliza-se a análise descritiva de mapas coropléticos do indicador local de associação espacial (LISA, sigla em inglês). Esse indicador, quando bivariado, mostra os clusters de associação espacial local entre duas variáveis (Anselin, 1995). Ao contrário do I de Moran, que indica o grau de associação espacial geral, o LISA mostra as associações locais por nível de significância e direção. Depois de randomizar os valores encontrados por permutações, ele identifica quais vizinhanças apresentam resultados estatisticamente significativos. Aqui, foram usadas 499 permutações para identificar a significância estatística das associações espaciais entre a variável dependente e uma das explicativas. Os mapas a seguir mostram cinco possibilidades de comportamento de associação local pelo indicador LISA. O primeiro, cor cinza, mostra as regiões onde os coeficientes de vizinhança entre voto para presidente e uma das variáveis explicativas não é significativo. As áreas com a cor vermelha escura mostram as áreas de vizinhança onde houve presença de valor alto para as duas variáveis e as áreas com azul escuro onde foi constatada vizinhança de baixos valores para as duas variáveis. O vermelho claro e o azul claro são áreas com vizinhança estatisticamente significativa, porém, entre valor alto para uma variável e baixo para a outra. Dada a similaridade dos modelos para 1º e 2º turnos, apresenta-se os resultados LISA apenas para o 1º turno. Para fins comparativos, acrescenta-se o indicador de

inclinação da reta de regressão (α padronizado) para cada uma das associações bivariadas LISA.



O maior α padronizado dos quatro modelos está no Mapa 1.1, para associação entre diferença do IDH-M e percentual de votos para presidente do PT. Nas regiões Nordeste e Norte há predomínio de clusters alto-alto e no Sul e Sudeste o predomínio de clusters baixo-baixo. O segundo maior α padronizado é negativo (-0,594) e refere-se à associação entre diferença de IDH-M e votos para presidente no PSDB (Mapa 2.1). É praticamente a inversão do mapa anterior, com predomínio de alto-baixo na região Nordeste, o que significa que nessa área, onde houve grande crescimento de IDH-M, o PSDB teve menor votação; e baixo-alto no Sul e Sudeste, ou seja, onde PSDB tendeu a ter mais votos os municípios apresentaram menor diferença de IDH-M. Apenas na região Centro-oeste do País é que percebe-se uma mancha de vizinhança maior entre municípios alto-alto, ou seja, onde houve maior diferença de IDH-M nessa região o PSDB tendeu a apresentar melhor desempenho para seu candidato a presidente.

Quanto às associações com as variáveis políticas, o maior α padronizado é do Mapa 2.2, entre votos de legenda para deputado federal e para presidente do PSDB (0,553). Há predomínio de áreas de vizinhança alto-alto, Sudeste e Centro-oeste do País, indicando associação entre os percentuais de voto na legenda para deputado federal do PSDB e para Aécio Neves para presidente. Por outro lado, nas regiões Nordeste e Norte, percebe-se grandes áreas de vizinhança para baixo-baixo, reforçando a ideia de que o candidato a PSDB tendeu a ter maior votação em áreas onde o partido recebeu mais votos de legenda para deputado federal. Já o mapa bivariado da LISA para votos de legenda e para a candidata a presidente do PT apresentou o menor α padronizado (0,045), indicando ser a associação mais fraca entre as quatro apresentadas aqui. Percebe-se que as vizinhanças significativas (alto-alto) e (baixo-baixo) são "cortadas" por áreas de municípios com alto-baixo ou baixo-alto, reduzindo o efeito de vizinhança local. Embora seja possível identificar associação de vizinhança em algumas regiões do mapa, ela não é tão forte quanto as apresentadas nos outros mapas.

4. CONCLUSÕES

Assim como proposto no modelo de Campbell (1948) para as eleições presidenciais norte-americanas e já testado por Soares e Terron (2008) e Terron e Soares (2010) em disputas nacionais brasileiras anteriores, os padrões de votação para os dois principais candidatos a presidente do Brasil em 2014 indicaram forte associação espacial entre ações governamentais (políticas públicas) e estruturação partidária. Na análise desenvolvida pelo presente trabalho, constatou-se uma associação positiva forte entre desenvolvimento do município, medido pela diferença do IDH-M, e percentual de voto na candidata à reeleição. Neste caso, a associação foi positiva. Para o principal opositor, a associação também foi forte, porém, no sentido inverso. Onde houve maior diferença de IDH-M, o PSDB tendeu a apresentar os menores percentuais de votação. Em complemento, a associação mais forte para os votos a presidente do candidato do PSDB foi observada com a estruturação partidária local, aqui medida pela participação do partido nos votos de legenda para deputado federal no município. Em localidade onde o PSDB teve maior participação nos votos de legenda para deputado federal, houve uma tendência de crescimento nos percentuais de votos para o candidato do partido à presidência. Já no caso do PT, as associações entre percentual de voto para presidente e respectiva participação do partido em votos de legenda são mais fracas. Esse comportamento foi percebido tanto no primeiro quanto no segundo turno.

Além da indicação de autocorrelação espacial entre voto para presidente com variáveis sociais e políticas, o indicador de associação local (LISA) mostrou que as vizinhanças estatisticamente significativas foram regionalmente localizadas em 2014. No caso do PT, a associação positiva entre maior diferença de IDH-M e voto para presidente localizou-se principalmente no Nordeste e Norte, enquanto nas regiões Sul e Sudeste a associação local mais significativa foi entre menor diferença de IDH-M e baixa votação para a candidata do PT. No caso do PSDB a associação de vizinhança entre IDH-M e votos para presidente foi invertida, porém, manteve-se predominantemente positiva entre votos de legenda e votos para candidato a presidente pelo partido. Nas regiões Norte e Nordeste, nota-se associação entre baixa votação de legenda e baixa votação para presidente do PSDB, enquanto que no Sudeste predominam municípios vizinhos com alta votação para legenda de deputado federal e alta votação para Aécio Neves. Tão importante quanto identificar as associações locais significativas é levar em conta as extensas áreas estatisticamente não significativas nos Mapas 1.1 a 2.2 (cor cinza). Elas mostram os espaços onde não é possível encontrar associação local entre as variáveis

inseridas no modelo, ou seja, onde não há cluster por vizinhança. Em especial no centro da região Norte e no extremo oeste da região Centro-oeste não há formação de cluster em nenhum dos mapas.

A ausência de clusters nas duas sub-regiões apontadas acima indica uma das limitações deste *paper*, pois não apresentam-se explicações para aqueles comportamentos específicos, conclusão que torna-se objeto para futuros trabalhos. Apesar dos resultados apresentados aqui terem comprovado a hipótese inicial presente na literatura, é necessário considerar as limitações do modelo. Por ser uma primeira aproximação ao tema, não pode-se garantir que as variáveis independentes utilizadas são as melhores para explicar as variações de voto para presidente por município. Campbell (1948) usa um conjunto de sete variáveis políticas e cinco variáveis socioeconômicas em seu modelo original. Como decidiu-se testar o modelo de Campbell acrescentando a dependência espacial, optou-se por reduzir o número de variáveis independentes a apenas duas para evitar a sobreposição de parâmetros no modelo de regressão espacial. Identificar qual o número adequado de variáveis sociais e políticas em um modelo de regressão espacial e, além disso, quais são as variáveis explicativas mais adequadas, são desafios para o avanço desse tipo de pesquisa.

5. REFERÊNCIAS

ANSELIN, Luc. **Spatial Econometrics: methods and models**. Kluwer Academic Publishers: Dordrecht, 1988.

_____. Local indicators of spatial association — LISA. **Geographical Analysis**, 27, 1995 (p.93 a 115).

GELMAN, Andrew & KING, Gary. Why Are American Presidential Election Campaign Polls So Variable When Votes Are So Predictable? **British Journal of Political Science**: 23, 1993 (p.409 a 451)

GUARNIERI, F. Comportamento eleitoral e estratégia partidária nas eleições presidenciais no Brasil (2002 - 2010). **Opinião Pública**, v. 20, n. 2, p. 157–177, 2014.

KERKAUY, M. T. M. Os programas de transferência de renda e o voto regional nas eleições presidenciais de 2010. **Opinião Pública**, v. 17, n. 2, p. 477–492, 2011.

KING, Gary. Electoral Responsiveness and Partisan Bias in multiparty democracies. **Legislative Studies Quarterly**. XV, 2, maio 1990 (p 159 a 181).

MARZAGÃO, T. A dimensão geográfica das eleições brasileiras. **Opinião Pública**, v. 19, n. 2, p. 270–290, 2013.

NICOLAU, J. M. **Vermelhos e Azuis: um estudo sobre os determinantes do voto nas eleições presidenciais brasileiras (2002-2010)** IX ENCONTRO DA ABCP AT: Anais...Brasília: 2014

PEIXOTO, V.; RENNÓ, L. Mobilidade social ascendente e voto: as eleições presidenciais de 2010 no Brasil. **Opinião Pública**, v. 17, p. 304–332, 2011.

RENNÓ, L.; CABELLO, A. As bases do Lulismo: a volta do personalismo, realinhamento ideológico ou não alinhamento? **Revista Brasileira de Ciências Sociais**, v. 25, p. 39–60, 2010.

SOARES, G. A. D.; TERRON, S. L. Dois Lulas: a geografia eleitoral da reeleição (explorando conceitos, métodos e técnicas de análise geoespacial). **Opinião Pública**, v. 14, n. 2, p. 269–301, 2008.

TERRON, S. L.; SOARES, G. A. D. As bases eleitorais de Lula e do PT: do distanciamento ao divórcio. **Opinião Pública**, v. 16, n. 2, p. 310–337, 2010.

ANEXO

PRIMEIRO TURNO				
PT		PSDB		
ORDINARY LEAST SQUARES ESTIMATION				
Data set	: 55mu2500gsd			
Dependent Variable	: PPRES_PT			
Number of Observations	: 5566			
Mean dependent var	: 52,2172			
Number of Variables	: 3			
S.D. dependent var	: 18,541			
Degrees of Freedom	: 5563			
R-squared	: 0,444157			
F-statistic	: 2222,61			
Adjusted R-squared	: 0,443957			
Prob(F-statistic)	: 0			
Sum squared residual	: 1,06355e+006			
Log likelihood	: -22516,1			
Sigma-square	: 191,184			
Akaike info criterion	: 45038,1			
S.E. of regression	: 13,8269			
Schwarz criterion	: 45058			
Sigma-square ML	: 191,081			
S.E. of regression ML	: 13,8232			

Variable	Coef	Std.Error	t-Statistic	Probability

CONSTANT	2,617	0,843	3,102	0,0019262
DIFF_IDHM	308,6	4,640	66,519	0,0000000
PFED_LEGPT	0,388	0,020	18,841	0,0000000

REGRESSION DIAGNOSTICS				
MULTICOLLINEARITY CONDITION NUMBER	9,592271			
TEST ON NORMALITY OF ERRORS				
TEST	DF	VALUE	PROB	
Jarque-Bera	2	17,62552	0,0001488	
DIAGNOSTICS FOR HETEROSKEDASTICITY				
RANDOM COEFFICIENTS				
TEST	DF	VALUE	PROB	
Breusch-Pagan test	2	111,6915	0,0000000	
Koenker-Bassett test	2	128,5098	0,0000000	
SPECIFICATION ROBUST TEST				
TEST	DF	VALUE	PROB	
White	5	154,06	0,0000000	
DIAGNOSTICS FOR SPATIAL DEPENDENCE				
FOR WEIGHT MATRIX : 55mu2500gsd.gal				
(row-standardized weights)				
TEST	MI/DF	VALUE	PROB	
Moran's I (error)	0,576	71,206	0,0000000	
Lagrange Multiplier (lag)	1	6007,72	0,0000000	
Robust LM (lag)	1	1255,50	0,0000000	
Lagrange Multiplier (error)	1	5051,74	0,0000000	
Robust LM (error)	1	299,52	0,0000000	
Lagrange Multiplier (SARMA)2		6307,24	0,0000000	
===== END OF REPORT				
SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION				
Data set	: 55mu2500gsd			
Spatial Weight	: 55mu2500gsd.gal			
Dependent Variable	: PPRES_PT			
Number of Observations	: 5566			
Mean dependent var	: 52,2172			
Number of Variables	: 4			
S.D. dependent var	: 18,541			
Degrees of Freedom	: 5562			
Lag coeff. (Rho)	: 0,790308			
R-squared	: 0,835548			
Log likelihood	: -19556,9			
Sq. Correlation	: -			
ORDINARY LEAST SQUARES ESTIMATION				
Data set	: 55mu2500gsd			
Dependent Variable	: PPRES_PSDB			
Number of Observations	: 5566			
Mean dependent var	: 32,7797			
Number of Variables	: 3			
S.D. dependent var	: 17,3572			
Degrees of Freedom	: 5563			
R-squared	: 0,457588			
F-statistic	: 2346,52			
Adjusted R-squared	: 0,457393			
Prob(F-statistic)	: 0			
Sum squared residual	: 909566			
Log likelihood	: -22080,8			
Sigma-square	: 163,503			
Akaike info criterion	: 44167,6			
S.E. of regression	: 12,7868			
Schwarz criterion	: 44187,5			
Sigma-square ML	: 163,415			
S.E. of regression ML	: 12,7834			

Variable	Coefficient	Std.Error	t-Statistic	Probability

CONSTANT	49,06427	0,806375	60,845	0,000000
DIFF_IDHM	-184,3327	4,671783	-39,456	0,000000
PFED_LEGPS	0,425653	0,0129992	32,740	0,000000

REGRESSION DIAGNOSTICS				
MULTICOLLINEARITY CONDITION NUMBER	9,931711			
TEST ON NORMALITY OF ERRORS				
TEST	DF	VALUE	PROB	
Jarque-Bera	2	198,1304	0,0000000	
DIAGNOSTICS FOR HETEROSKEDASTICITY				
RANDOM COEFFICIENTS				
TEST	DF	VALUE	PROB	
Breusch-Pagan test	2	191,8297	0,0000000	
Koenker-Bassett test	2	177,2562	0,0000000	
SPECIFICATION ROBUST TEST				
TEST	DF	VALUE	PROB	
White	5	331,72	0,0000000	
DIAGNOSTICS FOR SPATIAL DEPENDENCE				
FOR WEIGHT MATRIX : 55mu2500gsd.gal				
(row-standardized weights)				
TEST	MI/DF	VALUE	PROB	
Moran's I (error)	0,692156	85,422	0,000	
Lagrange Multiplier (lag)	1	7104,876	0,000	
Robust LM (lag)	1	503,593	0,000	
Lagrange Multiplier (error)	1	7271,210	0,000	
Robust LM (error)	1	669,926	0,000	
Lagrange Multiplier (SARMA)2		7774,803	0,000	
===== END OF REPORT				
SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION				
Data set	: 55mu2500gsd			
Spatial Weight	: 55mu2500gsd.gal			
Dependent Variable	: PPRES_PSDB			
Number of Observations	: 5566			
Mean dependent var	: 32,7797			
Number of Variables	: 4			
S.D. dependent var	: 17,3572			
Degrees of Freedom	: 5562			
Lag coeff. (Rho)	: 0,823709			
R-squared	: 0,854217			
Log likelihood	: -18908,1			
Sq. Correlation	: -			

Akaike info criterion : 39121,8
 Sigma-square : 56,5331
 Schwarz criterion : 39148,3
 S.E of regression : 7,51885

Variable	Coefficient	Std.Error	z-value	Probability
W_PPRES_PT	0,790	0,007	105,495	0,000
CONSTANT	-5,745	0,464	-12,364	0,000
DIFF_IDHM	93,361	3,161	29,534	0,000
PFED_LEGPT	0,218	0,011	18,594	0,000

===== END OF REPORT

SPATIAL ERROR MODEL - MAXIMUM LIKELIHOOD ESTIMATION

Data set : 55mu2500gsd
 Spatial Weight : 55mu2500gsd.gal
 Dependent Variable : PPRES_PT
 Number of Observations: 5566
 Mean dependent var : 52,217188
 Number of Variables : 3
 S.D. dependent var : 18,540957
 Degrees of Freedom : 5563
 Lag coeff. (Lambda) : 0,884918

R-squared : 0,841472
 R-squared (BUSE) :-
 Sq. Correlation :-
 Log likelihood :-19627,607414
 Sigma-square : 54,4966
 Akaike info criterion : 39261,2
 S.E of regression : 7,38218
 Schwarz criterion : 39281,1

Variable	Coefficient	Std.Error	z-value	Probability
CONSTANT	33,550	1,051	31,903	0,0000000
DIFF_IDHM	88,501	3,726	23,748	0,0000000
PFED_LEGPT	0,386	0,017	22,424	0,0000000
LAMBDA	0,8842	0,006	130,106	0,0000000

REGRESSION DIAGNOSTICS
 DIAGNOSTICS FOR HETEROSKEDASTICITY
 RANDOM COEFFICIENTS

TEST	DF	VALUE	PROB
Breusch-Pagan test	2	79,54528	0,0000000

DIAGNOSTICS FOR SPATIAL DEPENDENCE
 SPATIAL ERROR DEPENDENCE FOR WEIGHT MATRIX :
 55mu2500gsd.gal

TEST	DF	VALUE	PROB
Likelihood Ratio Test	1	5776,912	0,0000000

===== END OF REPORT

Akaike info criterion : 37824,1
 Sigma-square : 43,9208
 Schwarz criterion : 37850,6
 S.E of regression : 6,62727

Variable	Coefficient	Std.Error	z-value	Probability
W_PPRES_PSDB	0,823	0,007	106,280	0,0000000
CONSTANT	8,134	0,503	16,145	0,0000000
DIFF_IDHM	-35,979	2,615	-13,754	0,0000000
PFED_LEGPS	0,119	0,008	14,127	0,0000000

===== END OF REPORT

SPATIAL ERROR MODEL - MAXIMUM LIKELIHOOD ESTIMATION

Data set : 55mu2500gsd
 Spatial Weight : 55mu2500gsd.gal
 Dependent Variable : PPRES_PSDB
 Number of Observations: 5566
 Mean dependent var : 32,779718
 Number of Variables : 3
 S.D. dependent var : 17,357248
 Degrees of Freedom : 5563
 Lag coeff. (Lambda) : 0,894159

R-squared : 0,872729
 R-squared (BUSE) :-
 Sq. Correlation :-
 Log likelihood :-18670,307936
 Sigma-square : 38,3436
 Akaike info criterion : 37346,6
 S.E of regression : 6,19222
 Schwarz criterion : 37366,5

Variable	Coefficient	Std.Error	z-value	Probability
CONSTANT	26,687	0,942	28,319	0,0000000
DIFF_IDHM	-33,071	3,128	-10,571	0,0000000
PFED_LEGPS	0,462	0,014	32,173	0,0000000
LAMBDA	0,894	0,006	138,360	0,0000000

REGRESSION DIAGNOSTICS
 DIAGNOSTICS FOR HETEROSKEDASTICITY
 RANDOM COEFFICIENTS

TEST	DF	VALUE	PROB
Breusch-Pagan test	2	32,72957	0,0000001

DIAGNOSTICS FOR SPATIAL DEPENDENCE
 SPATIAL ERROR DEPENDENCE FOR WEIGHT MATRIX :
 55mu2500gsd.gal

TEST	DF	VALUE	PROB
Likelihood Ratio Test	1	6820,966	0,0000000

===== END OF REPORT

SEGUNDO TURNO

PT					PSDB				
ORDINARY LEAST SQUARES ESTIMATION					ORDINARY LEAST SQUARES ESTIMATION				
Data set : 55mu2500gsd					Data set : 55mu2500gsd				
Dependent Variable : PPRES2T_PT					Dependent Variable : PPRES2T_PS				
Number of Observations: 5566					Number of Observations: 5566				
Mean dependent var : 54,9239					Mean dependent var : 40,2568				
Number of Variables : 3					Number of Variables : 3				
S.D. dependent var : 17,2322					S.D. dependent var : 17,3571				
Degrees of Freedom : 5563					Degrees of Freedom : 5563				
R-squared : 0,408390					R-squared : 0,450716				
F-statistic : 1920,08					F-statistic : 2282,37				
Adjusted R-squared : 0,408178					Adjusted R-squared : 0,450519				
Prob(F-statistic) : 0					Prob(F-statistic) : 0				
Sum squared residual: 977822					Sum squared residual: 921075				
Log likelihood : -22282,2					Log likelihood : -22115,8				
Sigma-square : 175,772					Sigma-square : 165,572				
Akaike info criterion : 44570,3					Akaike info criterion : 44237,6				
S.E. of regression : 13,2579					S.E. of regression : 12,8675				
Schwarz criterion : 44590,2					Schwarz criterion : 44257,4				
Sigma-square ML : 175,678					Sigma-square ML : 165,482				
S.E of regression ML: 13,2543					S.E of regression ML: 12,864				
-----					-----				
Variable	Coefficient	Std.Error	t-Statistic	Probability	Variable	Coefficient	Std.Error	t-Statistic	Probability
CONSTANT	12,273	0,808	15,171	0,0000000	CONSTANT	58,902	0,811	72,587	0,0000000
DIFF_IDHM	275,717	4,449	61,968	0,0000000	DIFF_IDHM	-195,447	4,701	-41,573	0,0000000
PFED_LEGPT	0,264	0,019	13,359	0,0000000	PFED_LEGPS	0,383	0,013	29,346	0,0000000
-----					-----				
REGRESSION DIAGNOSTICS					REGRESSION DIAGNOSTICS				
MULTICOLLINEARITY CONDITION NUMBER 9,592271					MULTICOLLINEARITY CONDITION NUMBER 9,931711				
TEST ON NORMALITY OF ERRORS					TEST ON NORMALITY OF ERRORS				
TEST	DF	VALUE	PROB		TEST	DF	VALUE	PROB	
Jarque-Bera	2	21,26948	0,0000241		Jarque-Bera	2	43,24931	0,0000000	
DIAGNOSTICS FOR HETEROSKEDASTICITY					DIAGNOSTICS FOR HETEROSKEDASTICITY				
RANDOM COEFFICIENTS					RANDOM COEFFICIENTS				
TEST	DF	VALUE	PROB		TEST	DF	VALUE	PROB	
Breusch-Pagan test	2	82,63141	0,0000000		Breusch-Pagan test	2	90,94892	0,0000000	
Koenker-Bassett test	2	94,06786	0,0000000		Koenker-Bassett test	2	90,06541	0,0000000	
SPECIFICATION ROBUST TEST					SPECIFICATION ROBUST TEST				
TEST	DF	VALUE	PROB		TEST	DF	VALUE	PROB	
White	5	97,97456	0,0000000		White	5	282,561	0,0000000	
DIAGNOSTICS FOR SPATIAL DEPENDENCE					DIAGNOSTICS FOR SPATIAL DEPENDENCE				
FOR WEIGHT MATRIX : 55mu2500gsd.gal					FOR WEIGHT MATRIX : 55mu2500gsd.gal				
(row-standardized weights)					(row-standardized weights)				
TEST		MI/DF	VALUE	PROB	TEST		MI/DF	VALUE	PROB
Moran's I (error)		0,596	73,6071888	0,0000000	Moran's I (error)		0,661515	81,643289	0,0000000
Lagrange Multiplier (lag)	1		6268,7786197	0,0000000	Lagrange Multiplier (lag)	1		6591,00236	0,0000000
Robust LM (lag)	1		1161,1778734	0,0000000	Robust LM (lag)	1		529,60588	0,0000000
Lagrange Multiplier (error)	1		5398,3346919	0,0000000	Lagrange Multiplier (error)	1		6641,6729	0,0000000
Robust LM (error)	1		290,7339456	0,0000000	Robust LM (error)	1		580,2764	0,0000000
Lagrange Multiplier (SARMA)2			6559,5125653	0,0000000	Lagrange Multiplier (SARMA)2			7171,278	0,0000000
===== END OF REPORT					===== END OF REPORT				
SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION					SPATIAL LAG MODEL - MAXIMUM LIKELIHOOD ESTIMATION				
Data set : 55mu2500gsd					Data set : 55mu2500gsd				
Spatial Weight : 55mu2500gsd.gal					Spatial Weight : 55mu2500gsd.gal				
Dependent Variable : PPRES2T_PT					Dependent Variable : PPRES2T_PS				
Number of Observations: 5566					Number of Observations: 5566				
Mean dependent var : 54,9239					Mean dependent var : 40,2568				
Number of Variables : 4					Number of Variables : 4				
S.D. dependent var : 17,2322					S.D. dependent var : 17,3571				
Degrees of Freedom : 5562					Degrees of Freedom : 5562				
Lag coeff. (Rho) : 0,808199					Lag coeff. (Rho) : 0,79836				
R-squared : 0,832558					R-squared : 0,830448				
Log likelihood : -19227,5					Log likelihood : -19287				
Sq. Correlation :-					Sq. Correlation :-				
Akaike info criterion : 38463,1					Akaike info criterion : 38582				

Sigma-square : 49,7216					Sigma-square : 51,0808				
Schwarz criterion : 38489,6					Schwarz criterion : 38608,5				
S.E of regression : 7,05135					S.E of regression : 7,14708				
-----					-----				
Variable	Coefficient	Std.Error	z-value	Probability	Variable	Coefficient	Std.Error	z-value	Probability
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----
W_PPRES2T_PT	0,808	0,007	109,1283	0,0000000	W_PPRES2T_PS	0,798	0,008	95,335	0,0000000
CONSTANT	-3,014	0,449	-6,7096	0,0000000	CONSTANT	12,620	0,605	20,831	0,0000000
DIFF_IDHM	75,730	2,892	26,183	0,0000000	DIFF_IDHM	-49,534	2,881	-17,193	0,0000000
PFED_LEGPT	0,177	0,010	16,226	0,0000000	PFED_LEGPS	0,101	0,008	11,799	0,0000000
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----
===== END OF REPORT					===== END OF REPORT				
Regression					Regression				
SUMMARY OF OUTPUT: SPATIAL ERROR MODEL -					SUMMARY OF OUTPUT: SPATIAL ERROR MODEL -				
MAXIMUM LIKELIHOOD ESTIMATION					MAXIMUM LIKELIHOOD ESTIMATION				
Data set : 55mu2500gsd					Data set : 55mu2500gsd				
Spatial Weight : 55mu2500gsd.gal					Spatial Weight : 55mu2500gsd.gal				
Dependent Variable : PPRES2T_PT					Dependent Variable : PPRES2T_PS				
Number of Observations: 5566					Number of Observations: 5566				
Mean dependent var : 54,923909					Mean dependent var : 40,256816				
Number of Variables : 3					Number of Variables : 3				
S.D. dependent var : 17,232193					S.D. dependent var : 17,357108				
Degrees of Freedom : 5563					Degrees of Freedom : 5563				
Lag coeff. (Lambda) : 0,889315					Lag coeff. (Lambda) : 0,872595				
R-squared : 0,840181					R-squared : 0,845909				
R-squared (BUSE) :-					R-squared (BUSE) :-				
Sq. Correlation :-					Sq. Correlation :-				
Log likelihood :-19252,631971					Log likelihood :-19154,721806				
Sigma-square : 47,4579					Sigma-square : 46,4229				
Akaike info criterion : 38511,3					Akaike info criterion : 38315,4				
S.E of regression : 6,88897					S.E of regression : 6,81343				
Schwarz criterion : 38531,1					Schwarz criterion : 38335,3				
-----					-----				
Variable	Coefficient	Std.Error	z-value	Probability	Variable	Coefficient	Std.Error	z-value	Probability
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----
CONSTANT	38,956	1,005	38,73703	0,0000000	CONSTANT	37,706	0,925	40,73384	0,0000000
DIFF_IDHM	70,781	3,478	20,3494	0,0000000	DIFF_IDHM	-49,434	3,439	-14,3721	0,0000000
PFED_LEGPT	0,355	0,016	22,06551	0,0000000	PFED_LEGPS	0,398	0,015	25,50068	0,0000000
LAMBDA	0,889	0,0066	133,8999	0,0000000	LAMBDA	0,872	0,007	120,5723	0,0000000
-----	-----	-----	-----	-----	-----	-----	-----	-----	-----
REGRESSION DIAGNOSTICS					REGRESSION DIAGNOSTICS				
DIAGNOSTICS FOR HETEROSKEDASTICITY					DIAGNOSTICS FOR HETEROSKEDASTICITY				
RANDOM COEFFICIENTS					RANDOM COEFFICIENTS				
TEST	DF	VALUE	PROB		TEST	DF	VALUE	PROB	
Breusch-Pagan test	2	66,98328	0,0000000		Breusch-Pagan test	2	8,282217	0,0159052	
DIAGNOSTICS FOR SPATIAL DEPENDENCE					DIAGNOSTICS FOR SPATIAL DEPENDENCE				
SPATIAL ERROR DEPENDENCE FOR WEIGHT MATRIX :					SPATIAL ERROR DEPENDENCE FOR WEIGHT MATRIX :				
55mu2500gsd.gal					55mu2500gsd.gal				
TEST	DF	VALUE	PROB		TEST	DF	VALUE	PROB	
Likelihood Ratio Test	1	6059,068	0,0000000		Likelihood Ratio Test	1	5922,119	0,0000000	
===== END OF REPORT					===== END OF REPORT				