

UNIVERSIDADE FEDERAL DE PELOTAS
Faculdade de Agronomia Eliseu Maciel/Faculdade de Administração e Turismo
Programa de Pós-Graduação em Desenvolvimento Territorial e Sistemas
Agroindustriais



Dissertação

**Modelagem espacial do crescimento do PIB em cenários distintos de
desempenho agrícola do estado do RS**

Francisco Mazzarolo Seger

Pelotas, 2019.

FRANCISCO MAZZAROLO SEGER

Modelagem espacial do crescimento do PIB em cenários distintos de desempenho agrícola do estado do RS

Dissertação apresentada ao Programa de Pós-Graduação em Desenvolvimento Territorial e Sistemas Agroindustriais da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Desenvolvimento Territorial e Sistemas Agroindustriais.

Orientador: Prof. Dr. Rogério Costa Campos
Coorientador: Prof. Dr. Mário Duarte Canever

Pelotas, 2019.

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação na Publicação

S454m Seger, Francisco Mazzarolo

Modelagem espacial do crescimento do PIB em cenários distintos de desempenho agrícola do estado do RS / Francisco Mazzarolo Seger ; Rogério Costa Campos, orientador ; Mário Duarte Canever, coorientador. — Pelotas, 2019.

112 f. : il.

Dissertação (Mestrado) — Programa de Pós-Graduação em Desenvolvimento territorial e sistemas agroindustriais, Faculdade de Administração e Turismo, Universidade Federal de Pelotas, 2019.

1. GWR. 2. GWSS. 3. Análise espacial. 4. Economia. 5. Desenvolvimento territorial. I. Campos, Rogério Costa, orient. II. Canever, Mário Duarte, coorient. III. Título.

CDD : 338.1

Francisco Mazzarolo Seger

Modelagem espacial do crescimento do PIB em cenários distintos de desempenho agrícola do estado do RS

Dissertação aprovada como requisito parcial, para obtenção do grau de Mestre em Desenvolvimento Territorial e Sistemas Agroindustriais, Programa de Pós-Graduação em Desenvolvimento Territorial e Sistemas Agroindustriais, Faculdade de Agronomia Eliseu Maciel/Faculdade de Administração e Turismo, Universidade Federal de Pelotas.

Data da Defesa: 03/09/2019.

Banca examinadora:

.....
Prof. Dr. Rogério Costa Campos
Doutor em Sensoriamento Remoto pelo Instituto Nacional de Pesquisas Espaciais

.....
Prof. Dr. Gabrielito Rauter Menezes
Doutor em Economia pelo pela Universidade Federal do Rio Grande do Sul

.....
Prof. Dr. José Marinaldo Gleriani
Doutor em Sensoriamento Remoto pelo Instituto Nacional de Pesquisas Espaciais

Agradecimentos

Aos meus pais, José Irineu Seger e Clara Mazzarolo Seger, que sempre me apoiaram, e me auxiliaram para superar todas as dificuldades, especialmente durante o mestrado.

Ao meu irmão Fabrício Mazzarolo Seger, que apesar da distância, sempre pude contar.

Ao professor orientador, Eng. Agrônomo Dr. Rogério Costa Campos, pessoa ímpar durante essa caminhada, obrigado pelos grandes conselhos durante o período que convivemos, conhecimentos transmitidos e, especialmente, pela amizade. Esse trabalho passou muito pela sua orientação e esse aluno agradece.

Ao professor coorientador, Eng. Agrônomo Dr. Mário Duarte Canever, obrigado por todos os conselhos e orientação ao longo desse período do mestrado.

A minha namorada, Maíra Martim de Moura, pessoa muito especial e quem muito admiro. Obrigado por todo incentivo e ajuda principalmente nos momentos difíceis ao longo desses dois anos e alguns meses de mestrado. Teria sido mais difícil terminar essa dissertação sem a sua ajuda.

Aos amigos Roberto e Gean, pelo aprendizado e companheirismo. Acredito que os ensinamentos adquiridos no laboratório serão uteis para toda nossa vida profissional e sou grato por tê-los conhecido nesse período em que residi em Pelotas.

Aos amigos Alisson, Victória, Eduardo, João Vicente, Jonas, Rodrigo e demais amigos. Obrigado por toda ajuda e amizade durante o tempo do mestrado e da faculdade. Vocês tornaram essa caminhada mais tranquila.

À UFPel e o PPGDTSA, por toda a estrutura disponibilizada, oportunidades oferecidas para complementar minha a formação acadêmica.

"A alegria de ver e entender é o mais perfeito dom da natureza."

Albert Einstein

Resumo

SEGER, Francisco Mazzarolo. **Modelagem espacial do crescimento do PIB em cenários distintos de desempenho agrícola do estado do RS**. 2019. 112f. Dissertação (Mestrado em Desenvolvimento Territorial e Sistemas Agroindustriais) - Programa de Pós-Graduação em Desenvolvimento Territorial e Sistemas Agroindustriais, Faculdade de Agronomia Eliseu Maciel/Faculdade de Administração e Turismo, Universidade Federal de Pelotas, Pelotas, 2019.

A variabilidade espacial do crescimento da economia evidencia características locais específicas de grande importância para o planejamento do desenvolvimento regional. Neste sentido, este trabalho buscou entender a associação espacial entre o crescimento do Produto Interno Bruto (cPIB) e do crescimento do Valor da Produção Agrícola (cVPA) sobre o estado do Rio Grande do Sul (RS) entre os anos de 2004 e 2015. No primeiro capítulo foram realizadas análises espaciais exploratórias com diferentes *kernels* para as estatísticas locais: média, desvio-padrão, *z-score* e correlação. Um teste de Monte Carlo foi aplicado para avaliar se a relação entre cPIB e o cVPA é não estacionária no espaço do RS. Verificou-se que a força de associação varia entre as regiões oeste e leste do Estado. A região oeste apresentou associações positivas mais fortes entre cPIB e cVPA, enquanto a região leste apresentou associações negativas e mais fracas. No segundo capítulo foram comparados modelos de regressão geograficamente ponderados (GWR) com modelos lineares globais. A parametrização dos modelos GWR foi realizada com o *kernel Boxcar* e uma largura de banda obtida por meio de validação cruzada. Os modelos GWR foram superiores aos de regressão global em todos os critérios utilizados para avaliar os desempenhos, apresentaram menor erro global, maior coeficiente de determinação global e resíduos menos autocorrelacionados espacialmente. Foi possível verificar que a região noroeste tem a maior conversão de cVPA em cPIB dentre todas as regiões do Estado, enquanto o desempenho da agricultura pouco afeta a economia da região metropolitana. A relação entre cPIB e cVPA oscila no tempo e no espaço em um processo não estacionário que modulou o desenvolvimento econômico e agrícola do estado do RS.

Palavras-chave: GWR; GWSS; Análise Espacial; Economia; Desenvolvimento Territorial.

Abstract

SEGER, Francisco Mazzarolo. **Spatial modeling of GDP growth in different scenarios of agricultural performance of the state of RS.** 2019. 112f. Dissertation (Master of Science in Territorial Development and Agroindustrial Systems) – Postgraduate Program in Territorial Development and Agroindustrial Systems, Eliseu Maciel School of Agronomy/School of Business Administrations and Tourism, Federal University of Pelotas, Pelotas, 2019.

Spatial variability of the economy growth highlights local features to be taken into account when policy makers plan on regional development. In this sense, this work sought to understand the spatial association between the growth of the Gross Domestic Product (cPIB) and the growth of Value of Agricultural Production (cVPA) over the state of Rio Grande do Sul (RS) throughout the years from 2004 to 2015. In the first chapter spatial exploratory analyses were carried out with different kernels to depicted local averages, standard deviations, z-scores and correlations. Following, a Monte Carlo test was applied to assess whether the relationship between cPIB and cVPA shows to be non-stationary in the RS space. It was found the force of association varies along the western and eastern regions of the state. The western region showed the strongest positive associations between cPIB and cVPA while the eastern region showed the weakest negative association. In the second chapter results from geographically weighted regression models (GWR) were compared against those from global models. GWR parameterization was carried out by setting the Boxcar kernel with the optimum bandwidth defined through a cross-validation approach. The GWR models overtook global regression over all criterion used to evaluate model performances. GWR models presented smaller global error, higher overall determination coefficient and less spatially autocorrelated residuals. It was possible to verify that the northwest region has the highest conversion of cVPA into cPIB while the performance of agriculture has little effect on the economy of the metropolitan region. The relationship between cPIB and cVPA oscillates in time and space in non-stationary process that has modulated the economic and agricultural development over the RS state.

Key-words: GWR; GWSS; Spatial Analysis; Economy; Territorial Development.

Lista de Figuras

Figura 1 - Proporção do PIB brasileiro correspondente ao PIB do agronegócio.	17
Figura 2 - Composição do Agronegócio brasileiro: Setor Agrícola (Cinza) e Setor Pecuário (Azul).....	18
Figura 3 - Participação dos setores no valor adicionado na economia.	19
Figura 4 - Divisão territorial do Estado do Rio Grande do Sul e localização dos transectos utilizados na análise.....	23
Figura 5 - Distribuição dos crescimentos do PIB de 2004 a 2015. Figura truncada no eixo das abscissas em 3,0.	30
Figura 6 - Distribuição dos crescimentos do VPA de 2004 a 2015. Figura truncada no eixo das abscissas em 3,0.	31
Figura 7 - Média local dos crescimentos do PIB de 2004 a 2015. Escala da figura truncada em 0,5.	34
Figura 8 - Média local dos crescimentos do VPA de 2004 a 2015. Escala da figura truncada em 1,5.	35
Figura 9 - Desvio Padrão local dos crescimentos do PIB de 2004 a 2015. Escala da figura truncada em 0,5.	36
Figura 10 - Desvio Padrão local dos crescimentos do VPA de 2004 a 2015. Escala da figura truncada em 2,0.	37
Figura 11 – Z-score local do cPIB e do cVPA de 2004 a 2015.....	38
Figura 12 - Coocorrência de quartis (em cinza) de cPIB e cVPA de 2004 a 2015.	39
Figura 13 - Correlações lineares (Cor. Pe.) e robustas (Cor. Spe.) médias para os kernels Boxcar, Biquadrado e Gaussiano, com largura de banda de 5% (25) e 15% (75).....	41

Figura 14 - Correlações locais lineares com largura de banda de 5% (25) de 2004 a 2015. A linha pontilhada corresponde ao valor da correlação global linear.	42
Figura 15 - Correlações locais robustas com largura de banda de 5% (25) de 2004 a 2015. A linha pontilhada corresponde ao valor da correlação global robusta.	43
Figura 16 - Correlações locais lineares com largura de banda de 15% (75) de 2004 a 2015. A linha pontilhada corresponde ao valor da correlação global linear.	43
Figura 17 - Correlações locais robustas com largura de banda de 15% (75) de 2004 a 2015. A linha pontilhada corresponde ao valor da correlação global robusta.	44
Figura 18 - Correlações lineares e robustas médias nos transectos Norte/Sul e Oeste/Leste para os kernels Boxcar, Biquadrado e Gaussiano, com largura de banda de 5% (25).....	45
Figura 19 - Número de anos em que a relação entre o cPIB e o cVPA foi significativa ($\alpha = 0,1$) no teste de Monte Carlo para as correlações lineares (Cor. Pe.) e robustas (Cor. Spe.) utilizando os kernels Boxcar, Biquadrado e Gaussiano, com largura de banda de 5% (25).....	47
Figura 20 – Localização e divisão territorial do Estado do Rio Grande do Sul.	51
Figura 21 - Resíduos dos modelos GWR e RG (Regressão Global). Figura truncada no eixo das ordenadas em -1,0 e 1,0.	58
Figura 22 – Distribuição espacial do r^2 dos modelos GWR.	60
Figura 23 – Distribuição espacial dos coeficientes do cVPA dos modelos GWR. Escala da figura truncada em 0,72.	62
Figura 24 - Valor transferido pelo cVPA na economia local utilizando os modelos RG. Escala da figura truncada em -0,10 e 0,50.	64
Figura 25 - Valor transferido pelo cVPA na economia local utilizando os modelos GWR. Escala da figura truncada em -0,35 e 0,60.	65

Lista de Tabelas

Tabela 1 - Kernels utilizados no estudo	25
Tabela 2 - Estatísticas resumo para o conjunto de dados de cPIB	32
Tabela 3 - Estatísticas resumo para o conjunto de dados de cVPA.....	32
Tabela 4 - Correlações globais entre cPIB e o cVPA	33
Tabela 5 - Largura de banda ótima para cada ano com base na validação cruzada utilizando o kernel Boxcar	57
Tabela 6 - Desempenho global dos modelos RG e GWR	58
Tabela 7 - Índice de Moran para os modelos RG e GWR	61
Tabela 8 - Distribuição dos coeficientes do cVPA dos modelos RG e GWR.....	61

Lista de Abreviaturas e Siglas

CEPEA	Centro de Estudos Avançados em Economia Aplicada
COREDE	Conselho Regional de Desenvolvimento
cPIB	Taxa de crescimento anual do PIB
cVPA	Taxa de crescimento anual do VPA
FEE	Fundação de Economia Estatística Siegfried Emanuel Heuser
IBGE	Instituto Brasileiro de Geografia e Estatística
GWR	Regressão Geograficamente Ponderada
IDESE	Índice de Desenvolvimento Socioeconômico
PIB	Produto Interno Bruto
RG	Regressão Global
SEPLAN	Secretaria de Planejamento e Desenvolvimento Regional
VPA	Valor da Produção Agrícola

Sumário

1 Introdução	14
1.1 Objetivo geral.....	16
1.1.1 Objetivos específicos.....	16
2 Revisão de Literatura	17
2.1 Produto Interno Bruto e Agronegócio.....	17
2.2 Economia Local do Rio Grande do Sul.....	19
Capítulo 1 – Análise espacial exploratória da relação entre o crescimento do PIB e o desempenho agrícola no estado do Rio Grande do Sul	21
1 Introdução.....	22
2 Metodologia.....	23
2.1 Área de Estudo.....	23
2.2 Base de dados.....	23
2.3 Análise espacial exploratória.....	24
3 Resultados e discussões.....	29
4 Conclusões.....	48
Capítulo 2 – Modelagem espacial da relação entre o crescimento do PIB e o desempenho agrícola no estado do Rio Grande do Sul	49
1 Introdução.....	50
2 Metodologia.....	51
2.1 Área de Estudo.....	51
2.2 Base de Dados.....	52
2.3 Modelagem Espacial.....	52

3 Resultados e discussão	57
3.1 Desempenho global dos modelos	57
3.2 Distribuição espacial do r^2	59
3.3 Análise da autocorrelação espacial dos resíduos	60
3.4 Análise dos parâmetros estimados pelos modelos	61
4 Conclusões	66
Considerações Finais	67
Referências	68
Apêndices	72

1 Introdução

O Estado do Rio Grande do Sul (RS) possui como principais setores da economia, o de serviços, o industrial e o agropecuário (RISCO, 2016). O setor de serviços é majoritário na economia do RS, seguido pelo industrial e pelo agropecuário, respectivamente. Embora com menor participação relativa que os demais na composição do Produto Interno Bruto (PIB), o setor agropecuário estimula os outros setores por meio da tomada dos serviços e dos produtos industriais (FOCHEZZATTO; GHINIS, 2012; LAZZARI, 2012; SCHUH et al., 2018). Fochezzatto; Grando (2009) verificaram que 52% dos efeitos da estiagem que ocorreu no RS em 2008 recaíram sobre os setores de serviços e industrial. Isso demonstra que a economia do Estado está fortemente atrelada ao desempenho da agropecuária, especialmente da agricultura, que entre 2010 e 2014, contribuiu com aproximadamente dois terços (69%) do valor adicionado pelo setor agropecuário na economia (FEE, 2018a).

Apesar da importância da agropecuária para os demais setores e para a economia do RS, pouco se sabe como essas relações variam no espaço e no tempo, tampouco como é afetada pelo desempenho da agricultura e pelas economias locais.

Informações sobre a formação do PIB no contexto espacial permitem que agentes da cadeia tenham à disposição parâmetros para definir os limites de seus investimentos e o retorno da sua política de atuação na região. Além disso, possibilitam inferir sobre a existência de uma maior/menor eficiência na transferência desempenho da agricultura para a economia local onde diversos setores interagem.

Modelos não espaciais limitam a caracterização das relações locais entre o PIB e os seus formadores. Por outro lado, análises ponderadas espacialmente são mais adequadas para o estabelecimento de métricas de heterogeneidade das relações (FOTHERINGHAM et al., 2002) em cenários distintos de formação do PIB. Uma série de possibilidades para abordar fenômenos espaciais são possíveis por meio das técnicas de ponderação espacial dos modelos de regressão geograficamente ponderados (GWR), como por exemplo, as mudanças na paisagem em virtude da urbanização (HUILEI et al., 2017) e as diferenças regionais no desenvolvimento econômico (LI et al., 2007).

Análises que capturem as mudanças de relações entre variáveis no espaço e no tempo, em oposição aos modelos globais que analisam apenas a convergência, possibilitam avaliar como as relações locais entre variáveis se modificam em diferentes escalas espaciais e temporais (FOTHERINGHAM et al., 2002; MA et al., 2018).

Modelos empíricos espacialmente ponderados são pouco explorados na identificação da variabilidade dos coeficientes de regressão sobre o espaço geográfico em que o PIB e seus formadores interagem. Entretanto, aplicações em diversas pesquisas socioeconômicas apontam para um substancial aumento da compreensão de relações em múltiplas escalas. Lewandowska-Gwarda (2018) demonstrou por exemplo que determinantes do desemprego se diversificavam sobre um espaço geográfico dividido em 380 distritos na Polônia. Além disso, o impacto dos fatores do desemprego não foi significativo em todas as unidades distritais. A pesquisa também demonstrou que os modelos GWR foram eficientes no processo de identificação de clusters distritais formados pelas variáveis de influência e pelas forças de interação nos níveis de desemprego.

Hu et al. (2016) utilizaram um modelo GWR para verificar a variação espacial dos fatores que influenciam no preço da terra na cidade de Wuhan, na China. O estudo revelou que a taxa de ocupação da terra foi mais significativa para o aumento do preço da terra em áreas mais desenvolvidas do que em áreas menos desenvolvidas. Além disso, os autores observaram que a distância dos centros de comércio urbanos tem um efeito negativo mais forte em áreas mais desenvolvidas do que em áreas menos desenvolvidas.

No Rio Grande do Sul percebe-se uma escassez de aplicações de métodos de análises espaciais e temporais para geração de métricas de probabilidade sobre condicionantes do desempenho econômico. Além disso, pouca informação está disponível para o planejamento do desenvolvimento territorial do Estado sob a perspectiva das distinções locais da formação do PIB, o que torna oportuna a proposição de análises ponderadas espacialmente para o estabelecimento de políticas e investimentos específicos por região.

1.1 Objetivo geral

Analisar a variabilidade espacial da relação entre o PIB e o desempenho da agricultura no estado do Rio Grande do Sul no período de 2004 a 2015.

1.1.1 Objetivos específicos

- Analisar a relação espacial entre o PIB e o desempenho da agricultura em cenários distintos de desempenho anual do agronegócio capturado pelo Valor Produção Agrícola.
- Explorar a relação entre o desempenho da agricultura e o desempenho econômico em diferentes funções de ponderação espacial (*Kernels*).
- Estimar níveis de dependência econômica regional do desempenho da agricultura.
- Verificar a inadequação dos modelos globais em relação à ausência de estacionariedade contemplada pelos modelos ponderados geograficamente.
- Indicar as diferenças regionais da eficiência de transformação do Valor da Produção Agrícola em crescimento econômico.

2 Revisão de Literatura

2.1 Produto Interno Bruto e Agronegócio

O PIB mensura as riquezas produzidas em um local durante um determinado período, e por isso é considerado a métrica mais objetiva para medir o crescimento econômico (PASSOS et al., 2012). No Brasil, um dos maiores contribuintes para o crescimento do PIB brasileiro é o agronegócio (CEPEA, 2019a). A Figura 1 mostra a evolução temporal da participação do agronegócio no PIB brasileiro. Mesmo em queda durante a última década, o agronegócio representou uma parcela relevante do PIB brasileiro correspondendo em média a 21%. Assim sendo, o agronegócio se consolida como um setor de suma importância para o saldo econômico positivo da balança comercial brasileira.

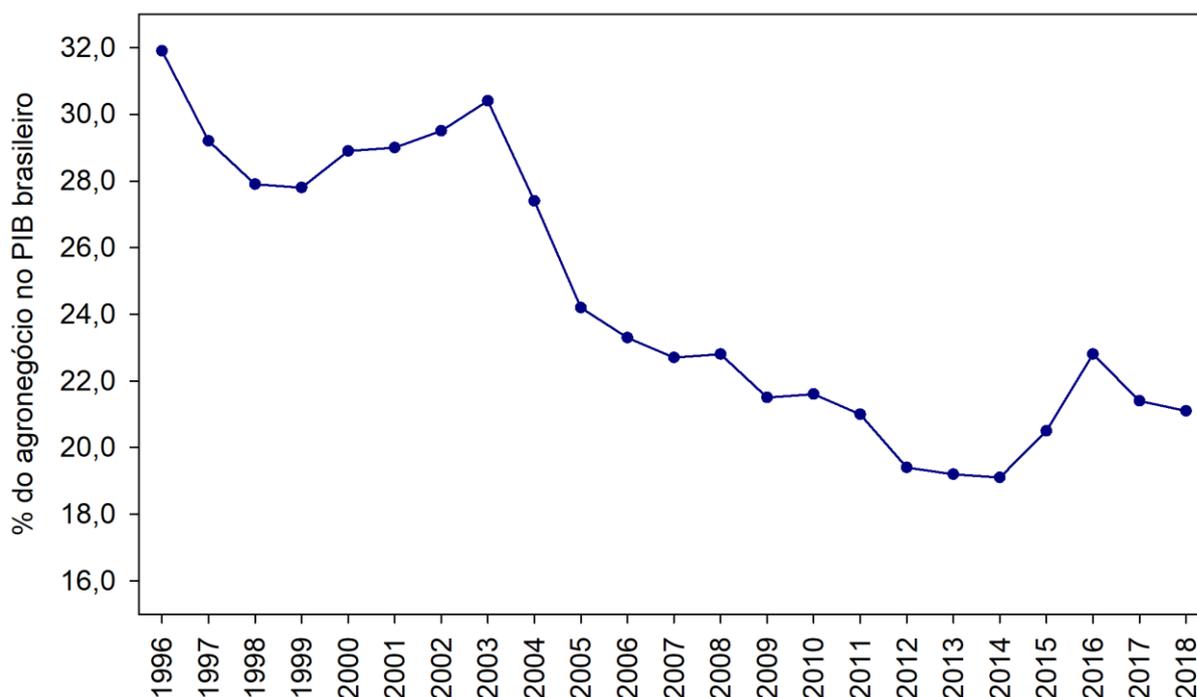


Figura 1 - Proporção do PIB brasileiro correspondente ao PIB do agronegócio.
Fonte: Adaptado de CEPEA (2019b).

Segundo CEPEA (2019a), o agronegócio é definido como a soma dos insumos necessários para as atividades agropecuárias, da produção agropecuária

propriamente dita, das indústrias de transformação (agroindústrias) e serviços relacionados a produção agropecuária (agrosserviços).

Os valores do agronegócio são obtidos com base em dois setores: o agrícola e o pecuário (CEPEA, 2014). Na Figura 2 são apresentadas as participações relativas da agricultura e pecuária na composição do PIB do agronegócio. De maneira geral, o setor agrícola contribui mais para a para o PIB do agronegócio, oscilando de 68 a 81%, enquanto que o setor pecuário oscila de 32 a 19%.

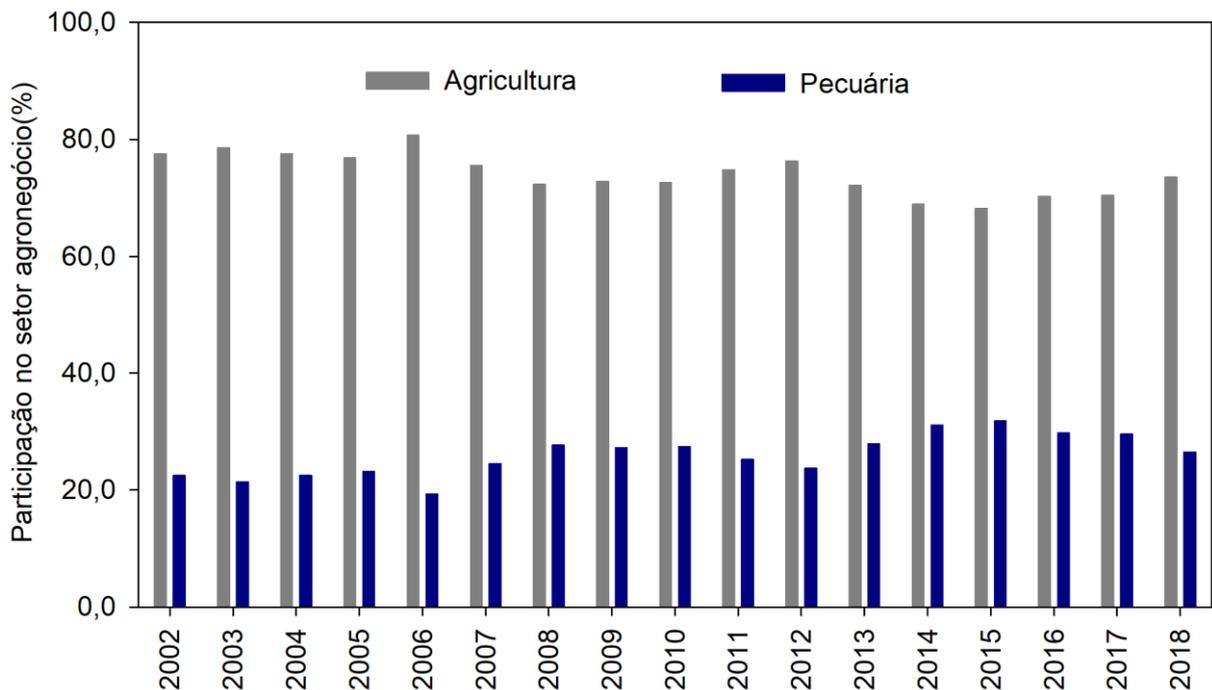


Figura 2 - Composição do Agronegócio brasileiro: Setor Agrícola (Cinza) e Setor Pecuário (Azul).
Fonte: Adaptado de CEPEA (2019b).

Para o Estado do Rio Grande do Sul (RS) foram encontrados dados oficiais do setor agropecuário e não do agronegócio como um todo. O setor agropecuário é o terceiro em ordem de importância econômica (RISCO, 2016), com uma participação em média entre 2004 e 2015 de aproximadamente 9% no valor adicionado pelos setores na economia (Figura 3). Contudo, algumas estimativas sugerem que toda a cadeia relacionada ao setor agropecuário (agronegócio) no RS tem na verdade uma participação de 43% no PIB do Estado (MONTROYA; FINAMORE, 2010). Os métodos de mensuração não são eficientes para contabilizar o transbordamento das riquezas produzidas no setor primário para os demais setores do Estado, e assim acabam por mascarar a contribuição real da agropecuária para a economia do RS.

Como exemplo dessa dependência, Fochezatto; Grando (2009) identificaram que 52% dos efeitos provocados pela estiagem de 2008, recaíram sobre os setores de serviços e industrial do RS. Na ausência desse evento, os autores estimam que o PIB do RS poderia ter crescido 1,3% a mais naquele ano.

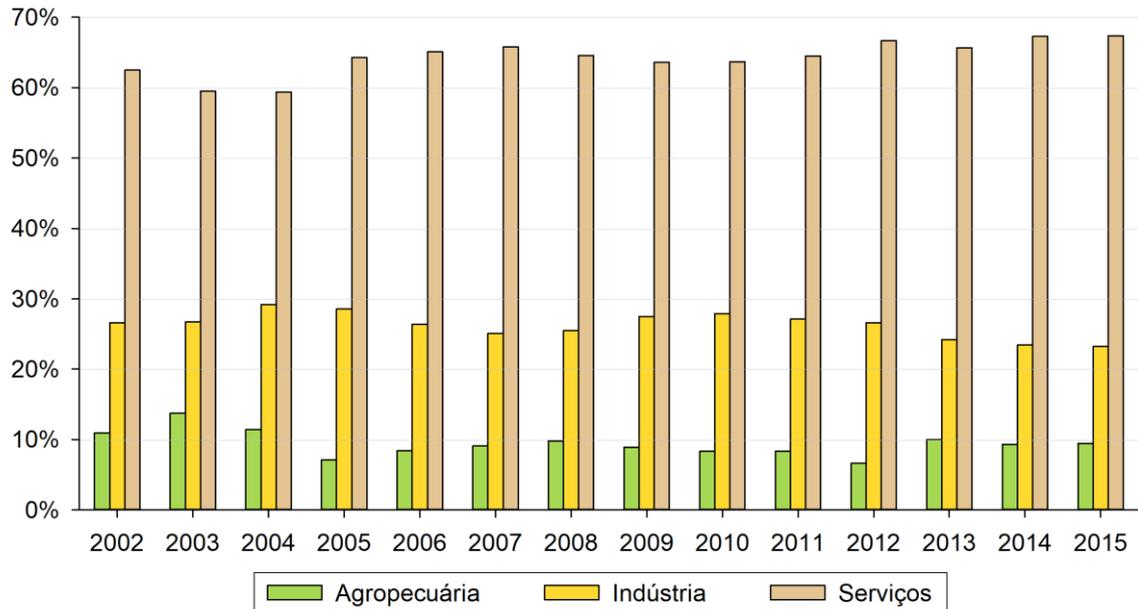


Figura 3 - Participação dos setores no valor adicionado na economia.
Fonte: Adaptado de FEE (2018a).

Conforme constatado, o desempenho de todos os setores econômicos do Estado está atrelado ao desempenho da agropecuária. Porém, apesar da importância do setor primário para a economia do RS, pouco se sabe sobre como as relações entre setor agropecuário e a economia variam em função das características locais.

2.2 Economia Local do Rio Grande do Sul

Segundo Alonso (2006), as diferenças econômicas entre as regiões do RS têm se amplificado nas últimas seis décadas, especialmente quanto a distribuição de indústrias. Quando considerados os Conselhos Regionais de Desenvolvimento (COREDEs), segundo a SEPLAN-RS (2015), a amplitude da diferença econômica entre as regiões atingiu aproximadamente R\$ 19.500,00. O COREDE Serra teve o maior PIB *per capita* do Estado, R\$ 34.642,00. Nesse COREDE estiveram presentes

19,8% das indústrias de transformação do Estado e o maior (0,812) Índice de Desenvolvimento Socioeconômico (IDESE) (SEPLAN-RS, 2015).

O COREDE Vale do Jaguari apresentou o menor maior PIB *per capita* do Estado sendo R\$ 15.032,00. A economia dessa região teve por 30% do PIB gerado na agropecuária, a indústria representou 10% e o setor de serviços 60%. Contudo, embora o setor de serviços tenha uma participação percentual alta se comparado com os demais setores, verifica-se um predomínio de atividades relacionadas a administração pública na composição do valor desse setor (SEPLAN-RS, 2015).

É possível verificar que as regiões do RS variam não somente quanto a proporção de participação entre os setores na economia, mas também em sua capacidade de produzir riquezas por habitante. Supostamente, a relação entre o crescimento dos setores e o crescimento da economia deve manifestar distinções locais no estado do RS.

Capítulo 1 – Análise espacial exploratória da relação entre o crescimento do PIB e o desempenho agrícola no estado do Rio Grande do Sul

1 Introdução

O estado do Rio Grande do Sul tem uma área territorial de aproximadamente 281.707 Km² e é atualmente o 9º Estado com a maior de área territorial do Brasil (IBGE, 2019a). Diversos estudos relatam a importância da agropecuária para a economia do RS (COLLE et al., 2017; FOCHEZZATO; GRANDO, 2009; LAZZARI, 2012), contudo devido aos fatores de formação do Estado, as regiões apresentam distintas características econômicas entre si.

Alonso et al. (1994), propuseram uma divisão em três regiões no Estado, denominadas de regiões Sul, Norte e Nordeste. A região Nordeste apresenta a maior quantidade de indústrias das três regiões, a região Norte tem base agrícola, mas com predominância de pequenas e médias propriedades e a região Sul também tem base agrícola, mas se caracteriza por possuir um número mais elevado de grandes propriedades que nas demais regiões.

Tendo em vista a grande extensão territorial do estado do RS e as diferenças regionais presentes, é pouco provável que a relação entre as economias locais e a agropecuária, especificamente a agricultura que correspondeu a cerca de dois terços (69%) do PIB Agropecuário entre 2010 e 2014 (FEE, 2018a), se mantenha constante ao longo de todo Estado.

Assim sendo, esse trabalho propõe uma análise exploratória espacial para identificar como se dá a relação entre o desempenho econômico e o desempenho da agricultura, se existem transições entre as regiões do RS e se as relações se mantêm constantes ao longo do tempo. A análise exploratória espacial é uma etapa importante que antecede a utilização de modelos espaciais como os modelos de regressão geograficamente ponderados (GWR) (FOTHERINGHAM et al., 2002), especialmente as correlações locais que fornecem indícios da ausência de estacionariedade da relação (HARRIS; BRUNSDON, 2010).

2 Metodologia

2.1 Área de Estudo

O estudo compreende o estado do Rio Grande do Sul localizado na região sul do Brasil (Figura 4). Com uma população estimada em 11.329.605 habitantes e possuindo 497 municípios (IBGE, 2019b), a economia do Estado em média entre 2004 e 2015, foi composta por 64,9% do setor de serviços, 26,2% do setor industrial e 8,9% do setor agropecuário (FEE, 2018a). Apesar de em termos absolutos o setor agropecuário ter uma participação inferior aos outros dois setores na economia, em 2013, ele foi o setor dominante em 30% dos municípios e teve participação superior a 30% em metade das economias municipais que tiveram o setor de serviços como majoritário (32%) (RISCO, 2016). Isso evidencia a importância econômica e social que a agropecuária tem para o RS.

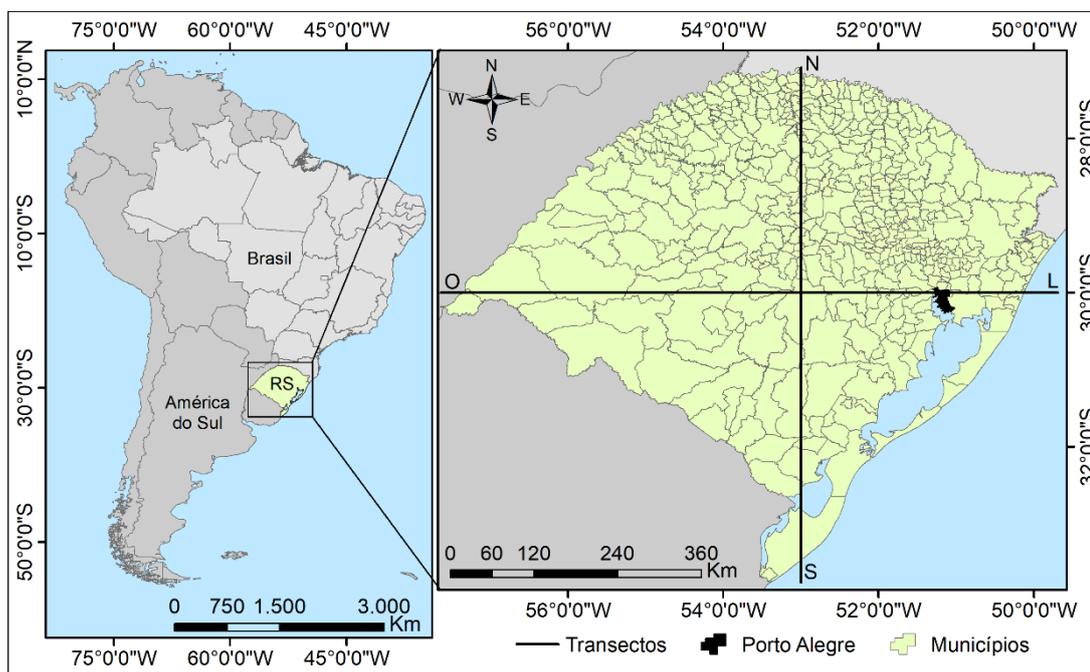


Figura 4 - Divisão territorial do Estado do Rio Grande do Sul e localização dos transectos utilizados na análise.

2.2 Base de dados

O estudo foi realizado com dados econômicos municipais de doze anos consecutivos, entre 2004 e 2015, obtidos pelo Instituto Brasileiro de Geografia e

Estatística (IBGE). Como métrica de desempenho econômico foram utilizados dados de PIB municipal e como métrica de desempenho agrícola foram utilizados dados de Valor da Produção Agrícola (VPA) municipal. Nesse estudo um município foi retirado da análise, pois não continha a série de dados completa, sendo analisados 496 municípios.

O VPA é obtido a partir do produto da multiplicação entre a produção das principais culturas de importância econômica e social do Brasil e o valor da comercialização das mesmas (IBGE, 2017).

Os valores do PIB e do VPA foram convertidos em suas taxas anuais de crescimento, $cPIB_t$ e $cVPA_t$, respectivamente, para minimizar os efeitos de economias municipais muito diferentes em valores absolutos. As taxas de crescimento foram relativas ao ano imediatamente anterior e o procedimento de cálculo é descrito nas Equações 01 e 02. Trabalhar com taxas de crescimento possibilita analisar de forma objetiva a associação entre o crescimento econômico e o desempenho da agricultura.

$$cPIB_t = \frac{(PIB_t - PIB_{t-1})}{PIB_{t-1}} \quad (01)$$

$$cVPA_t = \frac{(VPA_t - VPA_{t-1})}{VPA_{t-1}} \quad (02)$$

Em que $cPIB_t$ e $cVPA_t$ são as taxas de crescimento do PIB e do VPA para o ano t , respectivamente.

2.3 Análise espacial exploratória

Em modelos e métodos de análise espacial é necessária a utilização de uma função de ponderação espacial a qual é denominada de *kernel*, cujo domínio espacial é dado pela largura de banda (BIDANSET; LOMBARD, 2014; GUO et al., 2008).

O *kernel* é uma função de ponderação que penaliza as observações na análise em função da distância da posição de estimação (x_i, y_i) . Quanto maior a distância da posição de interesse, menor será o peso da observação na composição da estatística espacial. Nesse estudo foram utilizados três diferentes *kernels* (Tabela 1).

Tabela 1 - *Kernels* utilizados no estudo

<i>Kernel</i>	Função	
<i>Boxcar</i>	$w_{ij} = 1$ se $\text{dist} < bw$	$w_{ij} = 0$ caso contrário
Biquadrado	$w_{ij} = (1 - (\text{dist}/bw)^2)^2$ se $\text{dist} < bw$	$w_{ij} = 0$ caso contrário
Gaussiano	$w_{ij} = \exp(-0.5 * (\text{dist}/bw)^2)$	

Nota: *dist* é a matriz de distâncias entre as posições de interesse (os centroides dos vetores municipais) e *bw* é a distância máxima determinada pela largura de banda. Os índices *i* e *j* correspondem, respectivamente, aos centroides dos vetores municipais para o centro da matriz de ponderação e as posições vizinhas a posição (x_i, y_i) .

O *kernel Boxcar* consiste de uma função que não atribui pesos diferentes para as observações (x_j, y_j) dentro do seu domínio espacial, ou seja, todas as observações dentro do espaço finito delimitado pela largura de banda tem o mesmo peso na estimação para a posição (x_i, y_i) . Por não atribuir pesos, as estimativas locais realizadas com esse *kernel* são comparadas de forma direta com as estimativas globais.

No *kernel Biquadrado* a função de ponderação espacial atribui pesos seguindo uma função biquadrática da distância. O domínio espacial da função é finito e delimitado pela largura de banda.

No *kernel Gaussiano* todas as observações do conjunto de dados são incluídas na estimação para a posição (x_i, y_i) . Apesar disso, observações mais distantes que o limite definido pela largura de banda tem pouca influência nas estimativas. A ponderação nesse *kernel* é realizada com base em uma função gaussiana da distância sob a hipótese de um campo aleatório gaussiano. A largura de banda define a abrangência espacial dos *kernels* entorno da posição de estimação (x_i, y_i) . Essa definição pode ser feita de duas maneiras: pela escolha de uma distância fixa ao entorno da posição (x_i, y_i) que terá o número de observações variável em cada ponderação se a grade de observações não for regular, ou pela determinação de um número fixo de observações para a composição da estatística na posição (x_i, y_i) que terá distância variável em cada ponderação se a grade de observações não for regular.

Os polígonos municipais utilizados nesse estudo têm grande variação quanto ao tamanho e forma. Na região metropolitana (em torno de Porto Alegre) e nordeste predominam municípios pequenos (relativo ao tamanho médio dos municípios do Estado) com menor distância entre os centroides. Por outro lado, na região sudoeste do RS predominam municípios maiores com maior distância entre os centroides municipais. Por essa razão, optou-se pela abordagem que trabalha com um número

fixo observações, pois evita alguns problemas como as estatísticas serem computadas com um baixo número de observações em algumas regiões (HARRIS; BRUNSDON, 2010).

A estimativa da largura de banda ótima para um *kernel* é possível através de alguns métodos computacionais como a validação cruzada. No entanto, assim como na validação cruzada, para a maioria dos métodos de otimização da largura de banda, se faz necessária uma função objetiva (HARRIS; BRUNSDON, 2010). No caso de uma análise exploratória, funções objetivas não estão presentes e a largura de banda é definida de maneira subjetiva, o que, de acordo com Harris; Brunson (2010) não configura um problema neste tipo de análise.

Foram utilizados dois critérios na escolha da largura de banda. O primeiro foi o de evidenciar as relações locais respeitando um número mínimo de observações, de forma que o valor obtido para a posição de estimação (x_i, y_i) não seja somente dependente do valor observado na posição (x_i, y_i) . O segundo foi definir um limite máximo do número de observações que irão compor as estatísticas para a posição de estimação (x_i, y_i) , de modo que as estatísticas locais não se assemelhem as estatísticas globais, ocultando as variações locais. Assim, as larguras de banda definidas foram equivalentes a 5% e 15% do tamanho do conjunto de dados, ou seja, a aproximadamente 25 e 75 observações, respectivamente.

As métricas locais foram aplicadas preliminarmente para investigar a distribuição espacial das variáveis e possíveis associações no espaço entre o crescimento econômico e desempenho agrícola. Para isso foram utilizadas as médias locais (Equação 03), que resultam no crescimento médio de cada região, os desvios padrões locais (Equação 04), que indicam a variabilidade de crescimentos de cada região e os *z-scores* locais (Equação 05) que relativizam as médias locais com a média global. As estatísticas locais foram obtidas com largura de banda de 5% e, por não ponderar as observações em função das distâncias, o *kernel Boxcar* foi empregado para comparar as métricas locais com métricas globais.

$$m(x_i) = \frac{\sum_{j=1}^n w_{ij} x_j}{\sum_{j=1}^n w_{ij}} \quad (03)$$

Em que $m(x_i)$ é a média local para uma dada posição i . w_{ij} é a matriz de ponderação espacial atribuída pelo *kernel* (apresentado na Tabela 1).

$$s(x_i) = \sqrt{\frac{\sum_{j=1}^n w_{ij} (x_j - m(x_i))^2}{\sum_{j=1}^n w_{ij}}} \quad (04)$$

Em que $s(x_i)$ é o desvio padrão local.

$$zs_i = (m(x_i) - \mu) / \left(\sigma \sqrt{\sum_{j=1}^n w_{ij}^2} \right) \quad (05)$$

Em que zs_i é o z-score local, μ é a média global estimada e σ é o desvio padrão global estimado. A função de ponderação w_{ij} neste caso é escalonada para somar um na estimação de cada localização i .

A estacionariedade da relação entre o cPIB e o cVPA foi verificada por meio de correlações lineares e robustas locais. A Equação 06 descreve o procedimento de cálculo para o coeficiente de correlação de Pearson.

$$\rho(x_i, y_i) = c(x_i, y_i) / (s(x_i) \cdot s(y_i)) \quad (06)$$

Em que $\rho(x_i, y_i)$ é o coeficiente de correlação de Pearson local entre as variáveis x_i e y_i , e $c(x_i, y_i)$ é a covariância local (Equação 07) entre as variáveis x_i e y_i .

$$c(x_i, y_i) = \frac{\sum_{j=1}^n w_{ij} \{(x_j - m(x_i)) \cdot (y_j - m(y_i))\}}{\sum_{j=1}^n w_{ij}} \quad (07)$$

A significância da associação espacial entre o cPIB e o cVPA foi verificada em um teste de Monte Carlo. No teste, foi verificado se as correlações locais são diferentes das obtidas ao acaso, em 999 permutações. Resultados significativos ($\alpha = 0,1$) do teste levam a conclusão de que a associação entre cPIB e cVPA é não estacionária no espaço geográfico do Rio Grande do Sul. O teste foi aplicado obedecendo as seguintes etapas: (i) obtenção das estatísticas locais com os pares de coordenadas e variáveis mantidas nas posições reais, (ii) aleatorização sucessiva da posição das observações das variáveis, (iii) cálculo das estatísticas espaciais para cada permutação aleatória e (iv) ranqueamento do resultado das 999 permutações em cada posição no espaço. Quando posicionada nos limites inferior

ou superior da distribuição, a correlação local foi considerada como não ao acaso. Com o nível de significância do teste definido com $\alpha = 0,1$, foram significativas as correlações abaixo do percentil cinco ou acima do percentil noventa e cinco.

Por apresentarem diferenças em suas matrizes econômicas, as regiões Norte e Sul do RS geralmente são comparadas com relação aos níveis de geração de riqueza (ALONSO, 2006; CHELLOTTI; CASTANHO, 2006). Na delimitação regional apresentada em Alonso (1994), o PIB por Km² da região Norte entre 2004 e 2015 foi, em média, 2,6 vezes superior ao PIB por Km² da região Sul. Com base na heterogeneidade presente no espaço geográfico do RS, foram realizadas análises das relações locais no Estado ao longo de transectos (Figura 4). O primeiro transecto foi denominado de Transecto Norte/Sul e tem origem na região Norte do Estado se estende até a região Sul ao longo da longitude 53° 00' 00" O. O segundo transecto foi denominado de Transecto Oeste/Leste e tem origem na região Oeste do Estado se estende até a região Leste ao longo da latitude 30° 00' 00" S. Os transectos são assim empregados em análises de transição sobre as diferentes regiões do Estado.

Não foram realizadas transformações nos dados de cPIB e de cVPA, de modo que estes foram analisados em suas distribuições anuais naturais. A análise deve ser entendida como uma etapa *ad hoc* para utilização de modelos que incorporem as componentes espaciais e temporais. As análises e os modelos espaciais foram realizados com os algoritmos implementados no pacote *GWmodel* (GOLLINI et al., 2015) do software estatístico R.

3 Resultados e discussões

Nas Figuras 5 e 6 são apresentadas as distribuições do cPIB e do cVPA para todos os anos da análise. É possível observar que as distribuições do cPIB e do cVPA apresentam semelhanças. Isso reforça a hipótese de que o desempenho da agricultura é uma *proxy* para o PIB do Estado. As distribuições ano a ano dos crescimentos revelam alterações no formato da distribuição, sugerindo que a relação entre o cPIB e o cVPA sofre influência das características do ano-safra.

A distribuição do cPIB é geralmente mais simétrica que a do cVPA e a amplitude do cPIB é menor que a do cVPA em dez dos doze anos da série (Tabelas 2 e 3). Esse resultado pode estar relacionado aos efeitos das flutuações climáticas e de mercado sobre o VPA, que amplifica sua variação em relação ao PIB, cuja variabilidade é atenuada pelos setores de serviços e industrial principalmente em regiões onde a participação relativa da agricultura na economia é baixa.

Foram observados valores discrepantes nas distribuições do cPIB e do cVPA geralmente atribuídos a municípios com a economia pouco ativa onde as taxas de crescimento superam facilmente a média de crescimento anual. Nesses municípios o valor absoluto do PIB e do VPA é pequeno e gera um cenário propício para ocorrência de elevados incrementos relativos.

O crescimento médio do VPA é geralmente acompanhado pelo crescimento médio do PIB (Tabelas 2 e 3). As maiores e menores médias do cPIB e do cVPA ocorrem nos mesmos anos. Isso sugere que o desempenho da agricultura está atrelado ao desempenho econômico do Estado.

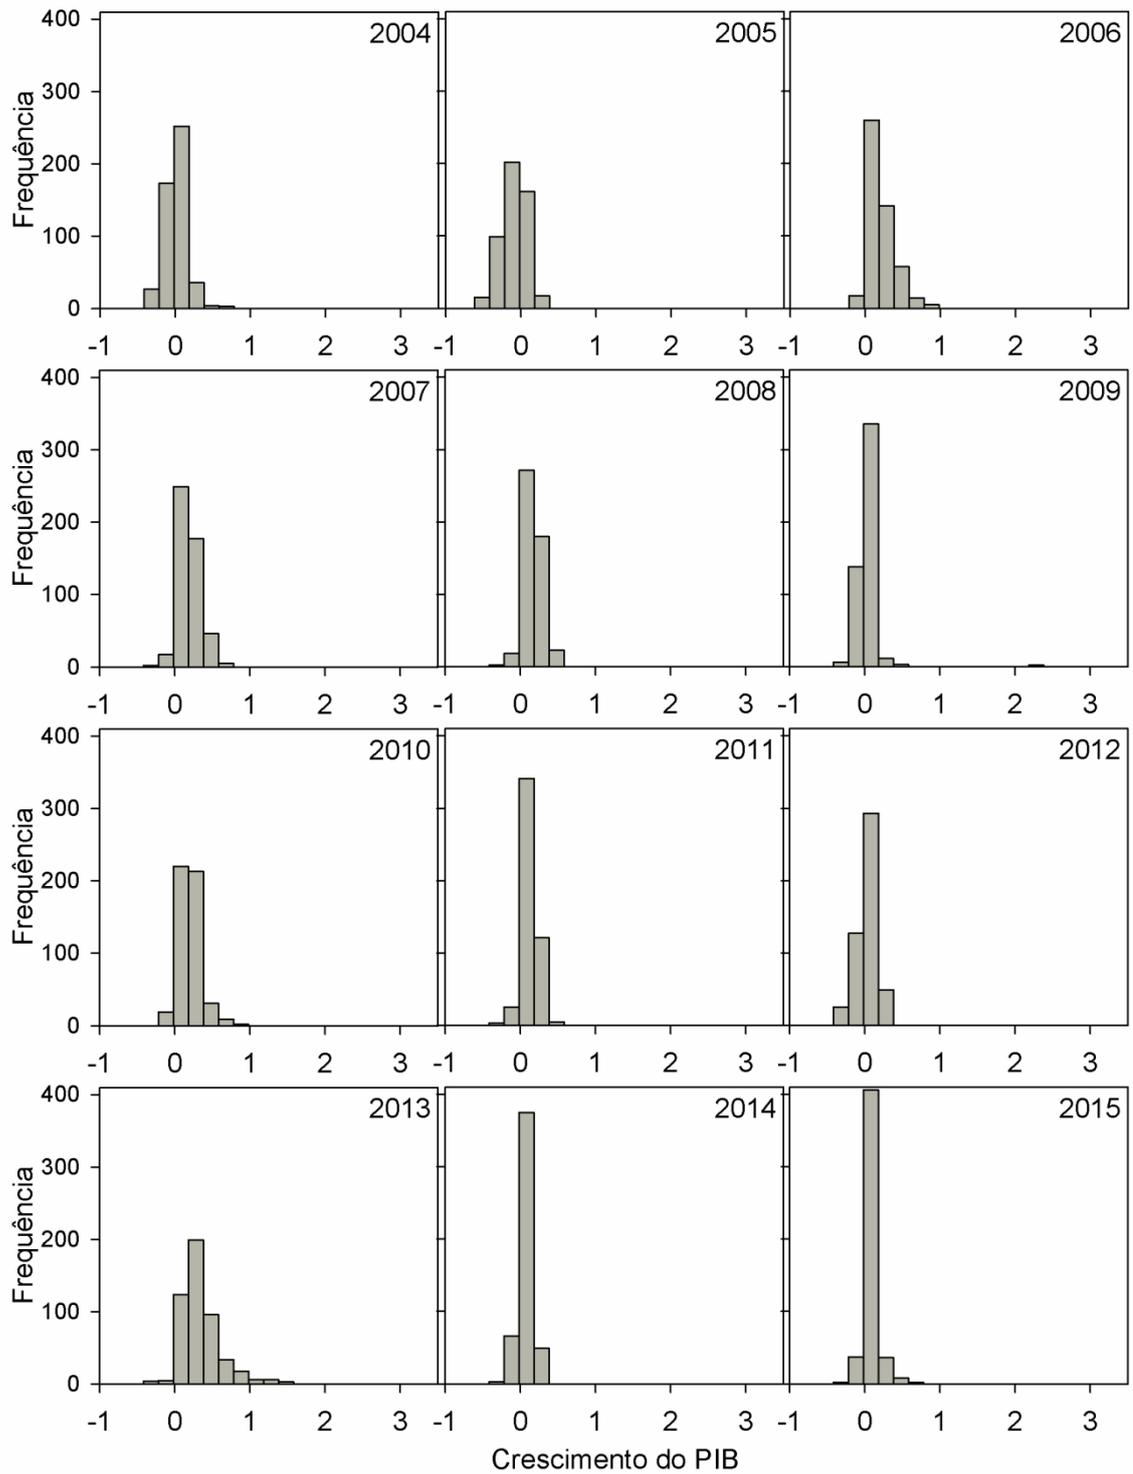


Figura 5 - Distribuição dos crescimentos do PIB de 2004 a 2015. Figura truncada no eixo das abscissas em 3,0.

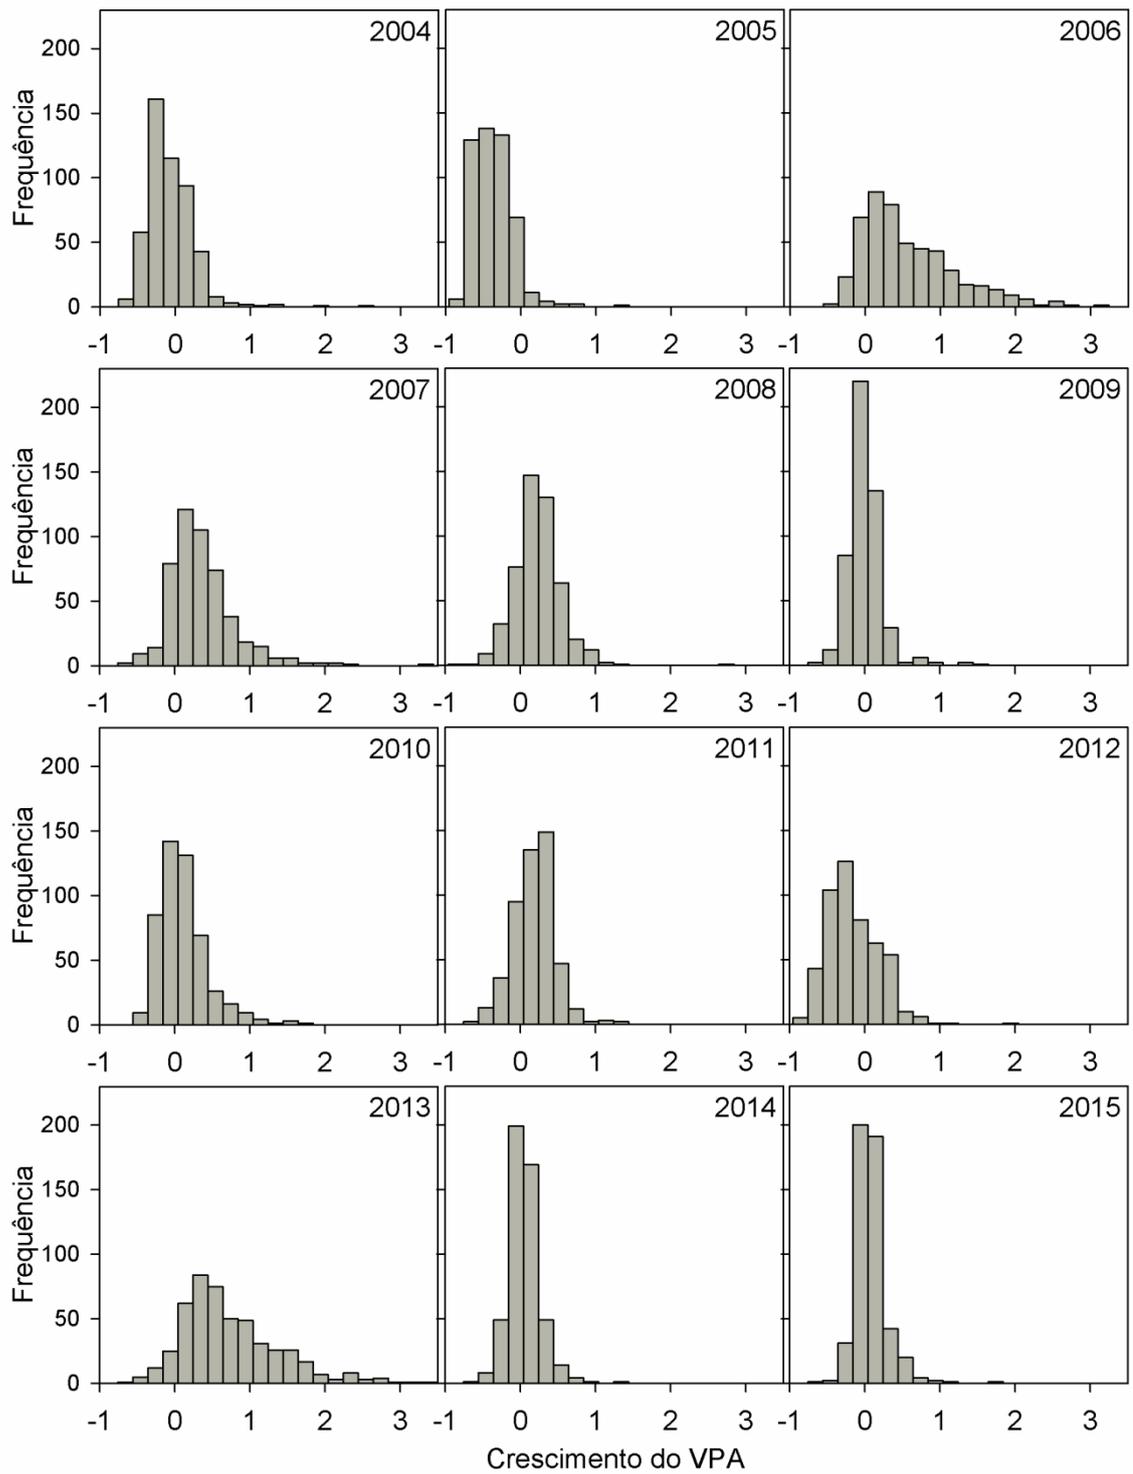


Figura 6 - Distribuição dos crescimentos do VPA de 2004 a 2015. Figura truncada no eixo das abscissas em 3,0.

Tabela 2 - Estatísticas resumo para o conjunto de dados de cPIB

Ano	Média	Mediana	Máximo	Mínimo	Desvio Padrão
2004	0,01	0,02	1,29	-0,41	0,16
2005	-0,08	-0,08	2,19	-0,61	0,20
2006	0,20	0,15	0,95	-0,10	0,17
2007	0,19	0,17	0,74	-0,38	0,14
2008	0,17	0,16	1,05	-0,25	0,12
2009	0,03	0,03	2,23	-0,35	0,17
2010	0,19	0,18	0,87	-0,59	0,15
2011	0,12	0,12	0,50	-0,53	0,10
2012	0,03	0,05	0,42	-0,62	0,14
2013	0,34	0,28	1,69	-0,38	0,27
2014	0,07	0,08	0,73	-0,57	0,10
2015	0,10	0,07	3,93	-0,48	0,26

Tabela 3 - Estatísticas resumo para o conjunto de dados de cVPA

Ano	Média	Mediana	Máximo	Mínimo	Desvio Padrão
2004	-0,02	-0,13	24,56	-0,76	1,15
2005	-0,36	-0,39	4,31	-0,80	0,33
2006	0,57	0,41	4,35	-0,46	0,64
2007	0,37	0,28	8,84	-0,64	0,59
2008	0,23	0,22	2,66	-0,96	0,31
2009	0,00	-0,01	1,59	-0,59	0,23
2010	0,11	0,06	1,74	-0,54	0,33
2011	0,18	0,21	1,33	-0,60	0,27
2012	-0,13	-0,21	11,31	-0,84	0,62
2013	0,77	0,58	6,09	-0,60	0,76
2014	0,05	0,04	1,39	-0,68	0,20
2015	0,08	0,05	1,74	-0,63	0,20

Com base nas correlações globais presentes na Tabela 4 é possível observar ausência de linearidade na relação ente cPIB e cVPA em quase toda série estudada. Tanto a correlação robusta de *Spearman* quanto a linear de *Pearson* apresentaram variação na força de associação entre os anos. Isso sugere a necessidade de se investigar a relação temporal entre o cPIB e o cVPA e como as alterações na relação global estão relacionadas com as correlações locais.

Tabela 4 - Correlações globais entre cPIB e o cVPA

Ano	Correlação linear	Correlação robusta
2004	0,20	0,59
2005	0,41	0,60
2006	0,50	0,54
2007	0,39	0,63
2008	0,40	0,51
2009	0,20	0,47
2010	0,41	0,48
2011	0,46	0,55
2012	0,35	0,64
2013	0,51	0,49
2014	0,34	0,42
2015	0,15	0,49

Na análise dos crescimentos locais do PIB e do VPA (Figuras 7 e 8) percebe-se uma convergência espacial e temporal do cPIB e do cVPA. Esse efeito não acontece em todas as regiões na mesma proporção em razão da participação dos setores de serviços e industrial na economia. Em 2005, por exemplo, por conta de um sinistro de estresse hídrico (FOCHEZATTO; GRANDO, 2009), a produção agrícola do RS foi impactada negativamente, resultando em um decréscimo do VPA para esse ano e conseqüentemente da economia como um todo. Mas como observado nas Figuras 7 e 8, apesar do sinistro ter afetado o cVPA de grande parte dos municípios do norte do Estado, apenas alguns tiveram esse impacto na mesma proporção em sua economia. Em 2013 as maiores taxas crescimento do PIB foram observadas na região noroeste do Estado, mas esse efeito no VPA (em mesma proporção espacial) foi acompanhado apenas em parte dos municípios dessa região. Isso mostra uma flutuação no espaço e no tempo do efeito do desempenho da agricultura na economia do RS.

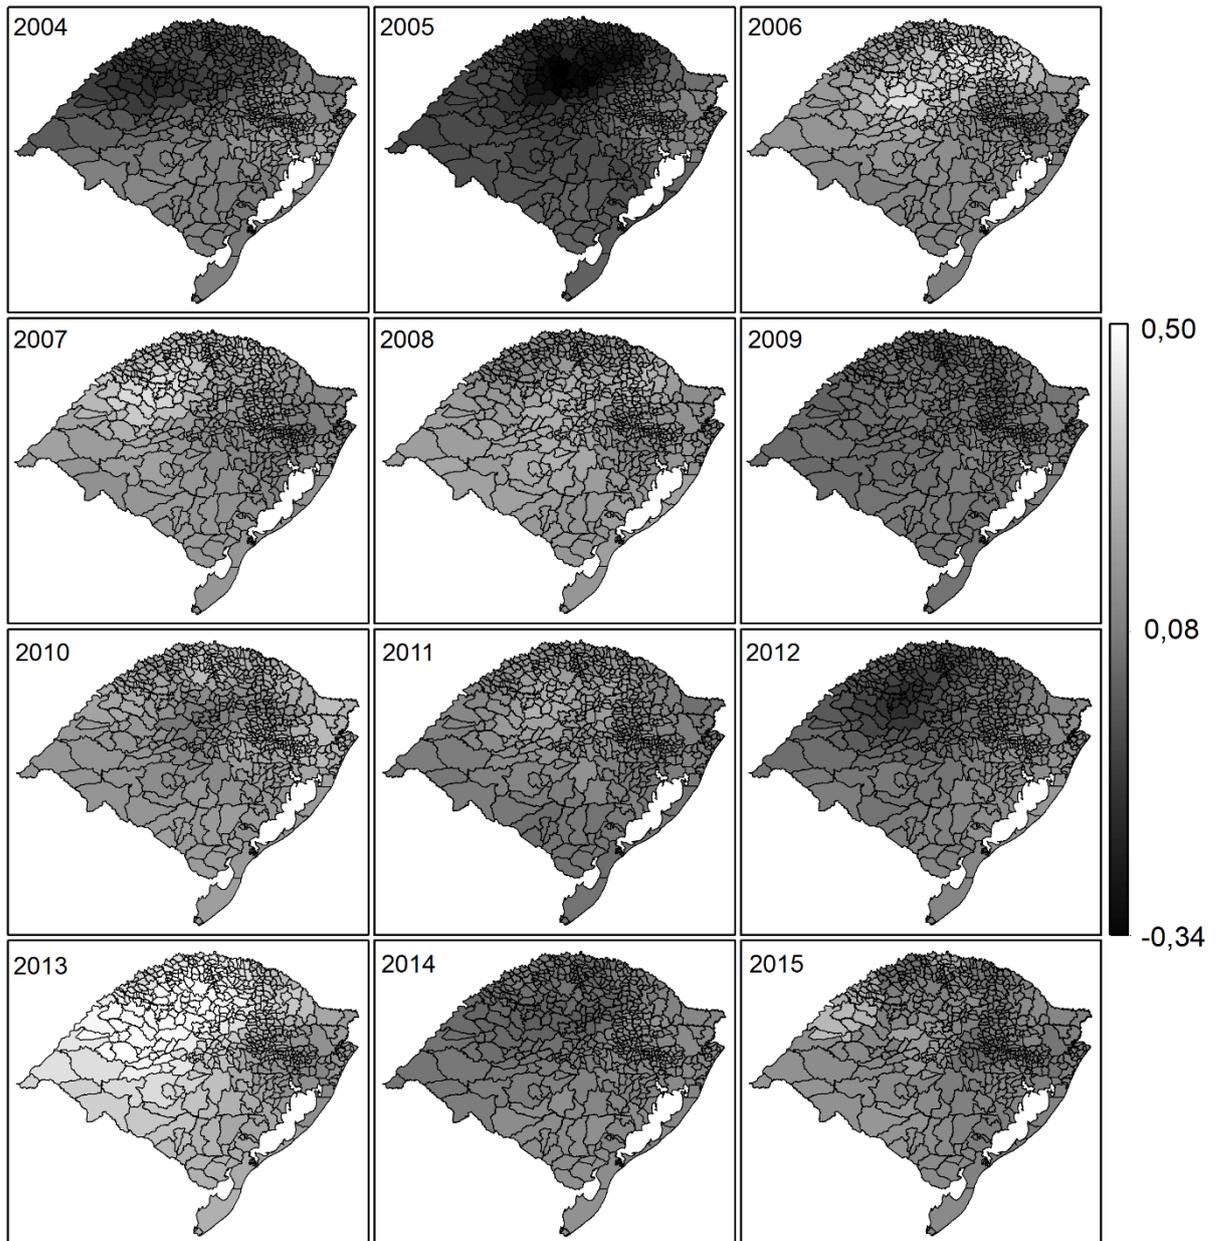


Figura 7 - Média local dos crescimentos do PIB de 2004 a 2015. Escala da figura truncada em 0,5.

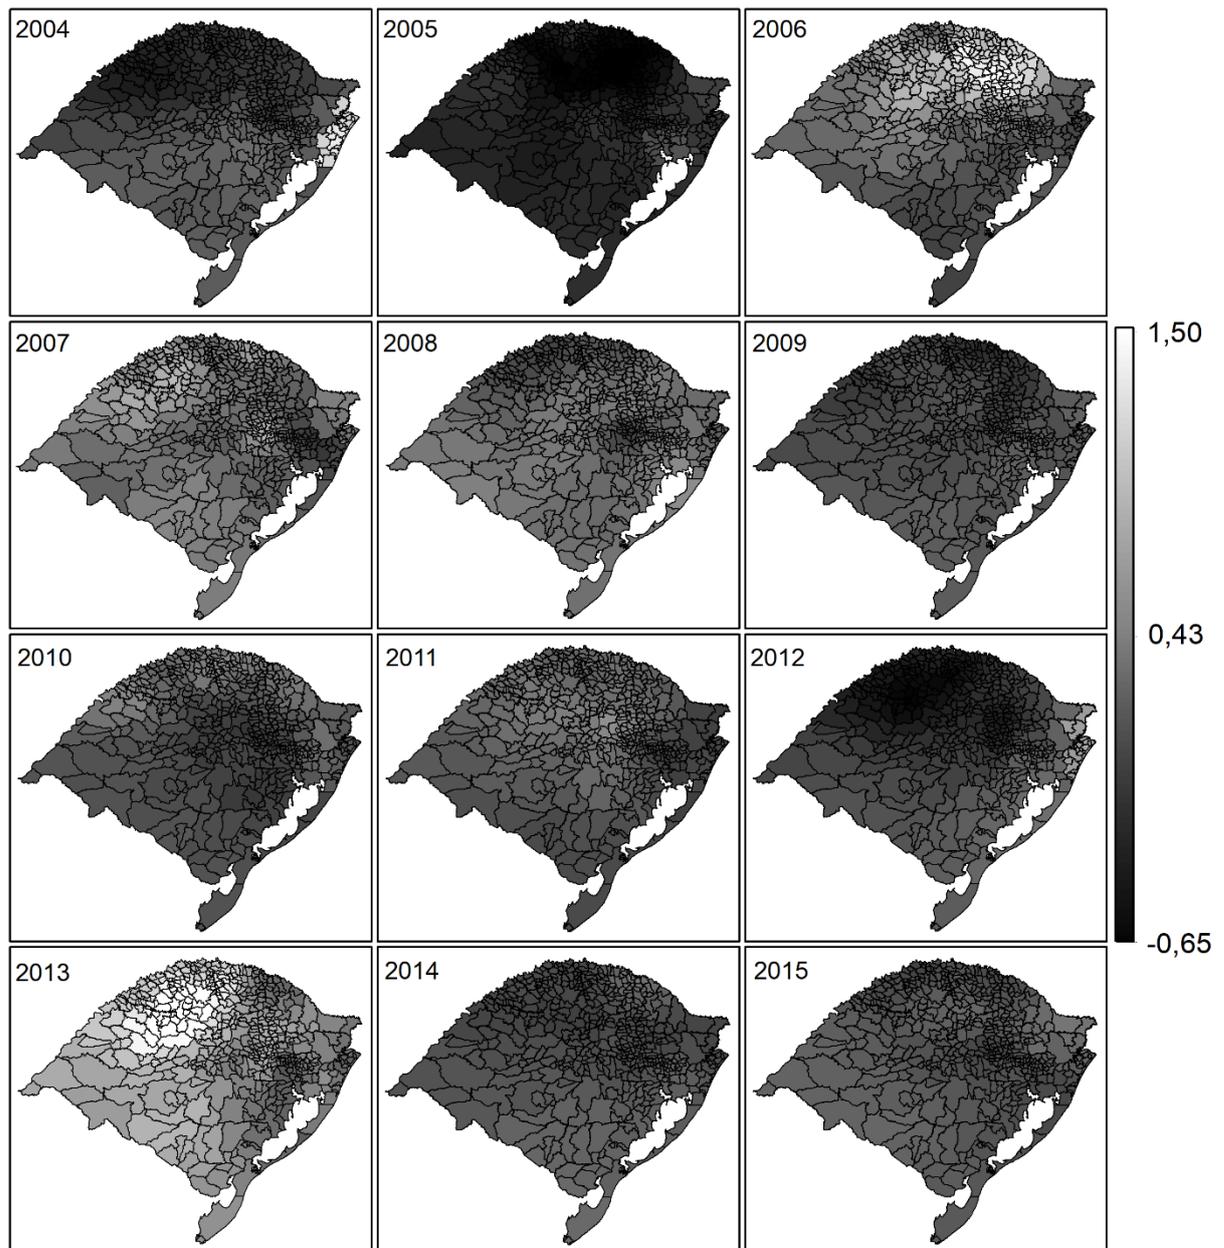


Figura 8 - Média local dos crescimentos do VPA de 2004 a 2015. Escala da figura truncada em 1,5.

As regiões com as maiores variabilidades locais para o cPIB (Figura 9) e o cVPA (Figura 10) se modificam no espaço conforme o ano analisado. O aumento e redução da variabilidade local para uma mesma região indica que as características do ano-safra tendem a modificar a relação espacial entre o crescimento econômico e o desempenho da agricultura nos municípios do RS.

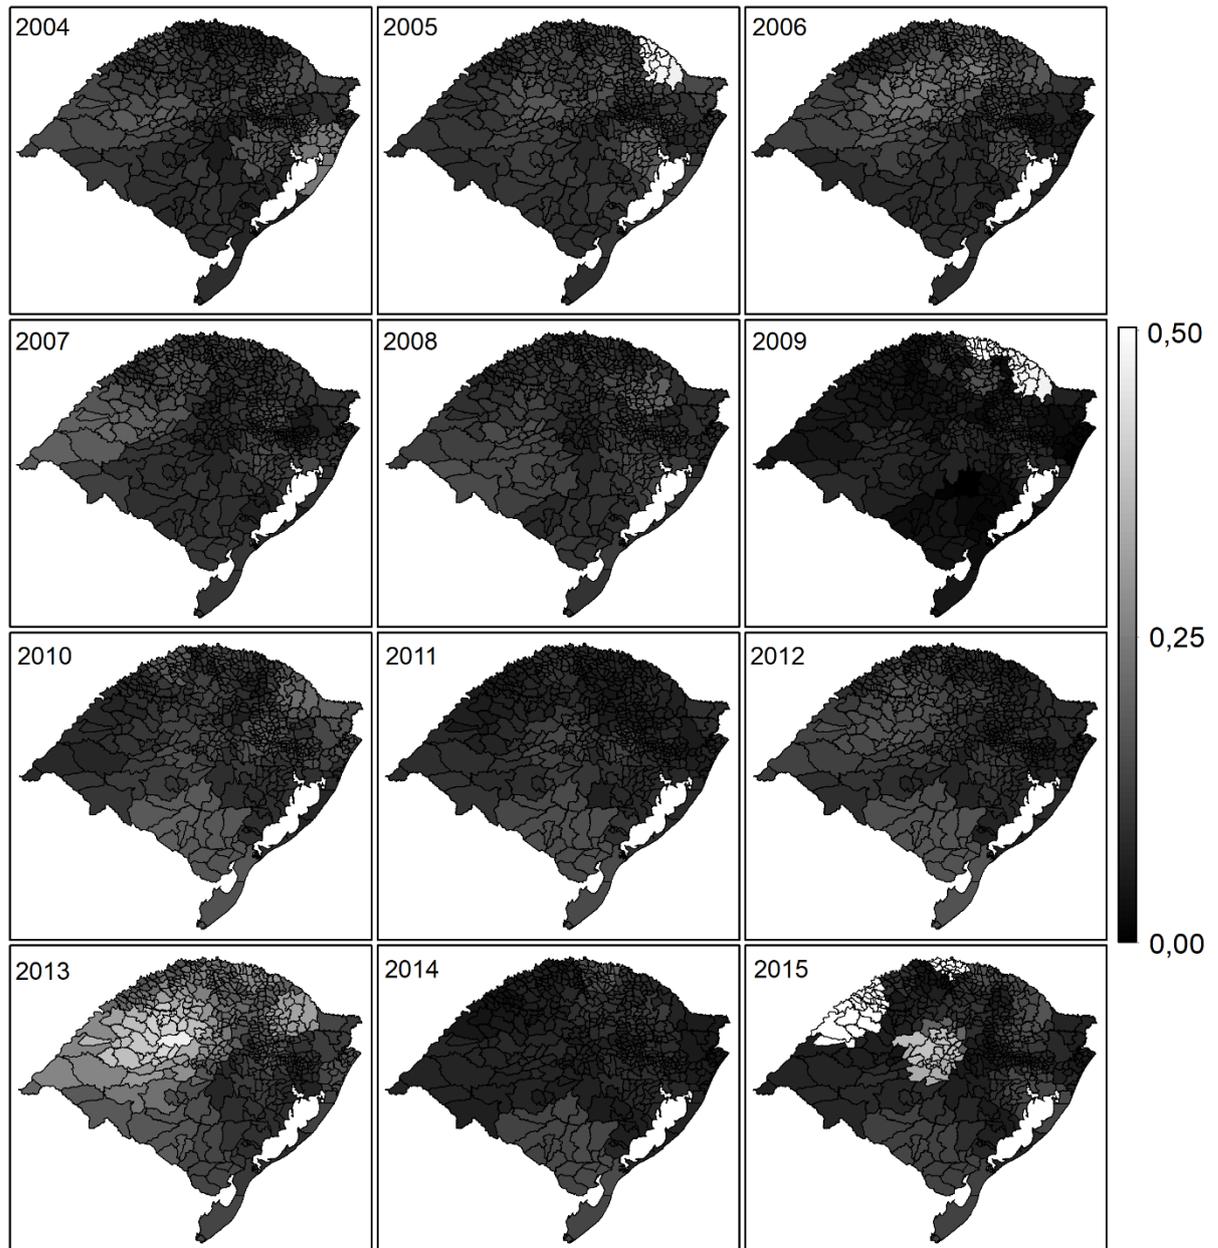


Figura 9 - Desvio Padrão local dos crescimentos do PIB de 2004 a 2015. Escala da figura truncada em 0,5.

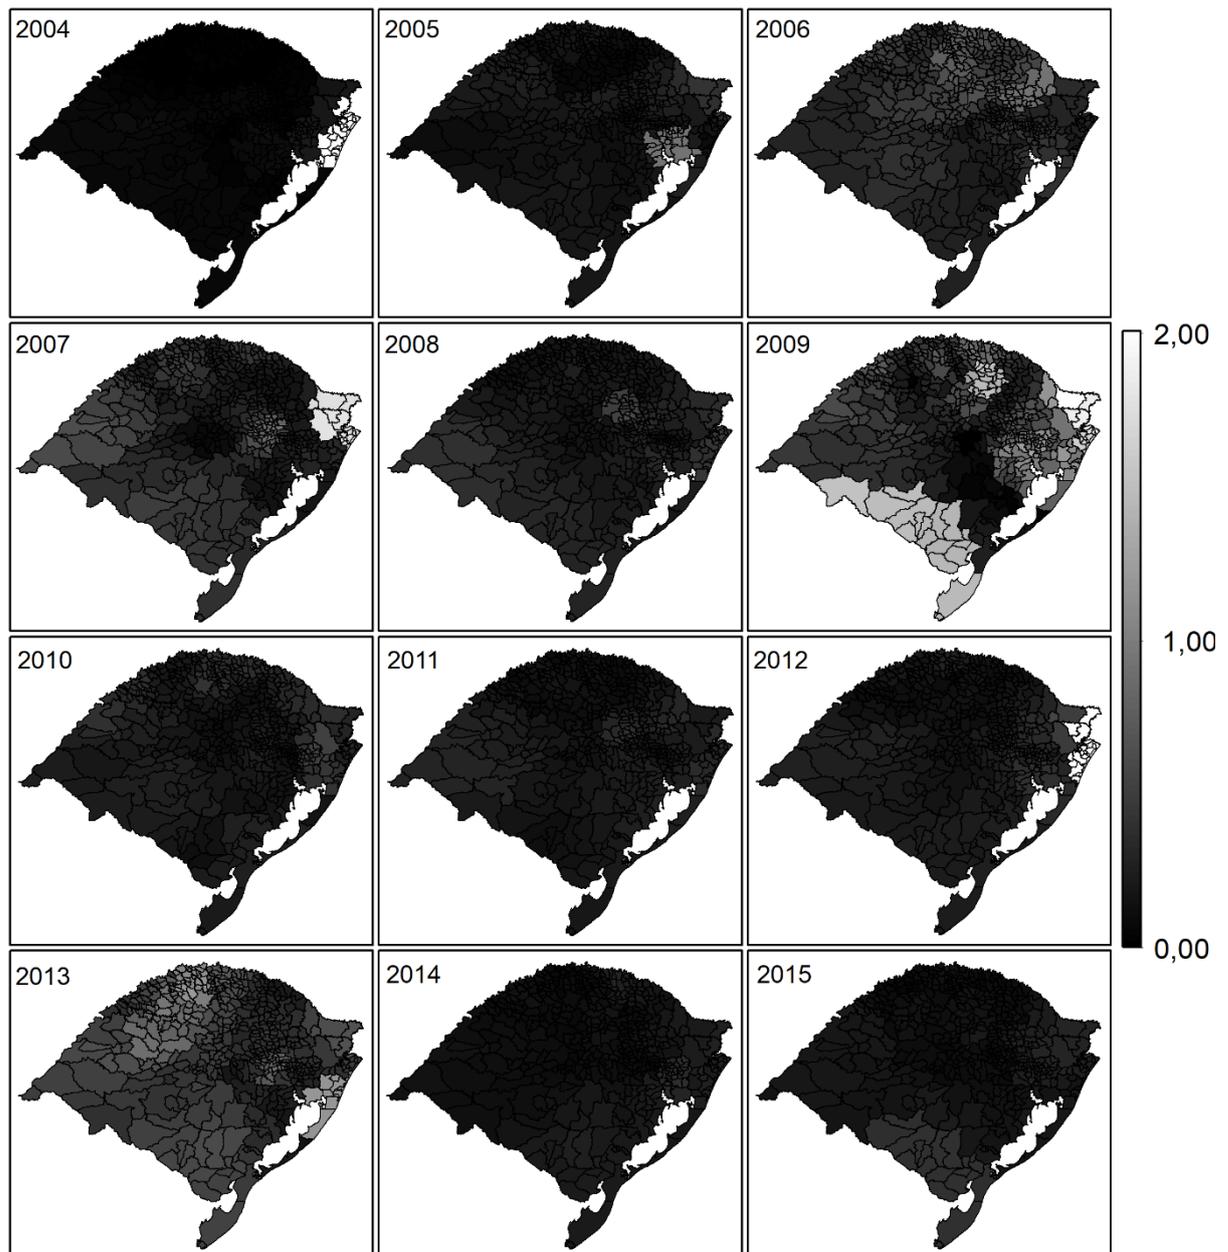


Figura 10 - Desvio Padrão local dos crescimentos do VPA de 2004 a 2015. Escala da figura truncada em 2,0.

Na análise do *z-score* local (Figura 11), observa-se uma tendência de crescimento conjunto espacialmente associada do cPIB e do cVPA em todos os anos estudados, sugerindo que o desempenho da agricultura tem impacto direto no crescimento PIB municipal. Essa tendência se modifica conforme o ano analisado e impõe dificuldade para o entendimento da relação entre o cPIB e o cVPA diante da imposição das características do ano-safra.

Em alguns anos, 2007, 2014 e 2015 por exemplo, é possível observar a formação de dois ou mais grupos de tendência de crescimento conjunto. Isso

significa que o impacto da agricultura na economia dos municípios é diferente ao longo do espaço. No Apêndice A é possível observar a variação espacial e temporal do z-score do cPIB e do cVPA.

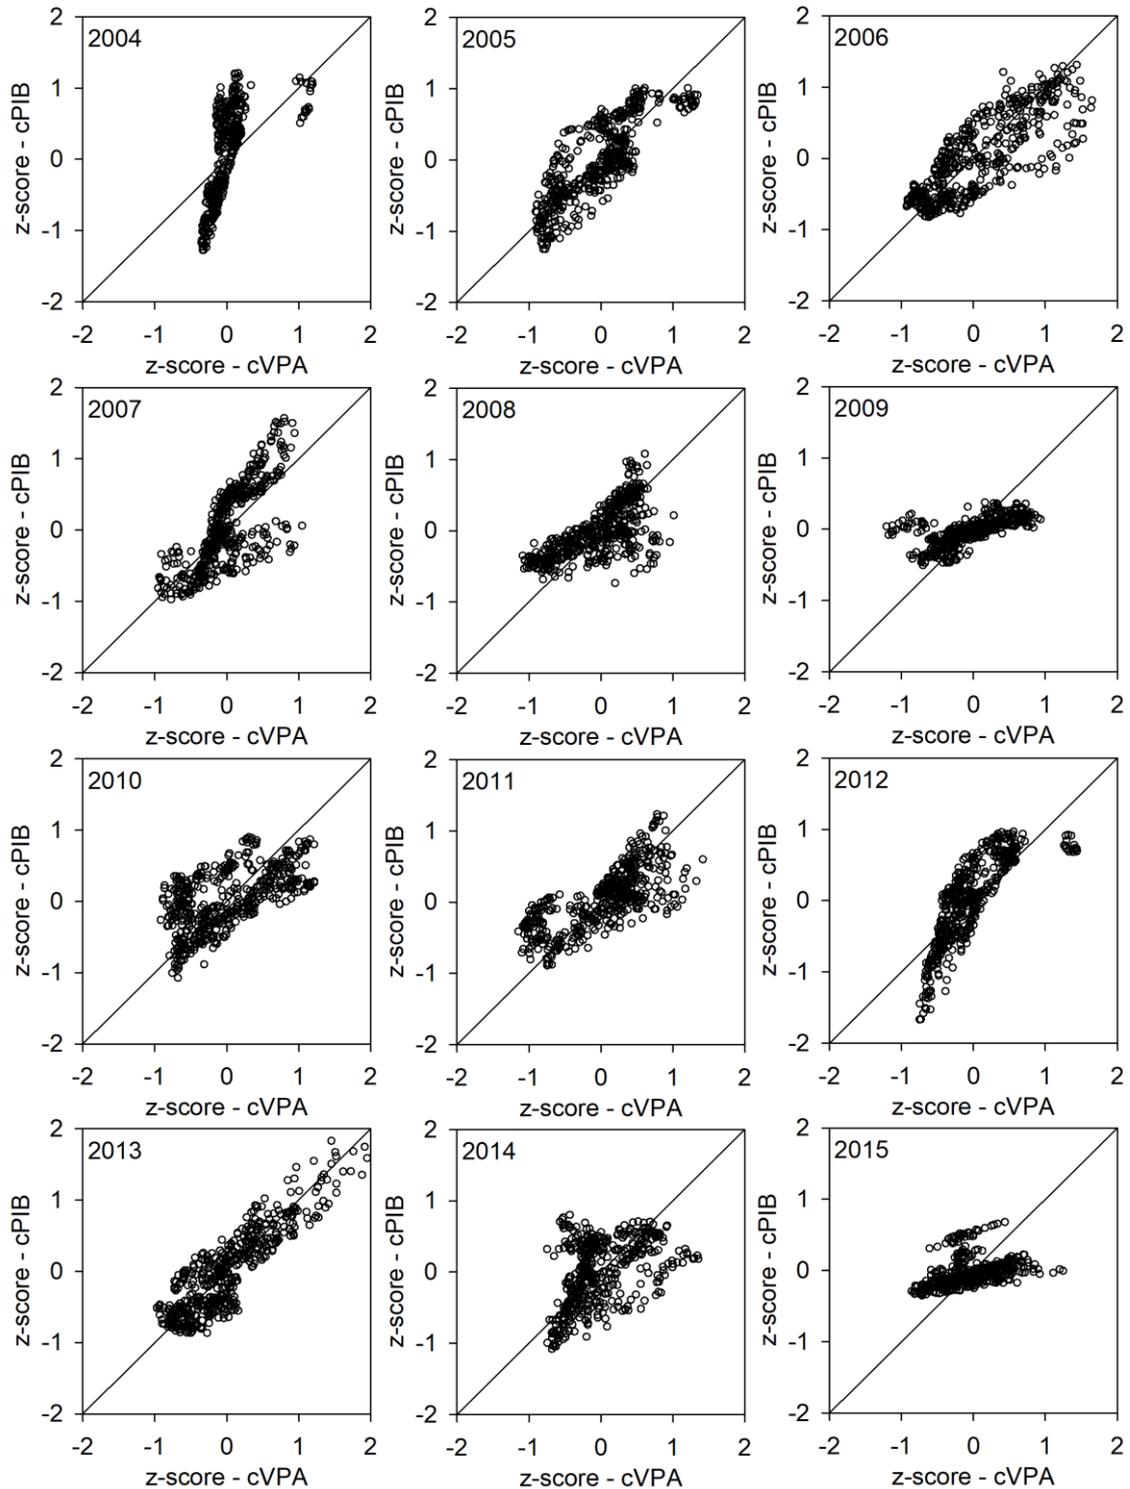


Figura 11 – Z-score local do cPIB e do cVPA de 2004 a 2015.

Os valores de z-score foram agrupados em quartis nos seus respectivos anos. A Figura 12 apresenta a coocorrência espacial de quartis entre o z-score local do cPIB e do cVPA. É possível observar que a relação entre o cPIB e o cVPA é dinâmica no espaço e no tempo. Outra característica é a tendência de constituição de aglomerados regionais que tem predominância de formação na região norte do Estado, indicando que nessa região a agricultura tem uma relação direta com o crescimento econômico.

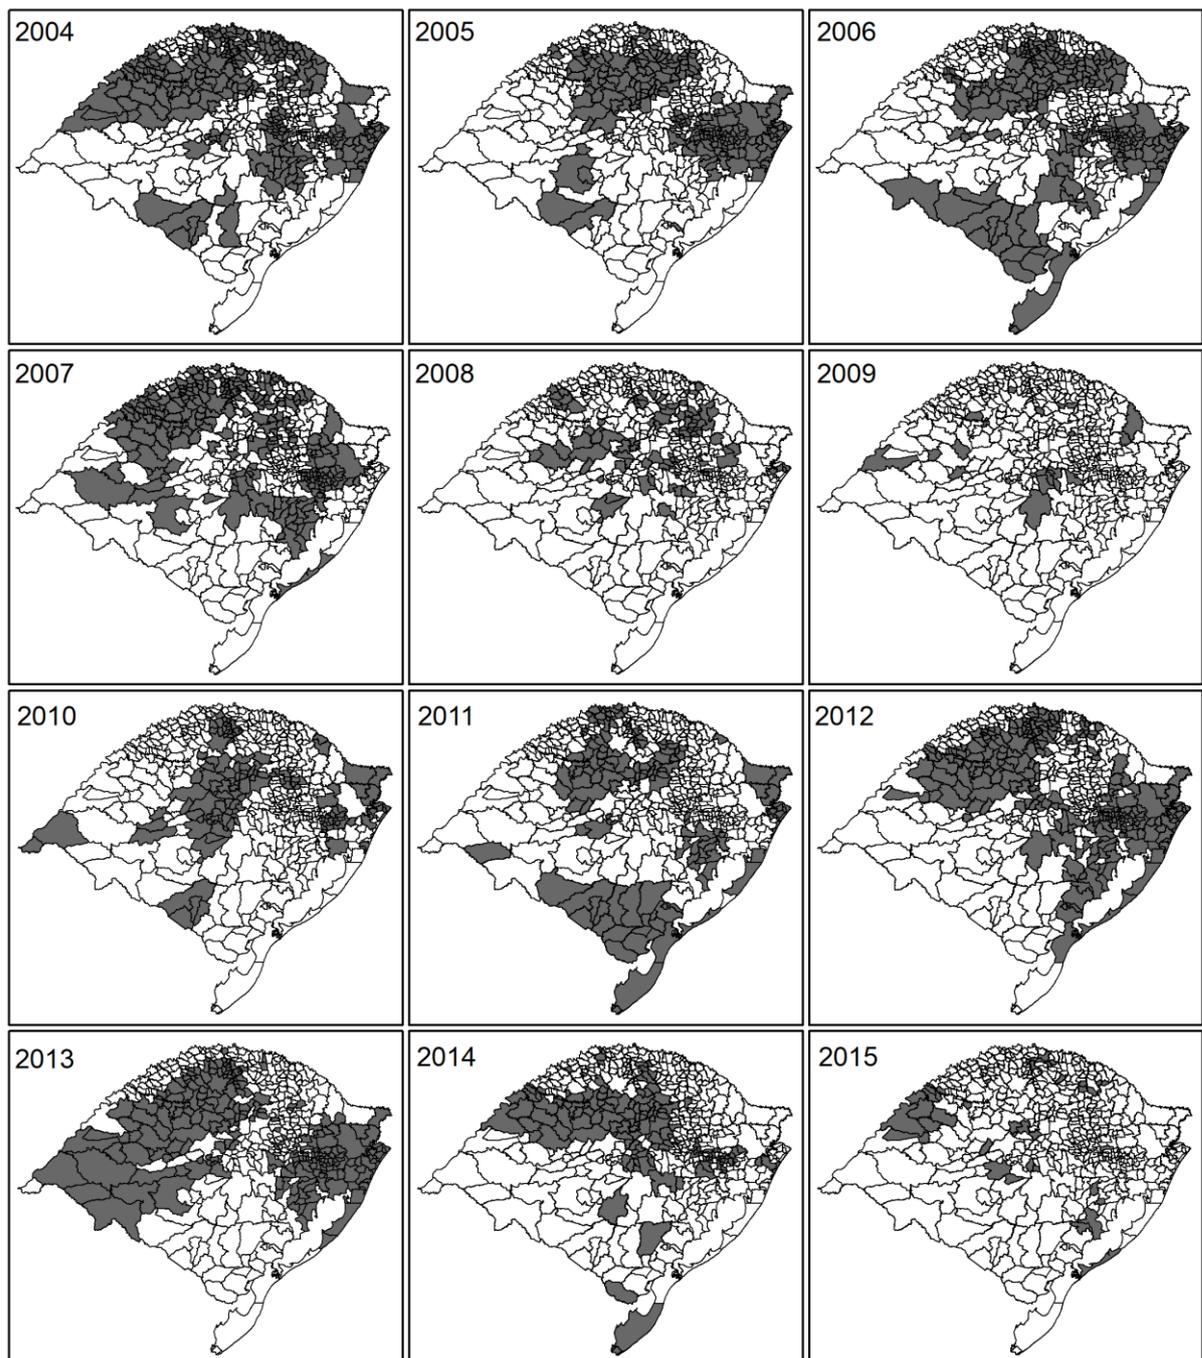


Figura 12 - Coocorrência de quartis (em cinza) de cPIB e cVPA de 2004 a 2015.

Nos anos com os três maiores crescimentos médios (2013, 2006 e 2007) e os três menores crescimentos médios (2005, 2012 e 2004) do PIB e do VPA (Tabelas 2 e 3), houve os maiores números de coocorrência de quartis do *z-score* do cPIB e do cVPA. Isso evidencia que a agricultura é um importante componente na economia dos municípios do RS, sendo capaz de impulsioná-la positiva e negativamente.

Na Figura 13 é possível visualizar que independente do *kernel*, da largura da banda e do método de correlação, existe uma transição da força de associação entre as regiões do Estado. Também se observa, principalmente com a largura de banda definida com 5% das observações, a ocorrência de transições espaciais abruptas. Por causa da função de ponderação, o *kernel* Gaussiano apresentou transições espaciais mais suaves do que os *kernels* *Boxcar* e Biquadrado. O aumento da largura provoca suavizações espaciais em todos os *kernels* e faz com que as correlações locais se aproximem da correlação global. No Apêndice B são apresentadas as correlações locais durante os doze anos desse estudo para três os *kernels*.

A variação observada na força de associação local ocorre principalmente entre as regiões oeste e leste, sendo originada das matrizes econômicas municipais. A região leste é a região industrialmente mais ativa do RS (FEE, 2018b), onde foram observadas correlações negativas e as menores forças de associação entre o cVPA e o cPIB.

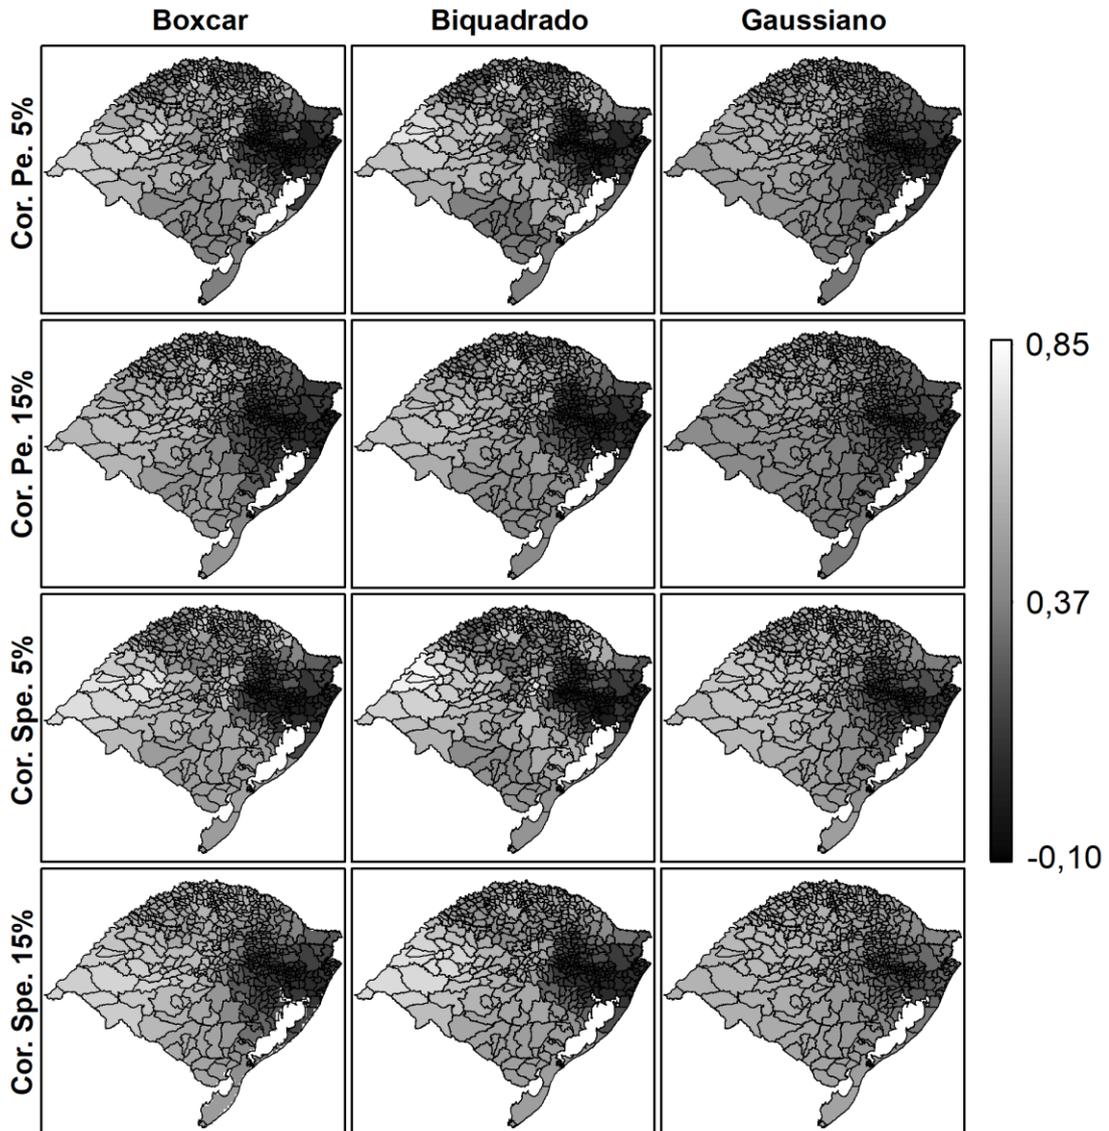


Figura 13 - Correlações lineares (Cor. Pe.) e robustas (Cor. Spe.) médias para os *kernels* Boxcar, Biquadrado e Gaussiano, com largura de banda de 5% (25) e 15% (75).

Como o cVPA é parte aditiva do cPIB, na ausência de outros influenciadores a correlação entre os crescimentos é, portanto, linear, positiva e perfeita. Porém, na presença dos outros formadores do PIB e de relações não lineares, correlações negativas e não lineares ocorrem em regiões do Estado onde a agricultura corresponde por uma parcela muito pequena da economia e o desempenho econômico é mais dependente dos setores industrial e de serviços. Isso mascara a relação entre o cPIB e o cVPA e por tanto a correlação positiva.

Na análise da variação temporal das medidas de localização/quantis (Figuras 14, 15, 16 e 17), nos três *kernels*, pode-se perceber a existência de um padrão com relação à amplitude das correlações anuais. O *kernel* Biquadrado apresentou as

maiores amplitudes das correlações locais, seguido pelos *Boxcar* e Gaussiano respectivamente. A função de ponderação do *kernel* Biquadrado reduz abruptamente o peso da observação na estimação, por isso o *kernel* expõe variações abruptas no espaço decorrentes da variação abrupta da associação entre cPIB e cVPA. Por exemplo, a transição entre as regiões oeste e leste, onde a primeira região possui sua economia mais dependente do desempenho da agricultura e a segunda da indústria (FEE, 2018b; SEPLAN-RS, 2015). Essa menor suavização promove a maior amplitude interquartílica e ocorrência de *outliers* observada. O *kernel* *Boxcar* não pondera os valores dentro do alcance da largura de banda e assim guarda uma relação objetiva com o processo global, mas em geral isso não promoveu a convergência das médias locais para as médias globais. Um processo não geostacionário da relação entre o cPIB e o cVPA fica evidente por conta dessa constatação. No *kernel* Gaussiano os valores mais distantes que o limite definido pela largura de banda tem pouca influência sobre as estimações locais. Porém a função gaussiana e a inclusão de todo o domínio espacial na estimação da correlação resultaram em transições suaves da força de associação.

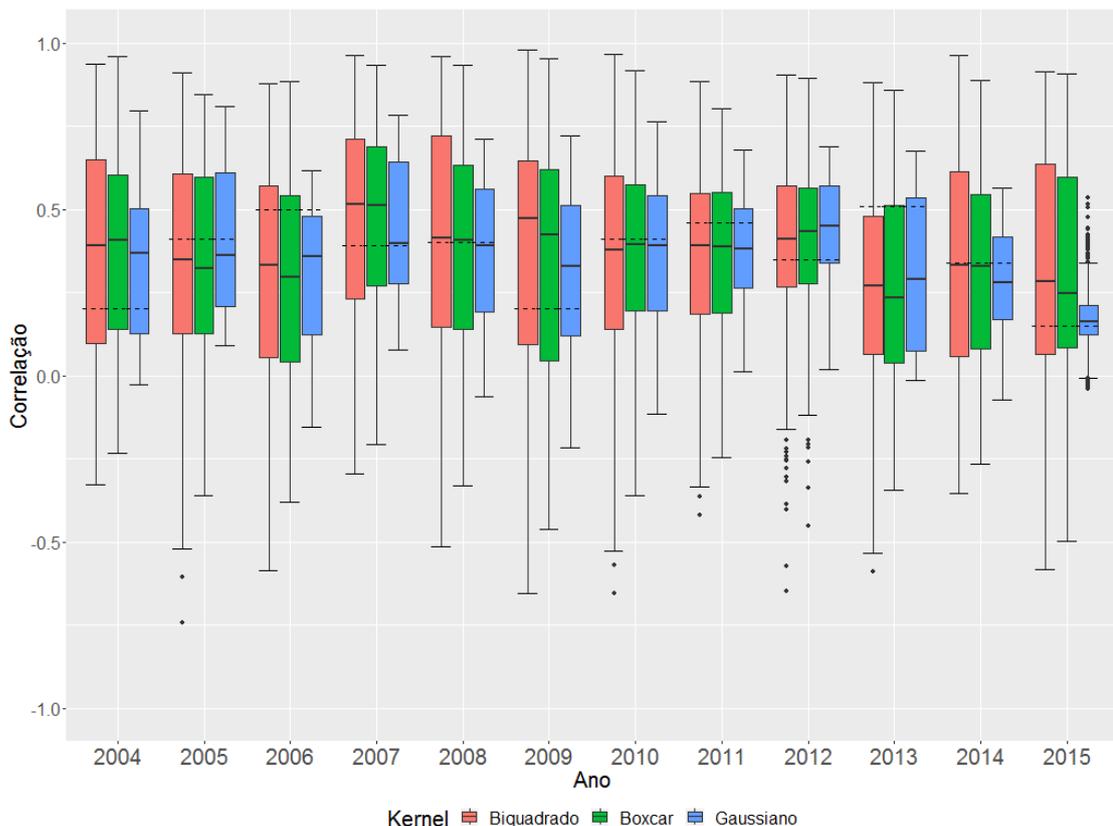


Figura 14 - Correlações locais lineares com largura de banda de 5% (25) de 2004 a 2015. A linha pontilhada corresponde ao valor da correlação global linear.

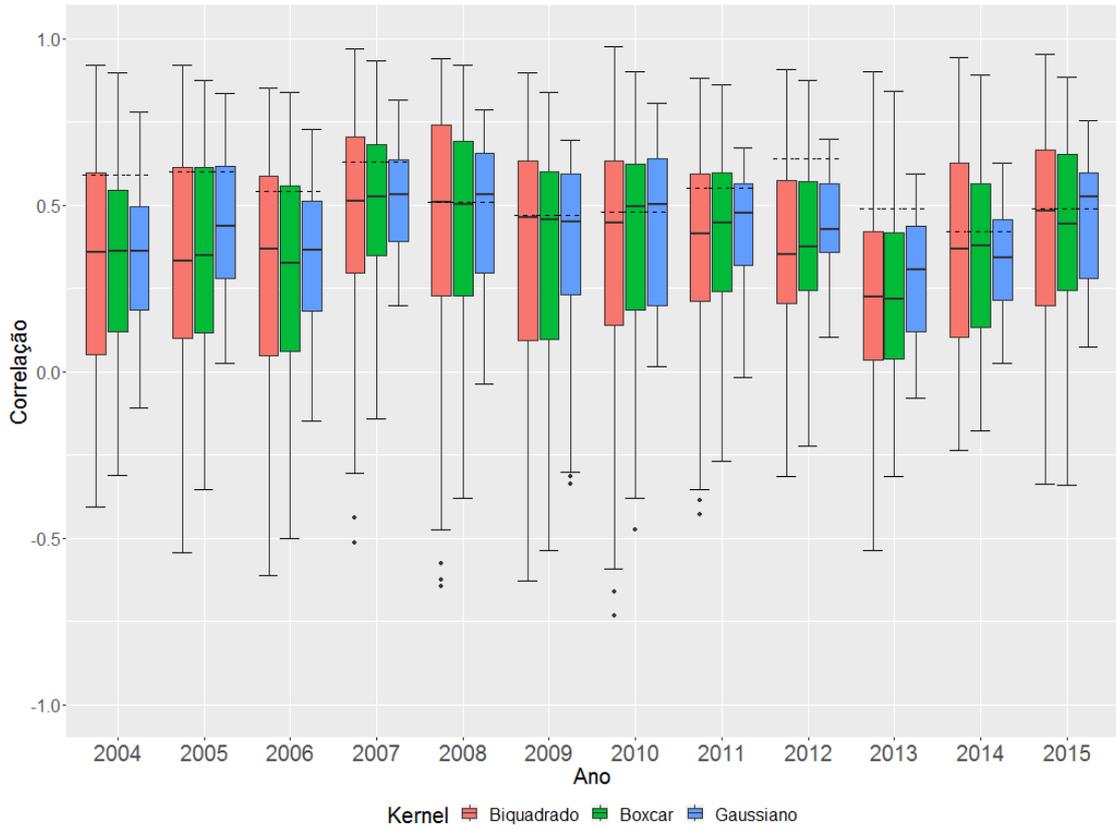


Figura 15 - Correlações locais robustas com largura de banda de 5% (25) de 2004 a 2015. A linha pontilhada corresponde ao valor da correlação global robusta.

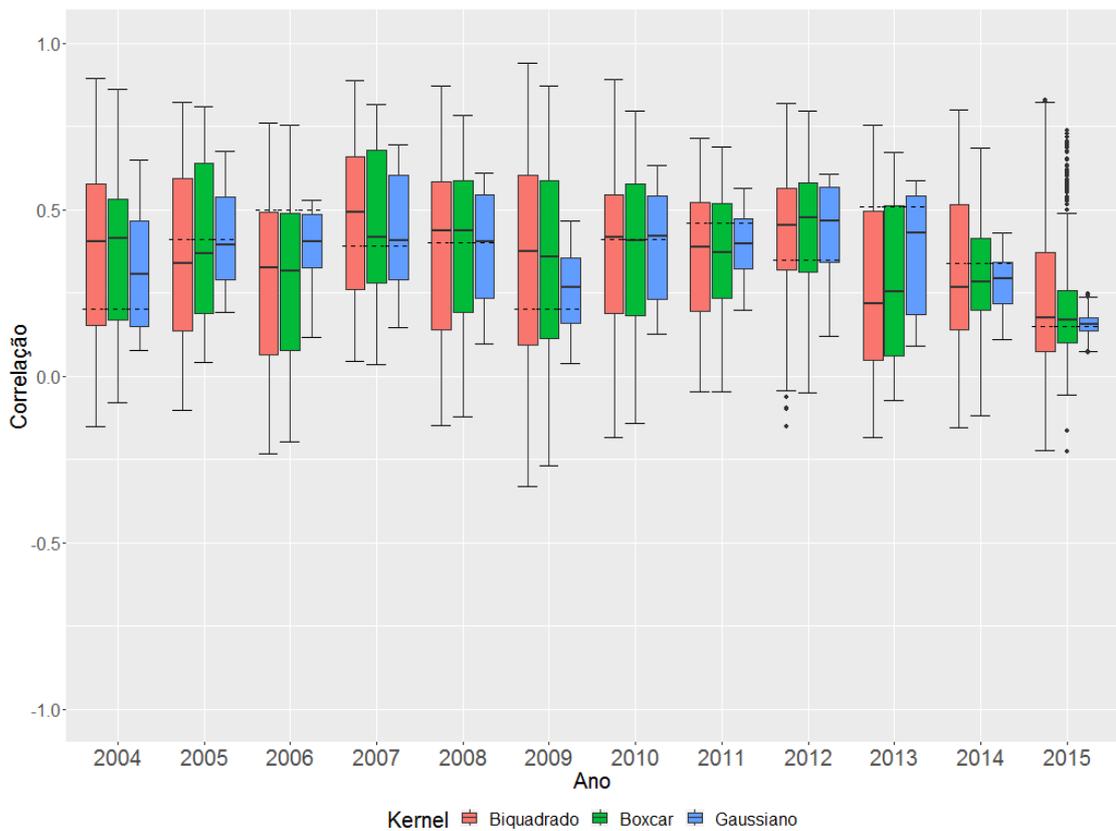


Figura 16 - Correlações locais lineares com largura de banda de 15% (75) de 2004 a 2015. A linha pontilhada corresponde ao valor da correlação global linear.

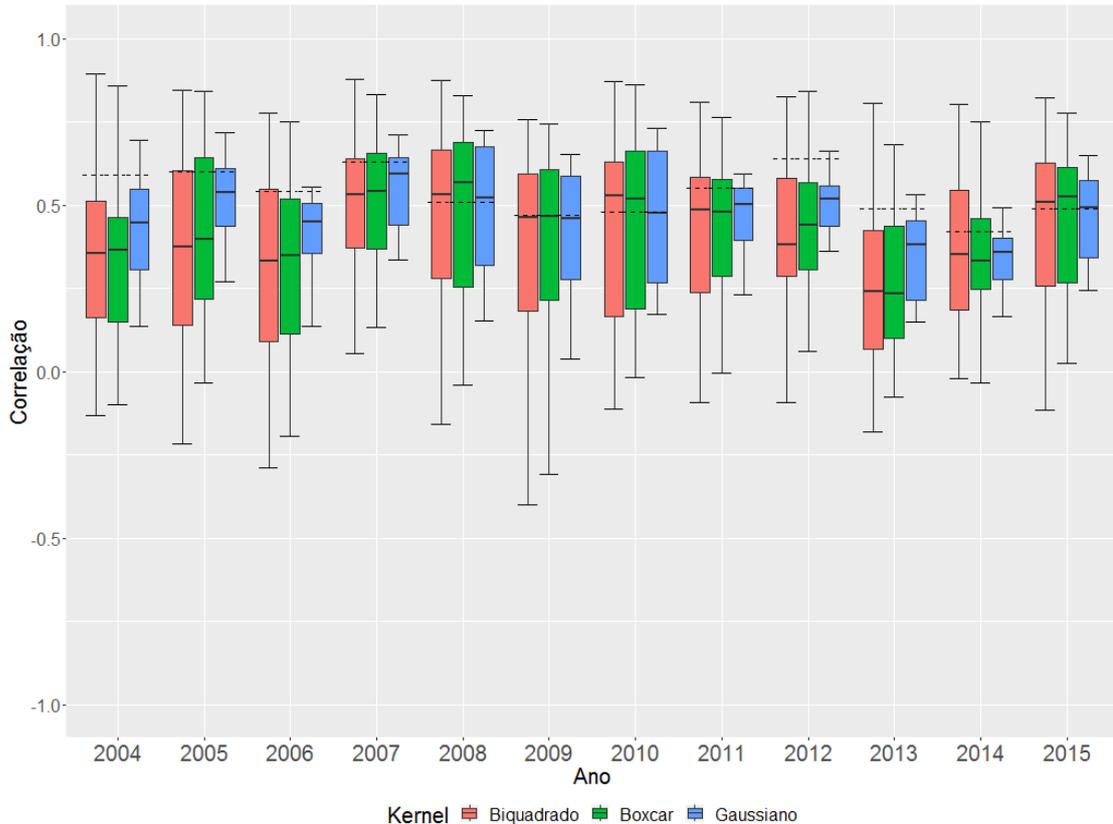


Figura 17 - Correlações locais robustas com largura de banda de 15% (75) de 2004 a 2015. A linha pontilhada corresponde ao valor da correlação global robusta.

A oscilação da posição dos quartis das correlações locais revela que o ano-safra modifica o alinhamento entre as economias municipais e o desempenho da agricultura. Isso indica que a exposição do cPIB a uma oscilação no cVPA é diferente dependendo do ano e da região analisada. Além disso, a oscilação temporal das diferenças entre as correlações locais e globais revela que o Estado está exposto a um processo não estacionário complexo que modula a transformação do VPA em riqueza. Tal processo demandará a realização de estudos com emprego de modelos espaço-temporais multivariados para incorporar os efeitos de clima, mercado e de mudanças nas matrizes econômicas municipais.

Independente do efeito do ano-safra que modifica a relação entre o cPIB e o cVPA, a correlação global subestima e superestima a força de associação em mais de 50% dos municípios do Estado. Em regiões onde a agricultura é suma importância para a economia a relação foi subestimada. Por outro lado, a relação foi superestimada em regiões onde os setores industrial e de serviços são mais importantes para o crescimento econômico.

O aumento da largura de banda incorpora mais observações no cálculo das estatísticas locais. Isso promove além de suavizações espaciais na transição da força de associação também redução da variabilidade em todos *kernels*, aproximando as correlações locais das globais.

A transição da força de associação média entre as regiões utilizando os transectos (Figura 18) revela que a maior variação na relação entre o cPIB e o cVPA ocorre ao longo do Transecto Oeste/Leste e não como era esperado no Transecto Norte/Sul devido as constantes comparações entre as regiões Norte e Sul (ALONSO, 2006; CHELLOTTI; CASTANHO, 2006). A região leste possui correlações mais fortes e positivas, enquanto a oeste possui correlações mais fracas e negativas. As regiões norte e sul apresentaram correlações semelhantes. A transição da força de associação entre as regiões com os três *kernels* e as duas larguras de banda durante os doze anos, pode ser observada no Apêndice C.

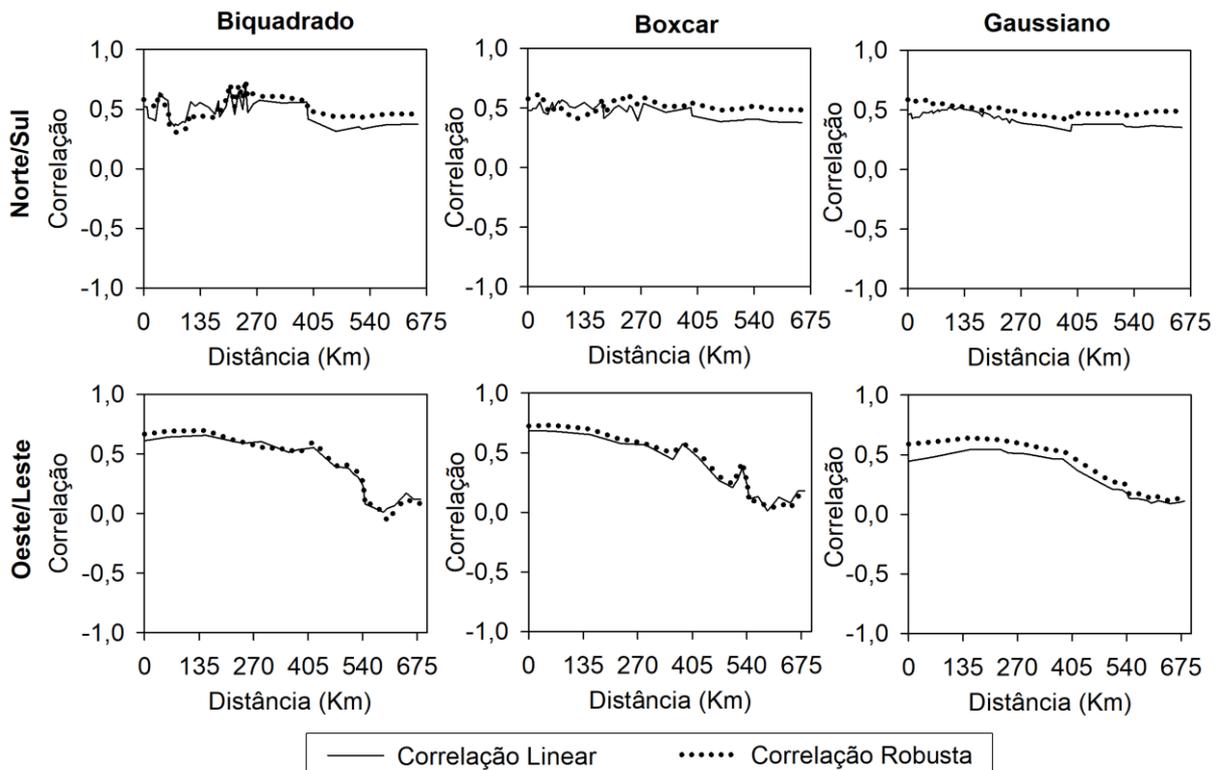


Figura 18 - Correlações lineares e robustas médias nos transectos Norte/Sul e Oeste/Leste para os *kernels* Boxcar, Biquadrado e Gaussiano, com largura de banda de 5% (25).

A correlação robusta geralmente maior indica que parte da força de associação entre o cPIB e o cVPA não é capturada sob a hipótese de correlação linear, talvez como resultado do reemprego do VPA em atividades com maior valor

econômico agregado. No entanto, a não linearidade parece ser um fenômeno com maior escala espacial, haja visto que as correlações robusta e linear são menos discrepantes com a redução da largura de banda.

O número de vezes em que a correlação local foi significativa pelo método de Monte Carlo ($\alpha = 0,1$ e 999 permutações) (Figura 19) sugere a predominância da ocorrência de relações significativas nas regiões leste e oeste do Estado. Isso revela que a estruturação espacial modula a associação entre o cPIB e o cVPA no RS. As correlações nessas regiões são moduladas por um processo espacial e conseqüentemente a transição da força de associação entre as regiões leste e oeste não acontece ao acaso.

Em números absolutos, o número de correlações significativas oscilou pouco entre os anos, *kernels*, modelo de correlação e diferentes larguras de banda. Em média, 50 resultados significativos para não estacionariedade da correlação em cada combinação. A diferença foi verificada na distribuição da estruturação espacial significativa da correlação. Em 2005 e 2010, por exemplo, resultados significativos foram observados em regiões onde o tamanho médio dos municípios é menor na comparação com o restante do Estado. No Apêndice D é possível observar a ocorrência das correlações significativas para os três *kernels* e duas larguras de banda durante os doze anos.

Novamente existe a evidência de que as características do ano-safra influenciam a relação espacial entre o cPIB e o cVPA no estado do RS. Tanto a força de associação quanto a estruturação espacial se modificam no tempo, supostamente em resposta aos campos aleatórios de variáveis climáticas específicos do ano-safra.

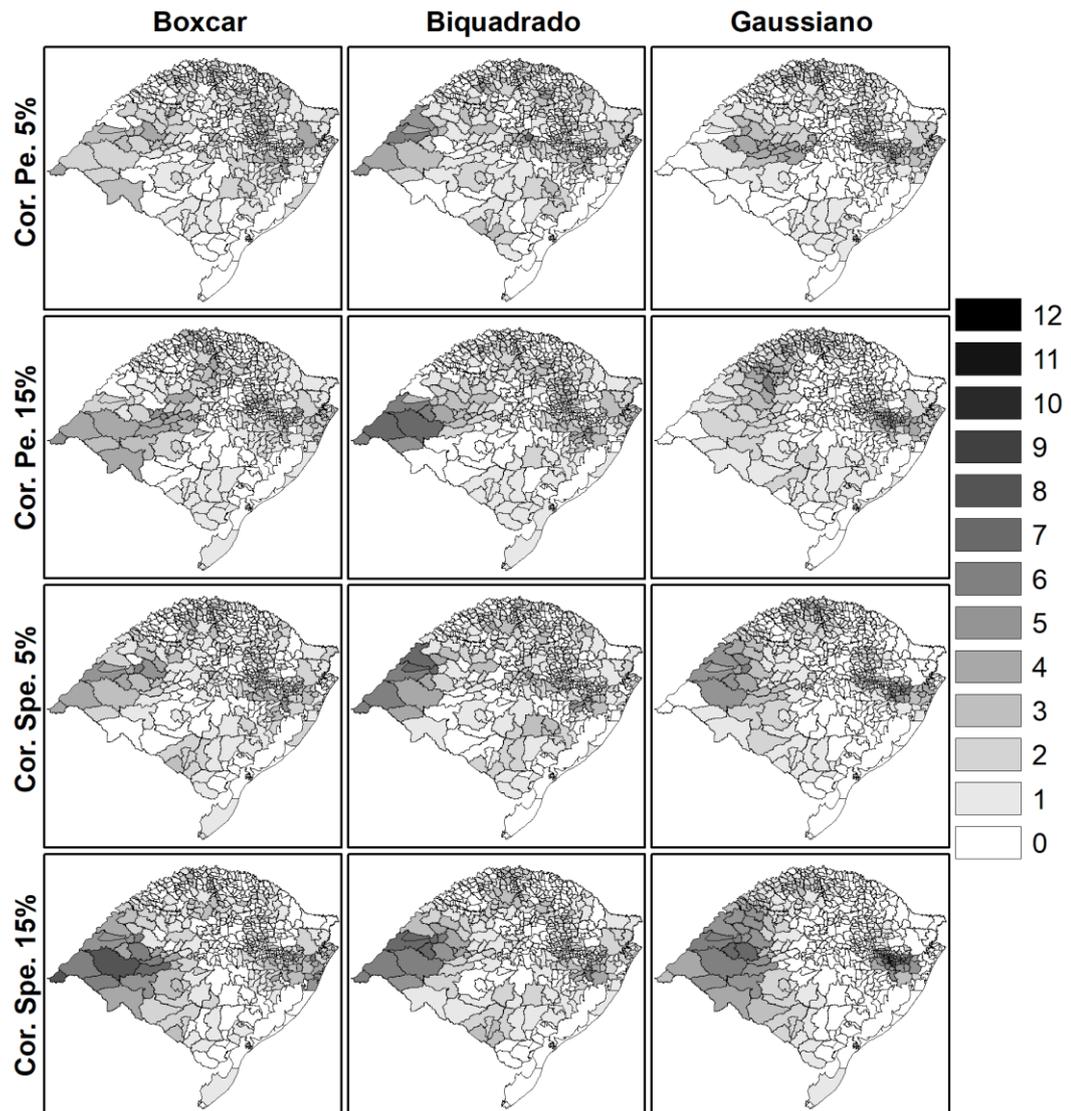


Figura 19 - Número de anos em que a relação entre o cPIB e o cVPA foi significativa ($\alpha = 0,1$) no teste de Monte Carlo para as correlações lineares (Cor. Pe.) e robustas (Cor. Spe.) utilizando os kernels *Boxcar*, *Biquadrado* e *Gaussiano*, com largura de banda de 5% (25).

4 Conclusões

No estado do Rio Grande do Sul existem correlações fortes e fracas espacialmente estruturadas o que demanda a utilização de modelos espaciais para analisar diferenças locais.

Existe variação na força de associação significativa entre as regiões oeste e leste do Estado. A região oeste possui o crescimento fortemente atrelado ao desempenho da agricultura, enquanto que na região leste essa dependência é menor.

Nas regiões norte e sul não foram observadas mudanças espaciais na força de associação entre as regiões, a relação entre a agricultura e a economia se mostrou semelhante nas duas regiões.

A utilização de diferentes *kernels* provoca suavizações espaciais e mudanças na amplitude da força de associação contudo, independente do *kernel* utilizado a estruturação espacial e as diferenças regionais sempre estiveram presentes na relação entre o cPIB e o cVPA.

A estruturação espacial observada no período de estudo sofreu grande influência das características do ano-safra. Isso revela a existência de uma componente temporal que é de suma importância para o entendimento da relação entre o cPIB e o cVPA.

Um dos motivos para influência do ano-safra na relação espacial pode ser a modificação das matrizes econômicas municipais, o que levaria a uma alteração da importância da agricultura na economia dos municípios.

Capítulo 2 – Modelagem espacial da relação entre o crescimento do PIB e o desempenho agrícola no estado do Rio Grande do Sul

1 Introdução

O estado do Rio Grande do Sul (RS) apresenta distinções quanto a capacidade de geração de riquezas dentro do seu território (SEPLAN-RS, 2015). Por conta disso, modelos globais que analisam apenas a convergência entre as variáveis acabam por negligenciar as variações locais (LI et al., 2019). Análises que capturem as mudanças de relações entre as variáveis no espaço e no tempo possibilitam avaliar como as relações locais entre as variáveis se modificam em diferentes escalas espaciais e temporais (FOTHERINGHAM et al., 2002; MA et al., 2018).

A economia do Estado possui uma relação reconhecidamente forte com a agropecuária (COLLE et al., 2017; FOCHEZZATO; GRANDO, 2009; LAZZARI, 2012), especialmente com o desempenho da agricultura que representou aproximadamente dois terços (69%) da agropecuária entre 2010 e 2014 (FEE, 2018a), porém, essa participação é pouco entendida sob o aspecto das condicionantes espaciais.

Métricas e modelos espaciais podem revelar relações detalhadas sobre a economia regional do território. A análise da variação espacial e temporal da economia do RS em função das condicionantes do mercado e da produção agrícola permite caracterizar os níveis de exposição, o potencial de retorno e a interdependência entre a economia e o desempenho da agricultura.

A relação global entre o crescimento da economia e o desempenho da agricultura resulta de variáveis locais até o momento pouco estudadas no RS. Diante do exposto, o objetivo desse estudo é utilizar modelos de regressão geograficamente ponderados (GWR) para estimar a variação espacial da contribuição do VPA para o PIB do RS entre 2004 a 2015.

2 Metodologia

2.1 Área de Estudo

O estudo compreende o estado do Rio Grande do Sul localizado na região sul do Brasil (Figura 20). Entre 2004 e 2015 a economia do Estado foi formada por 64,9% proveniente do setor de serviços, 26,2% do setor industrial e 8,9% do setor agropecuário (FEE, 2018a). O setor agropecuário apesar de ter participação menor que a dos demais, não pode ser visto como um setor com baixa importância uma vez que no ano de 2013, em 30% dos municípios ele foi o setor majoritário e em outros 32% teve participação superior a 30% na economia (RISCO, 2016). O Estado possui 497 municípios, contudo, foram analisados 496 municípios por terem a série de dados completa.

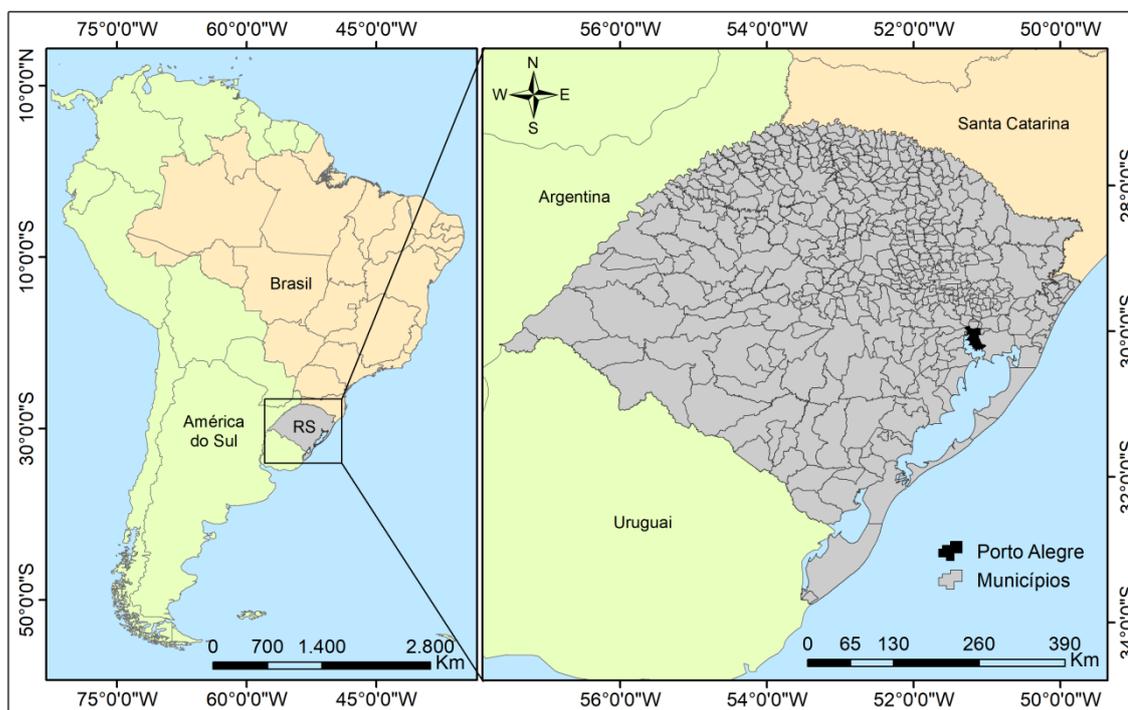


Figura 20 – Localização e divisão territorial do Estado do Rio Grande do Sul.

2.2 Base de Dados

O estudo foi realizado com dados econômicos municipais anuais coletados pelo Instituto Brasileiro de Geografia e Estatística (IBGE) de 2004 a 2015. Foram utilizados dados de PIB municipal como métrica de desempenho econômico e de Valor da Produção Agrícola (VPA) municipal como métrica de desempenho agrícola.

O VPA é uma métrica resultante do produto da multiplicação entre a produção das principais culturas de importância econômica e social do Brasil e o valor médio da comercialização das mesmas (IBGE, 2017).

Para minimizar problemas decorrentes da magnitude das economias municipais, os valores do PIB e do VPA foram convertidos em taxas anuais de crescimento, $cPIB_t$ e $cVPA_t$, respectivamente. A transformação em taxas de crescimento possibilita analisar de forma objetiva o crescimento das economias municipais em resposta ao desempenho da safra. Os procedimentos de cálculo das taxas são expressos nas Equações 08 e 09.

$$cPIB_t = \frac{(PIB_t - PIB_{t-1})}{PIB_{t-1}} \quad (08)$$

Em que $cPIB_t$ é o crescimento do PIB para o ano t.

$$cVPA_t = \frac{(VPA_t - VPA_{t-1})}{VPA_{t-1}} \quad (09)$$

Em que $cVPA_t$ é o crescimento do VPA para o ano t.

2.3 Modelagem Espacial

Foram utilizados modelos de regressão linear simples (Equação 10) para verificar a taxa global de transformação do crescimento do VPA para o crescimento do PIB. Enquanto regressões geograficamente ponderadas (GWR) (Equação 11) foram ajustadas para examinar a estacionariedade espacial da taxa de transformação em diferentes escalas. Os modelos foram estimados para cada ano do estudo e posteriormente analisados para verificação da significância.

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (10)$$

Em que Y e X são respectivamente as taxas (dependente e independente) do crescimento do PIB e do VPA. β_0 e β_1 são os parâmetros do modelo e ε é o erro associado a estimativa.

$$y_i = \beta_0(u_i, v_i) + \beta_1(u_i, v_i)x_i + \varepsilon_i \quad (11)$$

Em que y é a variável dependente e corresponde ao crescimento do PIB, i indica a região da área de estudo, (u_i, v_i) é o par de coordenadas de localização da região i , β_0 e β_1 são os parâmetros do modelo (Equação 12), x_i é a variável independente e corresponde ao crescimento do VPA e ε_i é o erro associado à estimativa da região i .

$$\hat{\beta}(u_i, v_i) = (X^T W(u_i, v_i) X)^{-1} (X^T W(u_i, v_i) Y) \quad (12)$$

Em que $\hat{\beta}$ é a estimativa do parâmetro, X é a matriz da variável independente, X^T é matriz X transposta, Y é a matriz da variável dependente e $W(u_i, v_i)$ é uma matriz diagonal com elementos w_{ij} que representam os pesos espaciais na região de estudo.

Nos modelos de regressão linear global (RG) a relação entre a variável dependente e independente é constante e por isso impossibilitam avaliar distinções locais da contribuição do VPA para a economia. Os modelos GWR levam em conta a heterogeneidade espacial na relação entre a variável dependente e independente (LI et al., 2019) e por isso as estimativas dos parâmetros do modelo de regressão estão condicionadas ao espaço.

O *kernel Boxcar* (Equação 13) foi utilizado como ponderador espacial por conta da conformidade com o modelo global. O *kernel Boxcar* não atribui pesos diferentes para as observações no domínio de inclusão espacial. Todas as observações dentro do espaço delimitado pela largura de banda têm o mesmo peso na estimação para a região de interesse. Como resultado dessa escolha, a análise comparativa é realizada entre a regressão linear global e a regressões locais sob o mesmo critério de ponderação espacial, ou seja, não há distinção entre os pesos das observações.

$$w_{ij} = 1 \text{ se } dist < bw \quad w_{ij} = 0 \text{ caso contrário} \quad (13)$$

Em que *dist* é a matriz de distâncias entre as posições de interesse (os centroides dos vetores municipais) e *bw* é a distância definida pela largura de banda. Os índices *i* e *j* correspondem, respectivamente, aos centroides dos vetores municipais para o centro da matriz de ponderação e para as posições adjacentes.

Existem duas abordagens na seleção da largura de banda. A primeira mantém a distância fixa, podendo o número de observações na estimativa para as regiões ser variável e a segunda mantém o número de observações fixo, podendo a distância entre as observações na estimativa para as regiões ser variável.

Como os polígonos municipais utilizados nesse estudo têm grande variação no que diz respeito ao tamanho e forma, optou-se por utilizar um número fixo de observações por região e tornar a abrangência espacial definida por raios adaptativos. Como implicação, nas regiões metropolitana (em torno de Porto Alegre) e nordeste os municípios são menores que no restante do Estado. Conseqüentemente, nessa região as distâncias entre os centroides municipais são menores e as análises são realizadas com menores raios de abrangência. Na região sudoeste do RS, os municípios são maiores com maior distância entre os centroides municipais e por isso as análises são realizadas com maiores raios de abrangência. A abordagem escolhida evita que em algumas regiões os modelos sejam ajustados com um baixo número de observações (HARRIS; BRUNSDON, 2010).

A estimativa da largura de banda ótima para cada ano safra foi determinada pelo método de validação cruzada (MIRZAEI, et al., 2019; VINAYARAJ, et al., 2016) com critério de otimização baseado na minimização da variância. Para tornar a análise baseada em uma única escala de variação durante os doze anos, a largura de banda foi definida como a mediana das larguras de banda ótimas em cada ano.

A significância das estimativas dos parâmetros dos modelos GWR foi verificada em um teste de Monte Carlo. No teste, a variabilidade dos coeficientes locais foi comparada com a variabilidade encontrada em uma série de conjuntos permutados aleatoriamente 999 vezes. Nesses conjuntos os pares de coordenadas foram sucessivamente permutados aleatoriamente e um modelo GWR foi aplicado em cada aleatorização. Posteriormente foi calculado o desvio padrão dos coeficientes. Com o resultado do teste, a variabilidade real observada foi comparada

com a série permutada, sendo então reportada a significância da variabilidade dos coeficientes.

Foram utilizados três critérios para avaliar os modelos, a proporção da variabilidade explicada pelos modelos (r^2), os erros nas estimativas anuais obtidos pela raiz do erro quadrático médio (RMSE) (Equação 14) e a redução da autocorrelação espacial dos resíduos medida pelo índice de Moran (Equação 15).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\text{Predito}_i - \text{Observado}_i)^2}{n}} \quad (14)$$

$$I = \frac{n}{W} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

Em que I é o índice de Moran, n é o número de observações, i e j correspondem respectivamente às observações no centro da análise e adjacentes, \bar{y} é a média das observações, w_{ij} neste caso é a matriz de pesos espaciais e W é o somatório de todos os pesos w_{ij} . O peso da matriz w_{ij} foi definido com a abordagem de normalização por linha e contiguidade espacial pelo critério de rainha onde a soma dos ponderadores dos polígonos que compartilham pelo menos um vértice é igual a um.

Por definição, os valores do r^2 variam entre 0 e 1, sendo 1 o valor ótimo para o índice e para o RMSE quanto mais próximo a 0 melhor. O índice de Moran varia entre -1 (autocorrelação espacial negativa) e 1 (autocorrelação espacial positiva). A presença de autocorrelação positiva indica que áreas adjacentes tendem a ter valores semelhantes, enquanto a presença da autocorrelação negativa indica que áreas adjacentes tendem a ter valores diferentes. Quando os valores do índice de Moran são próximos a zero o arranjo espacial é aleatório.

Um teste de Monte Carlo foi utilizado para verificar se a autocorrelação espacial verificada pelo índice de Moran é diferente das encontradas ao acaso. Os procedimentos do teste foram semelhantes aos utilizados nos modelos GWR. Os resíduos dos modelos foram permutados aleatoriamente 999 vezes no espaço para verificar se o valor observado do índice de Moran difere significativamente dos

índices obtidos na série permutada. O resultado do teste foi reportado com o valor da estatística p .

A contribuição local do cVPA para a o cPIB foi analisada com base na estimativa dos parâmetros relacionadas ao cVPA ($\hat{\beta}_1$). O procedimento de cálculo para avaliar as distinções regionais na transformação cVPA em cPIB é demonstrado na Equação 16.

$$cPIB_{cVPA_i} = \hat{\beta}_1(u_i, v_i)cVPA_i \quad (16)$$

Em que $cPIB_{cVPA}$ é a contribuição local do cVPA para o cPIB, i indica a região de estudo, $\hat{\beta}_1$ é a estimativa do parâmetro do modelo relacionado ao cVPA, (u_i, v_i) é o par de coordenadas de localização da região i e cVPA é o vetor de crescimentos do Valor da Produção Agrícola. No caso da regressão linear global o $\hat{\beta}_1$ é único para todo espaço.

Os dados de cPIB e cVPA não sofreram transformações, de modo que foram analisados em suas distribuições anuais naturais. As análises espaciais foram realizadas com os algoritmos implementados nos pacotes *GWmodel* (GOLLINI *et al.*, 2015) e *spdep* (BIVAND, 2002) do software estatístico R.

3 Resultados e discussão

A variação anual da largura de banda ótima (Tabela 5) mostra que a componente espacial dos modelos GWR sofrem influência das características do ano-safra. A largura de banda utilizada nos modelos GWR resultante da mediana das doze larguras de banda obtidas pela validação cruzada foi de 89.

Tabela 5 - Largura de banda ótima para cada ano com base na validação cruzada utilizando o *kernel Boxcar*

Ano	Largura de Banda
2004	94
2005	89
2006	30
2007	148
2008	168
2009	372
2010	43
2011	46
2012	89
2013	89
2014	89
2015	367

3.1 Desempenho global dos modelos

Na Tabela 6 é possível visualizar o desempenho global dos modelos de regressão para todos os anos estudados. Com exceção do ano de 2015, a proporção da variabilidade explicada pelo modelo GWR sempre foi superior à explicada pelo modelo RG. Pode-se evidenciar um aumento substancial da variabilidade do cPIB atribuída ao cVPA capturada pelos modelos GWR. Os modelos GWR indicaram, em média, que 31% da variabilidade do cPIB esteve associada ao cVPA por meio das relações espacialmente restritas. Apenas 15% da variabilidade, em média, do cPIB associada ao cVPA foi capturada pelos modelos de RG

Em alguns anos os erros dos modelos GWR e os RG apresentaram pouca diferença, porém os erros dos modelos GWR sempre foram menores. Em média, os erros em valores de cPIB foram de 15,4% para os modelos RG e 13,7% para os

modelos GWR. Independente das condições do ano-safra (com exceção do ano de 2015), as amplitudes e variabilidades dos resíduos dos modelos (Figura 21) foram inferiores nos modelos GWR. Isso sugere o melhor desempenho dos modelos GWR na estimativa da relação entre cPIB e cVPA. No Apêndice E é possível visualizar a espacialização dos resíduos da regressão para os modelos RG e GWR.

Tabela 6 - Desempenho global dos modelos RG e GWR

Ano	r^2_{RG}	r^2_{GWR}	RMSE _{RG}	RMSE _{GWR}
2004	0,04	0,47	0,159	0,117
2005	0,17	0,38	0,184	0,157
2006	0,25	0,37	0,149	0,135
2007	0,15	0,45	0,131	0,104
2008	0,16	0,23	0,113	0,107
2009	0,04	0,05	0,170	0,167
2010	0,17	0,28	0,133	0,122
2011	0,21	0,28	0,092	0,087
2012	0,12	0,50	0,129	0,096
2013	0,26	0,42	0,232	0,203
2014	0,11	0,27	0,096	0,086
2015	0,02	0,02	0,262	0,259

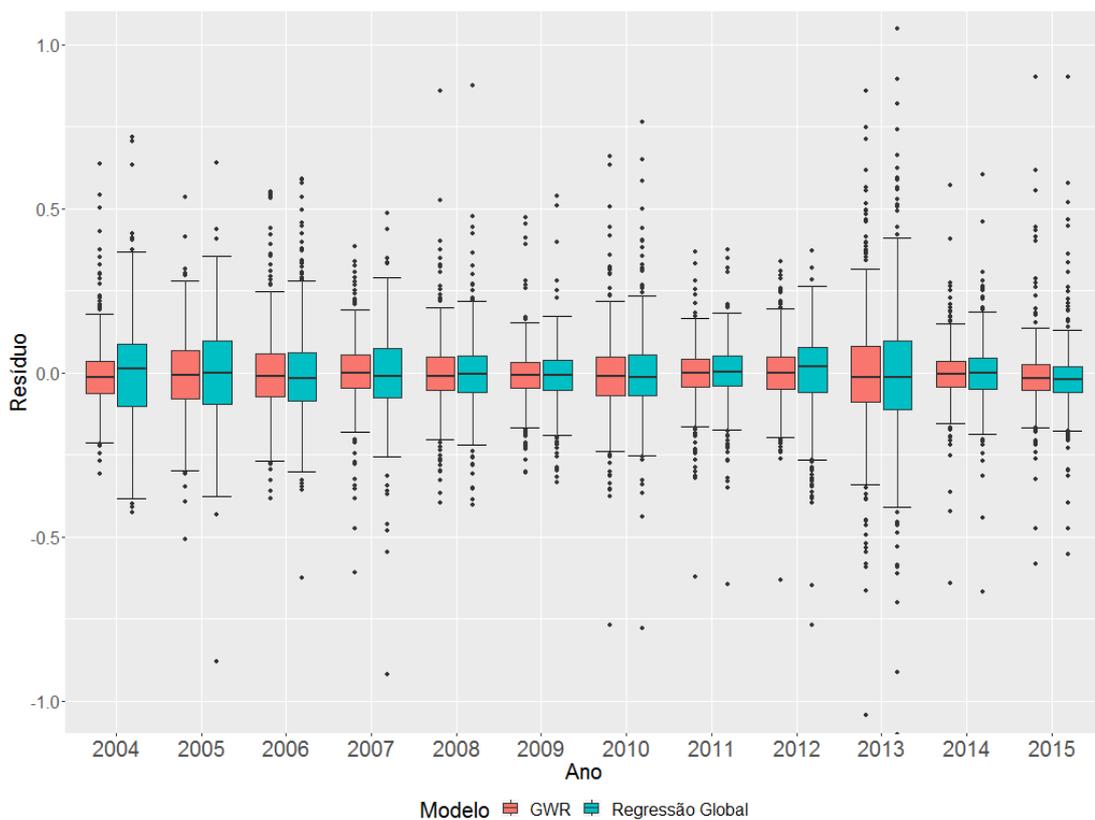


Figura 21 - Resíduos dos modelos GWR e RG (Regressão Global). Figura truncada no eixo das ordenadas em -1,0 e 1,0.

3.2 Distribuição espacial do r^2

A distribuição dos valores de r^2 do modelo GWR no espaço pode ser observada na Figura 22. Na região noroeste do Estado estão presentes as maiores proporções de variabilidade explicada. Isso indica que a variabilidade do desempenho econômico está mais fortemente atrelada a variabilidade do desempenho da agricultura nessa região do Estado. Na região metropolitana (em torno de Porto Alegre) geralmente estiveram presentes os modelos menos eficientes nesse critério (r^2). A região metropolitana possui os setores industrial e de serviços relativamente fortes se comparados as demais regiões do Estado, assim, era esperado esse comportamento dos modelos nessa região.

Independente da condição do ano safra, a relação estimada pelos modelos GWR atingiu pelo menos 0,5 de r^2 . Isso indica que mesmo nos anos em que o modelo global teve um baixo poder explicativo como em 2015, em pelo menos uma região do Estado é possível conseguir modelos com poder explicativo razoável utilizando os modelos GWR.

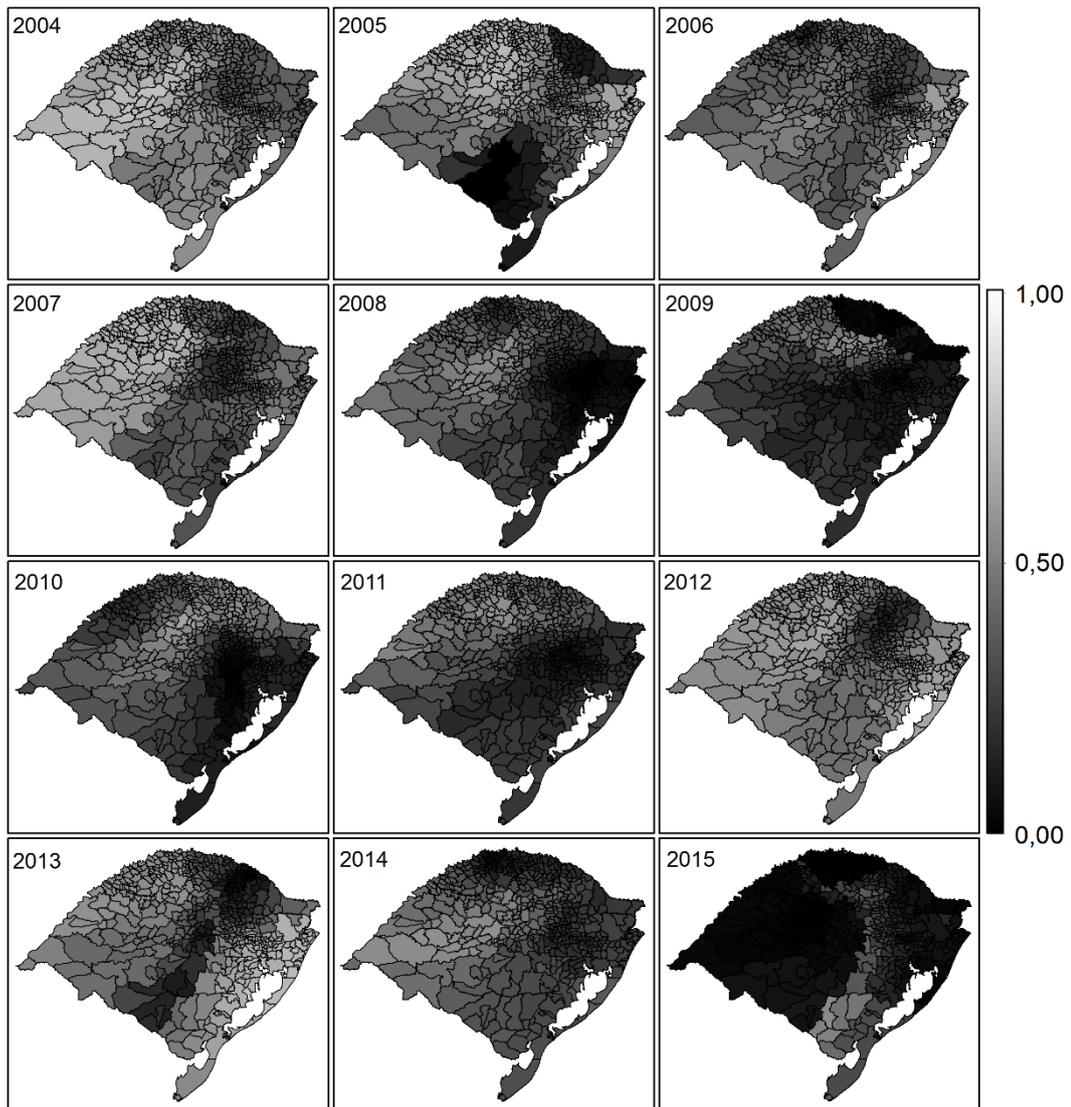


Figura 22 – Distribuição espacial do r^2 dos modelos GWR.

3.3 Análise da autocorrelação espacial dos resíduos

A Tabela 7 mostra os valores do Índice de Moran e sua significância pelo método de Monte Carlo. Os valores dos modelos GWR para o índice de Moran sempre foram inferiores aos dos modelos globais nos anos em que a significância foi verificada com pelo menos 10% de probabilidade ($p < 0,1$). De modo geral, nos anos em que os índices não foram significativos ($p > 0,1$) os modelos GWR também se mostraram mais eficientes na redução da autocorrelação espacial dos resíduos, contudo, existe uma maior probabilidade de que esses valores tenham ocorrido ao acaso.

Tabela 7 - Índice de Moran para os modelos RG e GWR

Ano	I. Moran _{RG}	ρ_{RG}	I. Moran _{GWR}	ρ_{GWR}
2004	0,394	0,001	0,051	0,030
2005	0,228	0,001	0,056	0,014
2006	0,212	0,001	0,105	0,001
2007	0,300	0,001	0,084	0,002
2008	0,107	0,001	0,065	0,006
2009	-0,014	0,743	-0,018	0,820
2010	0,104	0,001	0,016	0,250
2011	0,105	0,001	0,018	0,227
2012	0,292	0,001	0,030	0,150
2013	0,199	0,001	0,043	0,067
2014	0,223	0,001	0,082	0,002
2015	0,001	0,305	-0,011	0,644

3.4 Análise dos parâmetros estimados pelos modelos

Os parâmetros estimados pelos modelos GWR e RG foram comparados na Tabela 8. Os valores dos parâmetros atribuídos ao cVPA pelos modelos GWR oscilaram de maneira substancial no espaço do Estado para um mesmo ano (Figura 23). A distribuição dos parâmetros dos modelos GWR no espaço não ocorreu ao acaso e muitas vezes significativa a 1% ($p < 0,01$). Com isso é possível afirmar que em algumas regiões os parâmetros estimados pelos modelos RG subestimam e para outras superestimam o impacto que o cVPA tem no cPIB.

Tabela 8 - Distribuição dos coeficientes do cVPA dos modelos RG e GWR.

Ano	RG	GWR					Significância
		Mínimo	1º Quartil	Mediana	3º Quartil	Máximo	
2004	0,03	-0,02	0,08	0,30	0,38	0,48	***
2005	0,25	0,02	0,07	0,34	0,47	0,79	***
2006	0,14	-0,05	0,02	0,09	0,15	0,31	***
2007	0,09	0,00	0,06	0,15	0,24	0,39	***
2008	0,16	-0,04	0,07	0,19	0,30	0,41	***
2009	0,14	-0,07	0,07	0,21	0,31	0,50	
2010	0,18	-0,05	0,08	0,20	0,26	0,42	***
2011	0,17	0,00	0,08	0,14	0,27	0,37	***
2012	0,08	0,00	0,12	0,24	0,36	0,50	***
2013	0,18	-0,01	0,02	0,11	0,18	0,29	***
2014	0,17	-0,04	0,08	0,16	0,23	0,43	***
2015	0,18	-0,02	0,08	0,15	0,28	0,53	**

*** $p < 0,01$; ** $p < 0,05$; * $p < 0,10$

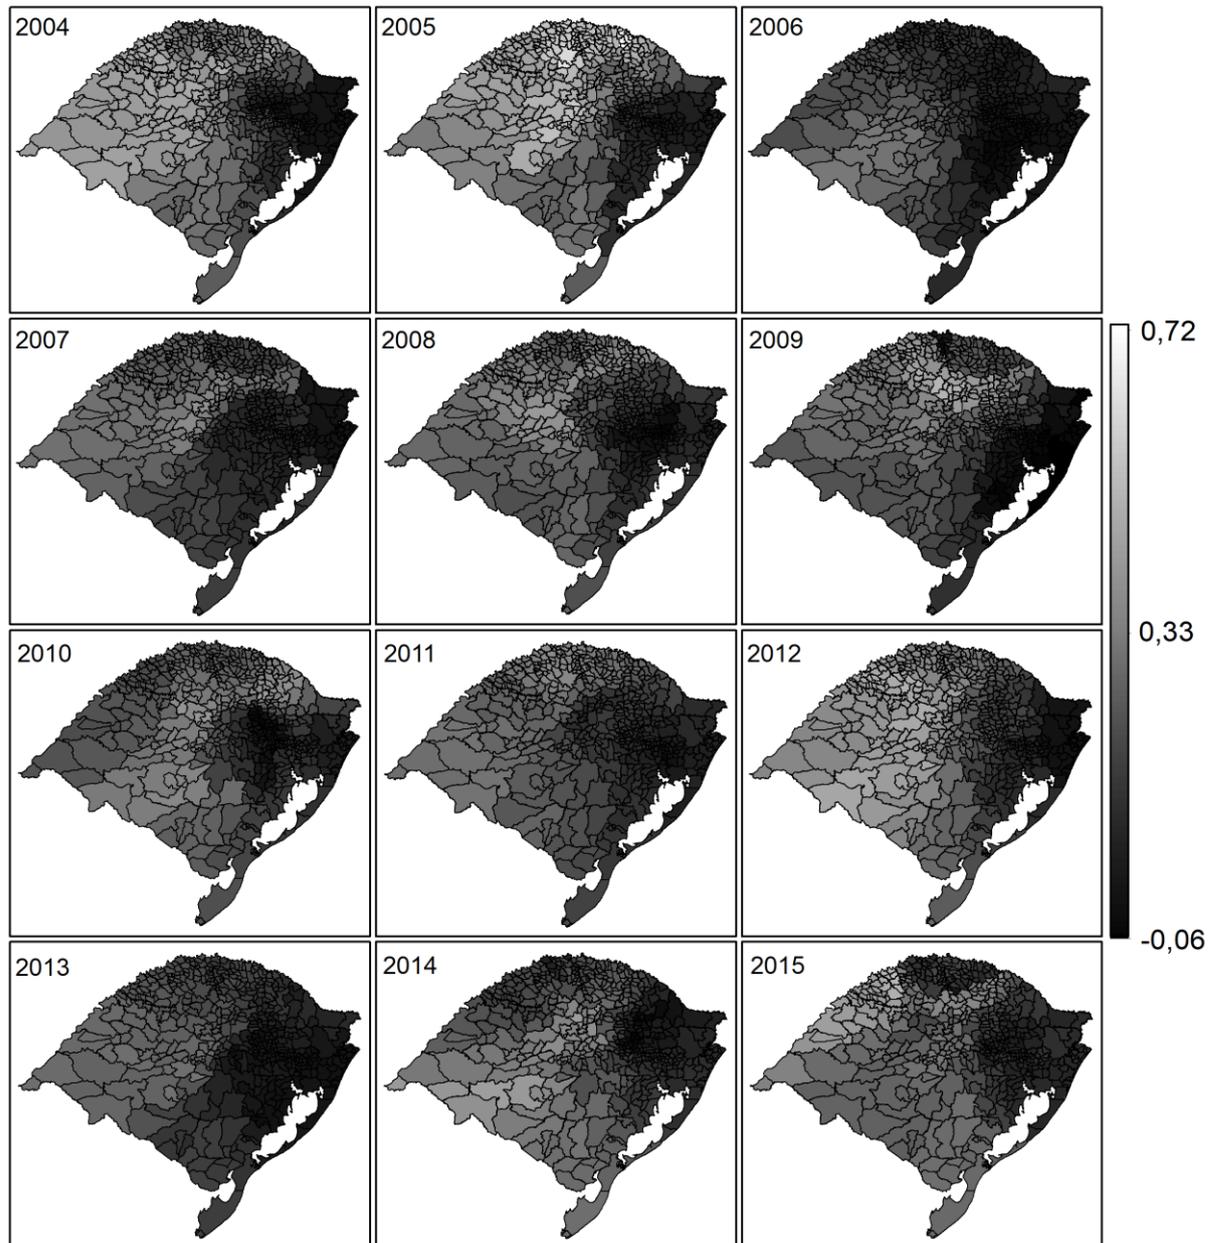


Figura 23 – Distribuição espacial dos coeficientes do cVPA dos modelos GWR. Escala da figura truncada em 0,72.

Assim como na distribuição espacial do r^2 , a distribuição espacial dos parâmetros referentes ao cVPA, de forma geral, tem seus maiores valores na região noroeste do Estado e os menores na região metropolitana. Os valores dos parâmetros dessas regiões revelam variações quanto a incorporação do VPA na economia. Na região noroeste o cVPA é incorporado quase que em sua totalidade no cPIB, enquanto na região metropolitana apenas uma pequena fração cVPA é incorporado no cPIB.

Nas Figuras 24 e 25 é possível observar a transferência local do cVPA para o cPIB segundo os modelos RG e GWR. Dependendo do ano analisado existem diferenças substanciais entre os modelos. Em 2005, utilizando o modelo RG boa parte do Estado teve uma adição negativa do cVPA no cPIB enquanto que no modelo GWR apenas a região norte do RS teve esse comportamento.

A análise dos coeficientes e da transformação do cVPA em cPIB na região noroeste indicam que essa região do RS tem estado economicamente mais exposta a uma oscilação do desempenho da agricultura. Nessa região também foram constatadas as maiores variações na transformação do cVPA em cPIB.

A variabilidade das relações espaciais foi quase sempre significativa ($p < 0,01$) pelo método de Monte Carlo, isso significa que a distribuição da transformação do cVPA em cPIB está espacialmente estruturada em um processo não estacionário. Os modelos de regressão globais assumem que a relação entre o cPIB e o cVPA é constante no espaço (estacionária), como consequência essa abordagem é inadequada para a estimação dos coeficientes dos modelos.

Em todos os critérios de comparação (r^2 , RMSE e Índice de Moran) os modelos GWR se mostraram superiores aos de RG. Isso se deve a capacidade dos modelos GWR modelarem as variações locais da relação entre o cPIB e o cVPA.

Independente do modelo utilizado percebe-se que o desempenho dos modelos depende do ano analisado. Isso indica que a relação entre o cPIB e o cVPA é temporalmente condicionada e a hipótese de linearidade pode não ser verificada.

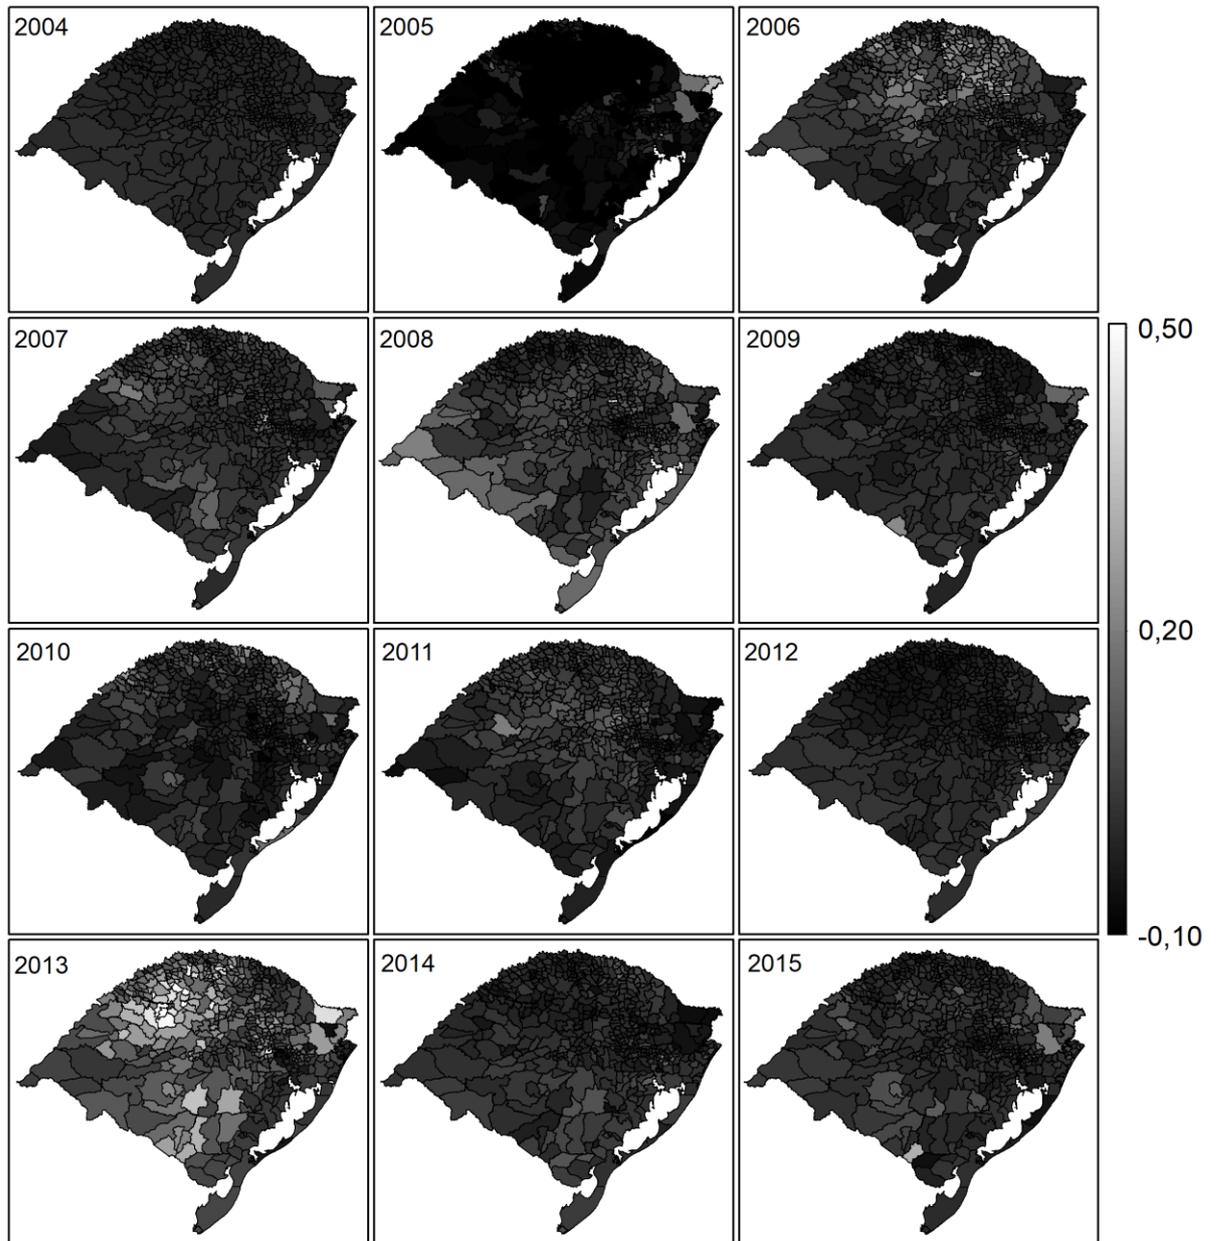


Figura 24 - Valor transferido pelo cVPA na economia local utilizando os modelos RG. Escala da figura truncada em -0,10 e 0,50.

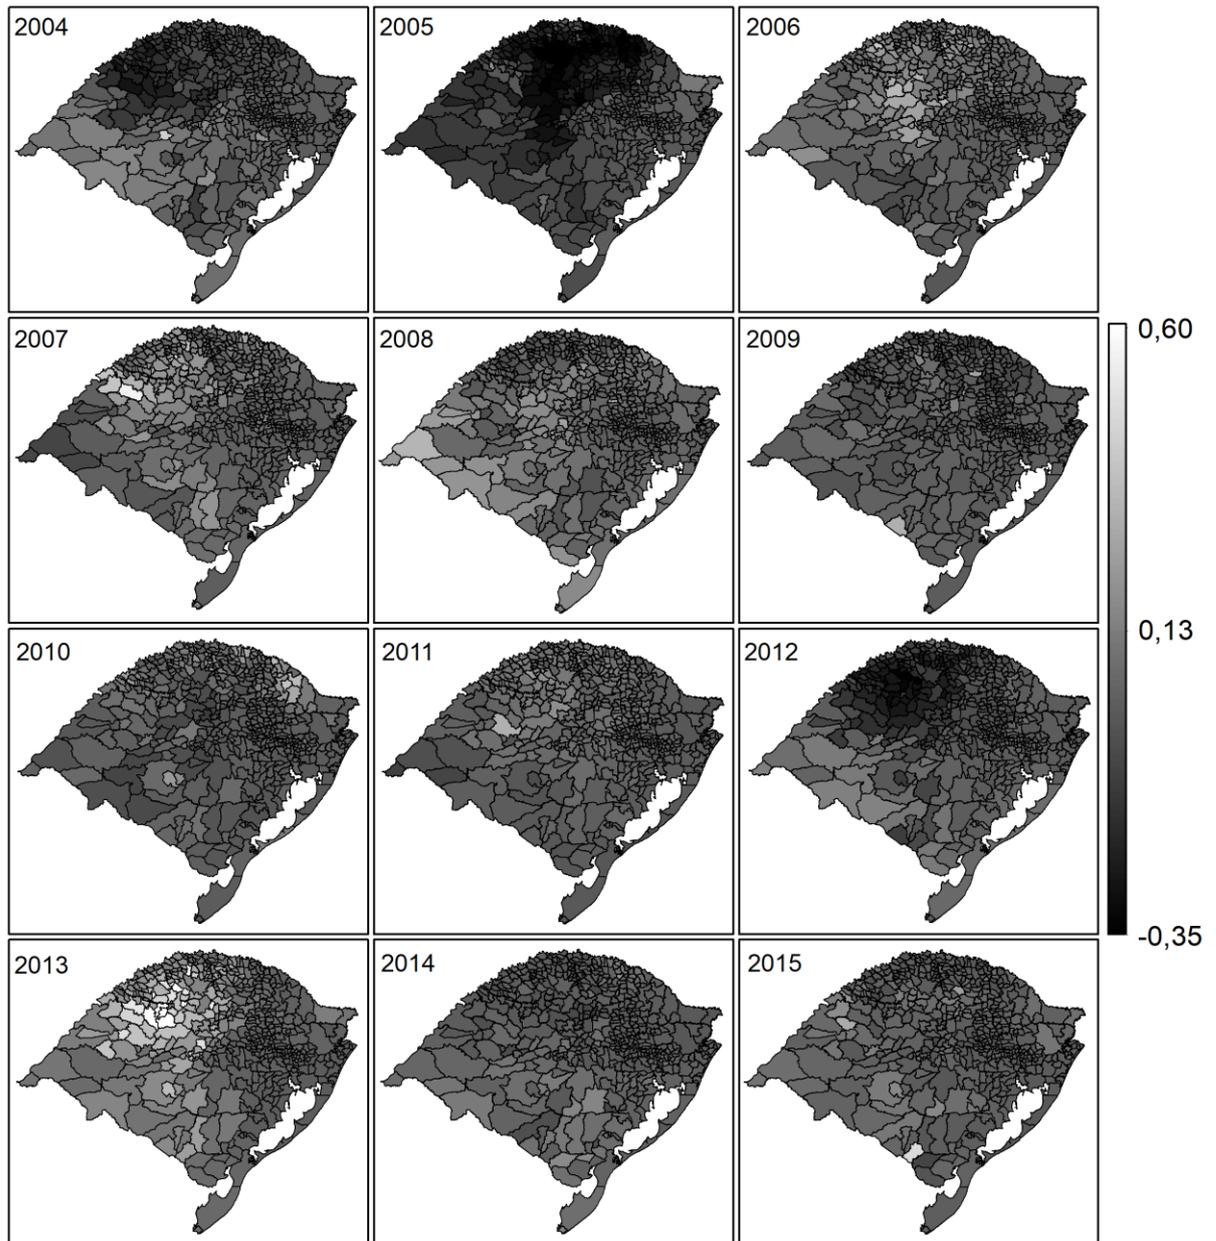


Figura 25 - Valor transferido pelo cVPA na economia local utilizando os modelos GWR. Escala da figura truncada em -0,35 e 0,60.

4 Conclusões

- Os modelos GWR foram superiores aos RG nos três critérios de avaliação utilizados nesse estudo, possuem menores erros e amplitudes dos erros globais, maior fração da variabilidade explicada pelos modelos e reduzem a autocorrelação espacial dos resíduos, o que indica que a relação entre o cPIB e o cVPA varia ao longo do espaço do Estado e por isso não pode ser tratada como homogênea.
- Na região noroeste ocorreram os maiores coeficientes para o cVPA em todos anos, bem como, a maior variabilidade do valor transferido pelo cVPA na economia local. Assim, pode-se afirmar que essa região está mais exposta que as demais a uma oscilação no desempenho da agricultura para o crescimento econômico.
- Na região metropolitana o cVPA pouco afetou o cPIB. Nessa região o desempenho da agricultura representa uma fração muito pequena da economia e o crescimento econômico está atrelado ao desempenho dos setores de serviços e industrial.
- A variação temporal da relação entre o cPIB e o cVPA provocou oscilações nos modelos RG e GWR, indicando que a não estacionariedade do ano-safra está presente e deve ser incorporada na modelagem.

Considerações Finais

A análise realizada neste estudo identifica as variações locais na relação entre o crescimento do PIB e do desempenho da agricultura e pode subsidiar políticas governamentais para o estado do Rio Grande do Sul, principalmente no âmbito das políticas municipais. Isso se deve aos resultados evidenciarem a existência importantes variações nas economias locais.

A região noroeste apresentou a maior taxa de transferência do cVPA para o cPIB, bem como, foi a mais dependente do desempenho da agricultura para o crescimento econômico

Na região metropolitana a relação entre o desempenho da agricultura e o crescimento econômico foi fraca. Isso se deve a forte atividade industrial na região tornando o desempenho agrícola pouco relevante na economia.

Existe uma variação, sempre presente, entre as regiões leste e oeste, tanto na força de associação, quanto nos coeficientes dos modelos de regressão. Isso indica que a região oeste do Estado é mais dependente do desempenho da agricultura.

As características do ano-safra provocaram oscilações na relação local entre o cPIB e o cVPA. Isso significa que em futuros estudos as oscilações temporais devem ser incluídas na modelagem.

Futuros trabalhos nesta temática devem ser desenvolvidos no intuito de:

- analisar a influência da componente temporal nas relações locais;
- avaliar a relação entre o cPIB e o cVPA com outros modelos como os espaço-temporais multivariados;
- investigar como as características locais, tais como tamanho médio de propriedade agrícola e diversidade de cultivos no município, afetam a relação entre o crescimento econômico e o desempenho da agricultura.

Referências

ALONSO, J. A. F. A persistência das desigualdades regionais no RS: velhos problemas, soluções convencionais e novas formulações. **Indicadores Econômicos FEE**, v. 33, n. 4, p. 101-114, 2006.

ALONSO, J. A. F.; BENETTI, M. D.; BANDEIRA, P. S. **Crescimento econômico da Região Sul do Rio Grande do Sul: causas e perspectivas**. Porto Alegre: FEE, 1994.

BIDANSET, P. E.; LOMBARD, J. R. The effect of kernel and bandwidth specification in geographically weighted regression models on the accuracy and uniformity of mass real estate appraisal. **Journal of Property Tax Assessment & Administration**, v. 10, n. 3, 2014.

BIVAND, R. Spatial econometrics functions in R: Classes and methods. **Journal of geographical systems**, v. 4, n. 4, p. 405-421, 2002.

CEPEA - Centro de Estudos Avançados em Economia Aplicada. **Relatório PIBAgro-Brasil**. Disponível em: https://www.cepea.esalq.usp.br/upload/kceditor/files/Nota_técnica_PIB.pdf. Acesso em 08 de Setembro de 2019a.

CEPEA - Centro de Estudos Avançados em Economia Aplicada. **PIB do Agronegócio - Dados de 1996 a 2018**. São Paulo: ESALQ, 2017. Disponível em: <https://www.cepea.esalq.usp.br/br/pib-do-agronegocio-brasileiro.aspx>. Acesso em 15 de setembro de 2019b.

CEPEA - Centro de Estudos Avançados em Economia Aplicada. **PIB do agronegócio brasileiro - Comentários metodológicos**. São Paulo: ESALQ, 2014. 13 p.

CHELOTTI, M. C.; CASTANHO, R. B. Territórios da lavoura de arroz e de soja no Rio Grande do Sul: especificidades na produção do espaço agrário regional. **Revista Sociedade & Natureza**, v. 18, n. 34, 2006.

COLLE, C. A.; HOECKEL, P. H. O.; ALVIM, A. M.; FOCHEZATTO, A. Distribuição espacial e efeitos de transbordamentos do setor agropecuário no Rio Grande do Sul. **Inovação, sustentabilidade e desenvolvimento no RS**. p. 101-116, 2017.

FEE – Fundação de Economia e Estatística Siegfried Emanuel Heuser. **PIB – RS | 2002 – 2016**. Disponível em: <https://www.fee.rs.gov.br/indicadores/pib-rs/estadual/serie-historica>. Acesso em 20 de maio de 2018a.

FEE – Fundação de Economia e Estatística Siegfried Emanuel Heuser. **Base de dados 2002 a 2015**. Disponível em: <https://www.fee.rs.gov.br/indicadores/pib-rs/municipal/serie-historica>. Acesso em 16 de março de 2018b.

FOCHEZATTO, A.; GHINIS, C. P. Estrutura produtiva agropecuária e desempenho econômico regional: o caso do Rio Grande do Sul, 1996-2008. **Revista de Economia e Sociologia Rural**, v. 50, n. 4, p. 743-762, 2012.

FOCHEZATTO, A.; GRANDO, M. Z. Efeitos da estiagem na economia do Rio Grande do Sul: uma abordagem multissetorial. **Texto para Discussão FEE**, n. 62, 2009

FOTHERINGHAM, A. S.; BRUNSDON, C.; CHARLTON, M. **Geographically weighted regression: the analysis of spatially varying relationships**. John Wiley & Sons, 2002.

GOLLINI, I.; LU, B.; CHARLTON, M.; BRUNSDON, C.; HARRIS, P. GWmodel: an R package for exploring spatial heterogeneity using geographically weighted models. **Journal of Statistical Software**, v. 63, n. 17, 2015.

GUO, L.; MA, Z.; ZHANG, L. Comparison of bandwidth selection in application of geographically weighted regression: a case study. **Canadian Journal of Forest Research**, v. 38, n. 9, p. 2526-2534, 2008.

HARRIS, P.; BRUNSDON, C. Exploring spatial variation and spatial relationships in a freshwater acidification critical load data set for Great Britain using geographically weighted summary statistics. **Computers & Geosciences**, v. 36, n. 1, p. 54-70, 2010.

HU, S.; YANG, S.; LI, W.; ZHANG, C.; XU, F. Spatially non-stationary relationships between urban residential land price and impact factors in Wuhan city, China. **Applied Geography**, v. 68, p. 48-56, 2016.

HUILEI, L.; JIAN, P.; YANXU, L.; YI'NA, H. Urbanization impact on landscape patterns in Beijing City, China: A spatial heterogeneity perspective. **Ecological Indicators**, v. 82, p. 50-60, 2017.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Território e Ambiente**. Disponível em <https://cidades.ibge.gov.br/brasil/rs/panorama>. Acesso em 30 de Junho de 2019a.

IBGE - Instituto Brasileiro de Geografia e Estatística. **População**. Disponível em <https://cidades.ibge.gov.br/brasil/rs/panorama>. Acesso em 30 de Junho de 2019b.

IBGE - Instituto Brasileiro de Geografia e Estatística. **Produção Agrícola Municipal - Culturas temporárias e permanentes**. Rio de Janeiro: IBGE, v. 44, 2017. 22 p.

LAZZARI, M. Economia gaúcha dependente da agropecuária. **Carta de Conjuntura FEE**, v. 21, n. 1, 2012.

LEWANDOWSKA-GWARDA, K. Geographically Weighted Regression in the Analysis of Unemployment in Poland. **ISPRS International Journal of Geo-Information**, v. 7, n. 1, p. 17, 2018.

LI, F.; LI, M.; LIANG, J. Study on disparity of regional economic development based on geoinformatic Tupu and GWR model: a case of growth of GDP per capita in China from 1999 to 2003. In: *Geoinformatics 2007: Geospatial Information Technology and Applications*. International Society for Optics and Photonics, 67543A, 2007.

LI, S.; ZHOU, C.; WANG, S.; GAO, S.; LIU, Z. Spatial heterogeneity in the determinants of urban form: an analysis of Chinese cities with a GWR approach. **Sustainability**, v. 11, n. 2, p. 479, 2019.

MA, X.; ZHANG, J.; DING, C.; WANG, Y. A geographically and temporally weighted regression model to explore the spatiotemporal influence of built environment on transit ridership. **Computers, Environment and Urban Systems**, v. 70, p. 113-124, 2018.

MIRZAEI, M.; BERTAZZON, S.; COULOIGNER, I. OLS and GWR LUR models of wildfire smoke using remote sensing and spatiotemporal data in Alberta. **Spatial Knowledge and Information Canada**, v. 7, n. 2, p. 3, 2018.

MONTOYA, M. A.; FINAMORE, E. B. Dinâmica de crescimento do agronegócio gaúcho no período de 1998 a 2003: renda, tributos e emprego. **Encontro de Economia Gaúcha**, v. 5, p. 1 – 27, 2010.

PASSOS, A. G.; MACIEL, M. A. C.; DORIA, M. R.; OLIVEIRA, R. B.; RUSSO, S. L. Análise estatística da evolução do produto interno bruto da indústria da construção civil brasileira utilizando regressão linear simples. **Revista GEINTEC-Gestão, Inovação e Tecnologias**, v. 2, n. 5, p. 505-514, 2012.

RISCO, G. Distribuição dos setores da economia gaúcha por municípios. **Carta de Conjuntura FEE**, v. 25, n. 1, 2016.

SCHUH, A. B.; SILVA, M. L.; TREVISAN, L. V.; CORONEL, D. A. Perfil industrial do Rio Grande do Sul e a hipótese de desindustrialização. **Perspectiva Econômica**, v. 13, n. 2, p. 116-133, 2018.

SEPLAN-RS – Secretaria de Planejamento e Desenvolvimento Regional. **Perfis Regiões Funcionais de Planejamento**. Porto Alegre, 2015. Disponível em: <https://planejamento.rs.gov.br/upload/arquivos/201512/15134058-20150319163519perfis-todos.pdf>. Acesso em 11 de junho de 2019.

VINAYARAJ, P.; RAGHAVAN, V.; MASUMOTO, S. Satellite-derived bathymetry using adaptive geographically weighted regression model. **Marine Geodesy**, v. 39, n. 6, p. 458-478, 2016.

Apêndices

Apêndice A – Variação espaço-temporal do z-score do cPIB e do cVPA no Estado do Rio Grande do Sul

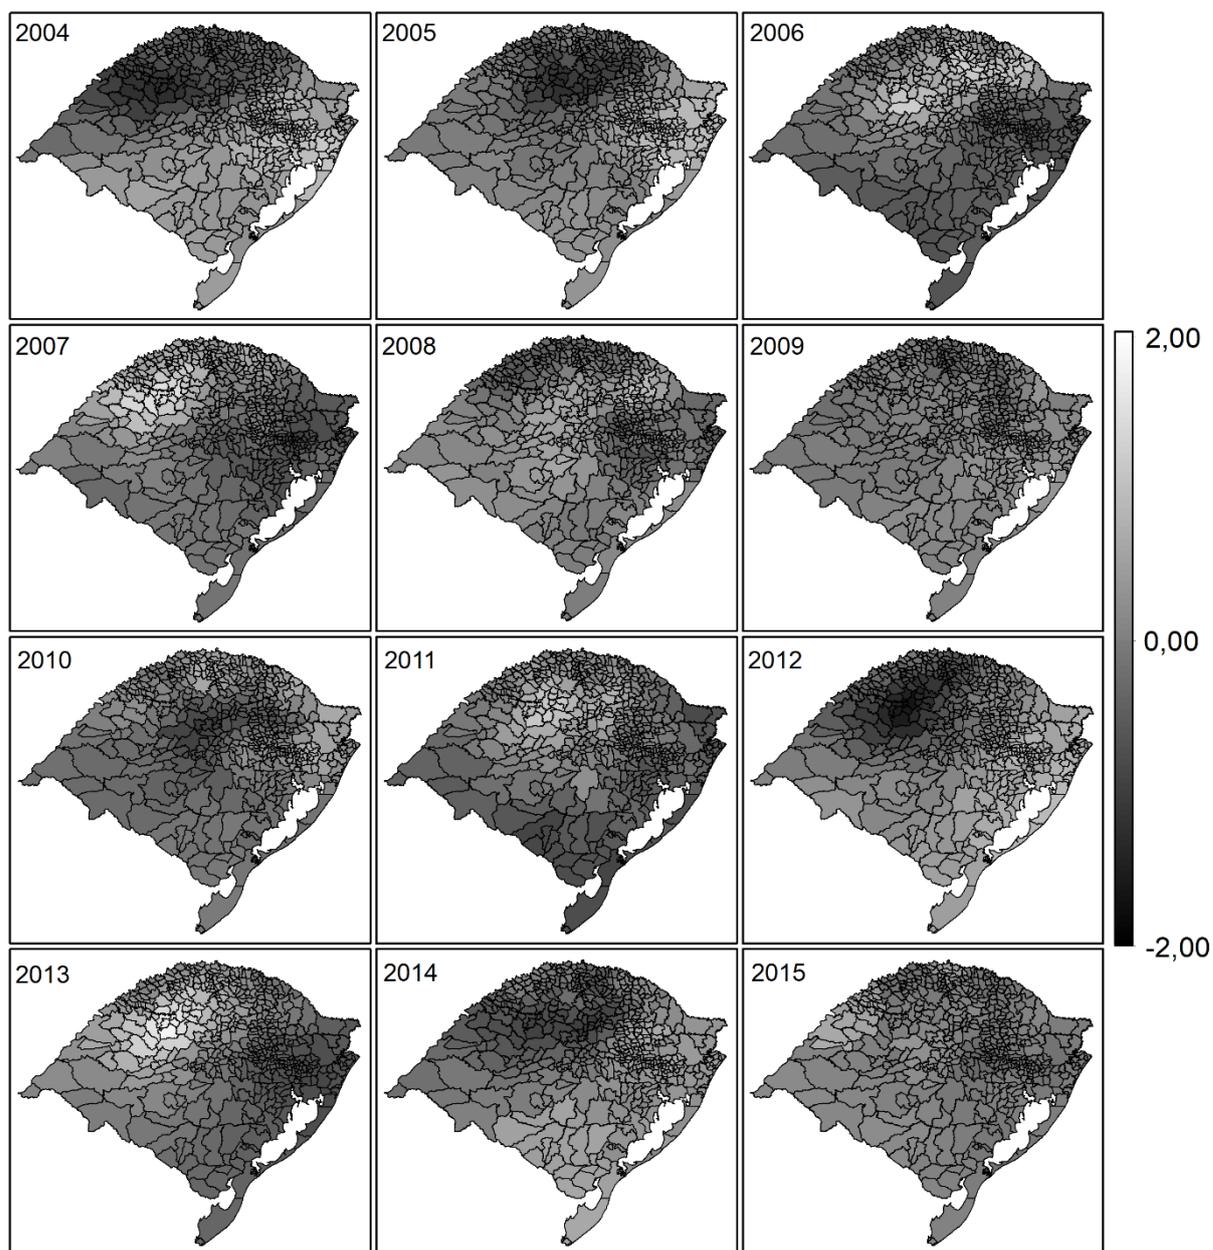


Figura A1 – Variação do z-score local do cPIB no Estado do Rio Grande do Sul.

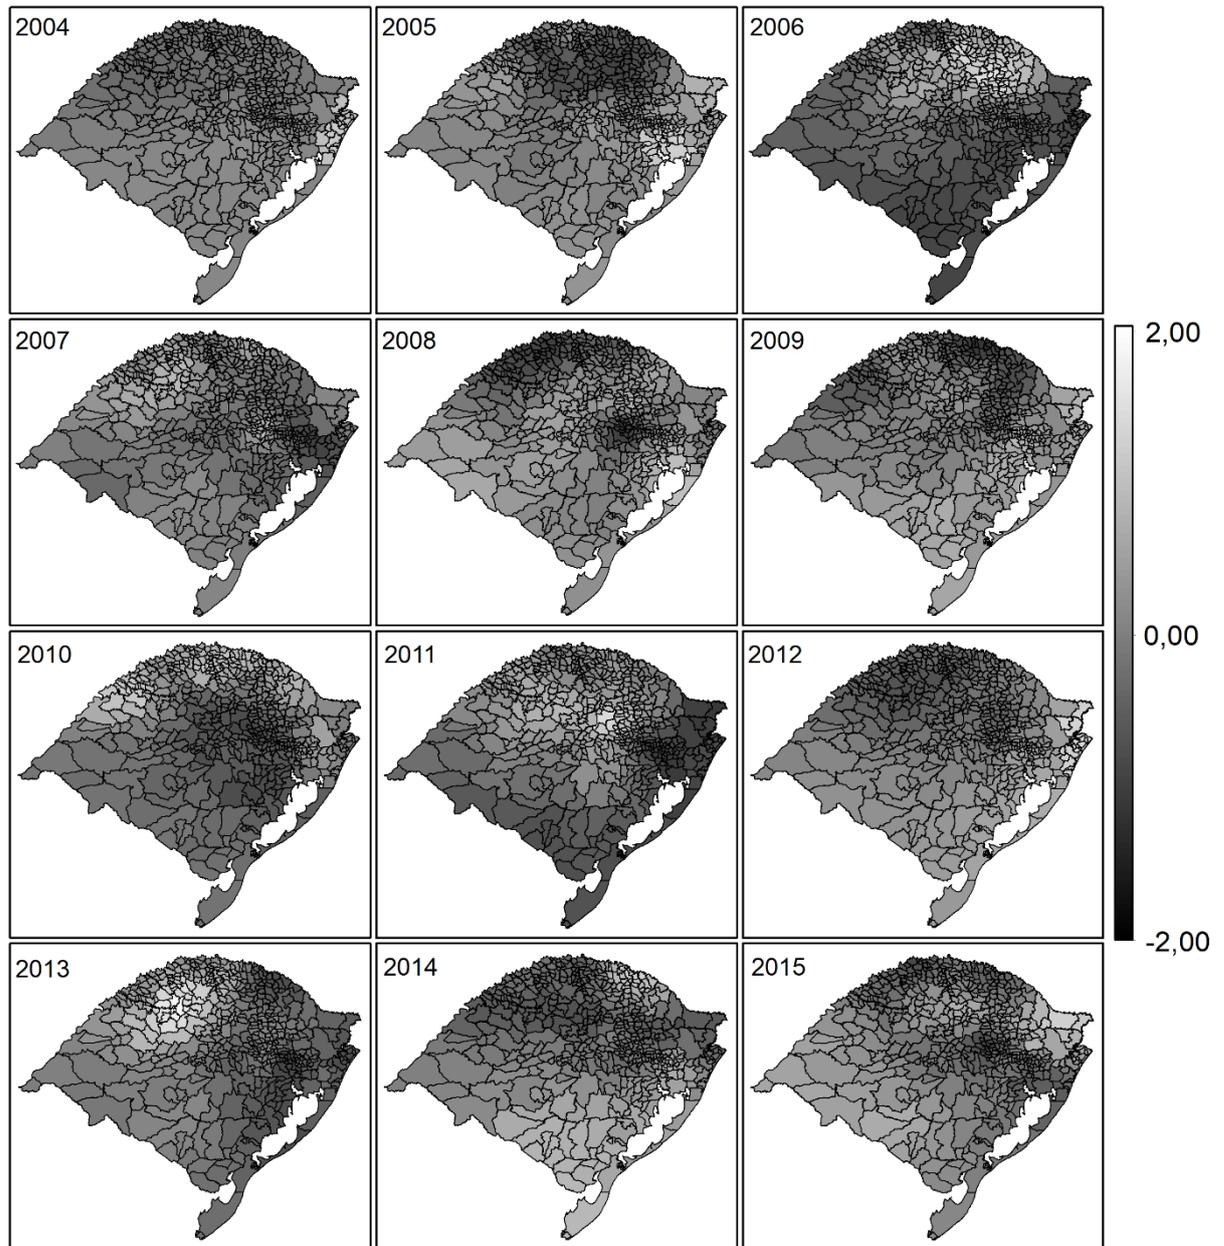


Figura A2 – Variação do z-score local do cVPA no Estado do Rio Grande do Sul.

Apêndice B – Correlações locais entre cPIB e cVPA no Estado do Rio Grande do Sul

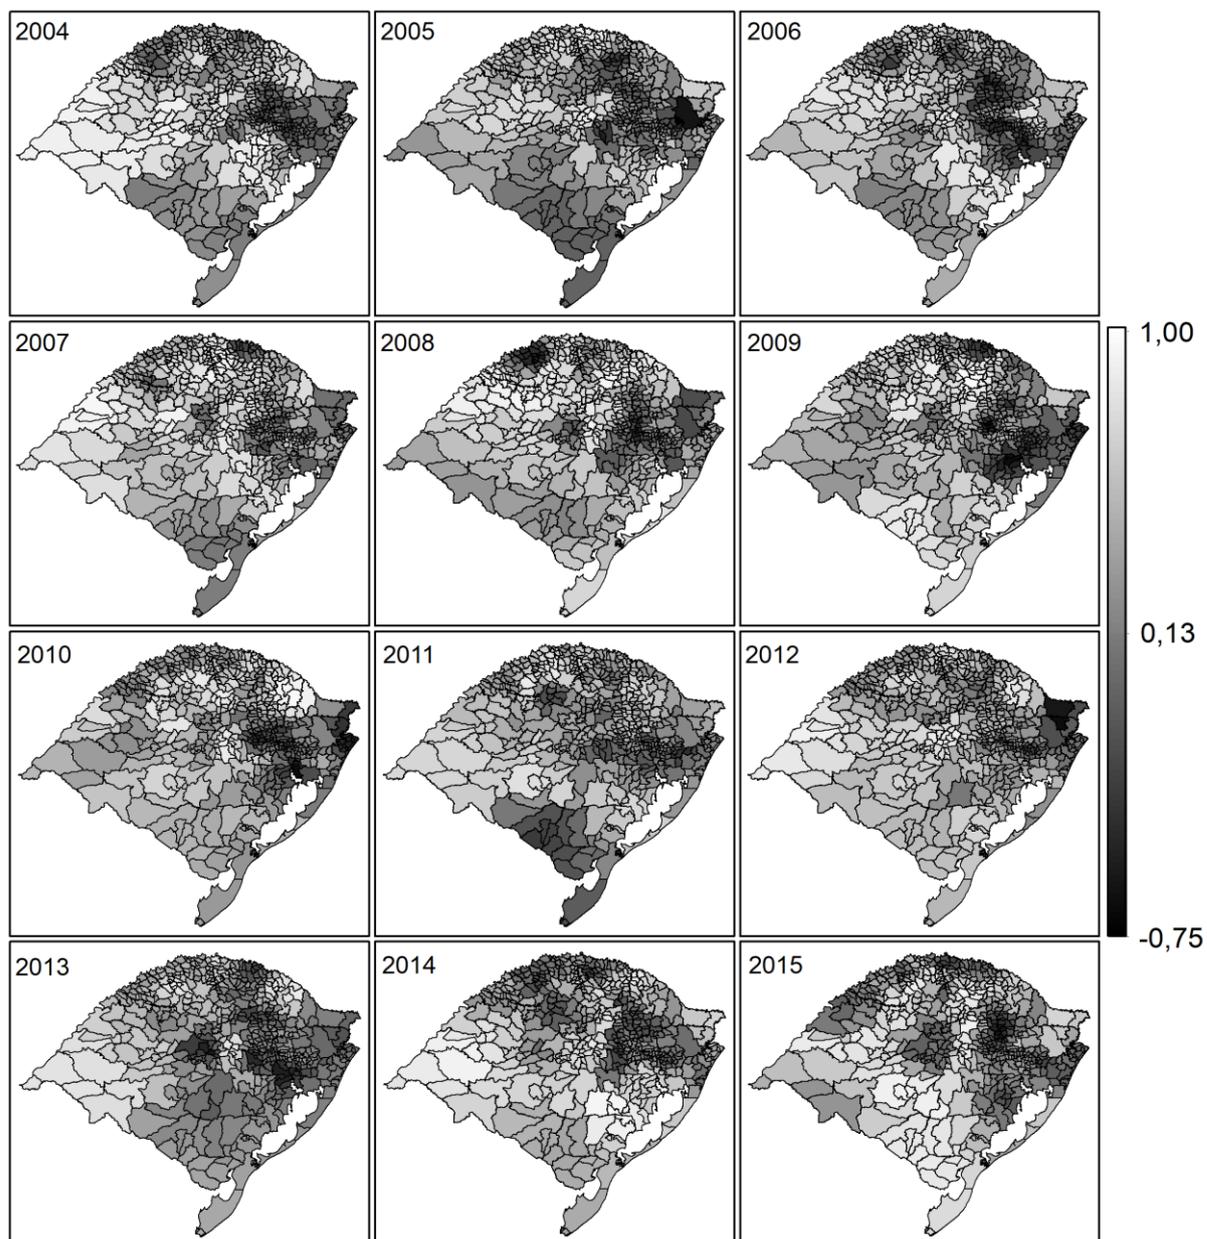


Figura B1 – Correlações lineares locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 5% (25) e *kernel* Biquadrado.

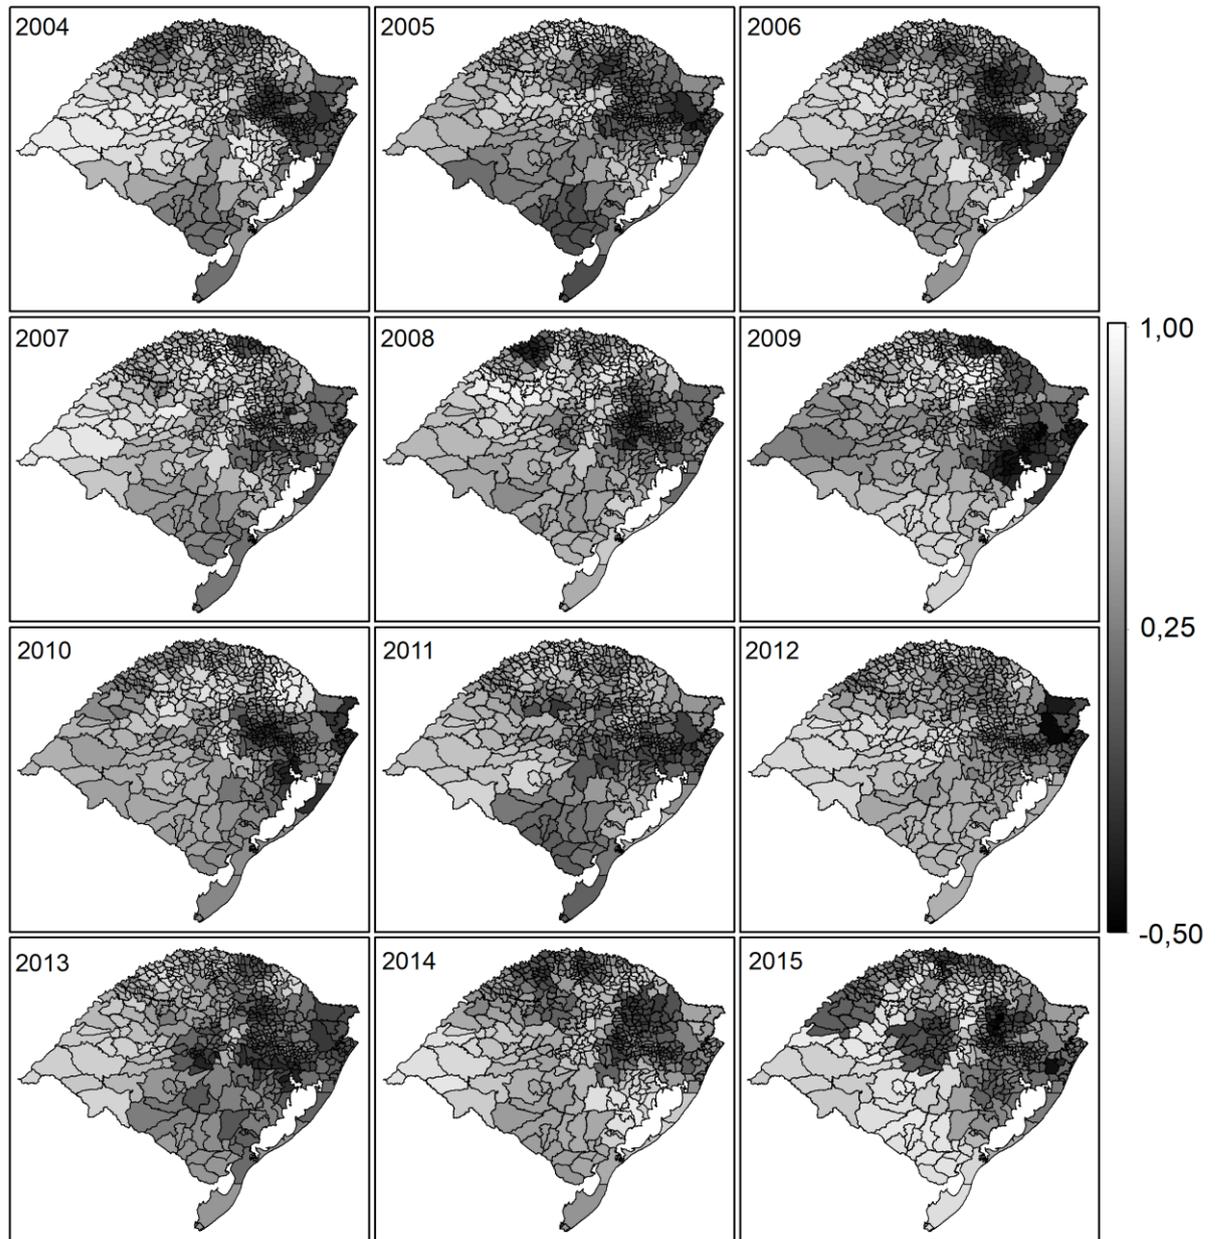


Figura B2 – Correlações lineares locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 5% (25) e *kernel Boxcar*.

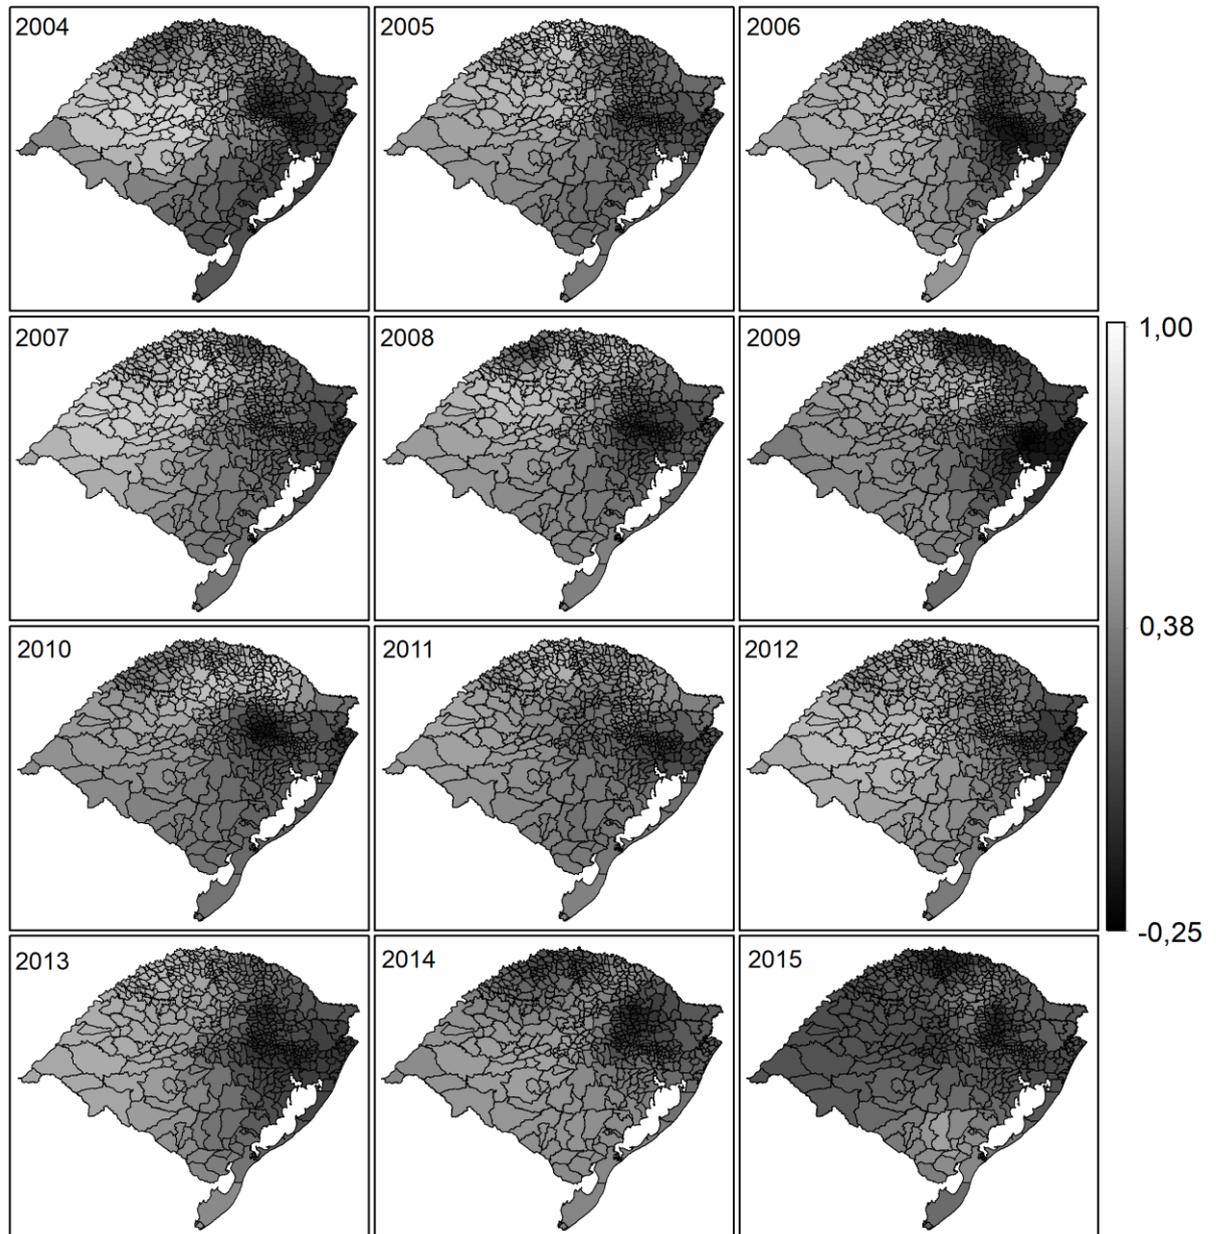


Figura B3 – Correlações lineares locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 5% (25) e *kernel* Gaussiano.

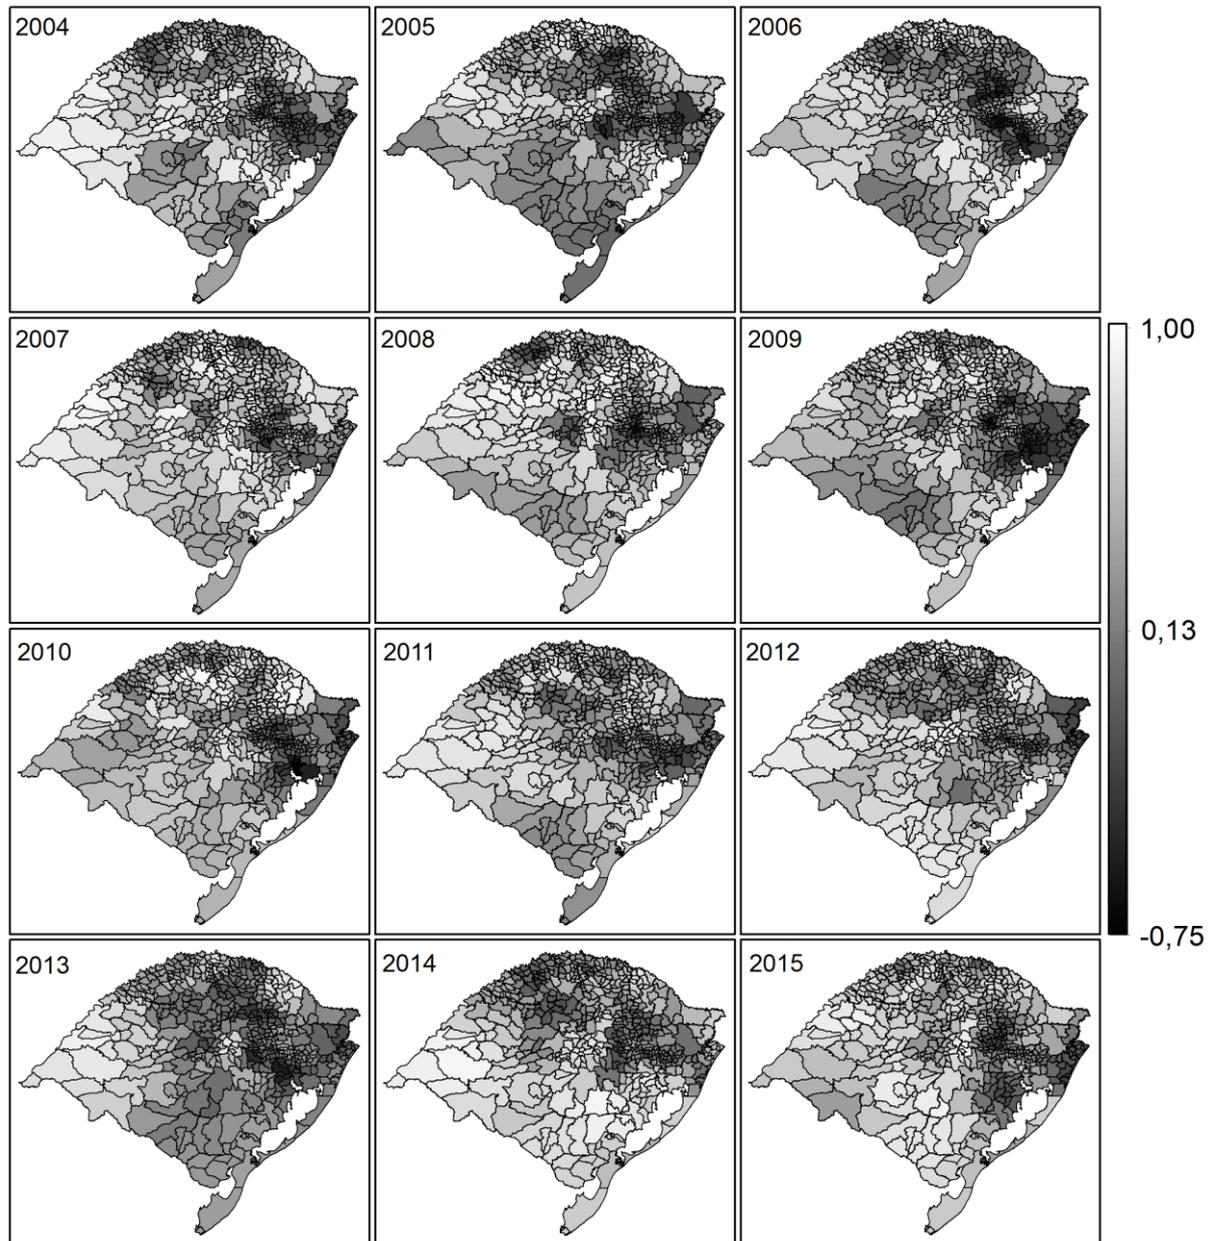


Figura B4 – Correlações robustas locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 5% (25) e *kernel* Biquadrado.

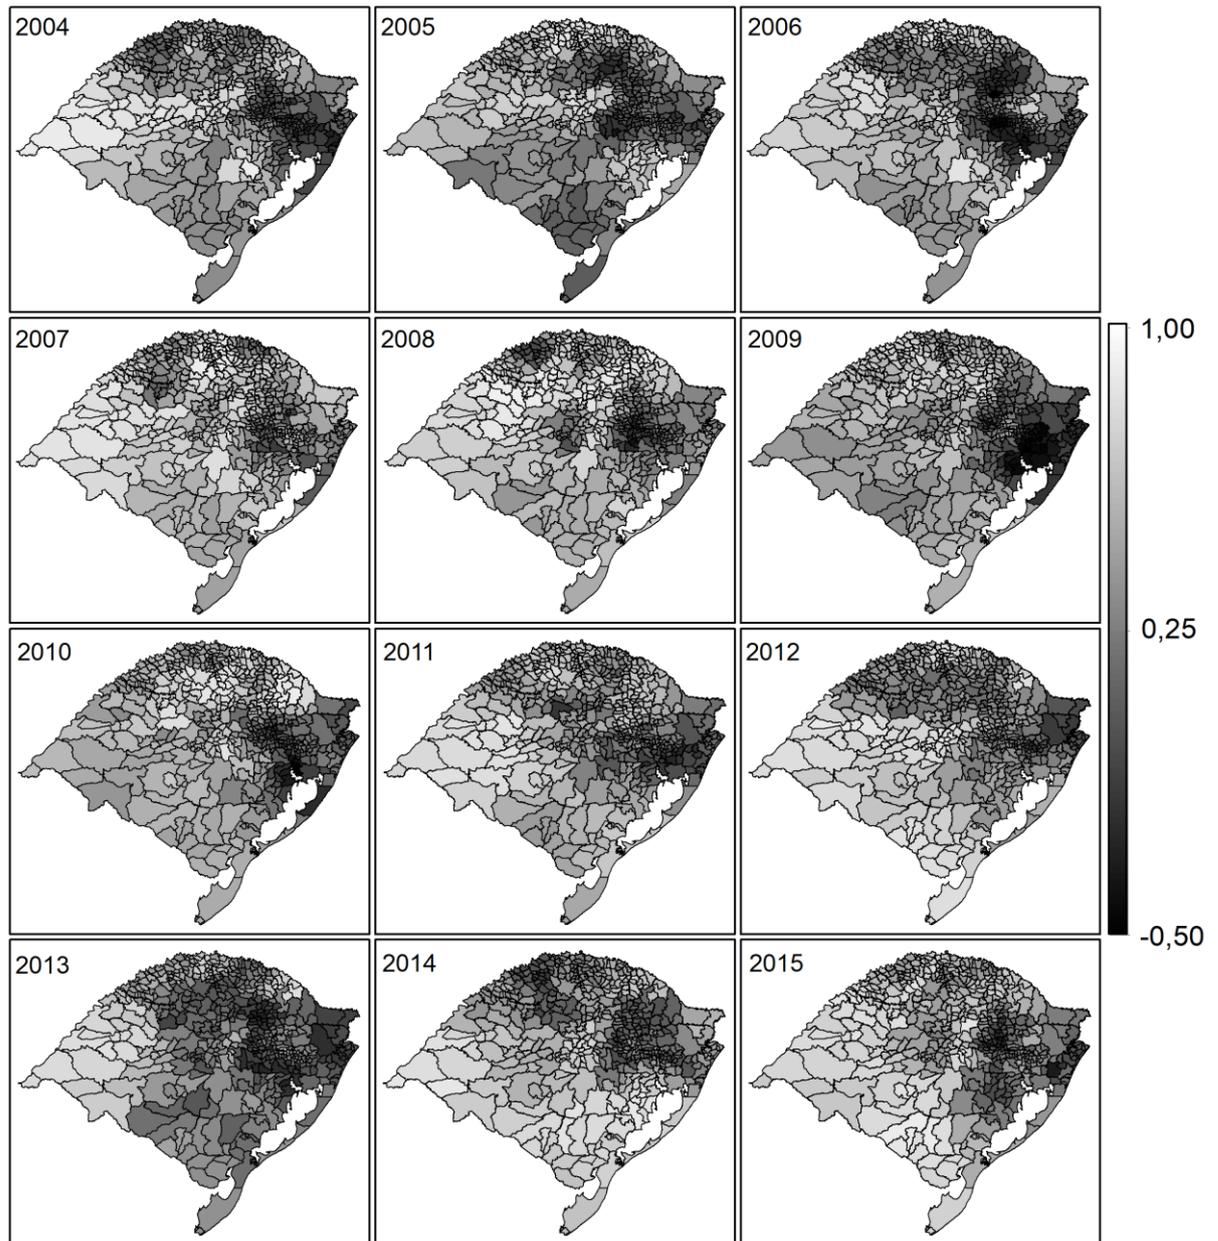


Figura B5 – Correlações robustas locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 5% (25) e *kernel Boxcar*. Escala da figura truncada em -0,50.

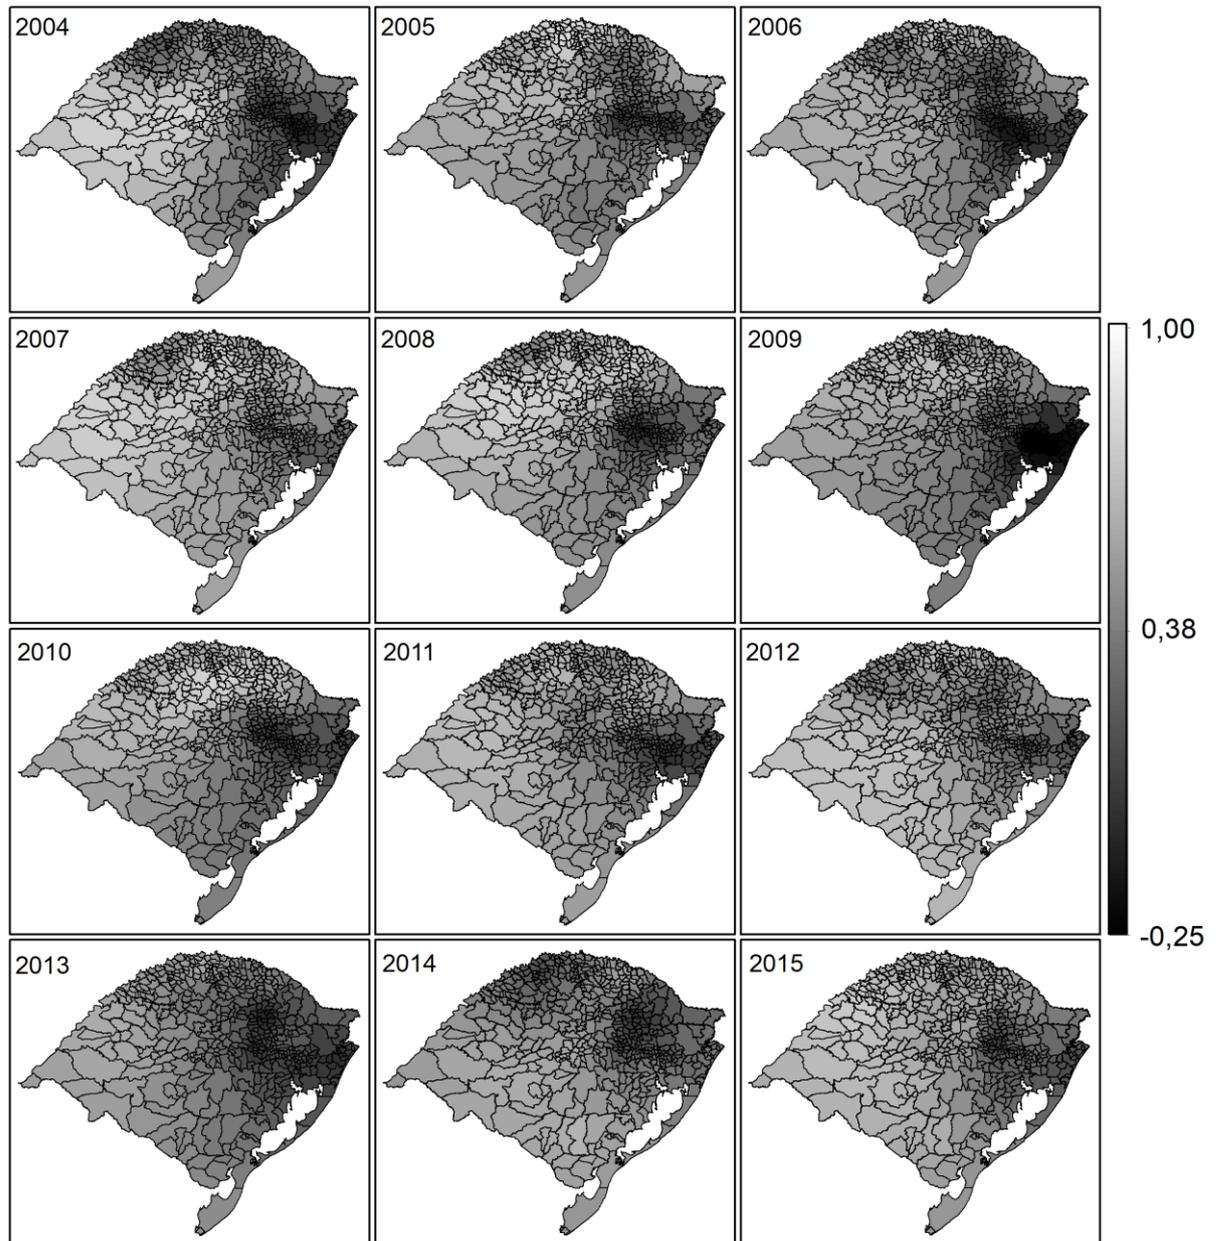


Figura B6 – Correlações robustas locais entre cPIB e cvPA no Estado no Rio Grande do Sul com largura de banda igual a 5% (25) e *kernel* Gaussiano. Escala da figura truncada em -0,25.

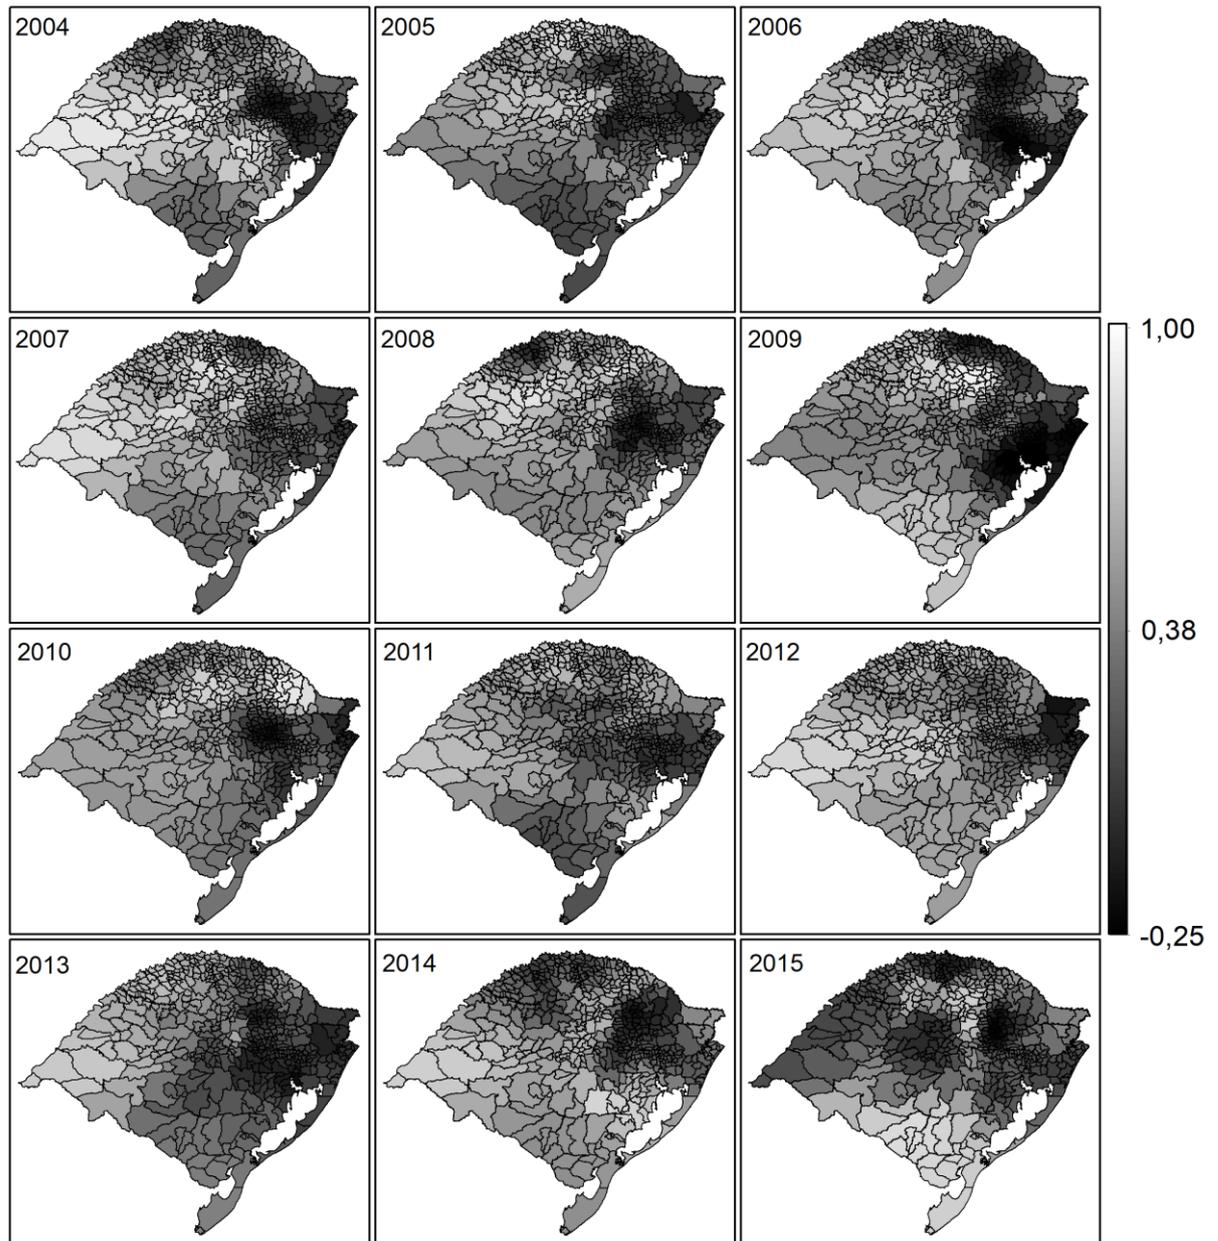


Figura B7 – Correlações lineares locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 15% (75) e *kernel*/Biquadrado. Escala da figura truncada em -0,25.

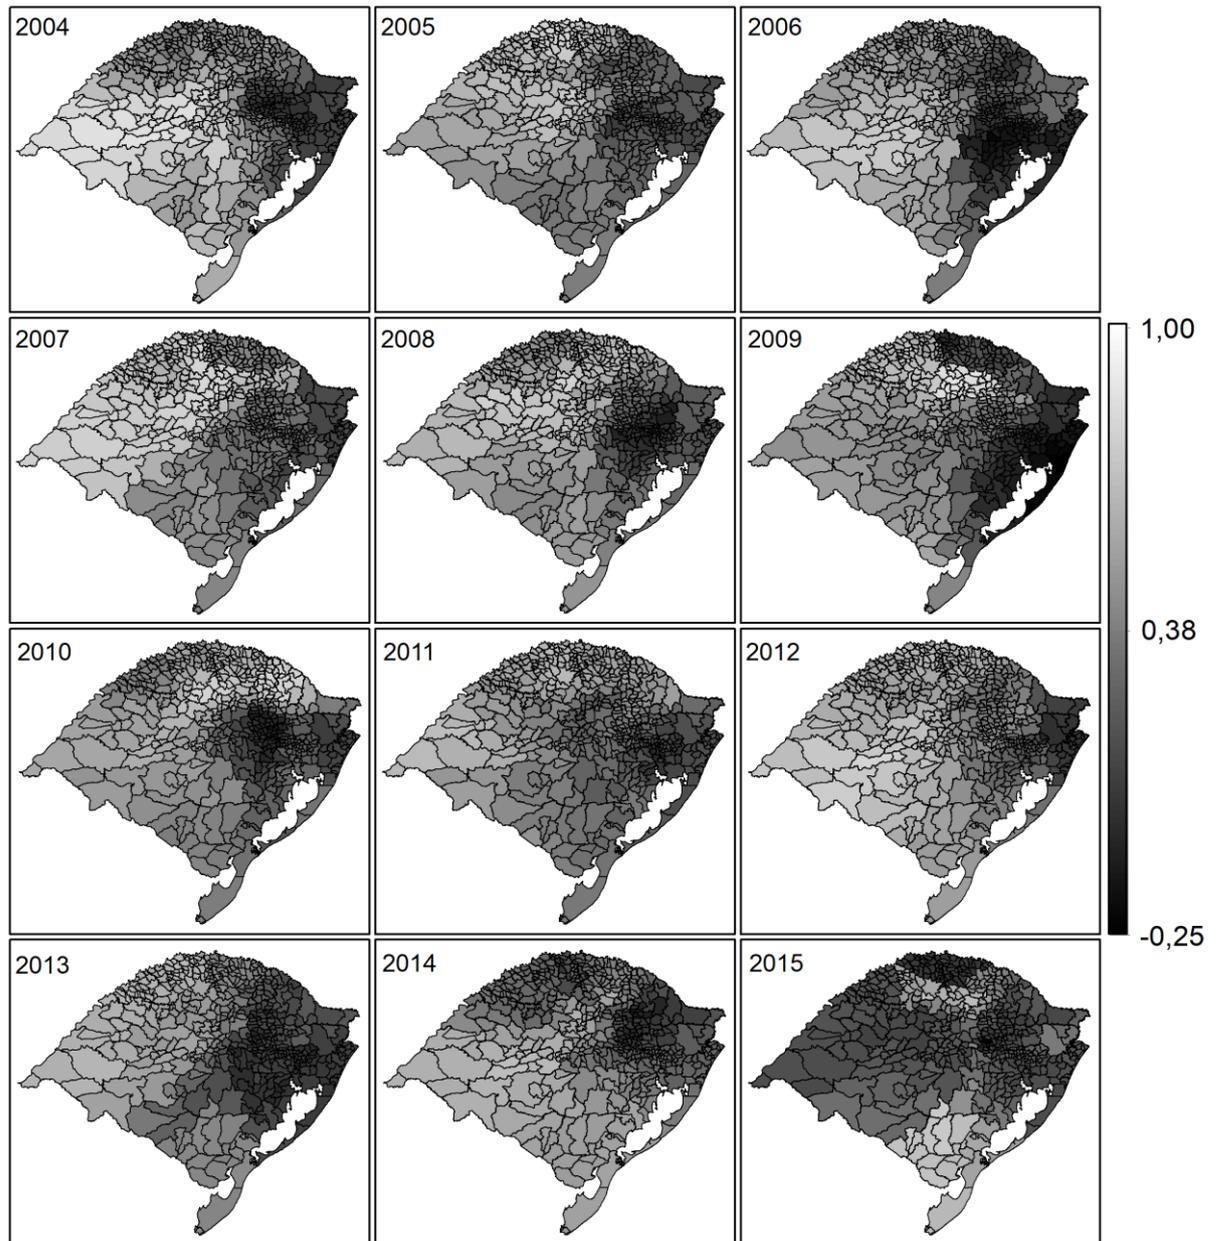


Figura B8 – Correlações lineares locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 15% (75) e *kernel Boxcar*. Escala da figura truncada em -0,25.

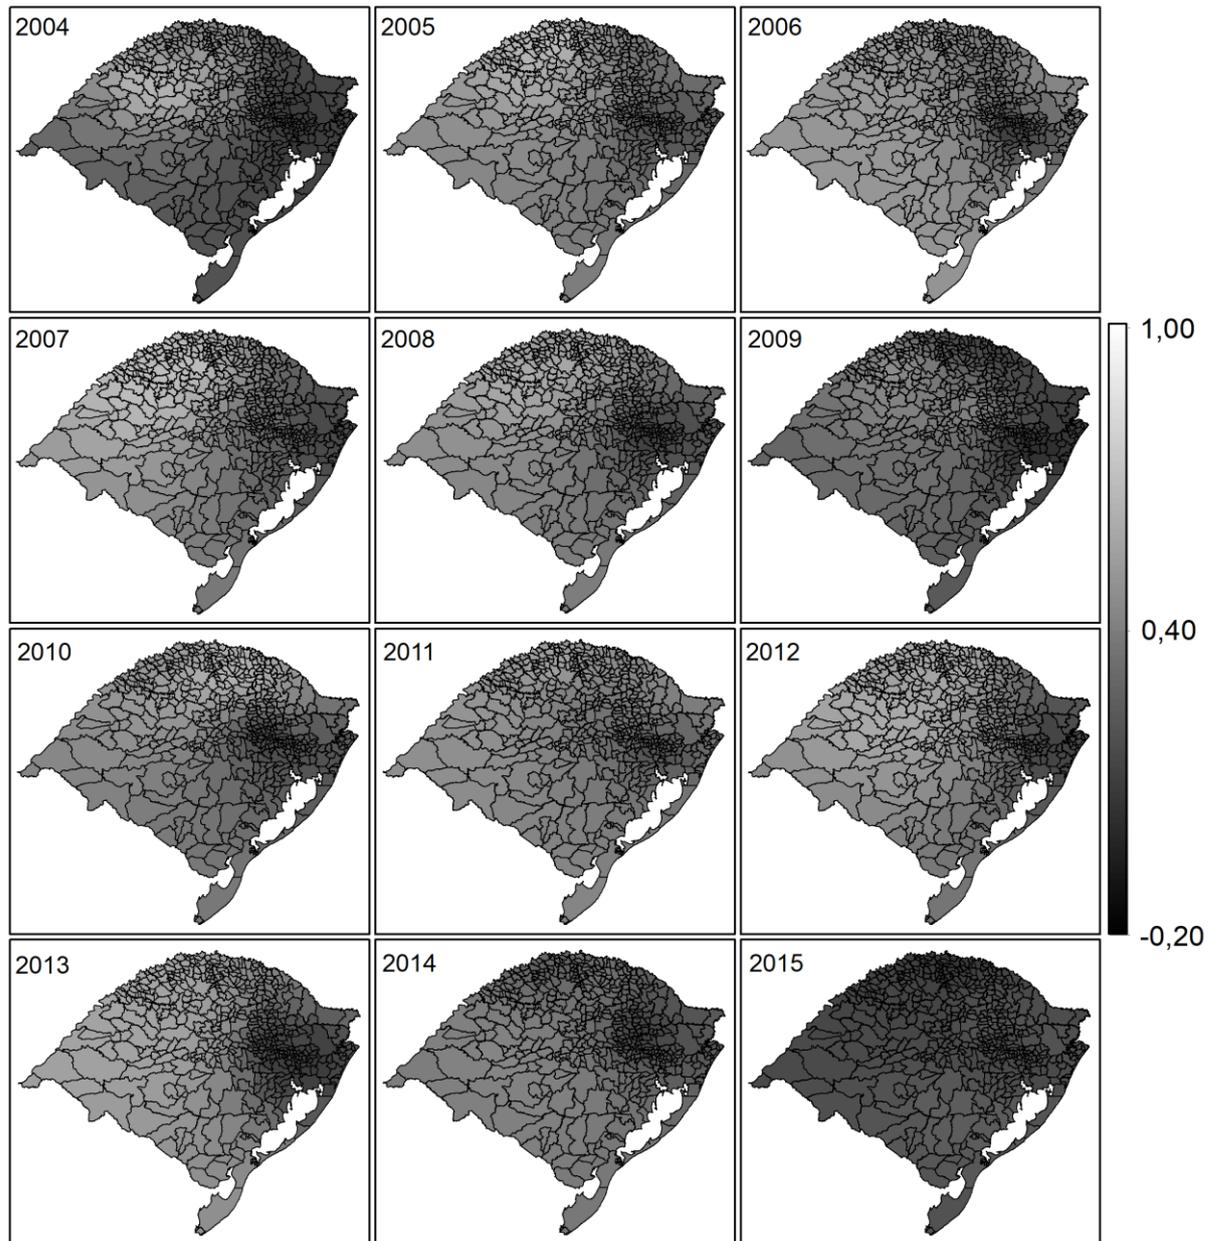


Figura B9 – Correlações lineares locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 15% (75) e *kernel* Gaussiano.

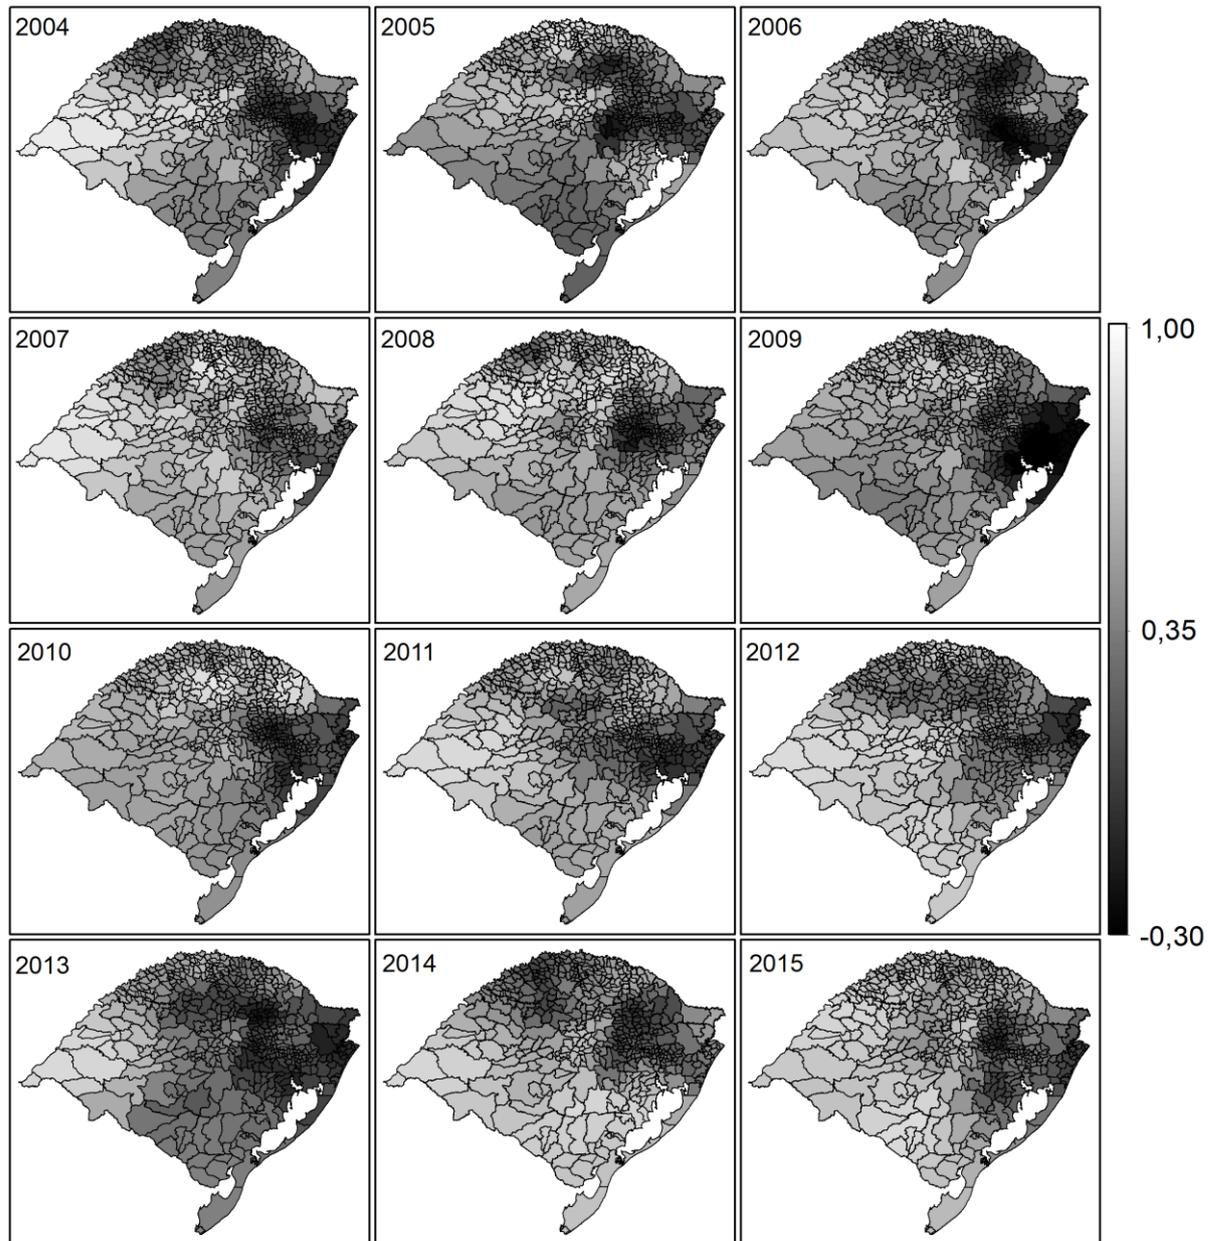


Figura B10 – Correlações robustas locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 15% (75) e *kernel* Biquadrado. Escala da figura truncada em -0,30.

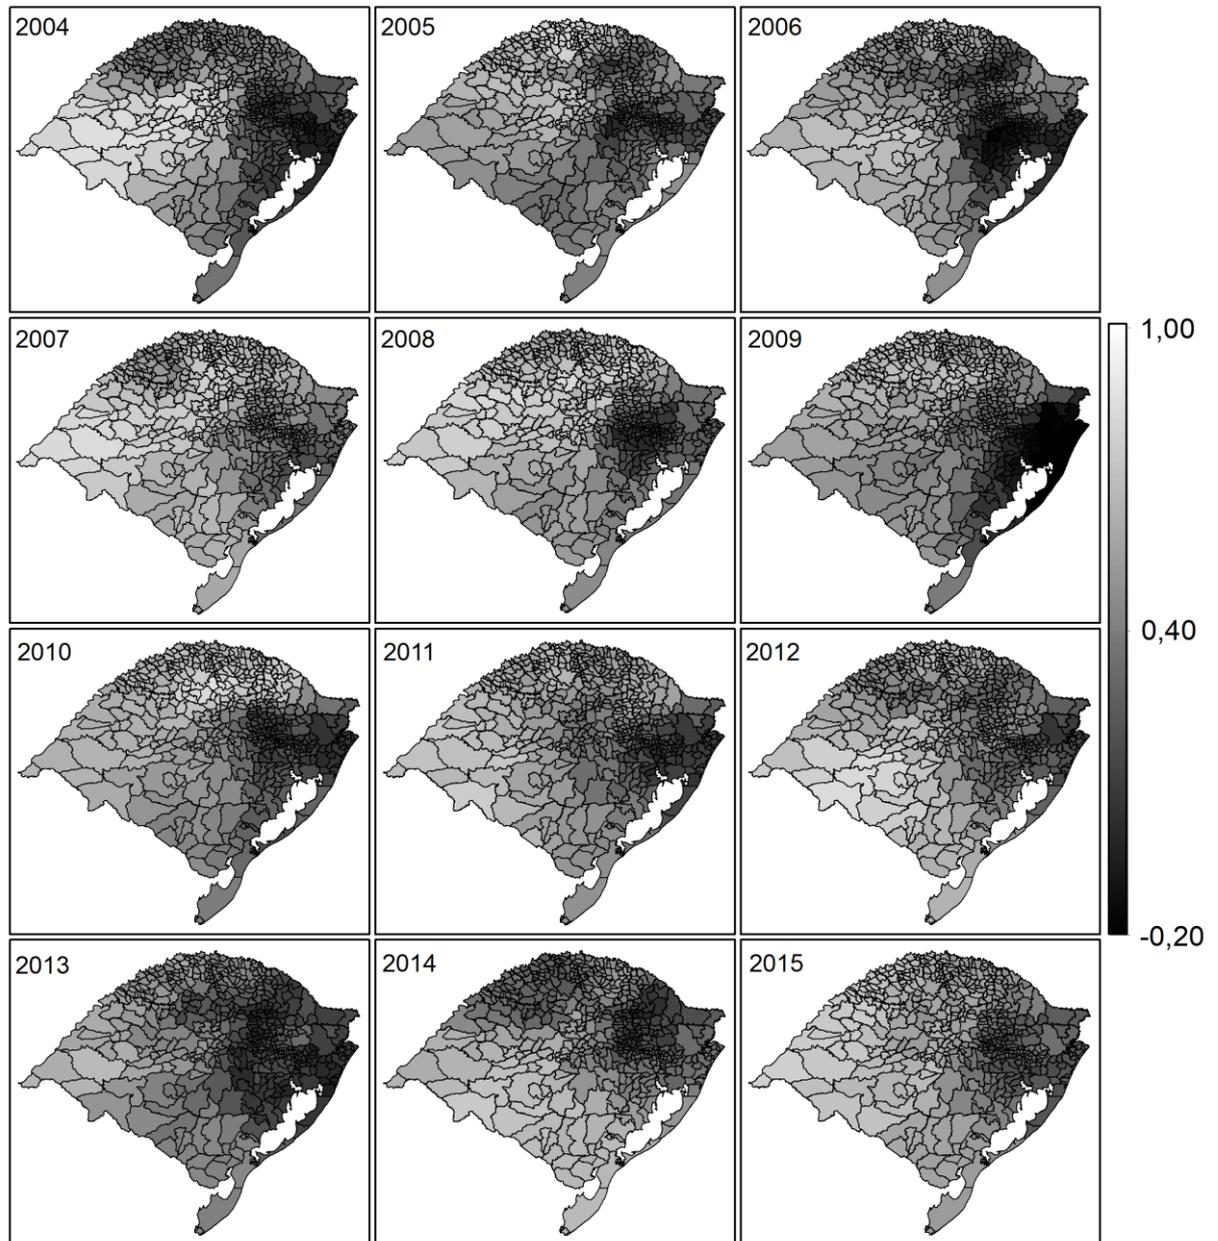


Figura B11 – Correlações robustas locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 15% (75) e *kernel Boxcar*. Escala da figura truncada em -0,20.

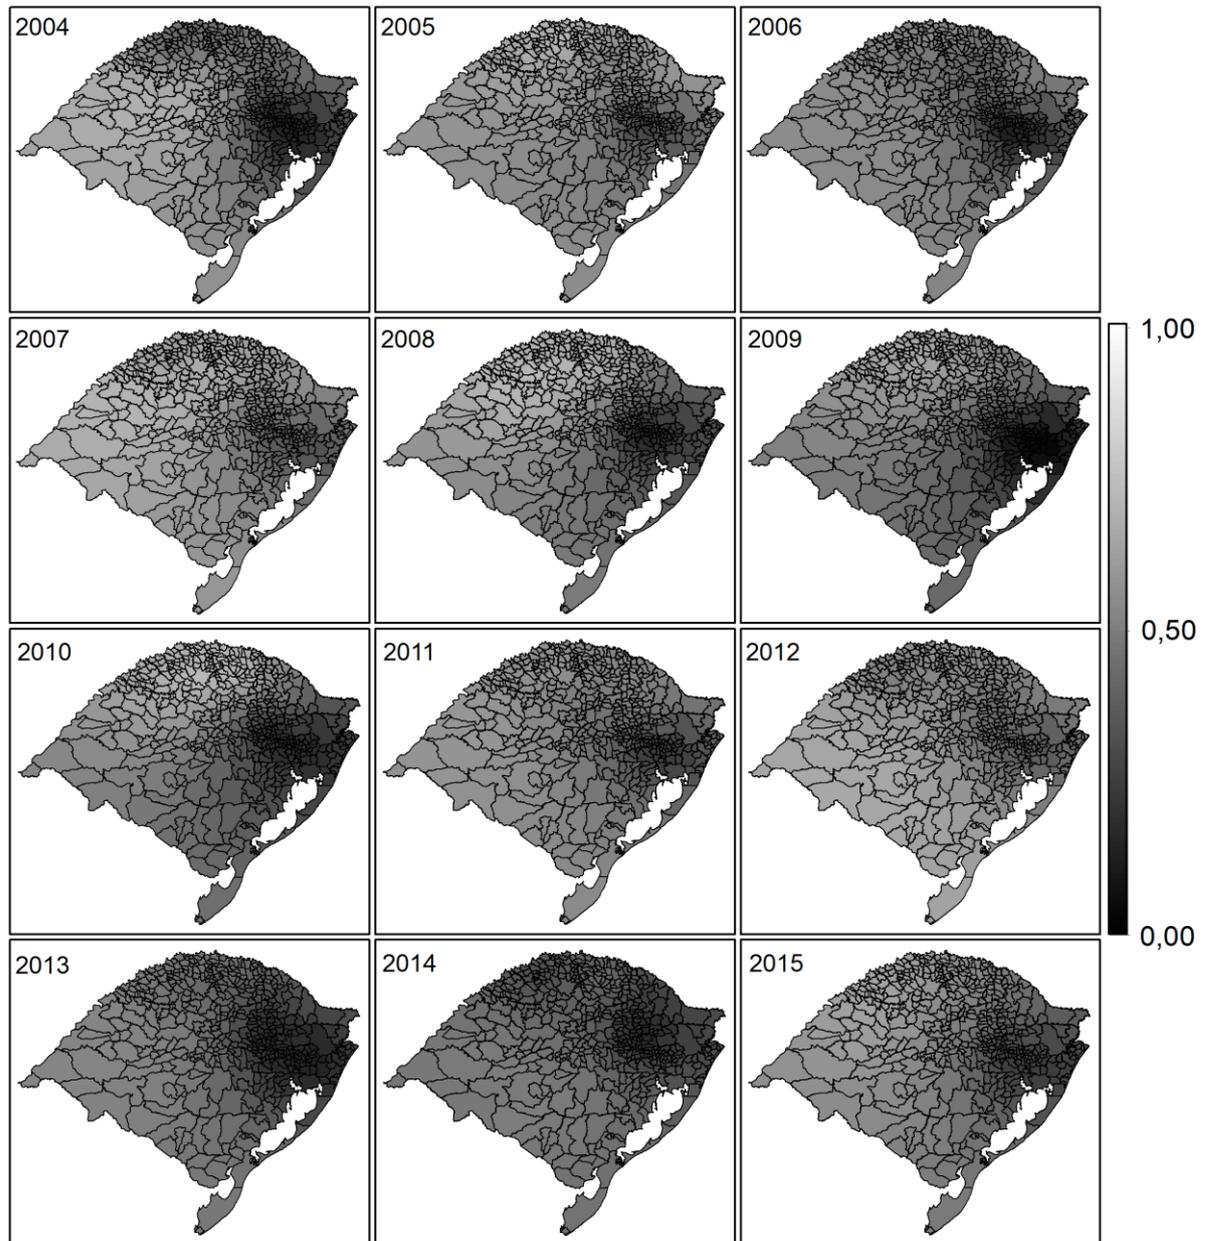


Figura B12 – Correlações robustas locais entre cPIB e cVPA no Estado no Rio Grande do Sul com largura de banda igual a 15% (75) e *kernel* Gaussiano.

Apêndice C – Variação das correlações entre cPIB e cVPA ao longo dos transectos

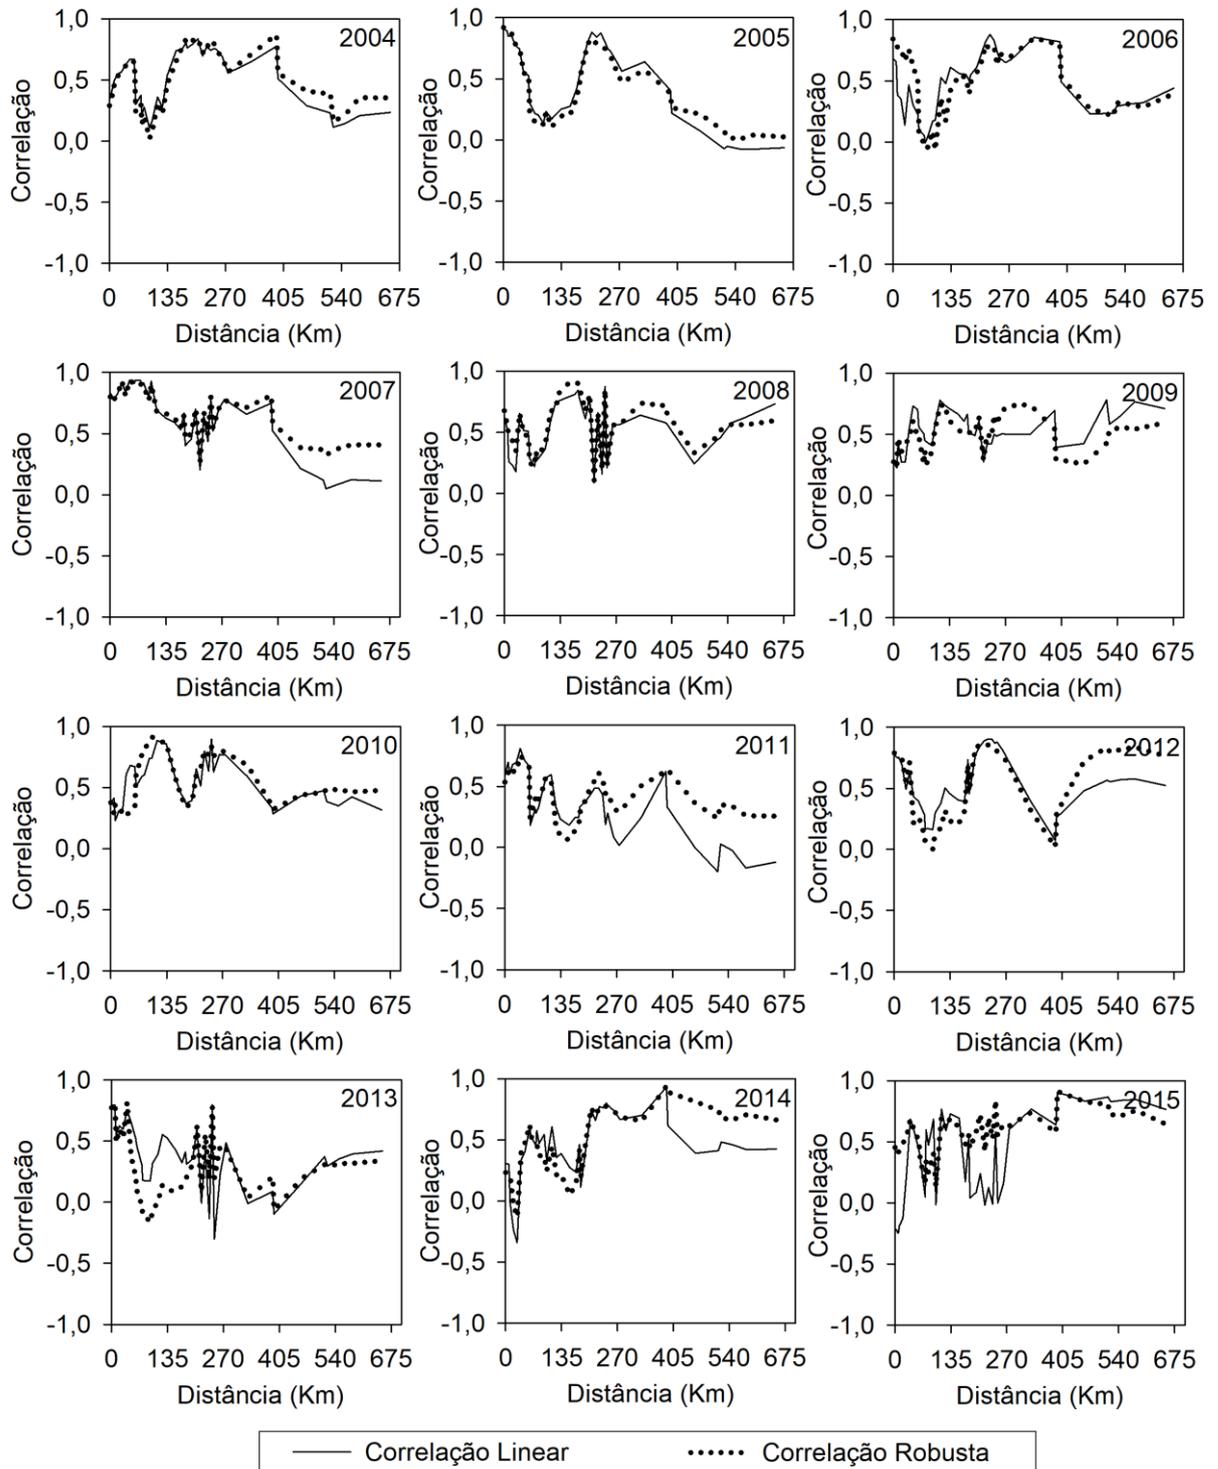


Figura C1 – Correlações locais entre cPIB e cVPA ao longo do Transecto Norte/Sul com largura de banda igual a 5% (25) e *kernel* Biquadrado.

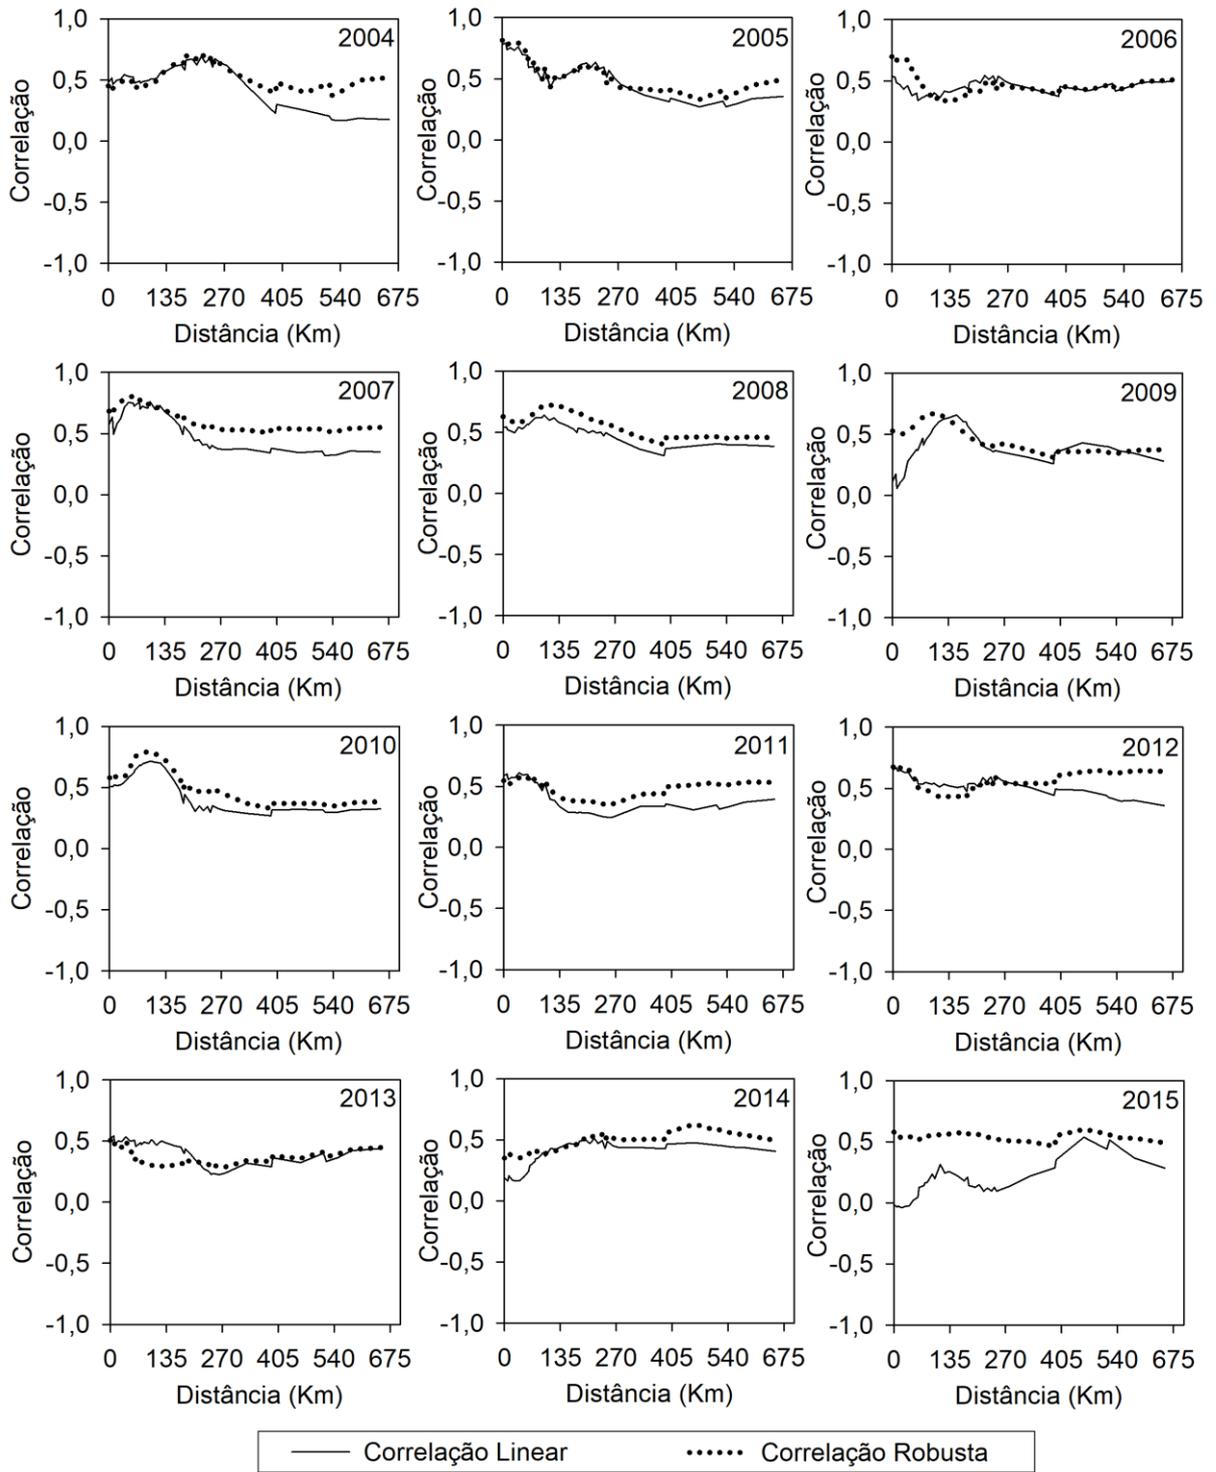


Figura C2 – Correlações locais entre cPIB e cVPA ao longo do Transecto Norte/Sul com largura de banda igual a 5% (25) e *kernel Boxcar*.

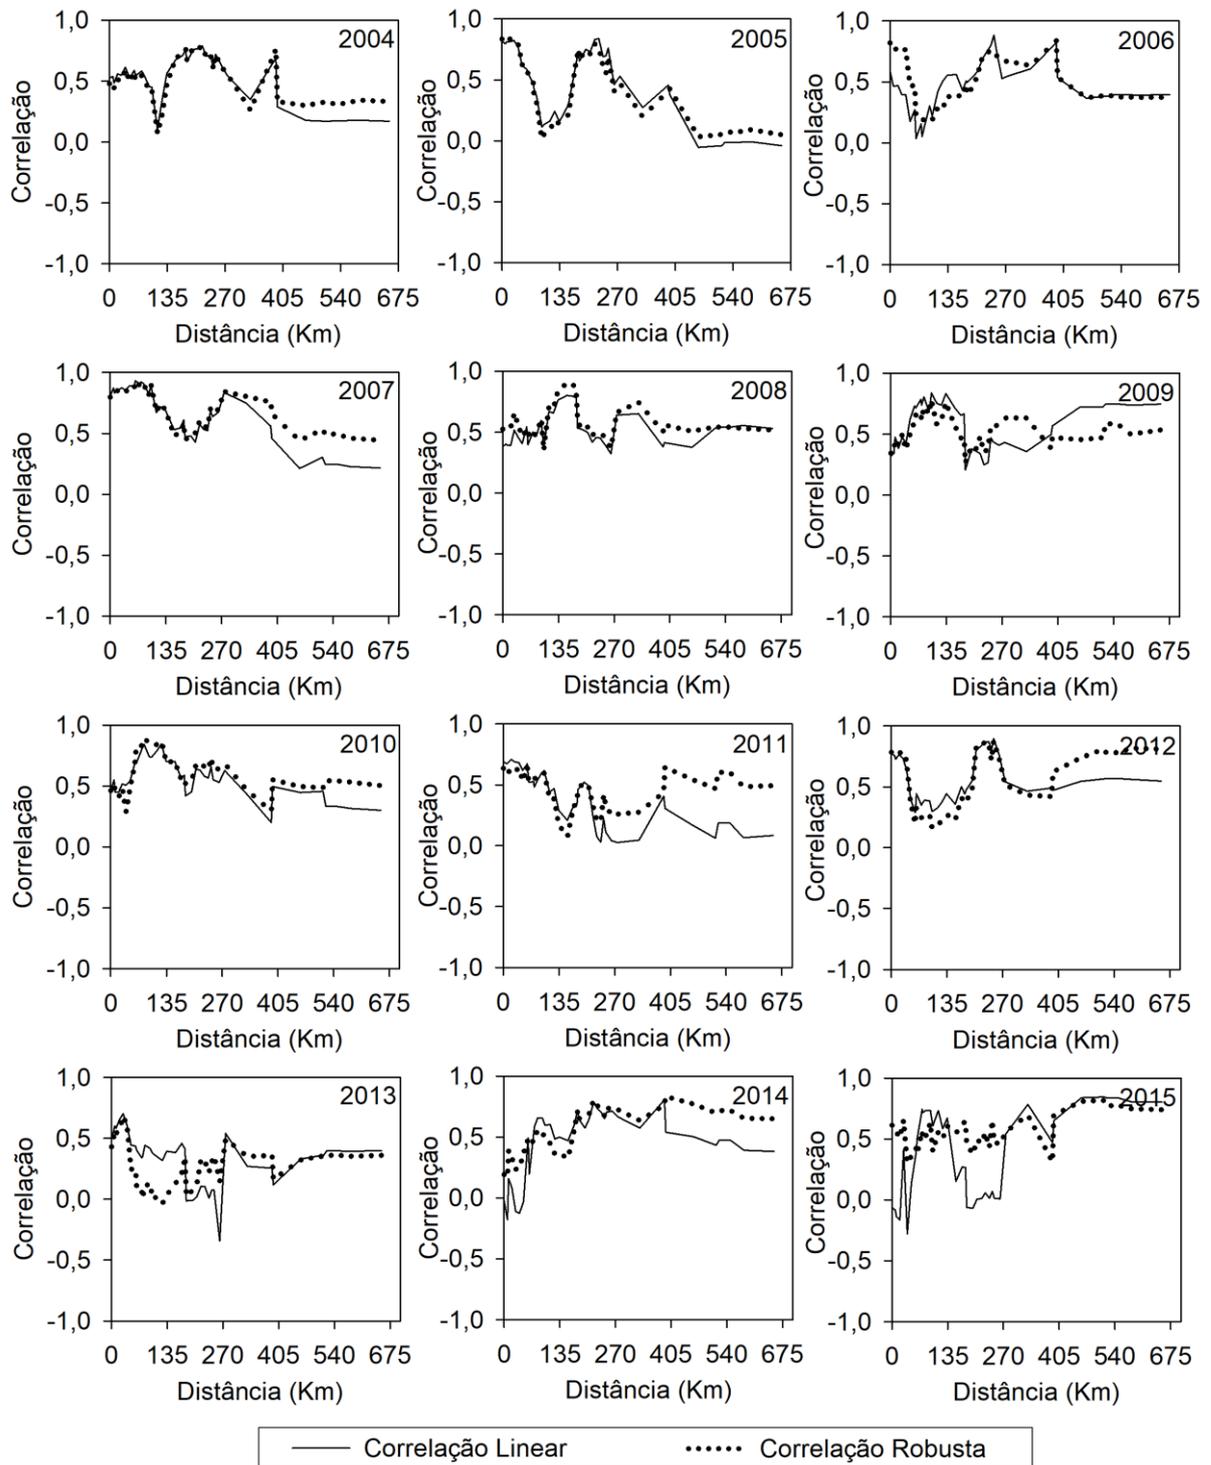


Figura C3 – Correlações locais entre cPIB e cVPA ao longo do Transecto Norte/Sul com largura de banda igual a 5% (25) e *kernel* Gaussiano.

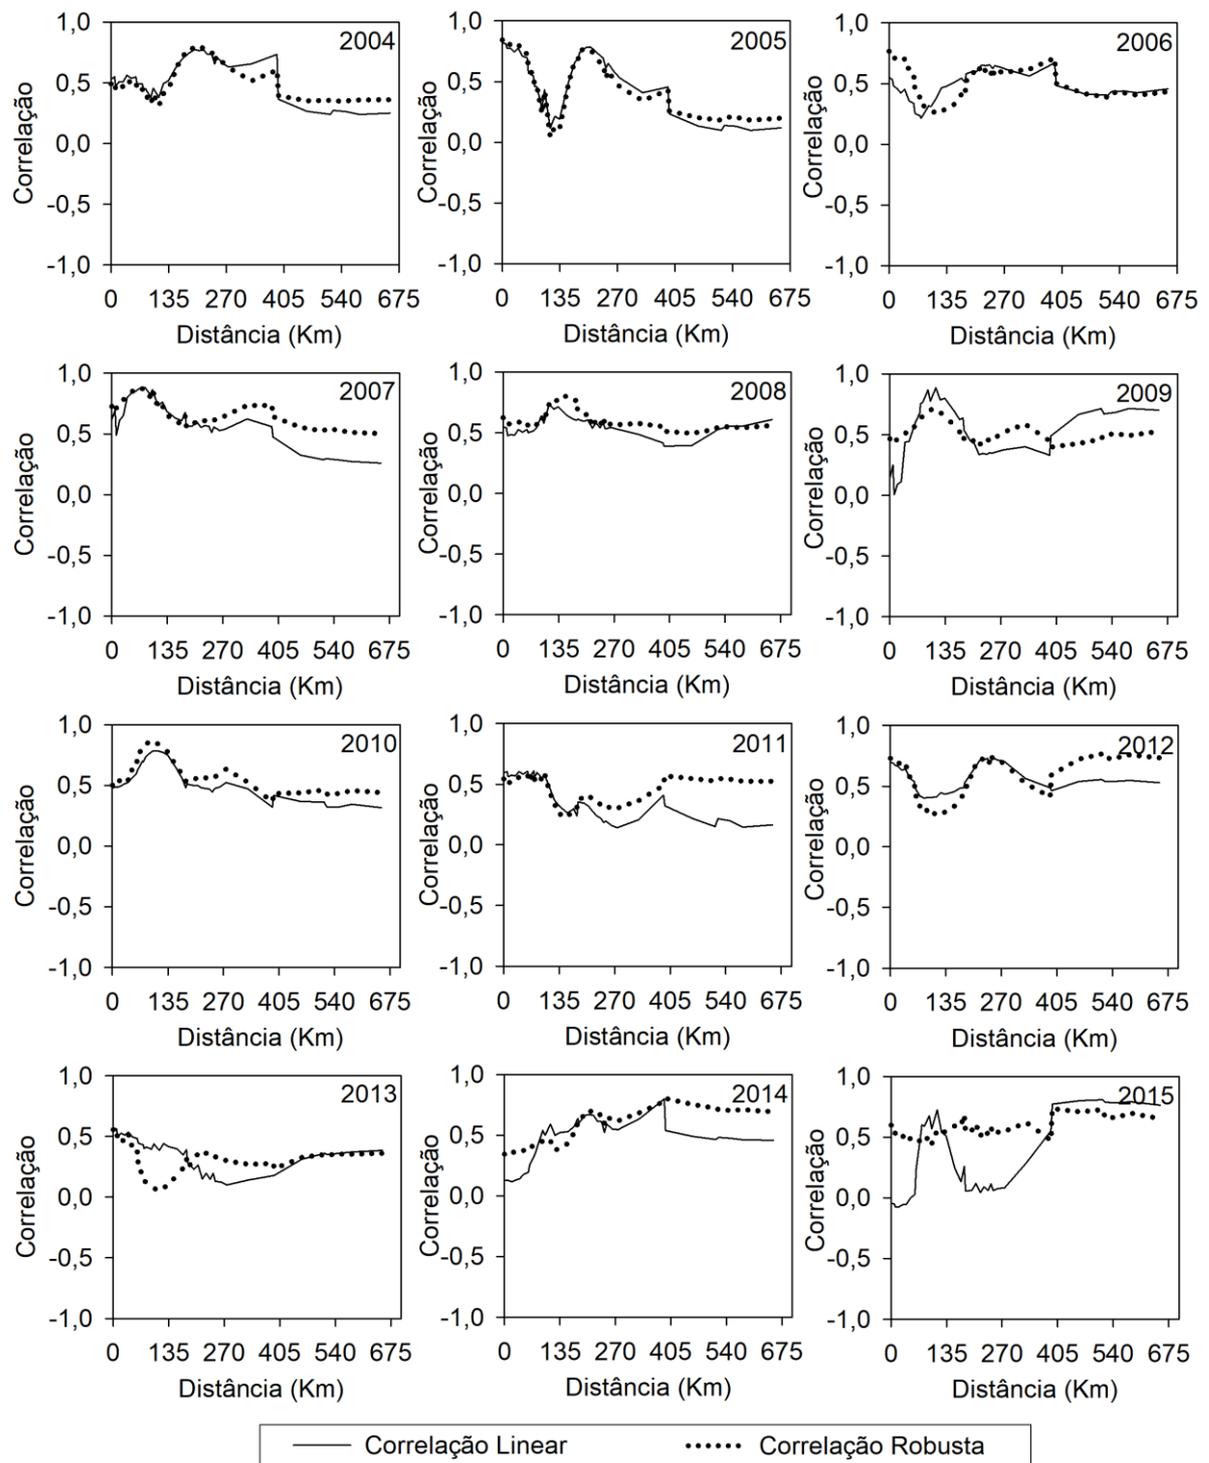


Figura C4 – Correlações locais entre cPIB e cVPA ao longo do Transecto Norte/Sul com largura de banda igual a 15% (75) e *kernel* Biquadrado.

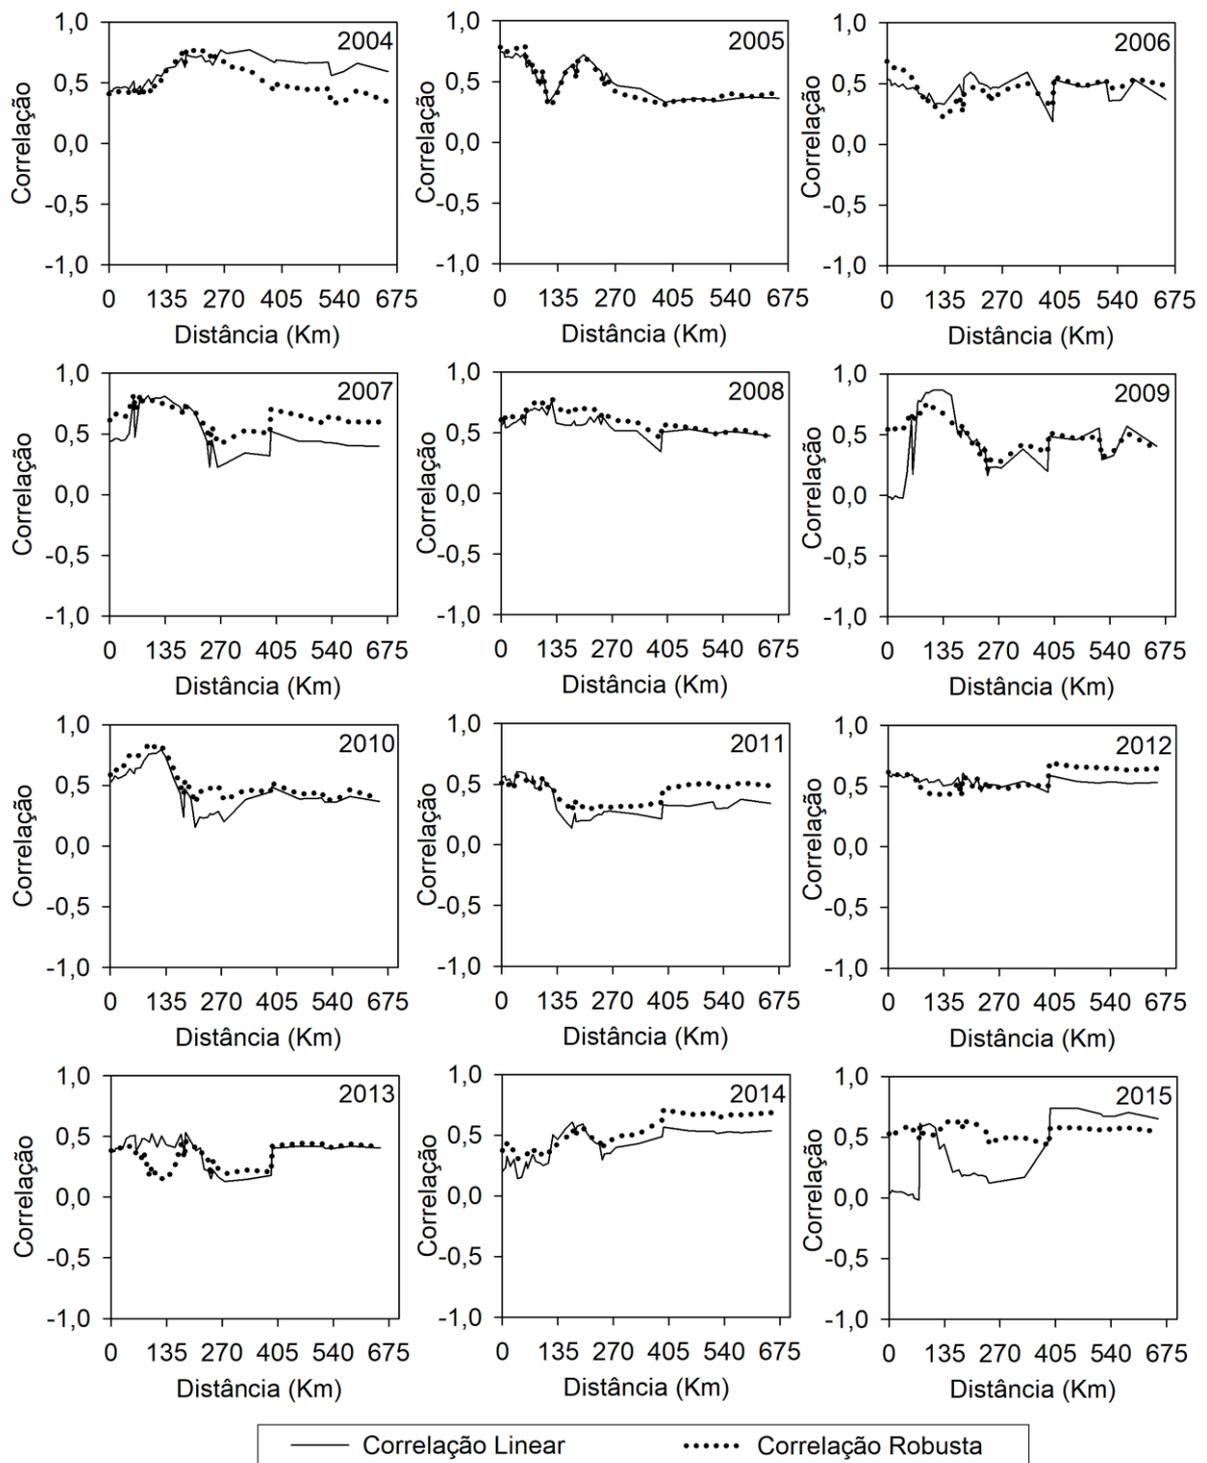


Figura C5 – Correlações locais entre cPIB e cVPA ao longo do Transecto Norte/Sul com largura de banda igual a 15% (75) e *kernel Boxcar*.

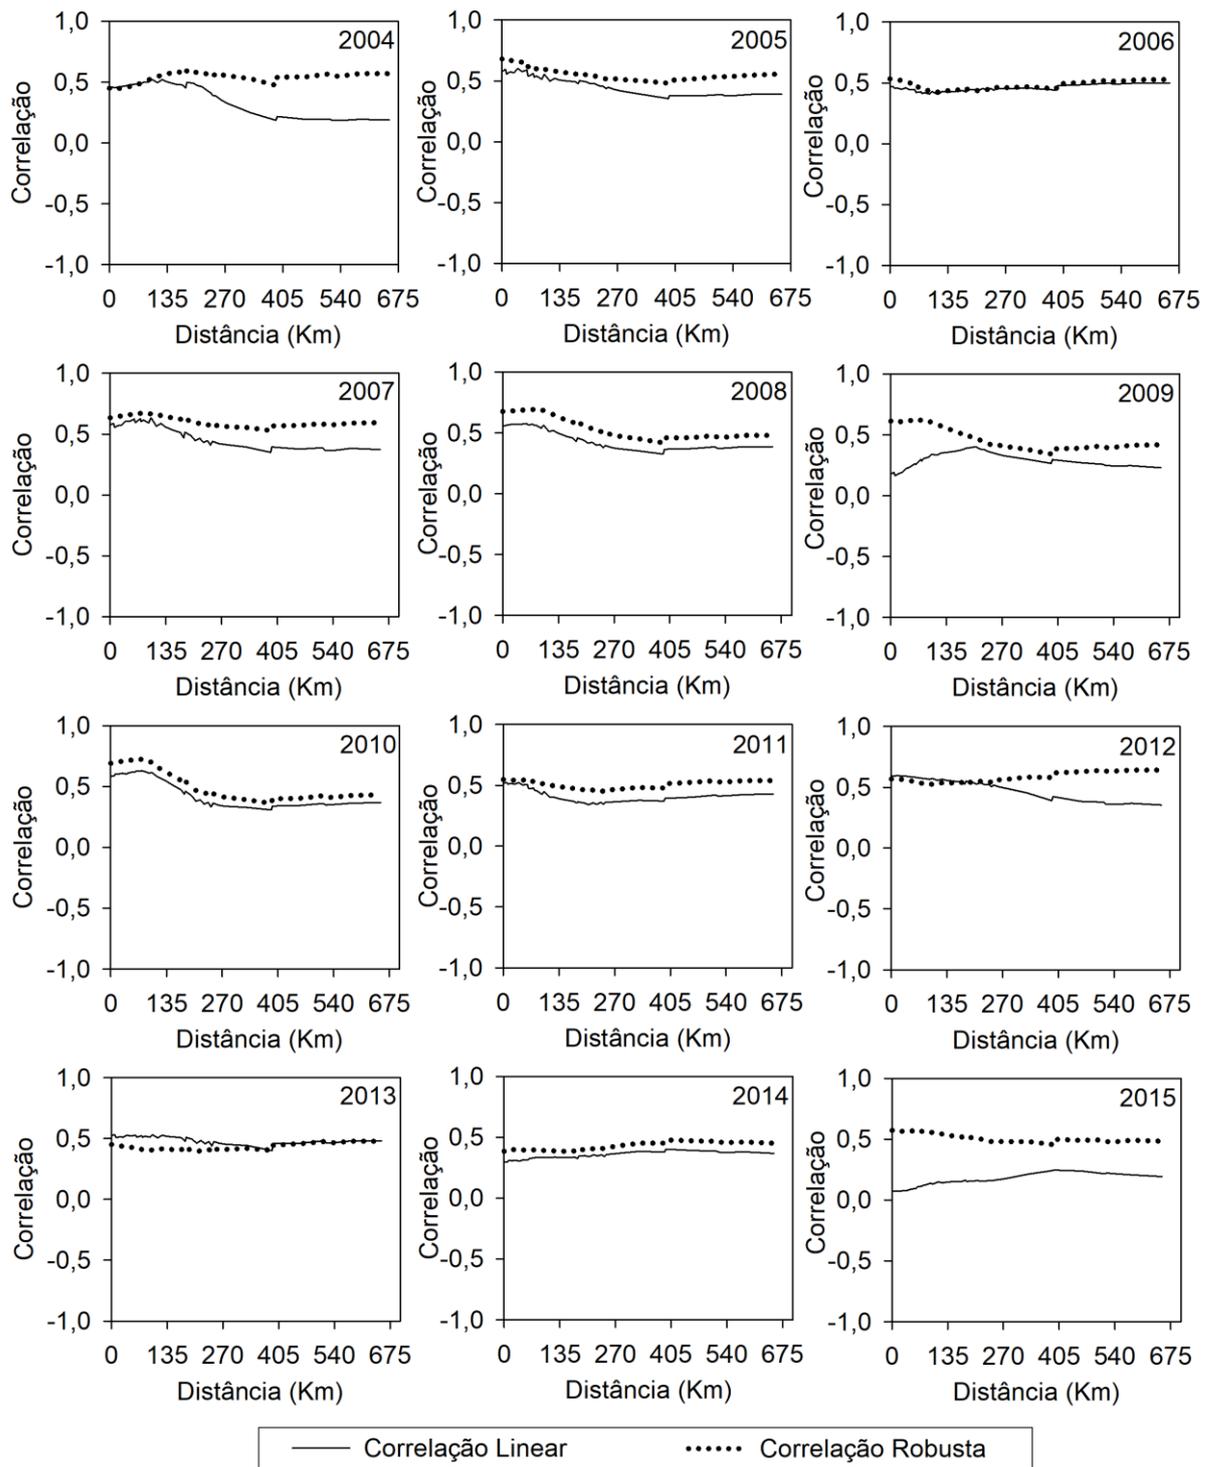


Figura C6 – Correlações locais entre cPIB e cVPA ao longo do Transecto Norte/Sul com largura de banda igual a 15% (75) e *kernel* Gaussiano.

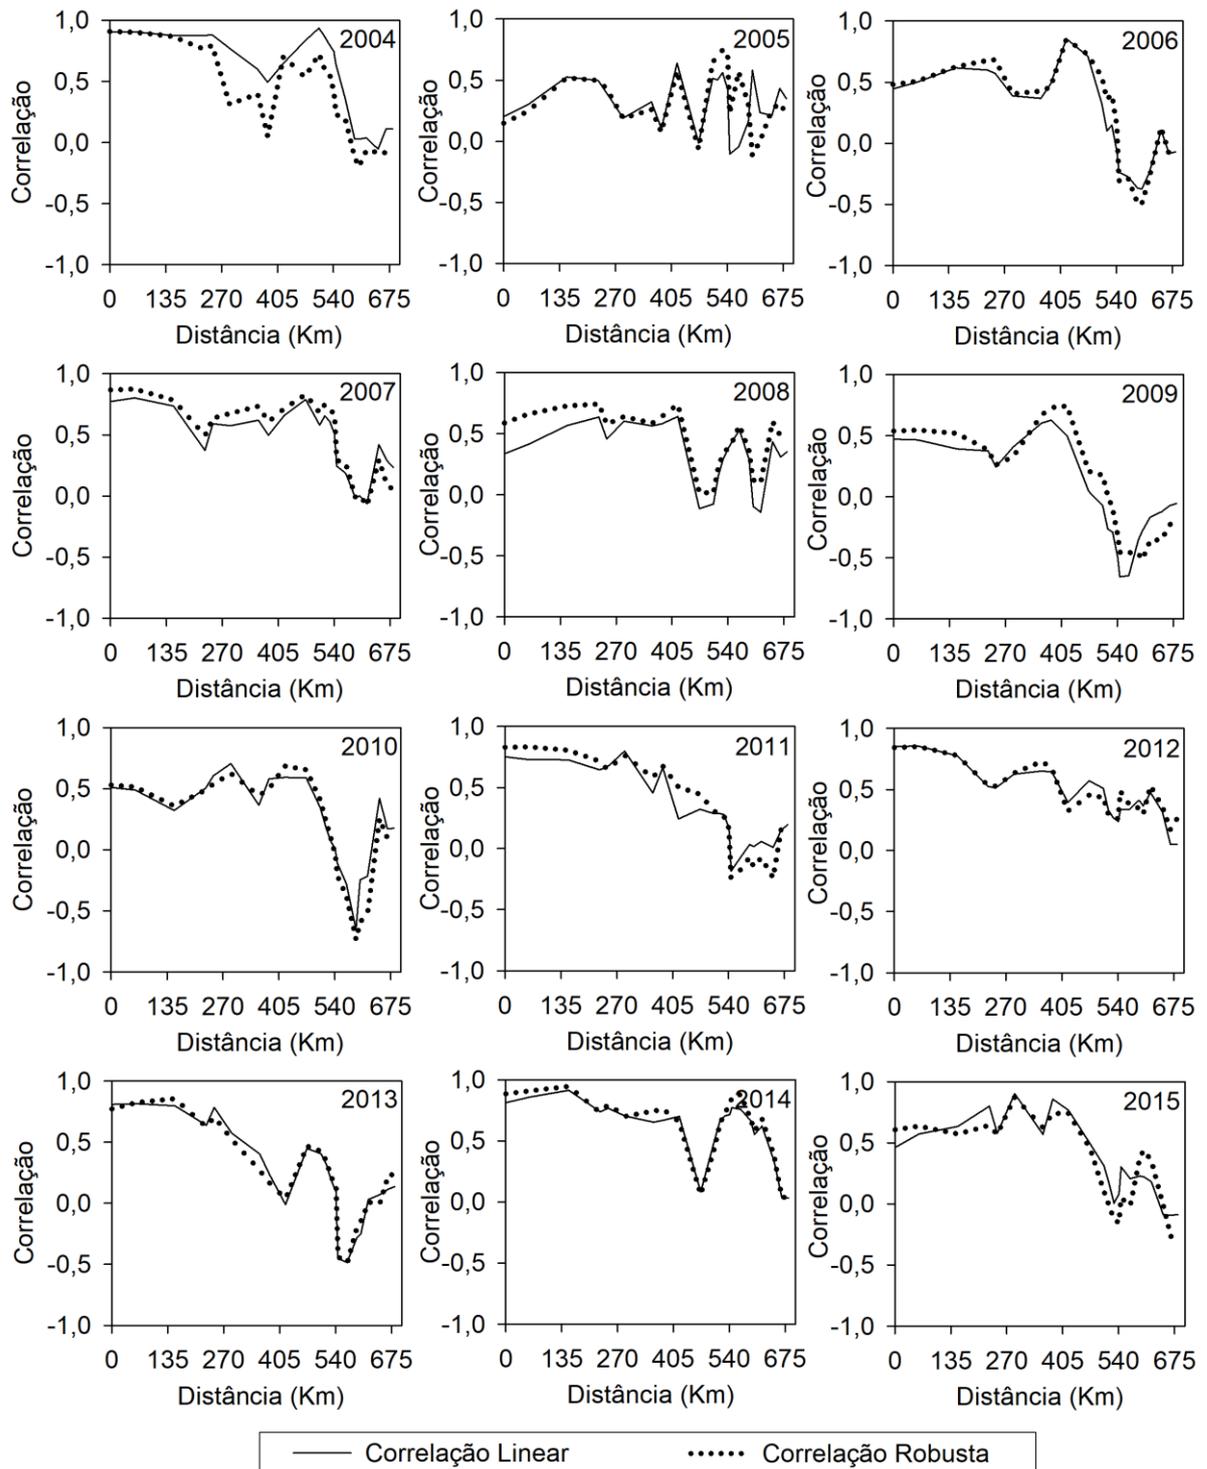


Figura C7 – Correlações locais entre cPIB e cVPA ao longo do Transecto Oeste/Leste com largura de banda igual a 5% (25) e *kernel* Biquadrado.

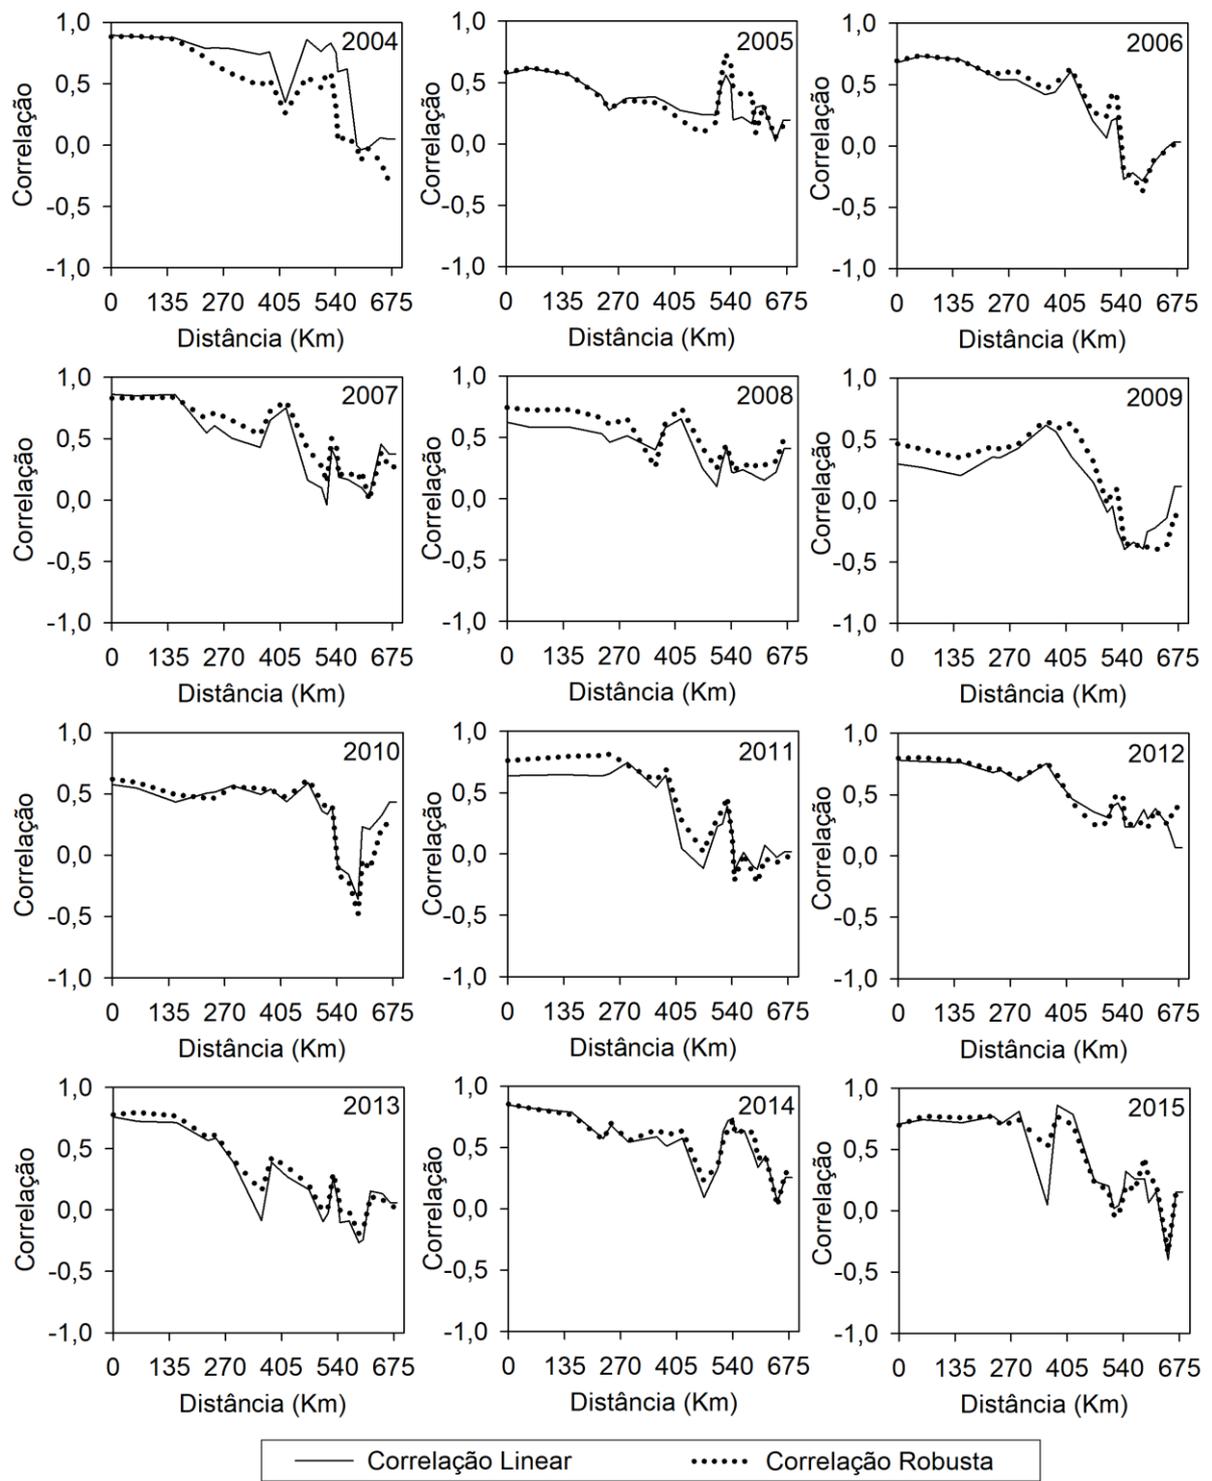


Figura C8 – Correlações locais entre cPIB e cVPA ao longo do Transecto Oeste/Leste com largura de banda igual a 5% (25) e *kernel Boxcar*.

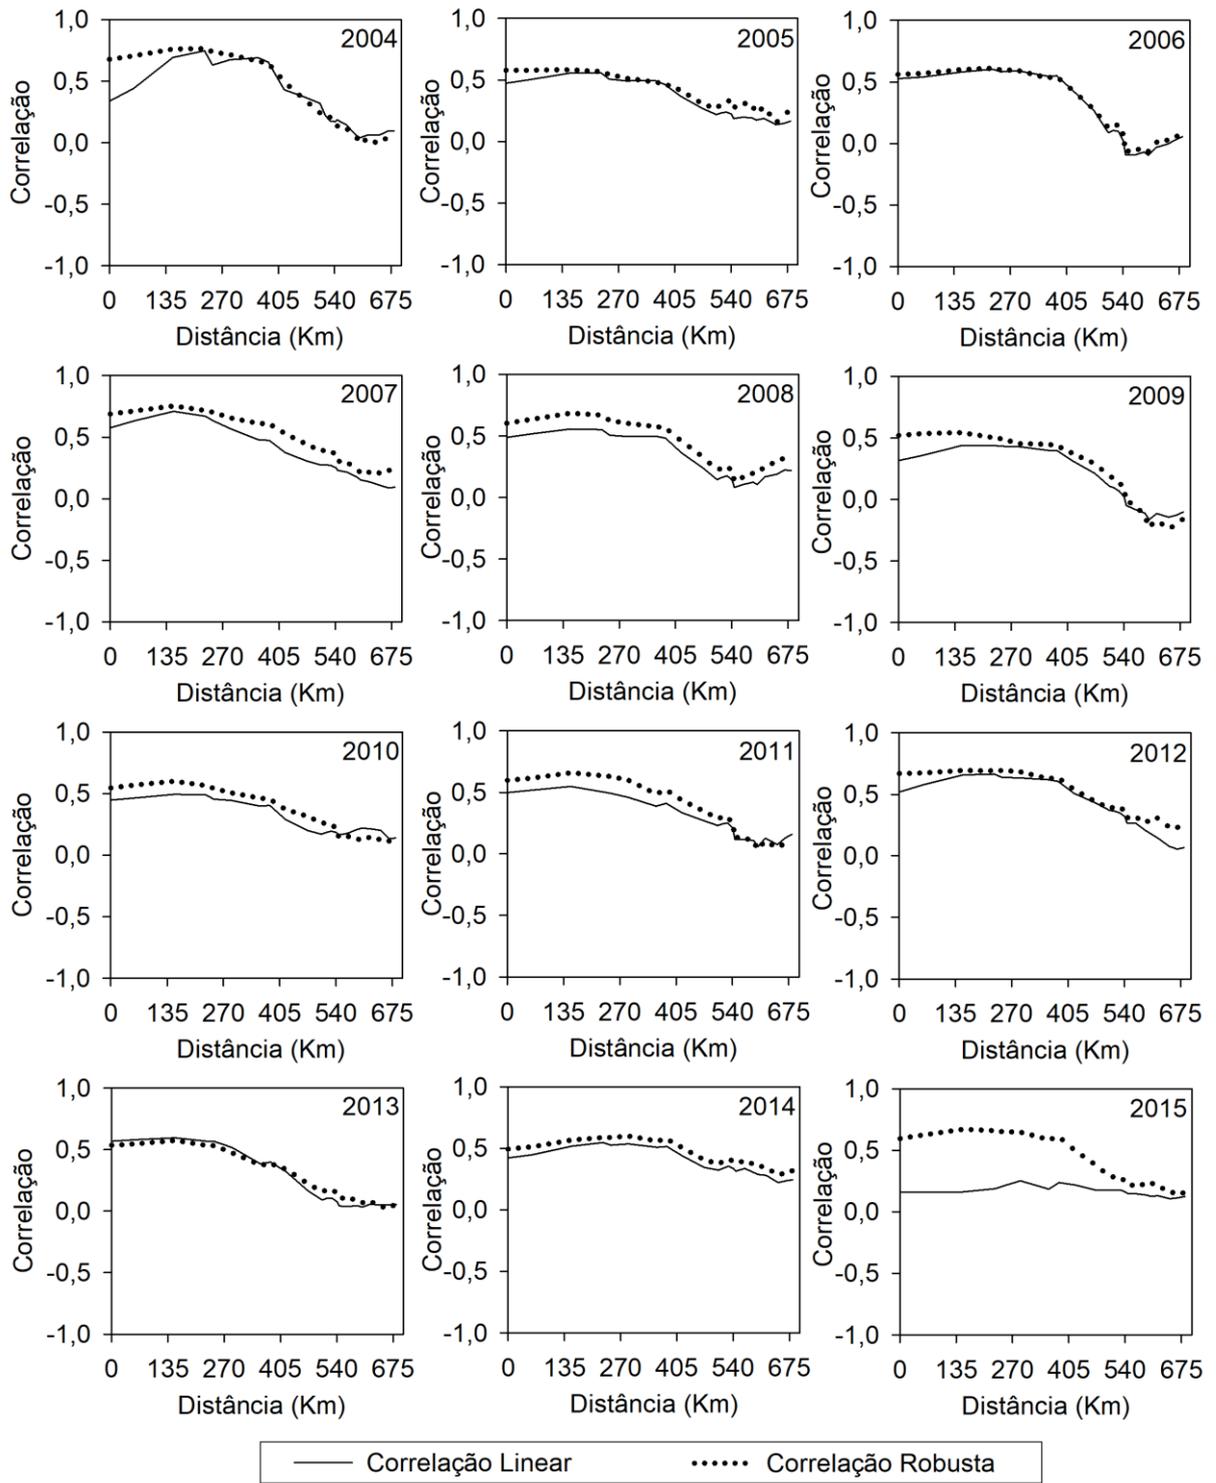


Figura C9 – Correlações locais entre cPIB e cVPA ao longo do Transecto Oeste/Leste com largura de banda igual a 5% (25) e *kernel* Gaussiano.

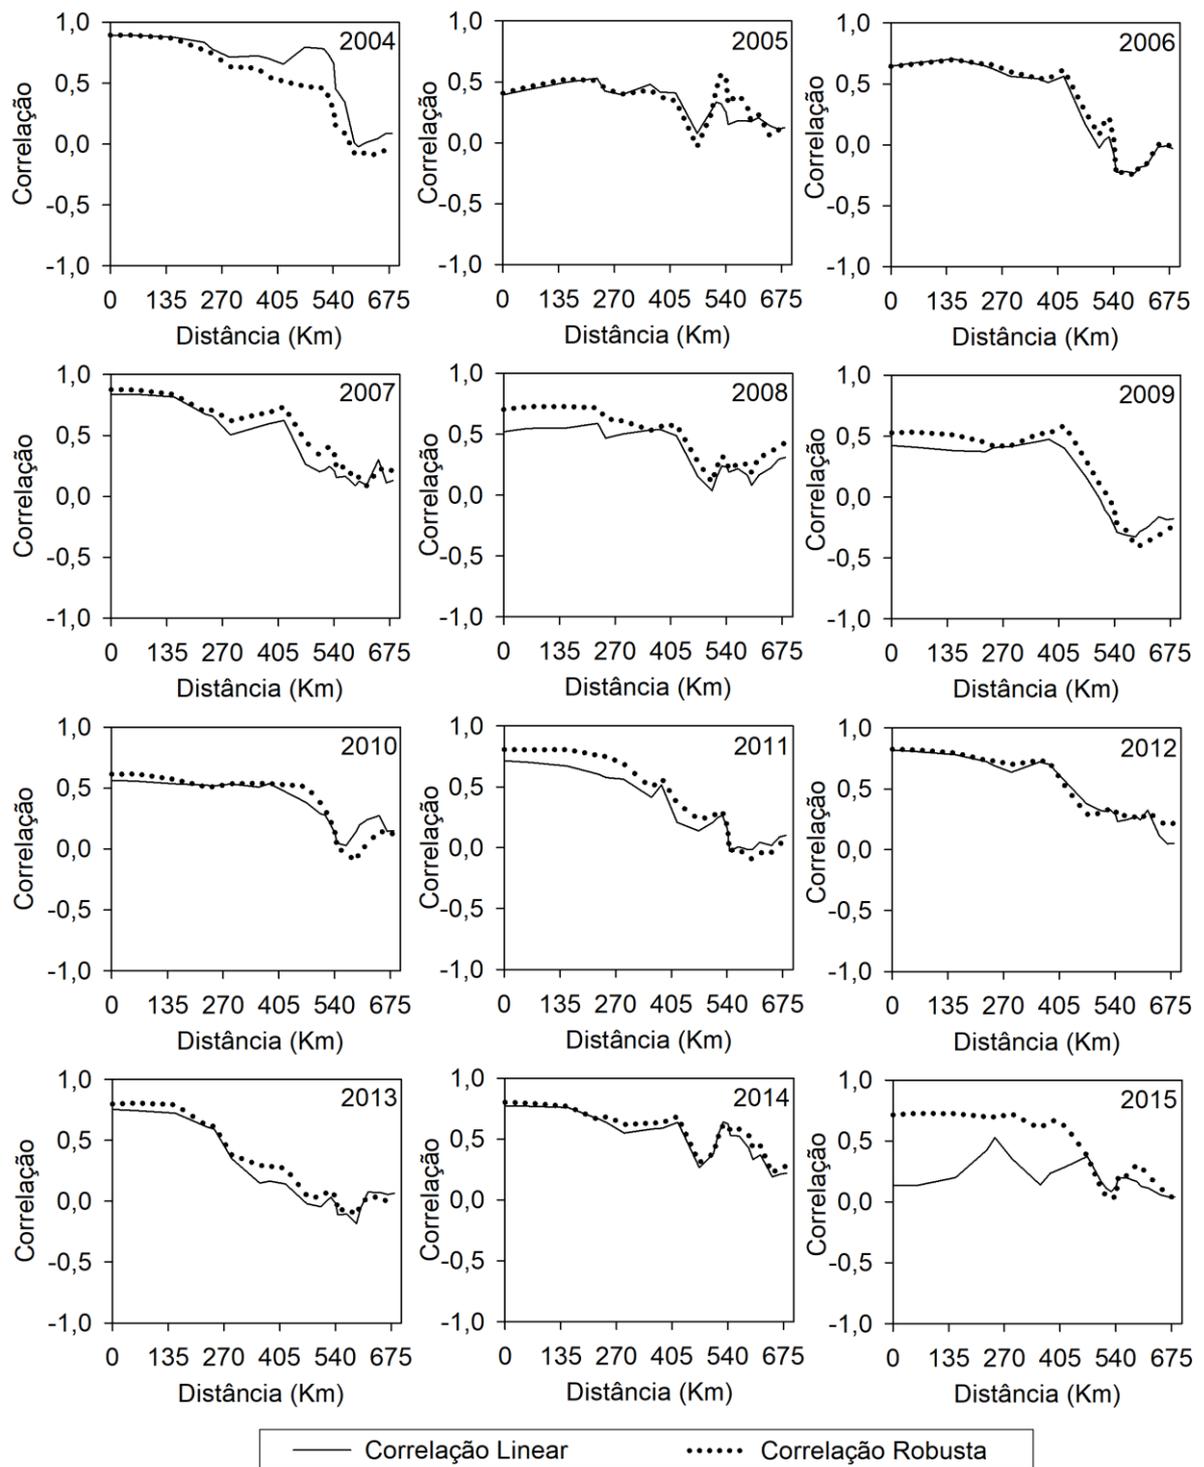


Figura C10 – Correlações locais entre cPIB e cVPA ao longo do Transecto Oeste/Leste com largura de banda igual a 15% (75) e *kernel* Biquadrado.

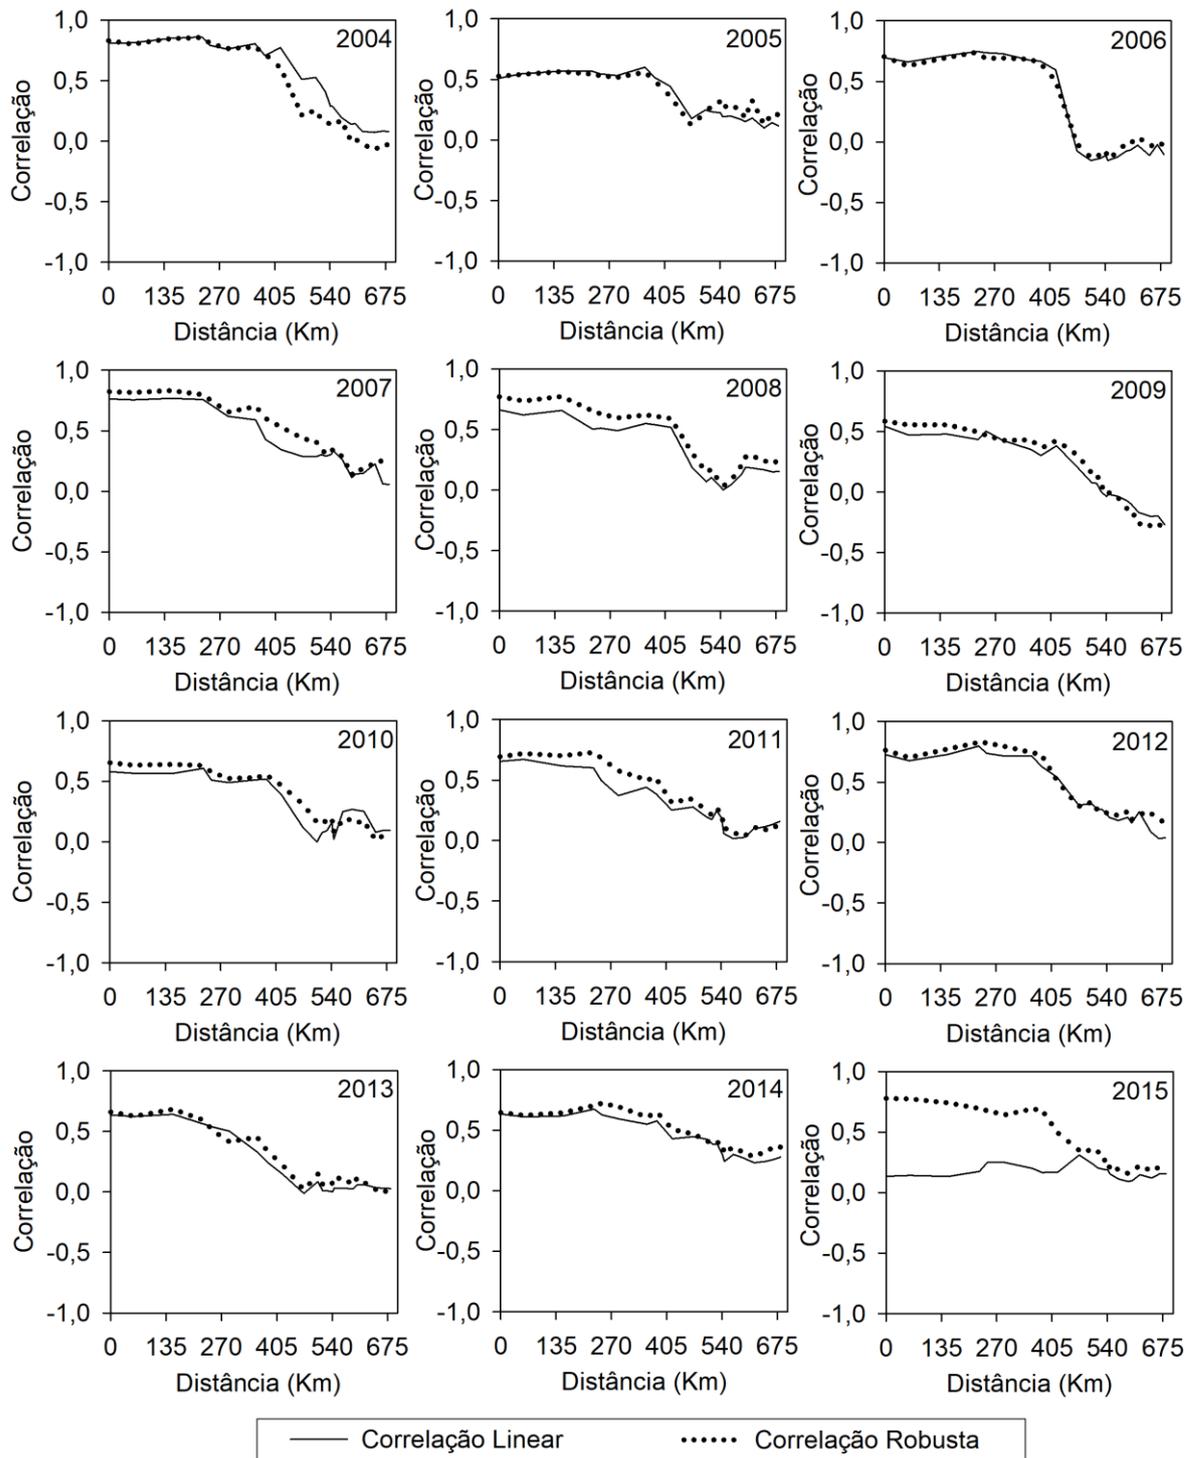


Figura C11 – Correlações locais entre cPIB e cVPA ao longo do Transecto Oeste/Leste com largura de banda igual a 15% (75) e *kernel Boxcar*.

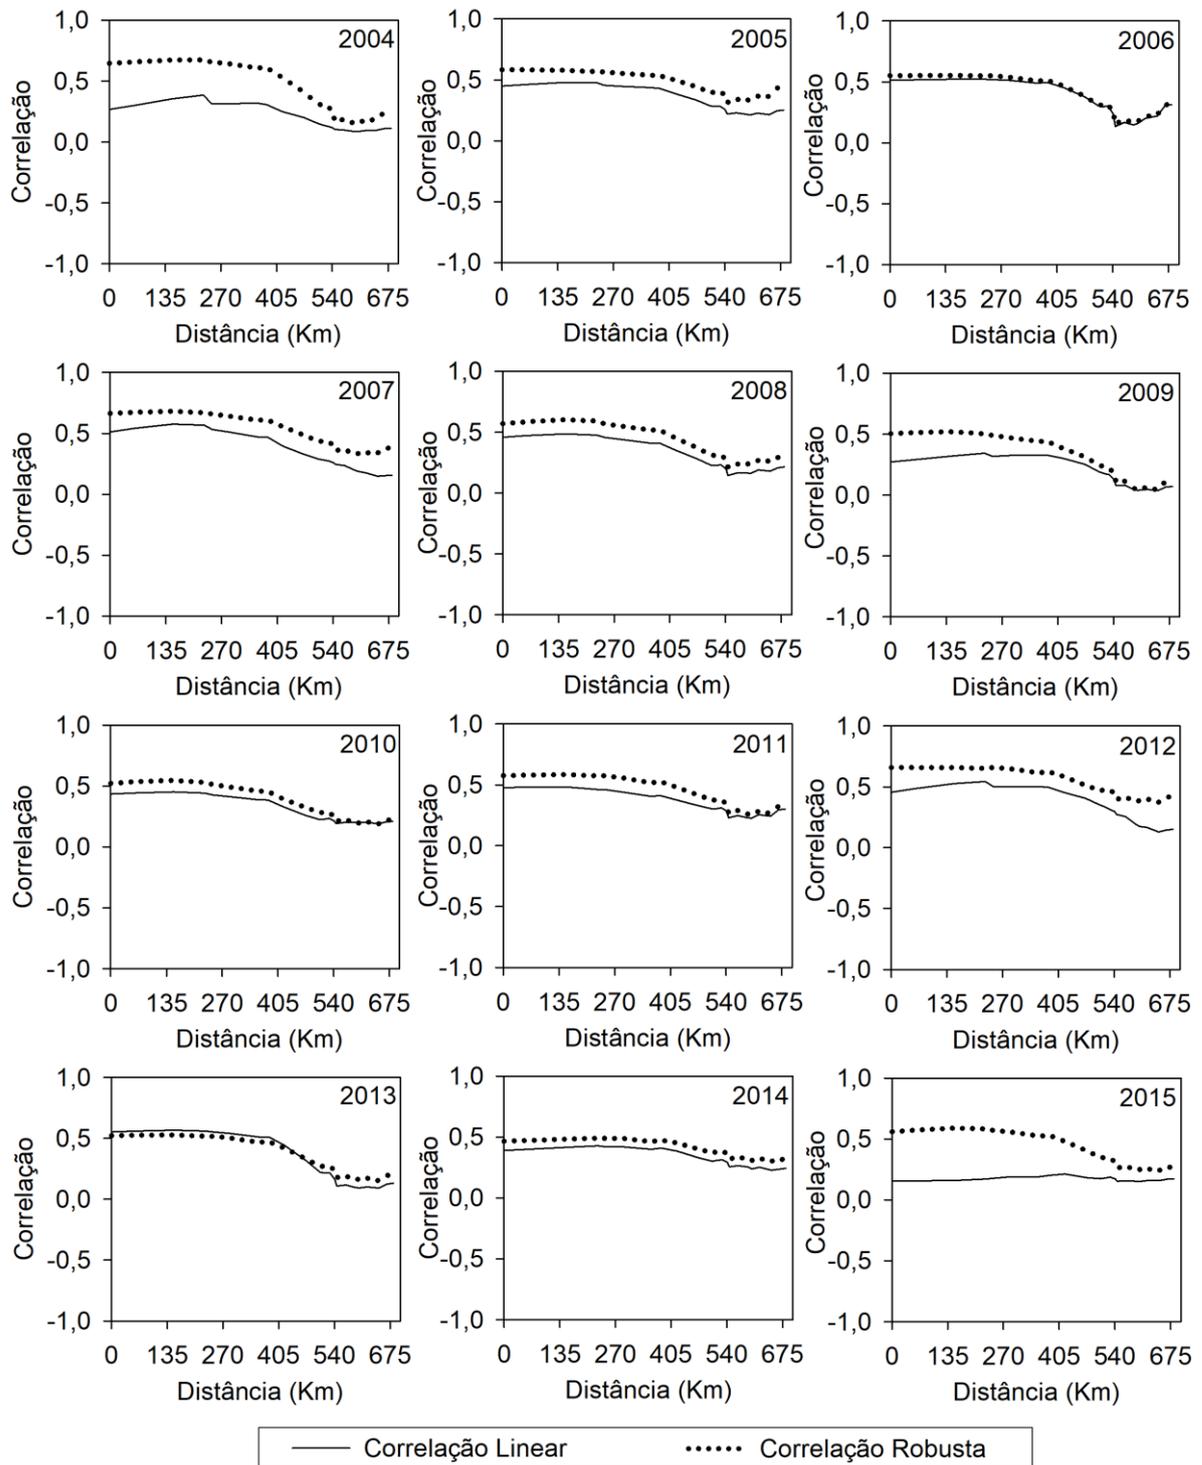


Figura C12 – Correlações locais entre cPIB e cVPA ao longo do Transecto Oeste/Leste com largura de banda igual a 15% (75) e *kernel* Gaussiano.

Apêndice D – Correlações significativas entre cPIB e cVPA no Estado do Rio Grande do Sul

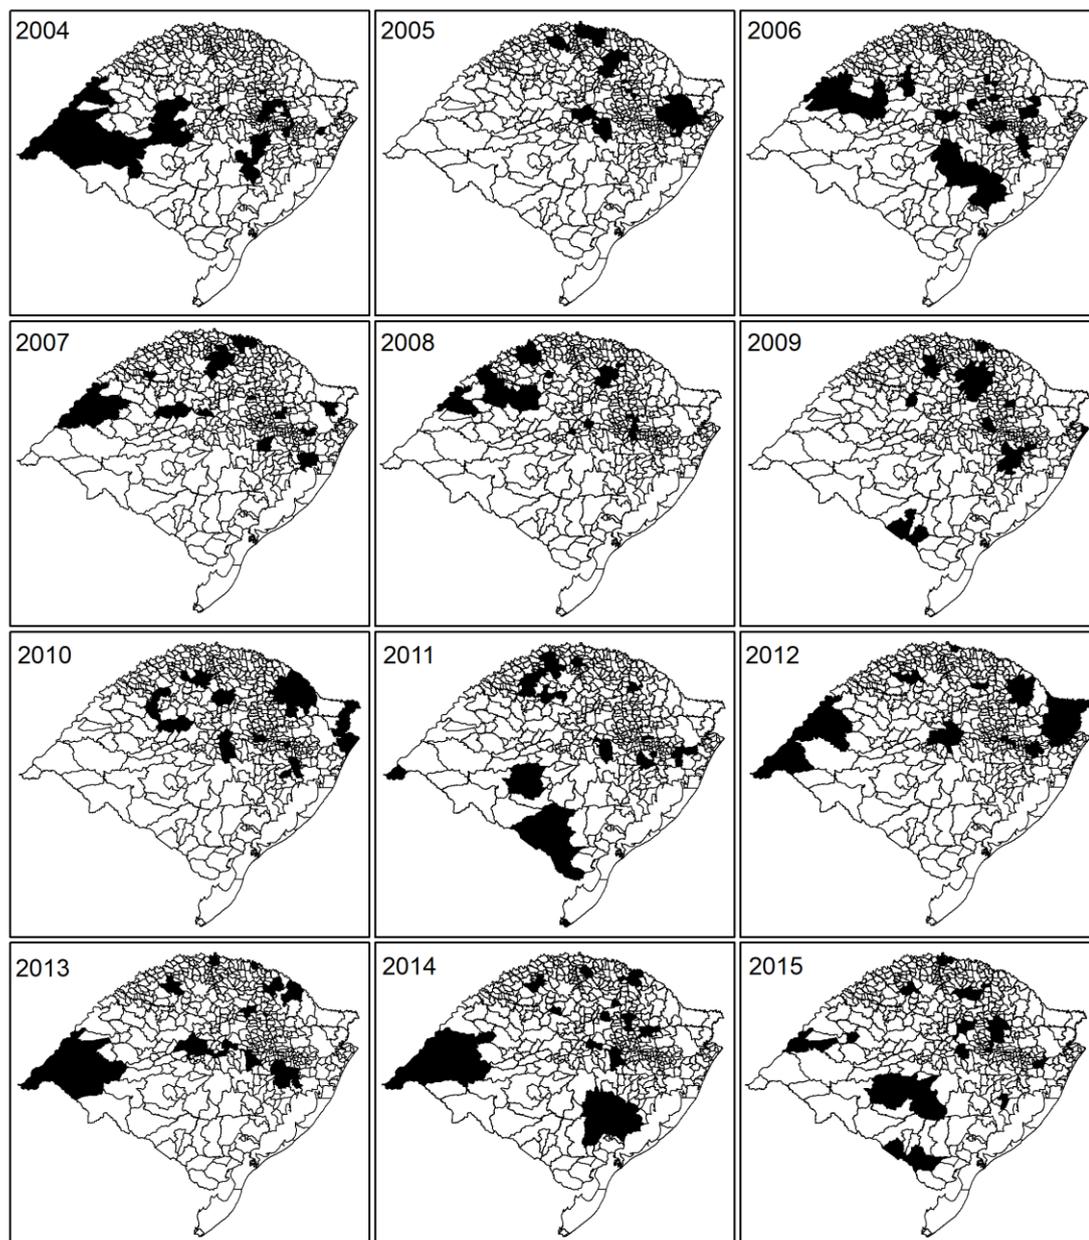


Figura D1 – Correlações lineares significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 5% (25) e *kernel* Biquadrado. A saber: significativo (1, em preto) e não significativo (0, em branco).

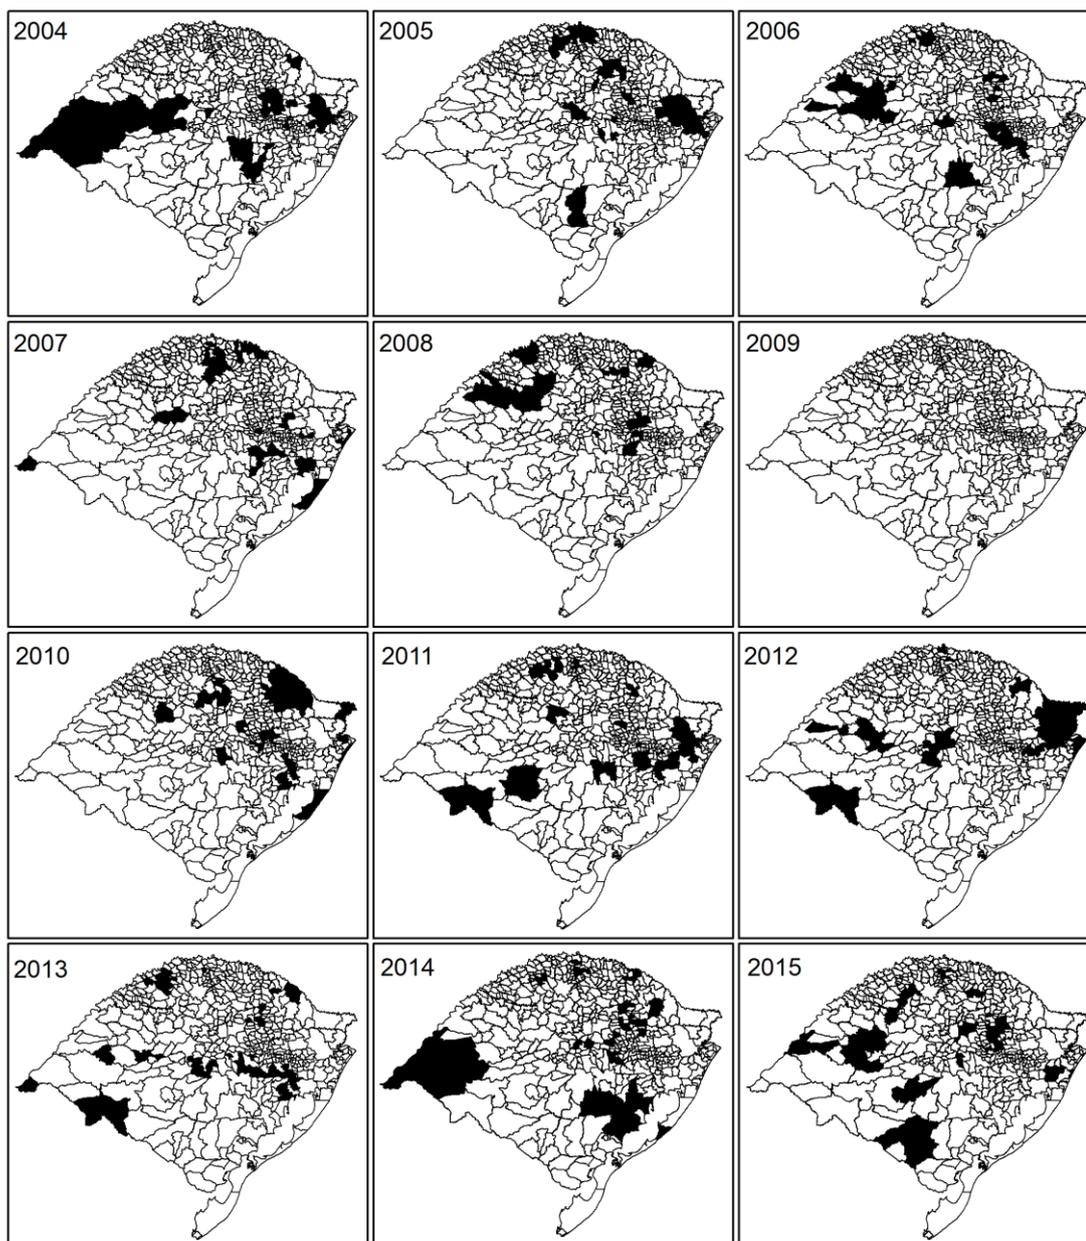


Figura D2 – Correlações lineares significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 5% (25) e *kernel Boxcar*. A saber: significativo (1, em preto) e não significativo (0, em branco).

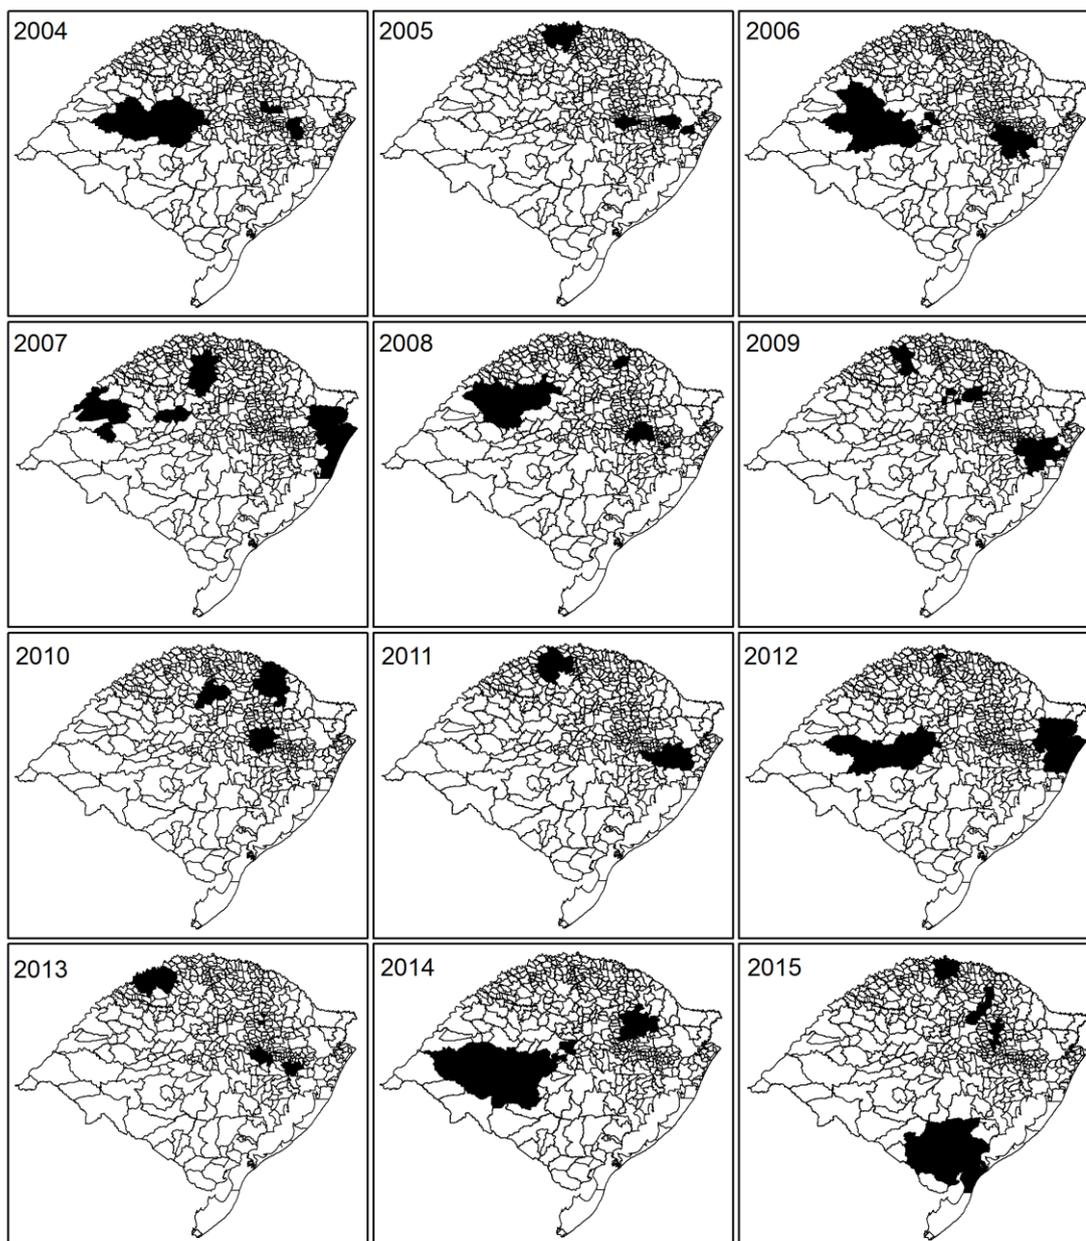


Figura D3 – Correlações lineares significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 5% (25) e *kernel* Gaussiano. A saber: significativo (1, em preto) e não significativo (0, em branco).

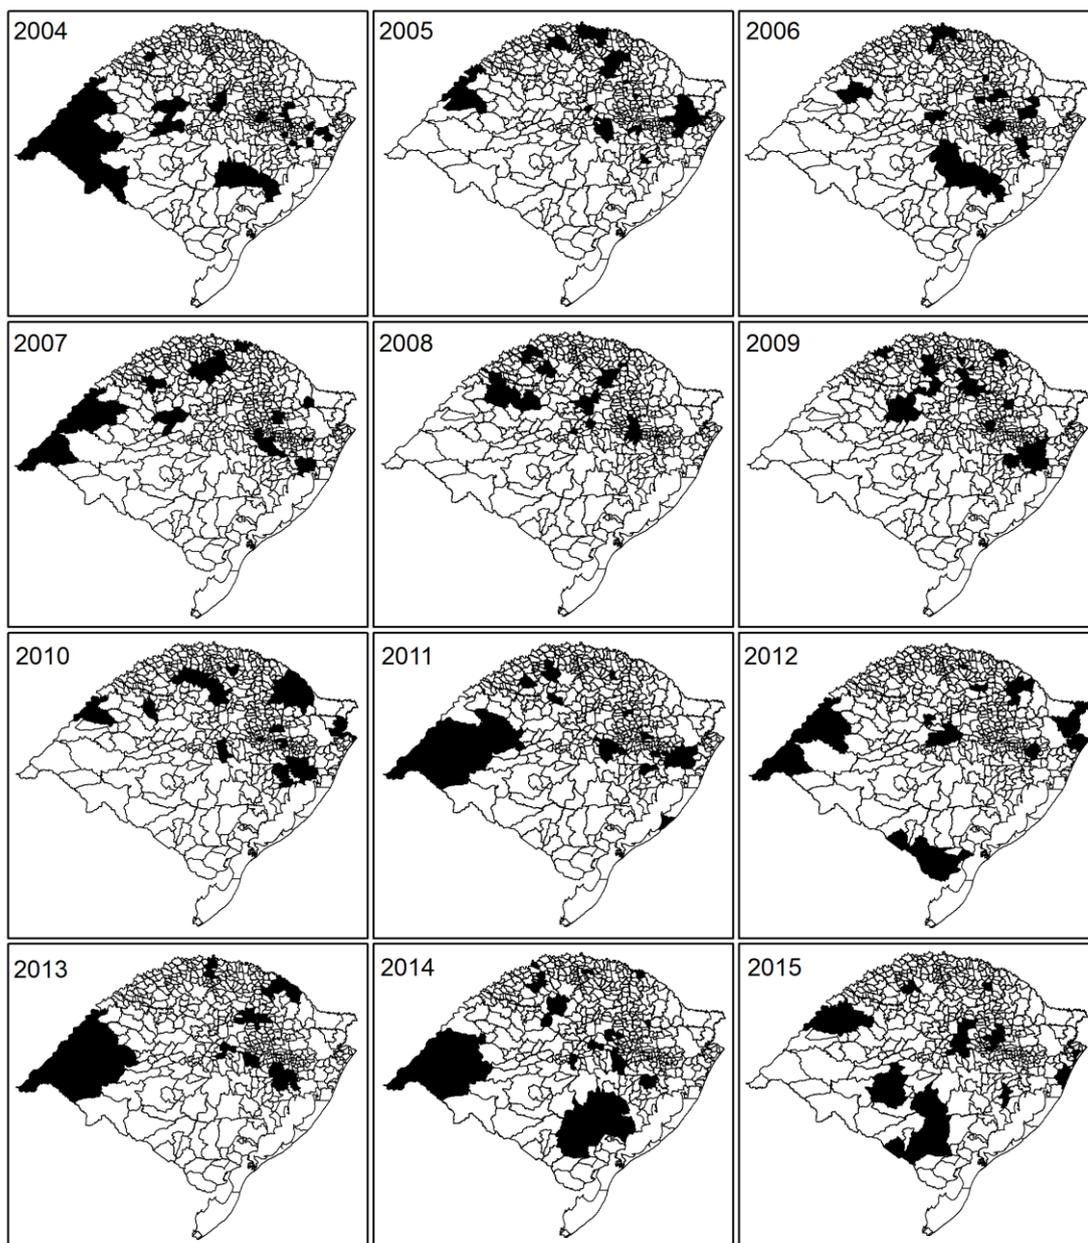


Figura D4 – Correlações robustas significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 5% (25) e *kernel* Biquadrado. A saber: significativo (1, em preto) e não significativo (0, em branco).

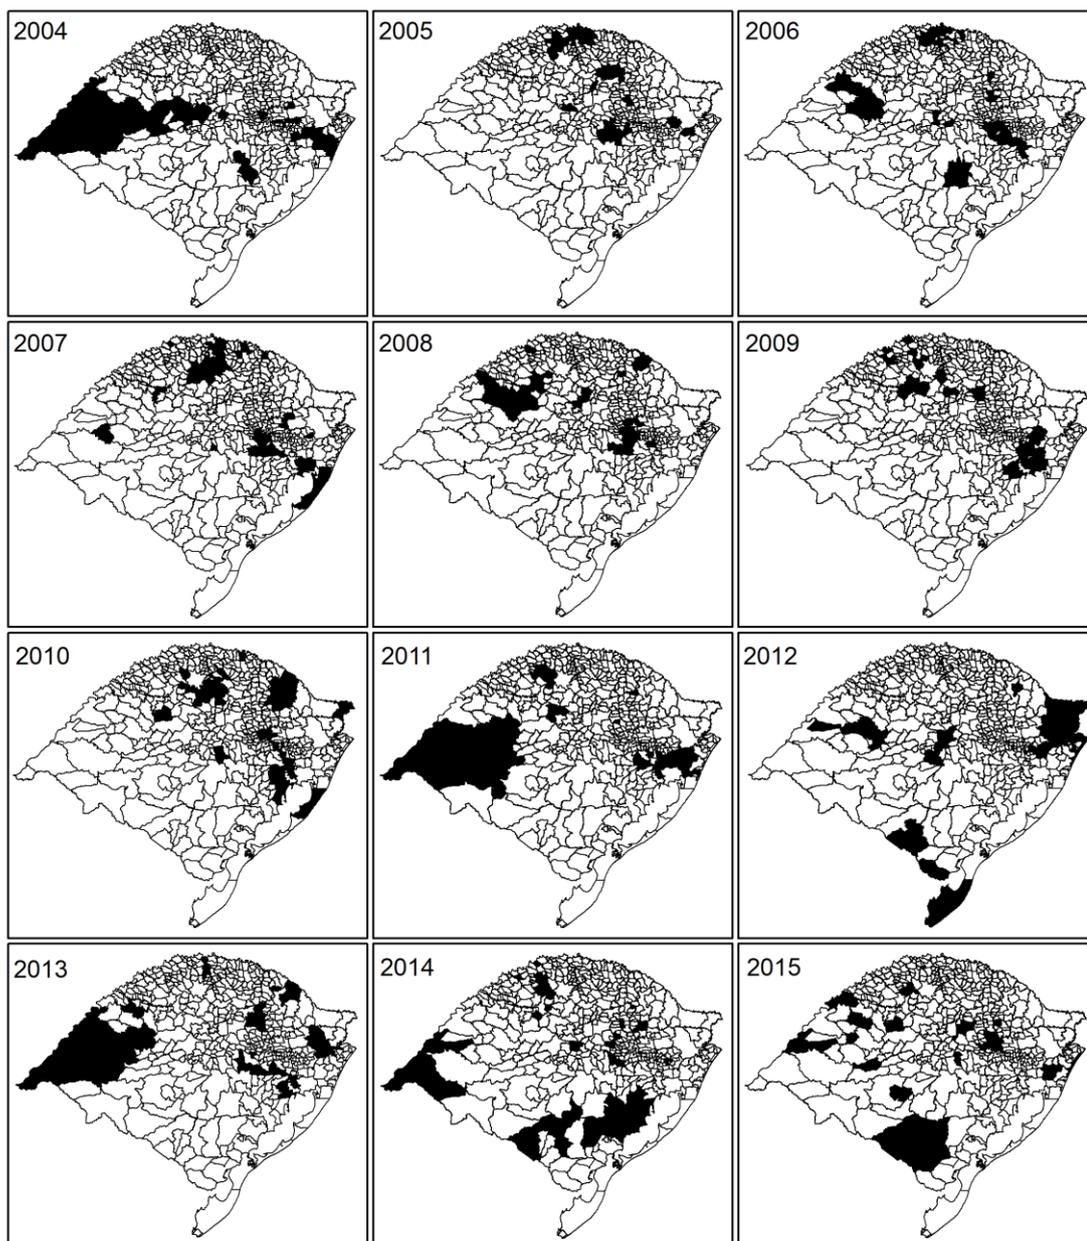


Figura D5 – Correlações robustas significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 5% (25) e *kernel Boxcar*. A saber: significativo (1, em preto) e não significativo (0, em branco).

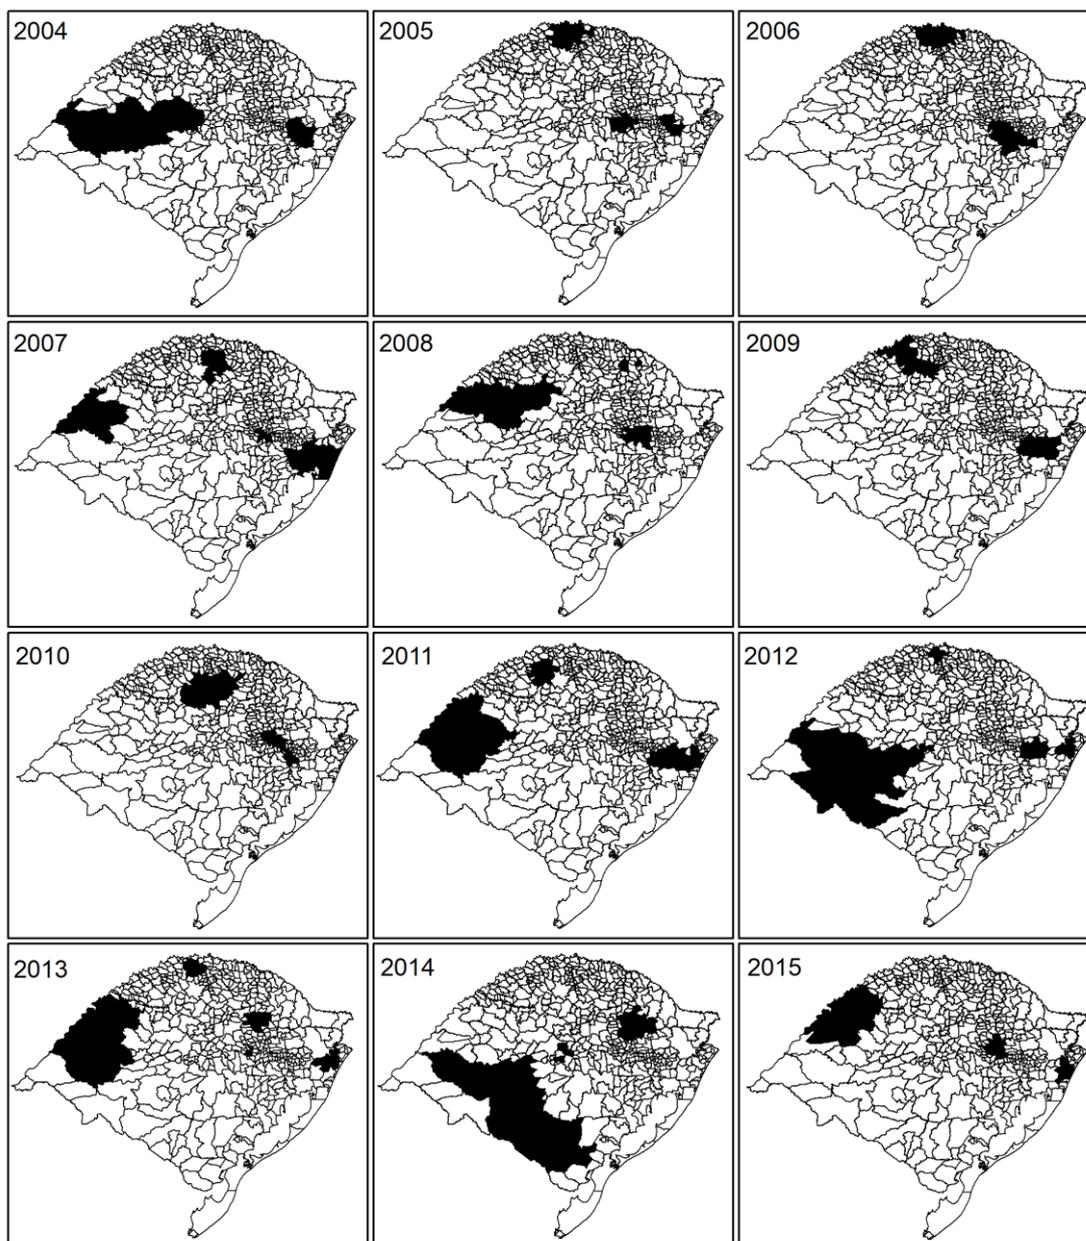


Figura D6 – Correlações robustas significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 5% (25) e *kernel* Gaussiano. A saber: significativo (1, em preto) e não significativo (0, em branco).

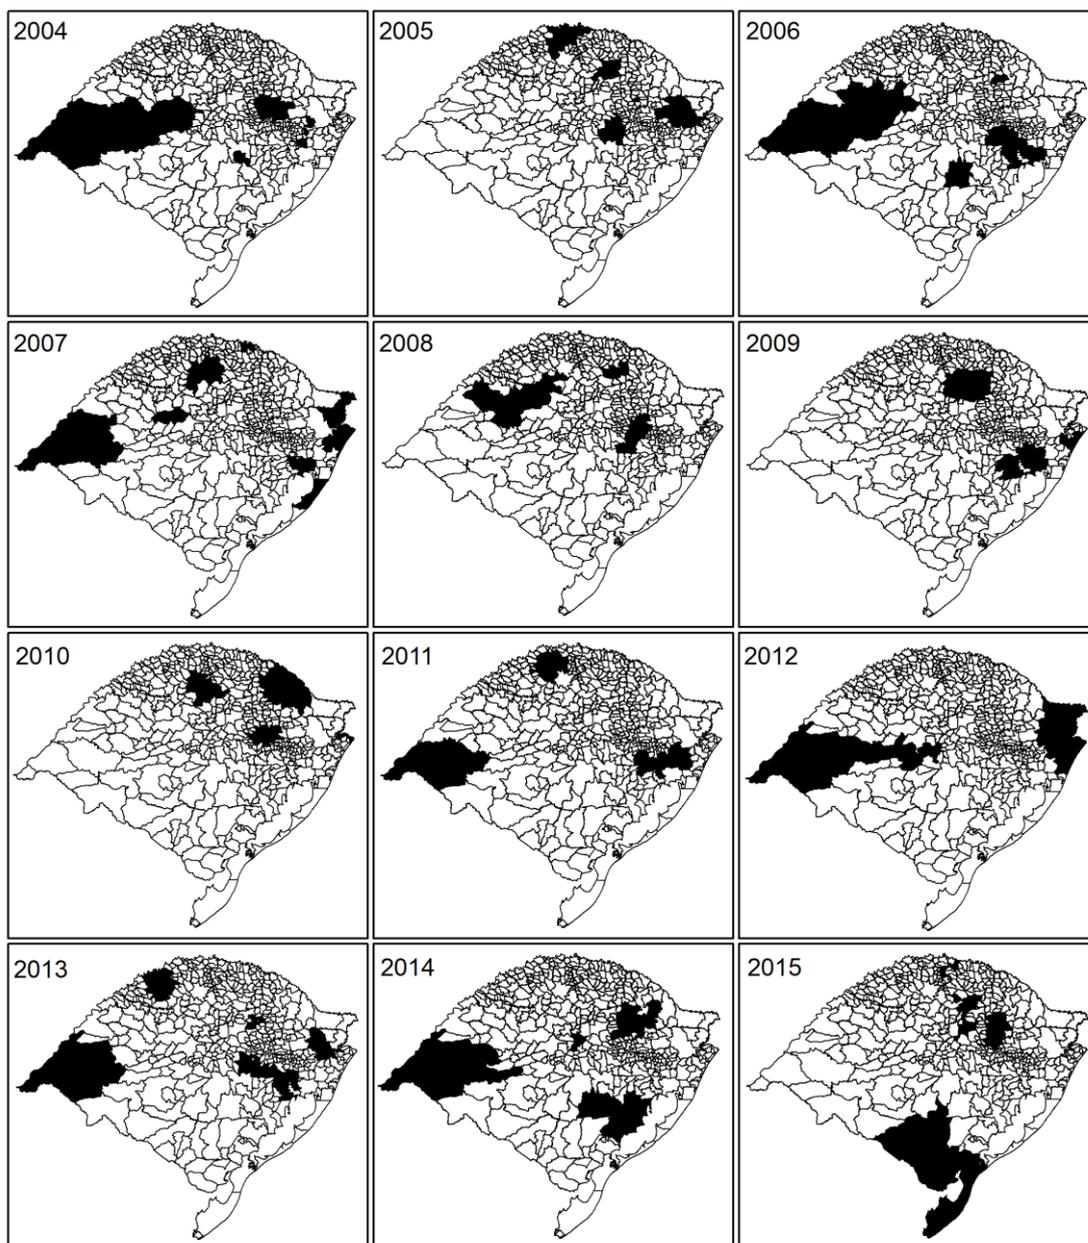


Figura D7 – Correlações lineares significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 15% (75) e *kernel* Biquadrado. A saber: significativo (1, em preto) e não significativo (0, em branco).

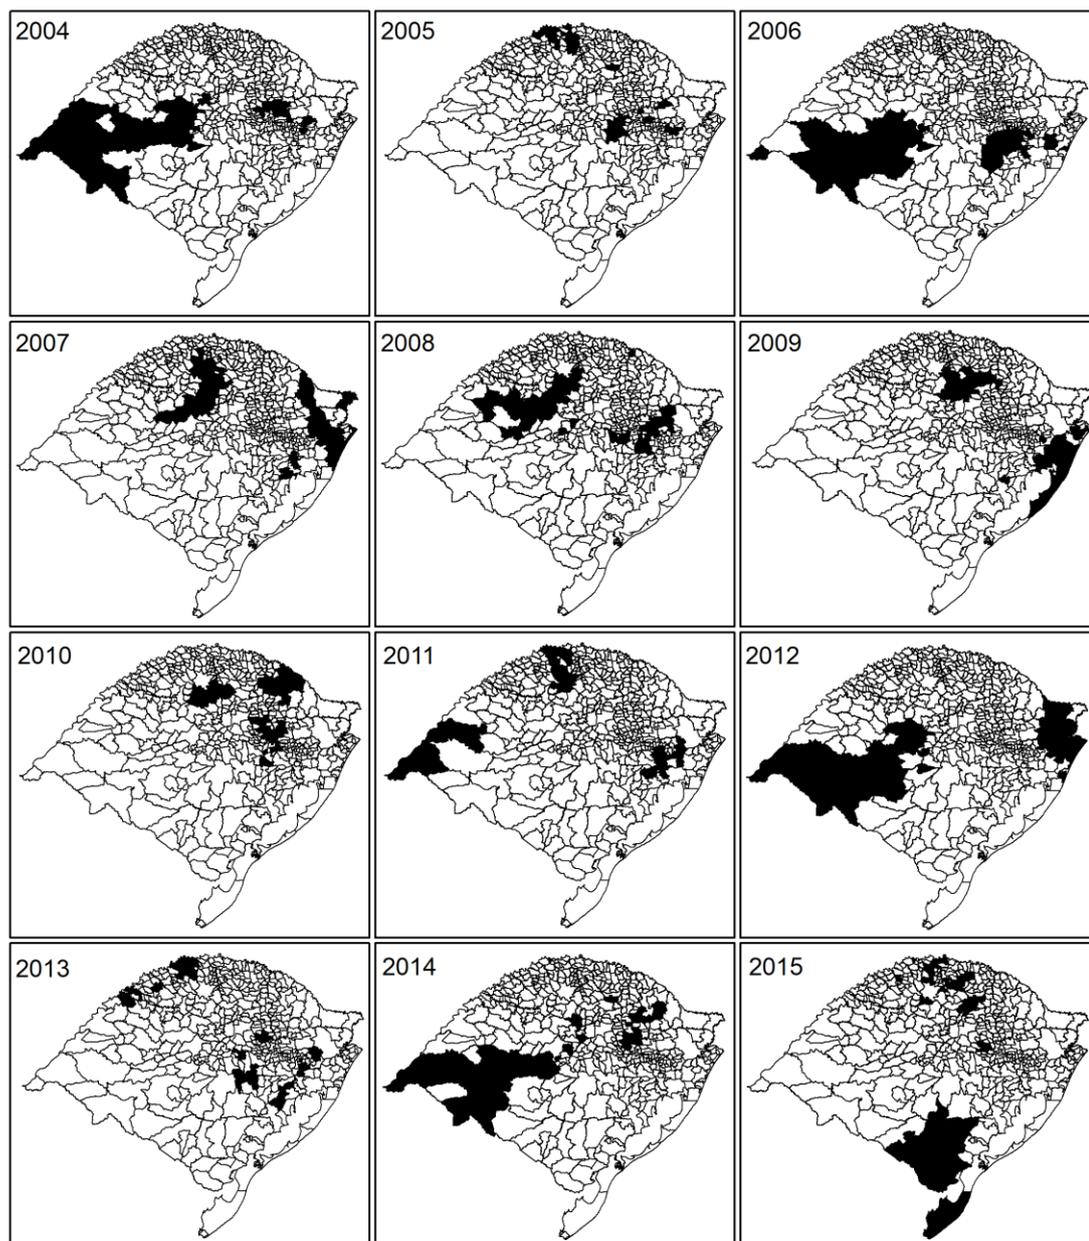


Figura D8 – Correlações lineares significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 15% (75) e *kernel Boxcar*. A saber: significativo (1, em preto) e não significativo (0, em branco).

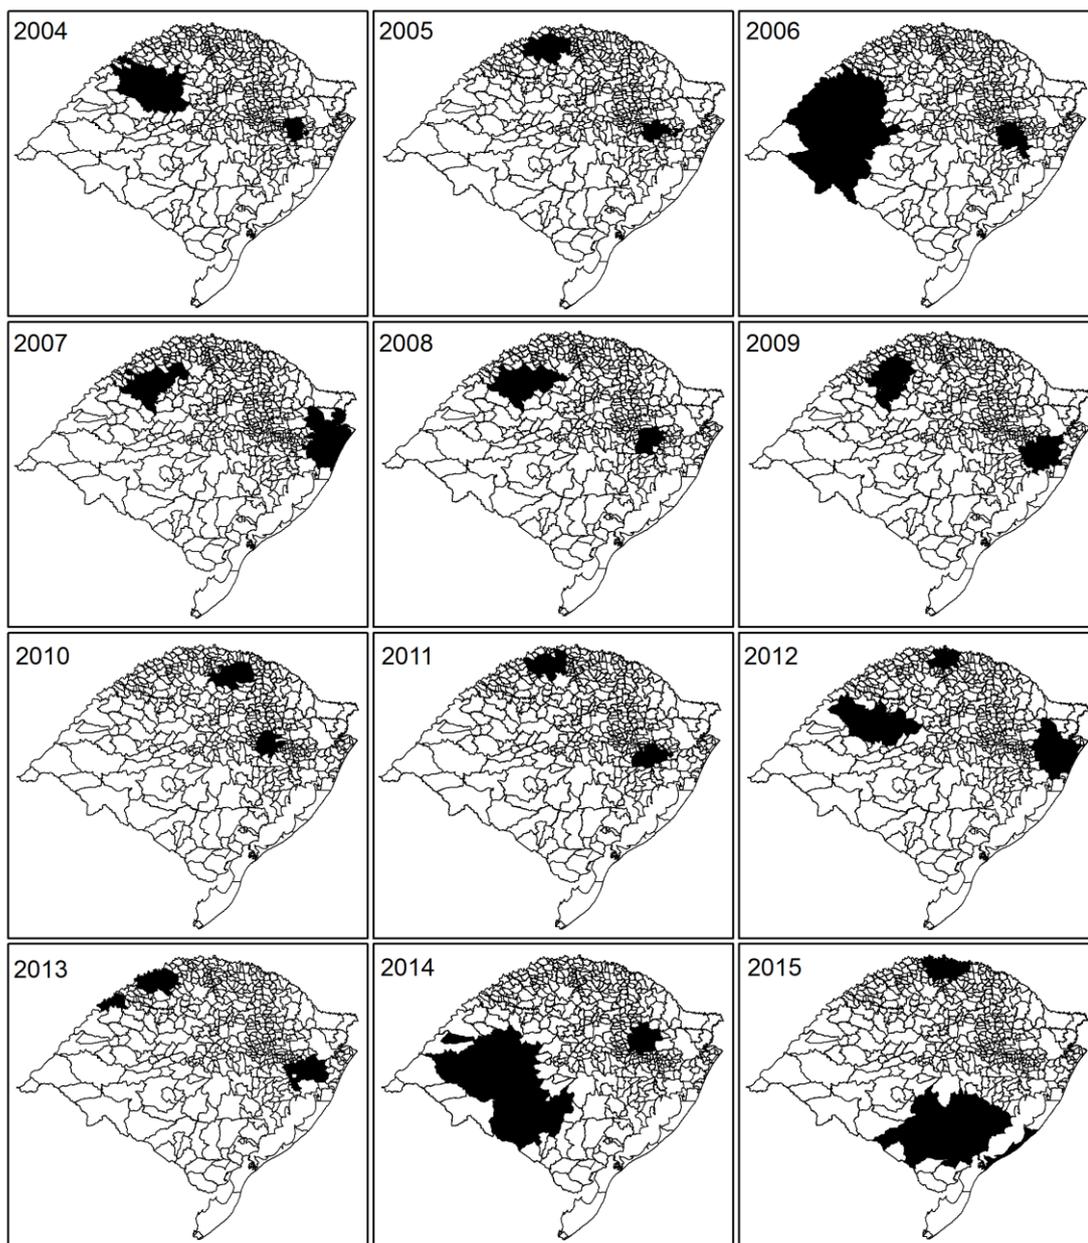


Figura D9 – Correlações lineares significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 15% (75) e *kernel* Gaussiano. A saber: significativo (1, em preto) e não significativo (0, em branco).

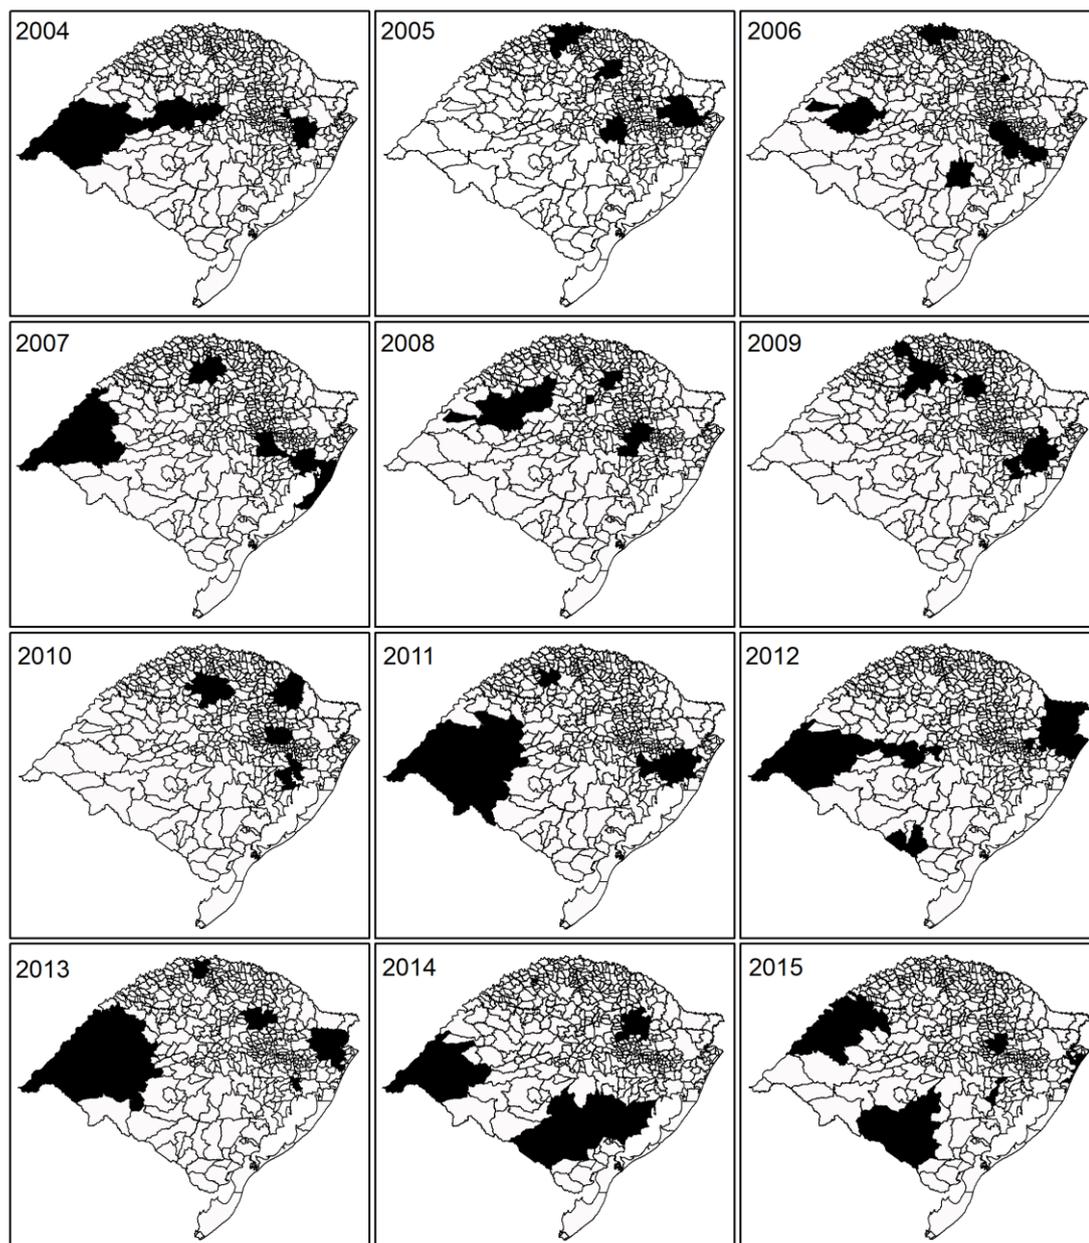


Figura D10 – Correlações robustas significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 15% (75) e *kernel* Biquadrado. A saber: significativo (1, em preto) e não significativo (0, em branco).

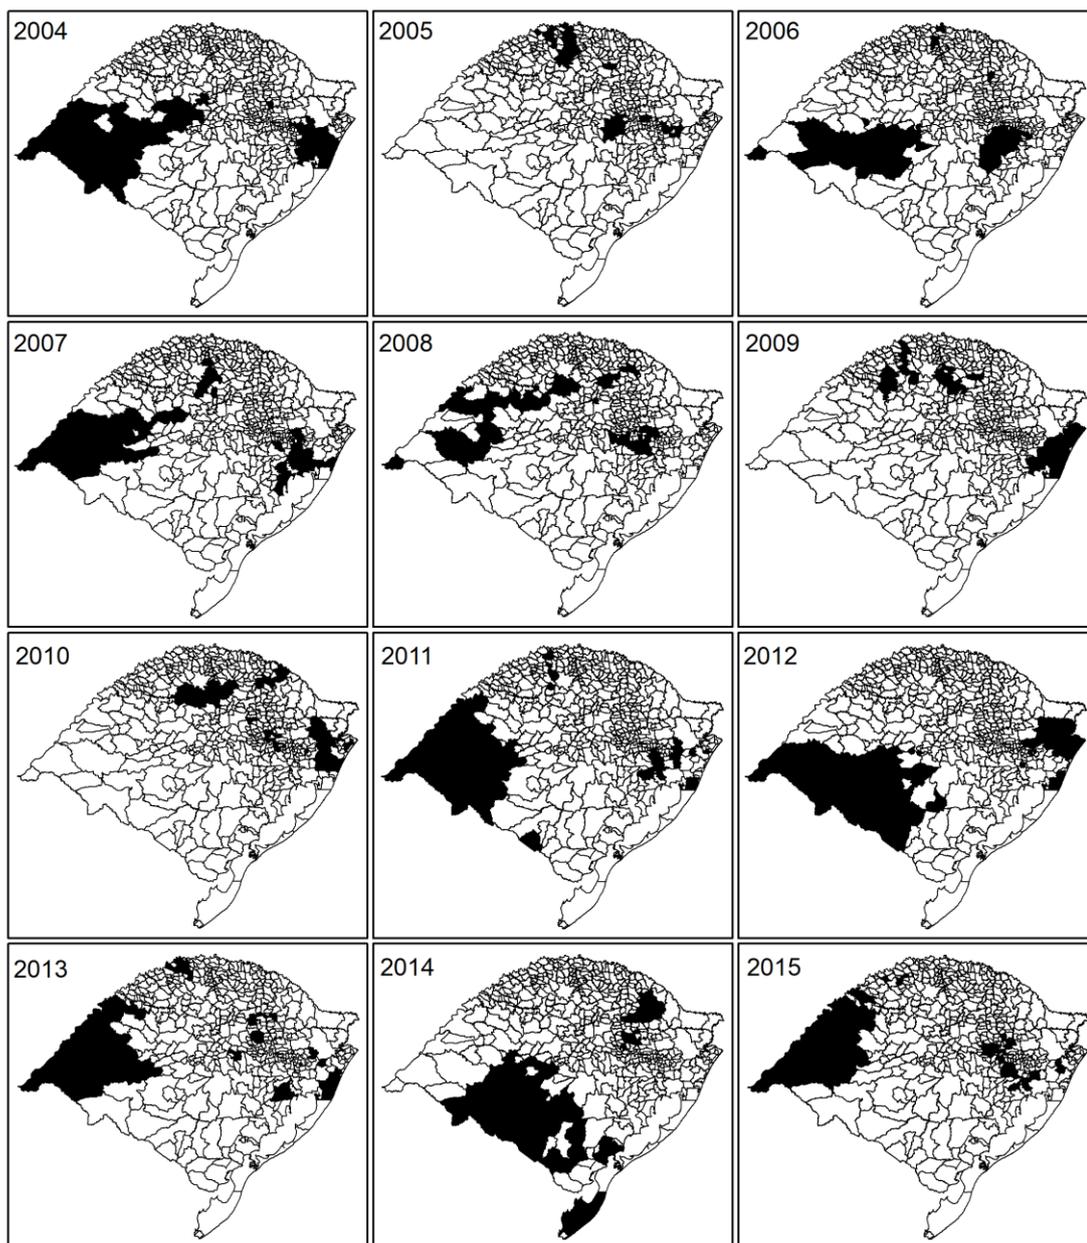


Figura D11 – Correlações robustas significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 15% (75) e *kernel Boxcar*. A saber: significativo (1, em preto) e não significativo (0, em branco).

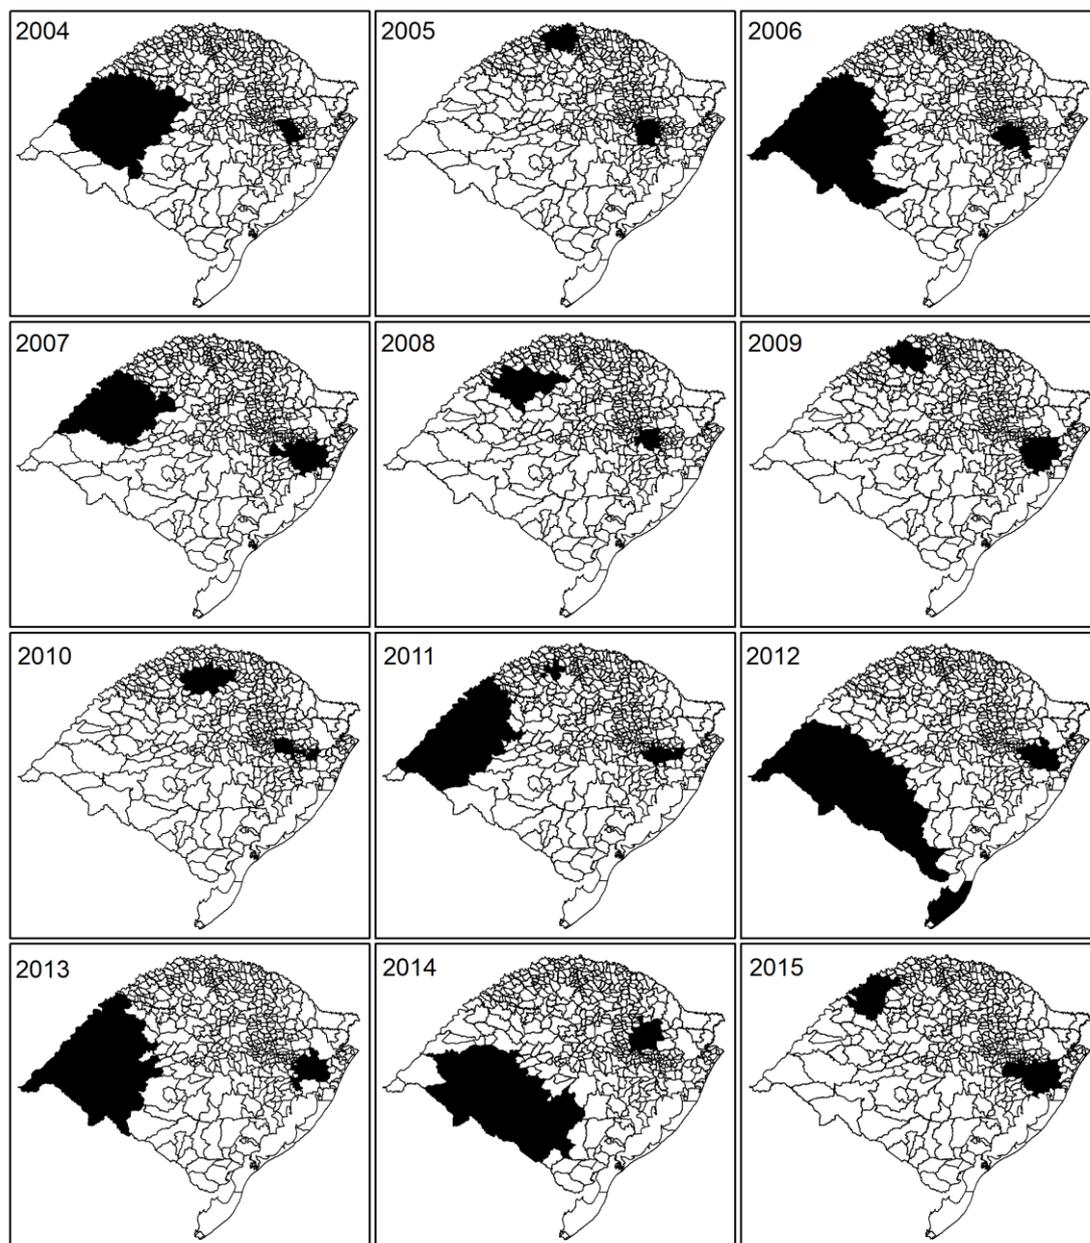


Figura D12 – Correlações robustas significativas ($\alpha = 0,1$) no teste de Monte Carlo entre cPIB e o cVPA com largura de banda igual a 15% (75) e *kernel* Gaussiano. A saber: significativo (1, em preto) e não significativo (0, em branco).

Apêndice E - Resíduos da regressão entre cPIB e cVPA no Estado do Rio Grande do Sul

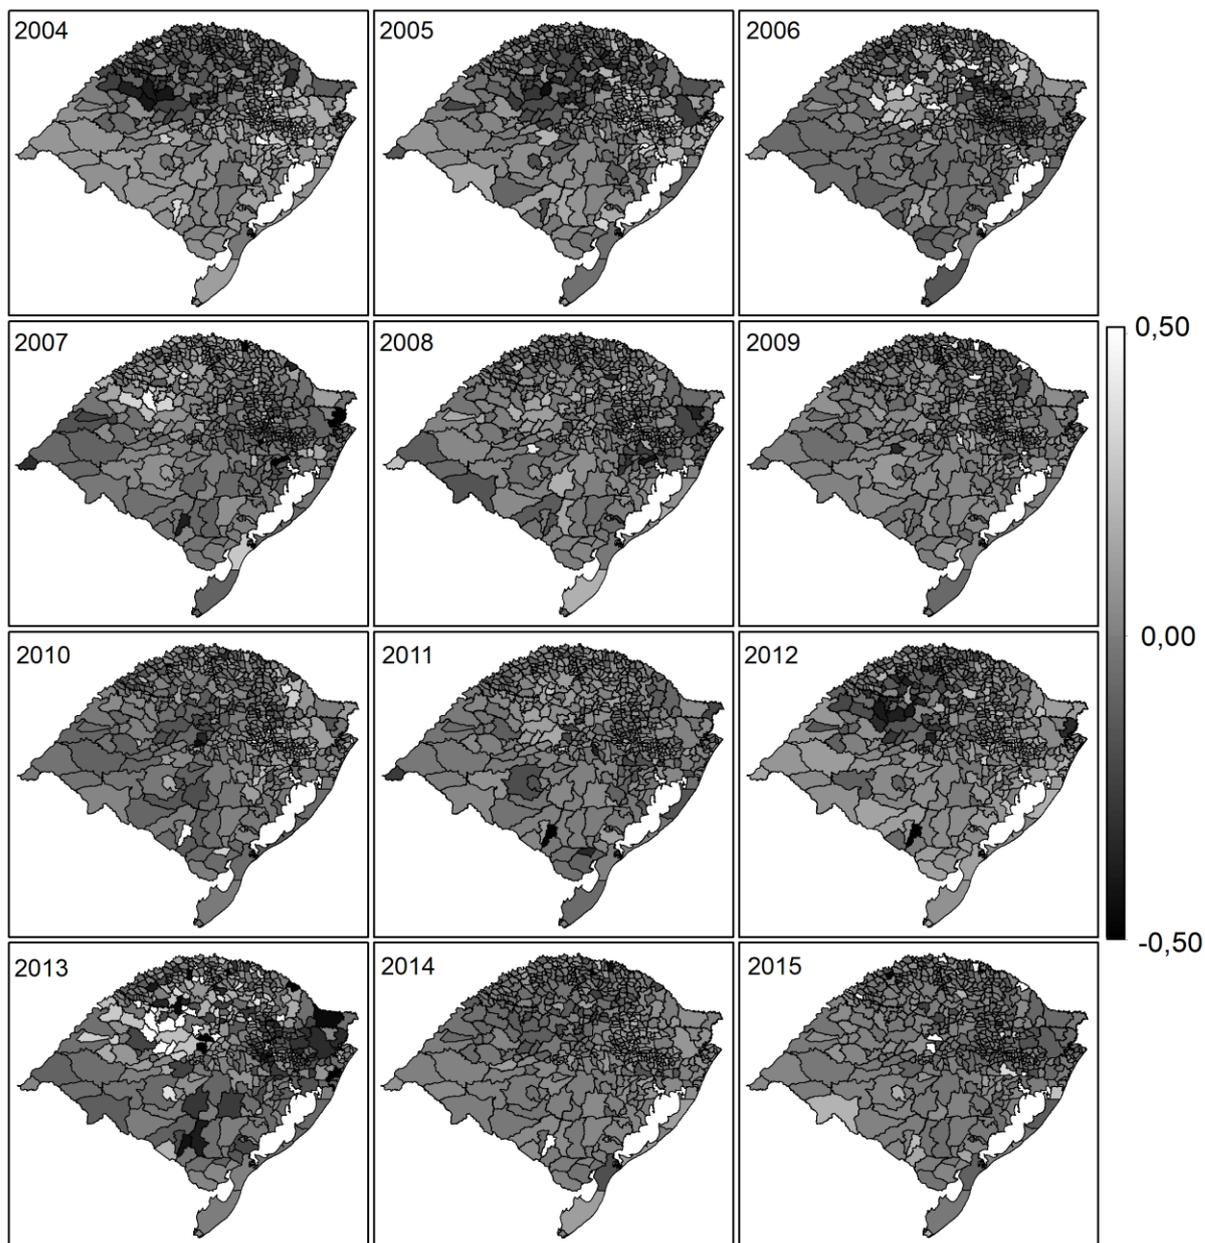


Figura E1 – Resíduos da regressão entre cPIB e o cVPA a partir de modelos de regressão global (RG). Escala da figura truncada em 0,5 e -0,5.

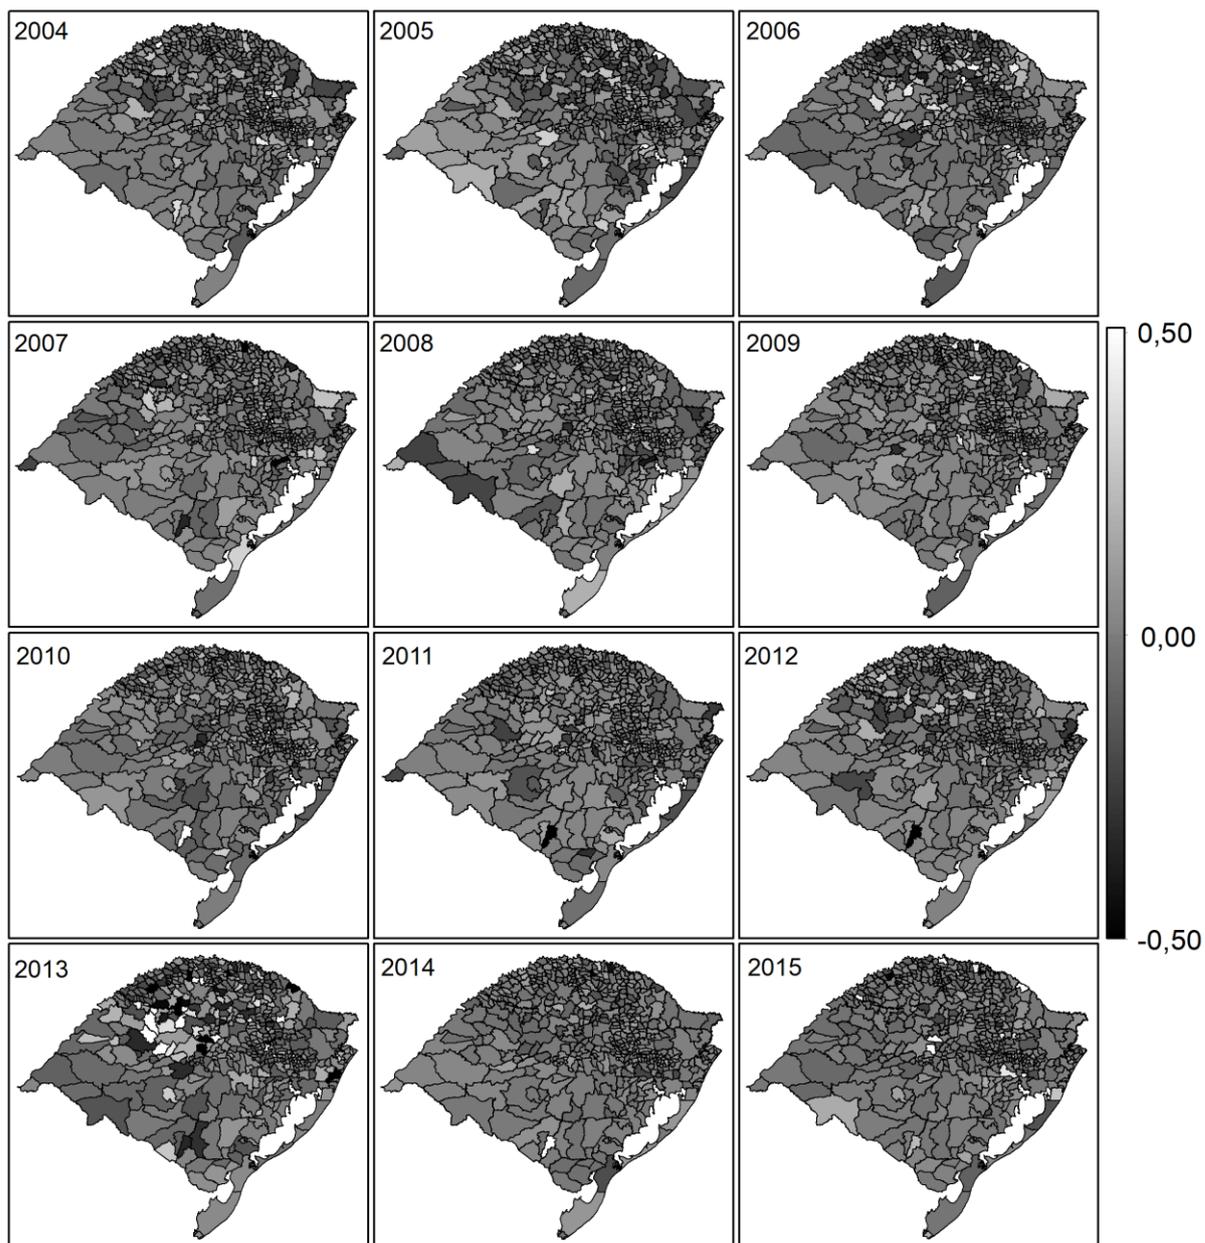


Figura E2 – Resíduos da regressão entre cPIB e o cVPA a partir de modelos de regressão geograficamente ponderados (GWR). Escala da figura truncada em 0,5 e -0,5.