

Análise da Distribuição Territorial da Sojicultura no Brasil: 1991-2003

Murilo Corrêa de Souza

- Mestrando em Economia Aplicada – Faculdade de Economia e Administração (FEA)/Universidade Federal de Juiz de Fora (UFJF).

Fernando Salgueiro Perobelli

- Doutor em Economia – Faculdade de Economia e Administração (FEA)/Universidade de São Paulo (USP).
- Bolsista de Produtividade Nível II do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).
- Coordenador do Mestrado em Economia Aplicada FEA/UFJF.

Resumo

Tem por objetivo central analisar a distribuição espacial da soja para as 558 microrregiões brasileiras no período 1991-2003. Podem-se apontar como objetivos secundários: a) analisar a evolução temporal da dinâmica espacial; b) identificar a formação de cluster; c) classificar a base produtiva das microrregiões; d) verificar a incidência de convergência do Quociente Locacional da soja, ou seja, testar se a produção de soja está ficando distribuída de forma mais homogênea no país. Para atingir o objetivo delineado neste trabalho, será implementada: a) uma Análise Exploratória de Dados Espaciais, que serve para identificar a formação de clusters e a evolução temporal da dinâmica espacial; b) uma análise de convergência, que visa a inferir se as microrregiões de menor produção de soja estão tendo sua produção elevada de forma mais acelerada que as produtoras de grande escala ou vice-versa. O trabalho permite verificar que: a) a produção de soja não é distribuída de forma homogênea por todo o território nacional; b) há certo espraiamento da cultura no período recente (cluster da região Nordeste); c) a taxa de convergência nacional é menor que as taxas de convergências regionais; d) a região que apresenta maior taxa de convergência é o cluster formado pelas unidades da Federação produtoras localizadas nas regiões Norte e Nordeste.

Palavras-chave:

Desenvolvimento Territorial; Análise Espacial; Convergência; Economia Agrícola; Complexo da Soja.

1 – INTRODUÇÃO

O agronegócio brasileiro é responsável por 33% do Produto Interno Bruto (PIB), 42% das exportações e 37% dos empregos brasileiros. Dentre os produtos do agronegócio, destaca-se o complexo da soja, que é o principal grão brasileiro e segundo maior produtor mundial. (BRASIL, 2005).

A soja é uma leguminosa cultivada pelos chineses há cerca de cinco mil anos e há três mil anos se espalhou pela Ásia, onde começou a ser utilizada como alimento. No Brasil, o grão chegou com os primeiros imigrantes japoneses, em 1908, sendo introduzida oficialmente no Rio Grande do Sul, em 1914. Sua expansão aconteceu nos anos de 1970, com o interesse crescente da indústria de óleo e a demanda do mercado internacional. (ALVIM, 2003).

A produção brasileira de soja iniciou-se na década de 1930, basicamente com a finalidade de atender uma demanda nacional relacionada às necessidades alimentícias da suinocultura, mas já nos anos de 1970 o país se destacava pela produção da leguminosa, embora tenha sido na década de 1990 que os efeitos do avanço em pesquisa e tecnologia de produção se fizeram sentir melhor.

A partir de 1992, a sojicultura se consolida e as boas colheitas propiciaram uma considerável recuperação da produção e produtividade no cultivo da soja. A ação conjunta do crescimento na produção interna e da expansão da demanda mundial de grãos resultou num desempenho significativamente positivo da sojicultura brasileira voltada ao mercado externo. De 1995 em diante, com exceção da safra 1998/1999, a produção de soja vem crescendo devido a vários fatores, embora tenha sido determinante a alta de preços da *commodity* no mercado internacional e a desvalorização do real frente ao dólar.

De modo geral, a década de 1990 ofereceu avanços no conhecimento tecnológico em relação ao cultivo de soja, de maneira mais acentuada no Brasil. Entre 1990 e 2000, a produção mundial de soja teve um aumento de 64 milhões de toneladas. No mesmo período, a produção de soja brasileira teve um aumento de 247%. No que tange à área plantada, pode-se observar que esta apresenta elevação de 119% (1991-

2003). De acordo com Brandão; Rezende e Marques (2005), a área plantada cresceu de forma acentuada por intermédio de conversão de pastagens.

Vale a pena salientar que esta maior expansão foi viabilizada, em parte, pelo aumento da facilidade de aquisição de máquinas e implementos agrícolas por parte dos agricultores, devido ao Programa de Modernização de Frota de Tratores e Máquinas Agrícolas (o Moderfrota).

Outro aspecto relevante em relação à soja é a importância da *commodity* para o resultado da balança comercial brasileira no período recente. No período entre 1991 e 2003, houve uma crescente participação das exportações do complexo da soja tanto em volume quanto em exportações totais do país. Em 1991, o complexo da soja era responsável por 6,42% do total exportado pelo Brasil. Já em 2003, o complexo da soja foi responsável por 10,85% do total exportado.

Devido a sua crescente importância e participação no cenário nacional, o complexo da soja tem sido objeto de estudo de diversos pesquisadores do país. Dentre os estudos, vale destacar: o trabalho realizado por Oliveira e Ferreira Filho (2005), que buscam analisar os impactos da expansão da União Européia no agronegócio da soja no Brasil; Silva et al. (2005), que tinham como objetivo principal estimar a função de produção de soja no Brasil no período de 1994 a 2003, e Carvalho; Silva e Ghilardi (2005), que analisam a competitividade da soja e sua geração de divisas.

O objetivo central deste artigo é analisar a distribuição espacial da soja para as 558 microrregiões brasileiras. Podem-se apontar como objetivos secundários: a) analisar a evolução temporal da dinâmica espacial; b) identificar a formação de *cluster*; c) classificar a base produtiva das microrregiões; e d) verificar a incidência de convergência do QL da soja, afinal a idéia de utilizar esta análise no trabalho é testar se a produção de soja está ficando distribuída de forma mais homogênea no país.

Destarte, para atingir o objetivo delineado neste trabalho, será implementada: a) uma Análise Exploratória de Dados Espaciais (AEDE), que serve

para identificar a formação de *clusters* e a evolução temporal da dinâmica espacial; e b) uma análise de convergência, que visa a inferir se as microrregiões de menor produção de soja estão tendo sua produção elevada de forma mais acelerada que as produtoras de grande escala.

No que tange à utilização da AEDE, em trabalhos para a economia brasileira, é possível citar, dentre outros, o trabalho de Almeida; Haddad e Hewings (2005), que estudam a criminalidade em Minas Gerais, ou seja, analisam a distribuição da incidência de crimes nos 750 municípios do Estado no ano de 1995; o artigo de Perobelli e Haddad (2006), que analisa o comércio inter-regional no Brasil, mostrando sua distribuição espacial para os 27 Estados brasileiros no período de 1985-1996, e o trabalho de Gonçalves (2005), que estuda a distribuição das inovações em microrregiões brasileiras.

Dentre os trabalhos de convergência, aplicados em distintas áreas, é possível citar: a) convergência da renda *per capita* entre Estados brasileiros no período de 1970 a 1995 (MAGALHÃES; HEWINGS; AZZONI, 2000); b) convergência do setor produtivo europeu de 1975 a 2000 (LE GALLO; ERTHUR, 2003); c) convergência da produtividade para regiões espanholas de 1980 a 1996 (DALL'ERBA, 2004) e d) convergência de produtividade da agricultura brasileira (ALMEIDA; PEROBELLI; FERREIRA, 2006). Assim sendo, este trabalho constitui mais uma aplicação destes métodos para questões ainda pouco exploradas pela literatura.

O artigo está dividido em quatro seções, inclusive esta, de caráter introdutório. A seção posterior apresenta uma breve discussão sobre convergência e econometria espacial. A terceira seção trata do banco de dados e da metodologia utilizada. A quarta seção apresenta os resultados da análise exploratória espacial (AEDE), e os resultados da econometria espacial. Na quinta seção são apresentadas as considerações finais.

2 – CONVERGÊNCIA E ECONOMETRIA ESPACIAL: UMA BREVE APRESENTAÇÃO

De acordo com Lopes (2004, p. 1), “a convergência é um processo em que uma mesma variável

(por exemplo, renda *per capita*) apresenta diferentes valores entre países, regiões ou estados, mas essa diferença se reduz ao longo do tempo, indicando que a desigualdade diminui”.

Baumol (1986) buscou analisar a existência de convergência de 1870 a 1979 entre 16 países industrializados, procurando verificar a existência de crescimento mais rápido dos países (regiões) mais pobres do que os países (regiões) ricos. A forma funcional apresentada por Baumol (1986) foi:

$$\ln[(Y/N)_{i,t}] - \ln[(Y/N)_{i,t-1}] = \alpha + \beta \ln[(Y/N)_{i,t-1}] + \varepsilon_i \quad (1)$$

onde $\ln(Y/N)$ é o logaritmo da renda *per capita*, ε é o termo de erro e i é o indexador para os diversos países.

De acordo com Baumol (1986), para que haja convergência, β será negativo, ou seja, países que possuírem renda inicial maior terão taxas de crescimento de renda menores.

Em outros termos, Baumol (1986) busca mostrar que ao longo do tempo, as rendas entre os países tenderiam a se igualar.

A exemplo do trabalho de Baumol (1986), o presente artigo tem por objetivo averiguar a existência de convergência. Vale destacar que este trabalho irá adaptar a idéia apresentada por Baumol (1986) para entender o comportamento da produção de soja no país. Ou seja, buscar-se-á verificar se microrregiões com baixa produção de soja (mensuradas pelo QL) estão crescendo de forma mais acentuada que as microrregiões que produzem em maior escala (mensuradas através do QL). O trabalho utiliza a análise de convergência no trabalho para testar se a produção de soja está distribuída de forma mais homogênea no país.

Para realizar esta análise, far-se-á uso de econometria espacial¹, isto, pois segundo Quah (1996),

1 Segundo Anselin (1999, p. 7), “econometria espacial é um subcampo da econometria que lida com as complicações causadas pela interação espacial (autocorrelação espacial) e pela estrutura espacial (heterogeneidade espacial) em modelos de regressão para dados na forma de seção cruzada e painel de dados”.

a maioria dos estudos sobre convergência utilizou dados regionais, mas a grande parte deles tratava as unidades regionais como unidades isoladas, ou seja, não considerava a interação com seu entorno. Ainda de acordo com Rey e Montouri (1999), o desenvolvimento de ferramentas de análise exploratória de dados espaciais permitiu uma nova percepção da dinâmica geográfica dos padrões de crescimento (*e.g.* renda), no tempo.

A econometria espacial difere da econometria convencional por incorporar na modelagem o padrão da interação socioeconômica entre os agentes em um sistema, assim como as características da estrutura desse sistema no espaço. (ANSELIN, 1988; ANSELIN; BERA, 1998).

O primeiro efeito refere-se à heterogeneidade espacial. Fenômenos que ocorrem no espaço não apresentam estabilidade estrutural. Em termos intuitivos, a heterogeneidade espacial manifesta-se quando ocorre instabilidade estrutural no espaço, fazendo que haja diferentes respostas, dependendo da localidade ou da escala espacial. Tal instabilidade pode ser identificada na forma de coeficientes variáveis, de variância não-constante ou, ainda, de formas funcionais diferentes para determinados subconjuntos de dados. Nesse caso, a consequência prática é a inadequação de se ajustar um mesmo modelo para todo o conjunto de dados.

O segundo efeito espacial refere-se à dependência espacial dada pela interação dos agentes no espaço. De forma geral, todo processo que se dá no espaço está sujeito à chamada Lei de Tobler², também conhecida como a Primeira Lei da Geografia, cujo enunciado pode ser estabelecido da seguinte forma: “Tudo depende de todo o restante, porém o que está mais próximo depende mais”. Com isto, a Lei de Tobler destaca o papel essencial da proximidade para o estabelecimento da interação espacial entre os fenômenos.

Faz-se necessário salientar que a agricultura é muito sensível a efeitos espaciais. As culturas agrí-

colas se desenvolvem de forma heterogênea através do espaço, e isto se deve ao fato de depender de diferentes técnicas de produção, clima, topografia e condições de solo.

Por outro lado, os efeitos de interdependência nas diferentes regiões produtoras manifestam-se de diversas formas, tais como ordenação geográfica dos dados, difusão espacial de certos fenômenos que influenciam os vizinhos, processos de competição espacial no âmbito da expansão da fronteira agrícola ou na formação de cinturões agrícolas.

3 – BASE DE DADOS E METODOLOGIA

Os dados analisados neste trabalho foram obtidos junto ao Sistema Instituto Brasileiro de Geografia e Estatística (IBGE) de Recuperação Automática (SIDRA) – Pesquisa Agrícola Municipal e foram distribuídos por 558 microrregiões no período de 1991 a 2003. Como os dados para 1991 - 2000 estão despadronizados, foi necessário fazer a conversão para toneladas. Para dar maior consistência ao modelo, foram retiradas da análise todas as microrregiões cuja produção fosse igual a zero.

Este trabalho tem por objetivo analisar a distribuição espacial da soja. Em outras palavras, tenta identificar algum tipo de regularidade espacial (*clusters*). Para tal será utilizada a Análise Exploratória dos Dados Espaciais (AEDE) que está baseada nos aspectos espaciais da base de dados, ou seja, trata diretamente de questões como dependência espacial (*e.g.* associação espacial) e heterogeneidade espacial, e análise de convergência, buscando identificar se o quociente locacional da produção de soja está se tornando mais homogêneo no período analisado.

3.1 – Quociente Locacional

É importante ressaltar que serão utilizados na análise variáveis relativas, pois variáveis absolutas podem levar a enganos. Logo, para implementar a análise de dados espaciais foram construídos indicadores de concentração da produção de soja para cada uma das 558 microrregiões do Brasil. O indicador de concentração utilizado neste artigo é o

² *Everything is related to everything else but nearby things are more related than distant things.* (TOBLER, 1970, p. 236).

Quociente Locacional (QL) que, segundo Haddad et al. (1985), é medido da seguinte maneira:

$$QL = \frac{E_j^i / E_j}{E_{BR}^i / E_{BR}} \quad (2)$$

Onde: E_j^i = produção da *commodity* i na região j ; E_j = produção total na região j ; E_{BR}^i = produção da *commodity* i no Brasil; E_{BR} = produção total no Brasil.

Segundo Haddad et al. (1985, p. 232), “se o valor do quociente for maior do que 1, isto significa que a região é relativamente mais importante, no contexto nacional, em termos do setor, do que em termos gerais de todos os setores”. Cabe ressaltar que este indicador tem sido utilizado, em trabalhos exploratórios, para mensurar a atividade exportadora da região. Em outras palavras, um quociente locacional acima da unidade poderia indicar que a atividade inerente ao setor na região em análise é uma atividade *básica*, ou seja, voltada para a exportação. Por outro lado, um quociente menor do que a unidade representaria uma atividade *não-básica*, ou seja, a produção setorial seria voltada para a própria região.

3.2 – Matriz de Pesos Espaciais

Para realizar tanto a Análise Exploratória de Dados Espaciais (AEDE), como para a implementação da econometria espacial, faz-se necessária a definição de uma matriz de pesos espaciais (W). A determinação desta matriz é de extrema importância nestes casos, já que todos os passos, assim como seus respectivos resultados, dependerão de sua determinação.

Para a realização deste trabalho será utilizada a matriz de k vizinhos mais próximos, que mede a vizinhança baseando-se nas distâncias das mesmas em relação ao ponto central da região analisada. Esta matriz de pesos espaciais apresenta-se da seguinte forma:

$$\begin{cases} w_{ij}(k) = 0 & \text{se } i = j \\ w_{ij}(k) = 1 & \text{se } d_{ij} \leq D_i(k) \text{ e } w_{ij}^*(k) = w_{ij}(k) / \sum_j w_{ij}(k) \text{ para } k = 1, 2, \dots, n \\ w_{ij}(k) = 0 & \text{se } d_{ij} > D_i(k) \end{cases}$$

Onde d_{ij} é a distância, medida pelo grande círculo, entre os centros das regiões i e j . $D_i(k)$ é um valor crítico que define o valor de corte, ou seja, a distância máxima para considerar regiões vizinhas à região i .

Neste estudo, foi utilizado $k=10$ para a análise das 558 microrregiões, além de $k=15$ e $k=20$, a fim de verificar se os resultados obtidos são robustos. Para a análise econométrica dos *clusters*, utilizou-se $k=5$, por se tratar de um número menor de microrregiões, tornando inviável a utilização de $k=10$, pois neste caso, todas as microrregiões dos respectivos *clusters* seriam vizinhas.

3.3 – Autocorrelação Espacial Global

A partir da construção deste indicador para cada uma das 558 microrregiões, é possível implementar a Análise Exploratória de Dados Espaciais (AEDE), com o intuito de descrever a distribuição espacial do setor em análise (*e.g* soja) no país.

Segundo Anselin (1995), para calcular a autocorrelação espacial é usado o I de Moran, que é determinado pela seguinte equação:

$$I_t = \left(\frac{n}{S_o} \right) \left(\frac{z_t' W z_t}{z_t' z_t} \right) \quad t = 1, \dots, n \quad (3)$$

Onde: z_t é o vetor de n observações para o ano t , W é a média ponderada de valores vizinhos e S_o representa a soma de todos os elementos da matriz W . Este indicador representa o grau de associação entre o vetor de valores observados e a média ponderada de valores vizinhos.

Segundo Gonçalves (2005), o I de Moran é capaz de apontar a tendência geral de agrupamento dos dados, mas não é capaz de mostrar a estrutura de correlação espacial em nível regional, sendo necessária a utilização de outros três instrumentos para verificar esta correlação: o diagrama de dispersão de Moran, o Mapa de dispersão de Moran e os Indicadores Locais de Associação Espacial (LISA).

3.4 – Diagrama de Dispersão de Moran

O diagrama de dispersão de Moran apresenta a tendência geral de associação através da reta que mostra como os dados se ajustam entre os

valores defasados espacialmente (Wz) e os valores observados em cada unidade espacial (z), além das tendências locais, representadas por cada ponto no interior do diagrama. (ANSELIN, 1995).

Este diagrama permite também identificar tendências locais que nele são representadas pelos pontos. Através desta análise é possível observar valores discrepantes (*outliers*), que são aqueles que destoam da tendência central, e também pontos de alavancagem (*leverage points*), que são os que influenciam fortemente a tendência central. Caso a reta de regressão possua inclinação positiva, os pontos que estiverem a mais de dois desvios-padrões do centro no quadrante superior direito e no inferior esquerdo serão classificados como pontos de alavancagem.³ (VARGA, 1998).

Este diagrama tem também como vantagem o fato de permitir a identificação de quatro tipos de padrões espaciais diferentes, que irão possibilitar a classificação das associações espaciais entre as microrregiões e seus respectivos vizinhos.

Padrão Alto-Alto (AA), localizado no quadrante superior direito, onde microrregiões de elevado valor da variável estão ligadas a vizinhos que também possuem um elevado valor para esta mesma variável;

Padrão Alto-Baixo (AB) quadrante inferior direito, caracteriza microrregiões que apresentam elevados valores e são circundadas por vizinhos que apresentam baixos valores;

Baixo-Alto (BA) caracteriza microrregiões que apresentam baixos valores e são circundadas por vizinhos que apresentam elevados valores;

Baixo-Baixo (BB) caracteriza microrregiões que apresentam baixos valores e são circundadas por vizinhos que também apresentam baixos valores.

As microrregiões com padrões AA e BB revelam associação espacial positiva, enquanto padrões AB e BA revelam associação espacial negativa.

3 Para identificar estes pontos neste trabalho, será utilizada a distância de Cook.

3.5 – Autocorrelação Espacial Local

Por não fornecer indicações da significância do agrupamento espacial, o diagrama de Moran precisa ser complementado com os indicadores LISA. Por se tratar de um indicador local, a soma deste indicador de todas as microrregiões é proporcional ao indicador de autocorrelação de espaço global. O indicador LISA pode ser encontrado da seguinte forma:

$$I_{i,t} = \frac{(x_{i,t} - \mu_t)}{m_o} \sum_j w_{ij} (x_{j,t} - \mu_t) \text{ com } m_o = \frac{(x_{i,t} - \mu_t)^2}{n} \quad (4)$$

Onde: $I_{i,t}$ é o Moran local para a observação. Caso presente I negativo, equivale dizer que existe concentração espacial negativa, e caso haja I positivo, vale dizer que existe concentração espacial positiva.

Vale ressaltar que para a realização do cálculo dos índices anteriormente citados, será analisada apenas a região produtora da *commodity* em estudo, para não haver a possibilidade de a quantidade de números de zeros diminuir o valor médio e aumentar os agrupamentos de valores altos, já que estas estatísticas são calculadas a partir da soma das diferenças e da média dos valores observados⁴.

3.6 – Econometria Espacial⁵

De acordo com Anselin e Bera (1998), a econometria espacial pode ser definida como o conjunto de técnicas que trabalham com as particularidades causadas pelo espaço em análises estatísticas de modelos de ciência regional.

Essencialmente, esse artifício visa a melhorar os métodos econométricos tradicionais aderindo a estes seus efeitos espaciais diferenciados em dois tipos: dependência espacial, e heterogeneidade espacial.

3.6.1 – Análise de convergência espacial

De acordo com Rey e Montouri (1999), o conceito de β convergência, utilizado neste artigo, pode ser baseado na idéia de que microrregiões

4 Procedimento implementado por Varga (1998) e Gonçalves (2005).

5 Esta seção do trabalho baseia-se na estrutura de apresentação metodológica do trabalho de Almeida; Perobelli e Ferreira (2006).

que possuam um baixo quociente locacional de produção de soja tenham sua produção elevada de forma mais acelerada que as microrregiões que possuam um alto quociente locacional.

Com o intuito de verificar a existência de convergência, inicialmente estimou-se o modelo via mínimos quadrados ordinários (MQO), através do modelo de β convergência dado por:

$$\ln\left(\frac{QL03}{QL91}\right) = \alpha + \beta \ln(QL91) + \varepsilon_i \quad (5)$$

Onde, $\ln (QL03/QL91)$ é o logaritmo natural da razão entre o quociente locacional da produção de soja em 2003 e 1991; $\beta \ln (QL91)$ é o logaritmo natural do quociente locacional da produção de soja em 1991 e ε_i é o termo de erro.

No entanto, Rey e Montouri (1999) admitiram que um modelo de convergência contendo unidades espaciais deveria considerar também os efeitos de dependência espacial, que poderiam resultar do efeito transbordamento.

Com o intuito de melhor identificar a especificação do modelo de β convergência segue-se a proposta feita por Florax; Folmer e Rey (2003), ou seja, inicialmente os autores aconselham que seja seguido o seguinte roteiro:

- 1) Deve-se estimar o modelo clássico de análise de regressão linear por meio de Mínimos Quadrados Ordinários (MQO);
- 2) Testar a hipótese de ausência de autocorrelação espacial buscando identificar defasagem ou erro por meio das estatísticas Multiplicador de Lagrange λ (ML) (erro espacial) e Multiplicador de Lagrange (ML) ρ (defasagem espacial);
- 3) Caso os testes não sejam significantes, a utilização do modelo clássico é mais apropriada. Caso contrário faz-se necessário estender-se ao passo seguinte;
- 4) Caso ambos sejam significantes, estima-se o modelo apontado como o mais significativo de acordo com as versões robustas desses testes, ou seja, Multiplicador de Lagrange Robusto

(MLR) ρ (defasagem espacial) e Multiplicador de Lagrange Robusto (MLR) λ (erro espacial). Assim, caso $MLR \rho > MLR \lambda$ usa-se o modelo com defasagem espacial como o mais apropriado. Caso contrário, $MLR \rho < MLR \lambda$, usa-se o modelo de erro auto-regressivo como o mais apropriado.

Em outras palavras, caso a hipótese de ausência de autocorrelação espacial seja rejeitada, deve-se especificar a equação de β convergência através dos modelos mais freqüentemente adotados nas aplicações de econometria espacial (modelo de erro, modelo de defasagem e modelo regressivo cruzado espacial).

3.6.2 – Modelo de erro espacial

A primeira modificação poderia ser o caso em que o termo de erro ε_i na equação 5 siga um processo espacial auto-regressivo.

$$u_i = \lambda W u_i + \varepsilon_i \quad (6)$$

onde λ é o coeficiente escalar do erro espacial; ε_i é normalmente distribuído, com média zero e variância constante.

A literatura preexistente, no que tange a este tema, considera a dependência espacial nos erros uma espécie de “ruído”. Isto se deve ao fato de o termo “erro” refletir apenas o impacto de uma autocorrelação presente em processos com erros de medida ou em variáveis irrelevantes e, portanto, ausentes do modelo. Seria um fenômeno importante, porém de menor relevância que o encontrado para as variáveis espacialmente auto-regressivas.

Substituindo a equação (6) em (5) tem-se:

$$\ln\left(\frac{QL03}{QL91}\right) = \alpha + \beta \ln(QL91) + (I - \lambda W) \varepsilon_i \quad (7)$$

Observe que a matriz W é a mesma matriz de contigüidade utilizada para o cálculo do I de Moran. Cabe ressaltar que caso $\lambda=0$, não existe autocorrelação espacial do erro, e caso $\lambda \neq 0$, um choque ocorrido em uma unidade geográfica não se espalha somente a seus vizinhos imediatos, mas também

por todas as unidades. Esta forma de dependência espacial pode ser resultante de variáveis não modeladas. (REY; MONTOURI, 1999).

3.6.3 – Modelo de defasagem espacial

A dependência espacial, neste modelo, é considerada como aquela criada pela interação atual entre as unidades espaciais. Neste caso, é adicionada uma defasagem espacial como variável independente na equação original de β convergência. O modelo é especificado da seguinte forma:

$$\ln\left(\frac{QL03}{QL91}\right) = \alpha + \beta \ln(QL91) + \rho W \ln\left(\frac{QL03}{QL91}\right) + \varepsilon_i \quad (8)$$

ρ é o coeficiente de defasagem espacial (escalar).

O elemento novo nesta forma funcional pode ser entendido como uma média dos valores da taxa de crescimento das unidades espaciais vizinhas. Caso $\rho > 0$, existe autocorrelação espacial positiva, levando a crer que o crescimento da vizinhança de uma unidade espacial tenha influência mais positiva que negativa sobre o seu crescimento econômico.

3.6.4 – Modelo regressivo cruzado espacial

Este modelo trata de incluir o efeito *spillover*⁶. No modelo de convergência adotado neste artigo, o efeito transbordamento seria representado pela defasagem espacial do quociente locacional de 1991, assumindo, portanto, a seguinte expressão:

$$\ln\left(\frac{QL03}{QL91}\right) = \alpha + \beta \ln(QL91_i) + \tau W \ln(QL91_i) + \varepsilon_i \quad (9)$$

Sendo que $\ln(QL03/QL91)$ é o logaritmo natural da razão entre o quociente locacional da produção de soja em 2003 e 1991; $\beta \ln(QL91)$ é o logaritmo natural do quociente locacional da produção de soja em 1991; $\tau W \ln(QL91)$ é a defasagem espacial do quociente locacional em 1991 e ε_i é o termo de erro bem comportado.

6 O termo *spillover* neste trabalho é utilizado no sentido de transbordamento.

Nesse modelo, conforme apontado por Rey e Montouri (1999), a dependência espacial remanescente toma a forma da média do quociente locacional da produção de soja do começo do período nas microrregiões vizinhas, que seria o termo de transbordamento cruzado.⁷ Note que τ é, neste modelo específico, um escalar.⁸

3.6.5 – Taxa de convergência

De acordo com Rey e Montouri (1999) a taxa de convergência é calculada conforme a equação (10).

$$\theta = (\beta + 1) / -K \quad (10)$$

Onde θ é a taxa de convergência; β é o parâmetro relativo a β convergência e K é o número de anos do período analisado.

4 – ANÁLISE DOS RESULTADOS

Os Mapas 1 e 2 mostram a distribuição dos quocientes locacionais da soja (QL) em 1991, 1997 e 2003. Após observar tais mapas, pode-se notar que o quociente locacional vem passando por um processo de homogeneização, ou seja, conforme se passam os anos, a disparidade de produção entre as microrregiões vem diminuindo.

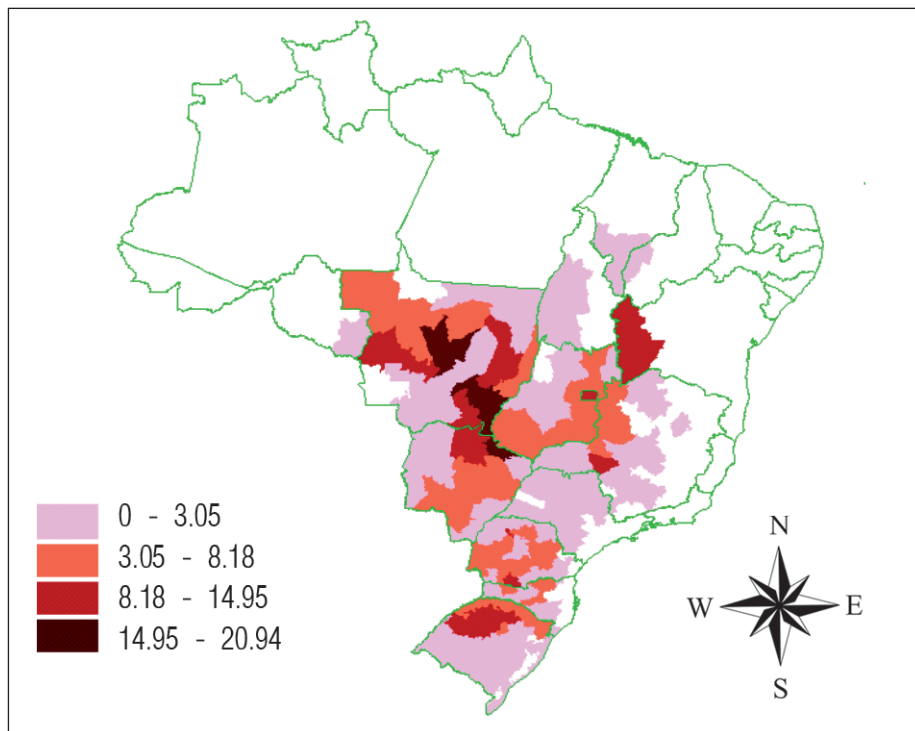
4.1 – I de Moran

O passo inicial para verificar a existência de autocorrelação espacial é a análise do *I* de Moran, que mostra a associação espacial global indicando que a obtenção de valores positivos implica autocorrelação espacial positiva.

No caso do presente artigo, afirmar que existe autocorrelação espacial positiva é o mesmo que dizer que microrregiões que possuem quociente locacional elevado para a produção de soja são vizinhas de microrregiões que também possuem quociente locacional elevado, ou, alternativamente, microrre-

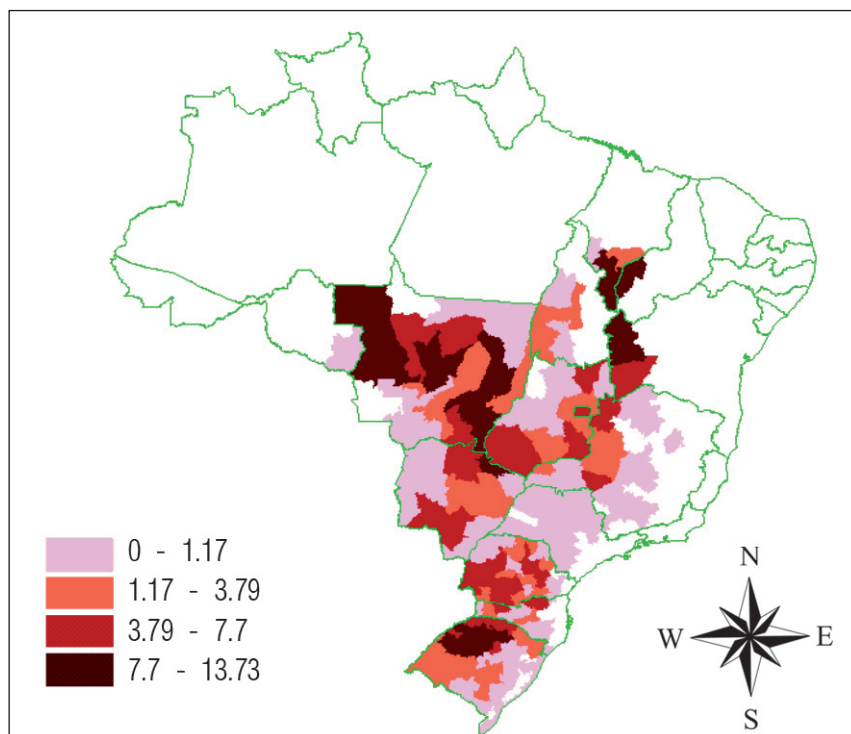
7 Considerando $\ln(QL91_i)$ como uma variável exógena, assim o é a variável defasada espacialmente $W \ln(QL91_i)$. Portanto, é possível estimar esse modelo por intermédio dos mínimos quadrados ordinários. (REY; MONTOURI, 1999).

8 Se houvesse efeitos de transbordamentos de outras variáveis explicativas, τ seria um vetor e não um escalar.



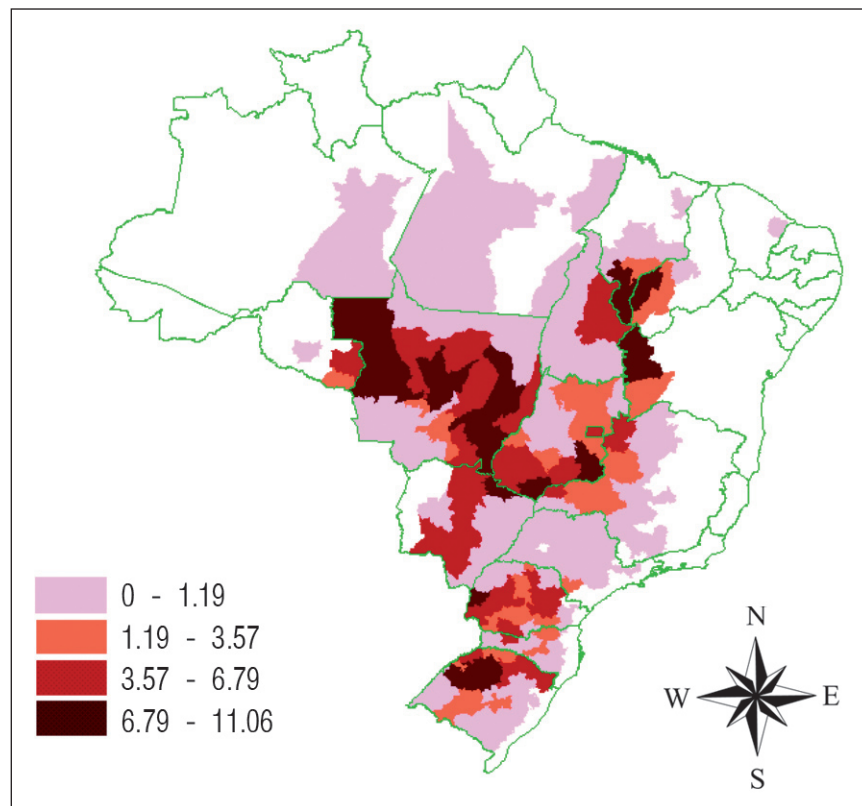
Mapa 1 – Quociente Locacional da Soja - 1991 e 1997

Fonte: Elaboração Própria dos Autores com Base no Programa *ArcView*.



Mapa 2 – Quociente Locacional da Soja - 2003

Fonte: Elaboração Própria dos Autores com Base no Programa *ArcView*.



Mapa 3 – Quociente Locacional da Soja - 2003

Fonte: Elaboração Própria dos Autores com Base no Programa ArcView.

giões com baixo quociente locacional estão ligadas a microrregiões também de baixos valores.

A Tabela 1 mostra o *I* de Moran, a média, o desvio padrão e o *z value*⁹ (e.g. valor padronizado) para o período analisado. Ao observar tanto o *I* de Moran quanto o *z value*, utilizando matriz para 10 vizinhos mais próximos, pode-se verificar que em todos os períodos há autocorrelação espacial. Vale destacar, também, que neste período os índices em análise têm apresentado elevação, passando de 30,39926 em 1991 para 36,46910 em 2003, ou seja, há um aumento da importância da questão espacial.

4.2 – Diagrama de dispersão de Moran

O passo seguinte é a implementação do diagrama de dispersão de Moran que, ao contrário do

⁹ O *z value* é o número de desvios padrões em que se situa determinado valor da variável aleatória acima ou abaixo da média. É encontrado usando-se a seguinte expressão:

$$z = \frac{(x - \bar{x})}{s}$$

I de Moran apresenta padrões locais de associação espacial. Este diagrama (Figura 1) apresenta em seu eixo horizontal o QL da soja para os anos de 1991, 1997 e 2003, e apresenta em seu eixo vertical a defasagem espacial (*lag*) do ano analisado. Pode-se também, através deste diagrama, classificar as microrregiões entre quatro diferentes regimes espaciais (BA, BB, AB, AA), conforme afirmado na seção 3.4.2. Os valores discrepantes serão identificados através da distância de Cook e pela regra de dois desvios padrões.

Os resultados obtidos através da construção do diagrama de dispersão de Moran servem como forma de confirmar os resultados apresentados na seção anterior, ao verificar que a incidência de microrregiões nos quadrantes AA e BB ocorrem em maior volume que as demais.

4.3 – Indicadores Locais de Associação Espacial (LISA)

Os Mapas 4, 5, 6, 7, 8 e 9 de *clusters* foram calculados para os anos de 1991, 1997 e 2003, para

Tabela 1 – Índice de Moran – Teste de Autocorrelação Espacial

Ano	I de Moran	Média	Desvio Padrão	Z
1991	0,34990	-0,01100	0,01187	30,39926
1992	0,39690	-0,01100	0,01182	34,50931
1993	0,39300	-0,01100	0,01184	34,11010
1994	0,37340	-0,01100	0,01190	32,31610
1995	0,37150	-0,01100	0,01190	32,14826
1996	0,36150	-0,01100	0,01190	31,30252
1997	0,36220	-0,01100	0,01192	31,31923
1998	0,38860	-0,01100	0,01191	33,56291
1999	0,35690	-0,01100	0,01191	30,89260
2000	0,33820	-0,01100	0,01192	29,29039
2001	0,39150	-0,01100	0,01185	33,96051
2002	0,34500	-0,01100	0,01190	29,91094
2003	0,42280	-0,01100	0,01190	36,46910

Fonte: Elaboração Próprio dos Autores com Base no *SpaceStat*.

o QL da soja a um nível de significância de até 0,1%. Os *clusters* AA são os mais significativos nos três anos analisados e apresentam QL maior que um, mostrando ser produtores de soja para exportação.

Os anos de 1991, 1997 e 2003 apresentam 84,61%, 86,67% e 95,5% de associação positiva respectivamente, sendo que nos dois primeiros anos o *cluster* AA representa 100% das microrregiões significativas e no ano de 2003 passa a representar apenas 43,75%. Com o passar dos anos, a associação positiva aumenta, seguindo a tendência global, mostrando que a correlação espacial cresce no período analisado.

4.4 – Análise de Robustez

Outra etapa da análise exploratória de dados espaciais é verificar se as estatísticas LISA são es-

táveis havendo alterações no número de vizinhos. Esta etapa pode ser realizada através de matrizes de transição de probabilidades, conforme sugerido por Le Gallo e Ertur (2003).

Neste caso, são considerados robustos os resultados que permanecerem estáveis após a alteração do número de vizinhos. Vale destacar que quanto mais próximo de 100 estiver a diagonal da matriz, mais robusto será o resultado. Neste trabalho a matriz de robustez foi implementada utilizando 10, 15 e 20 vizinhos mais próximos.

4.5 – Resultados Econométricos

Ao estimar a equação (5), pode-se obter a estimativa do parâmetro de β convergência que, por sua vez, estuda a possibilidade de microrregiões


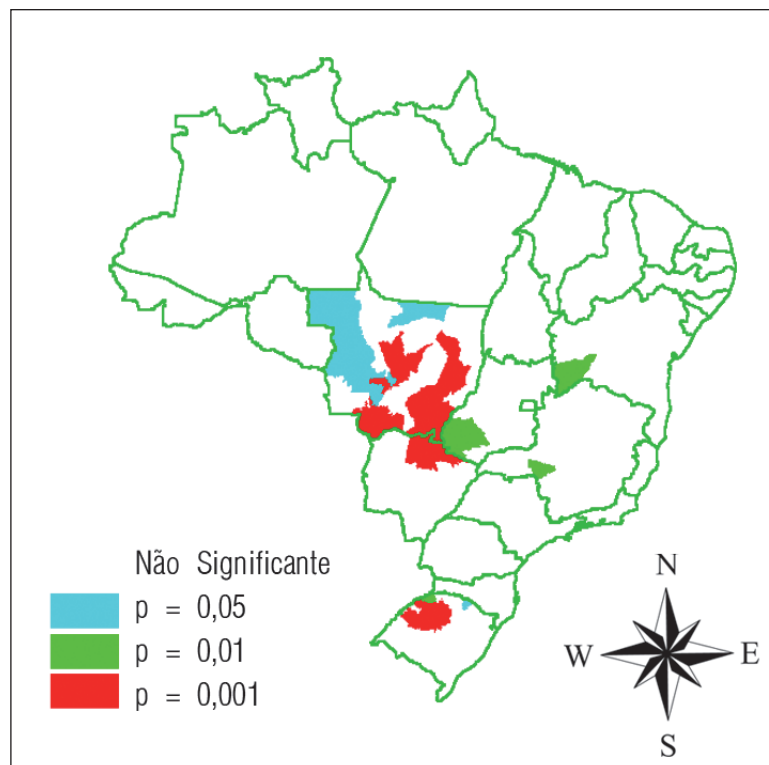
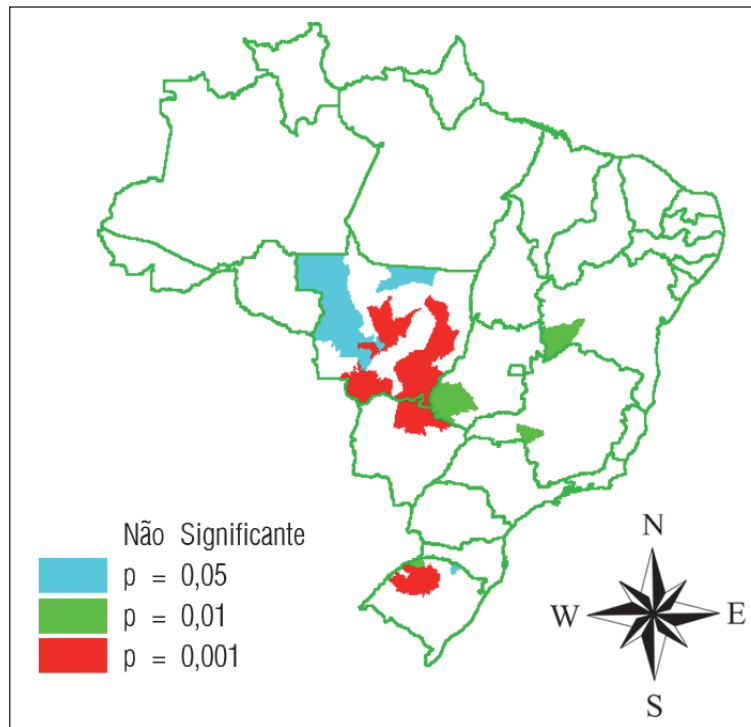


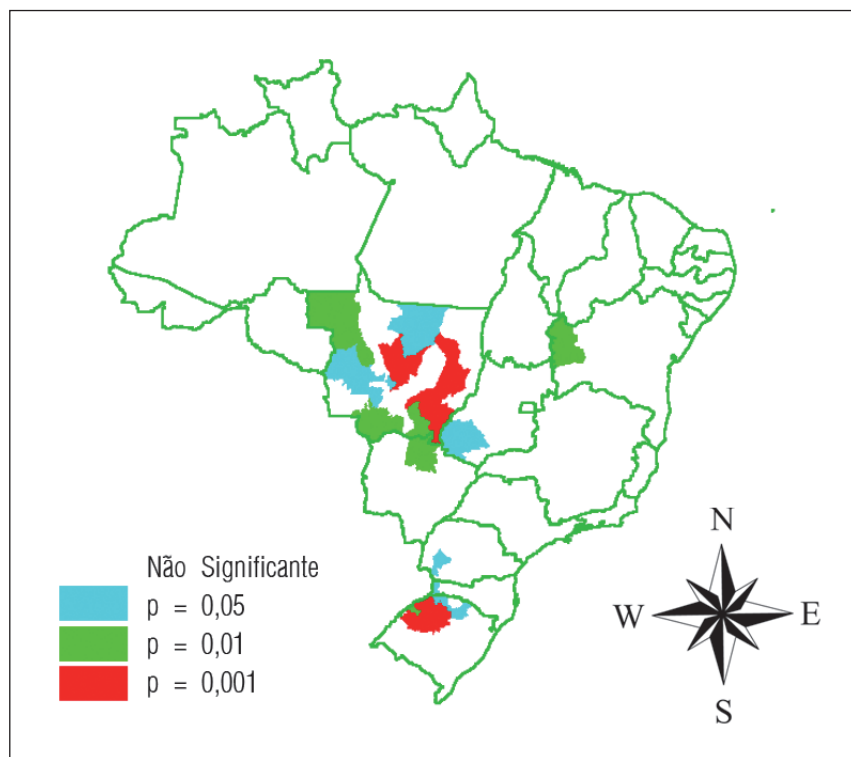
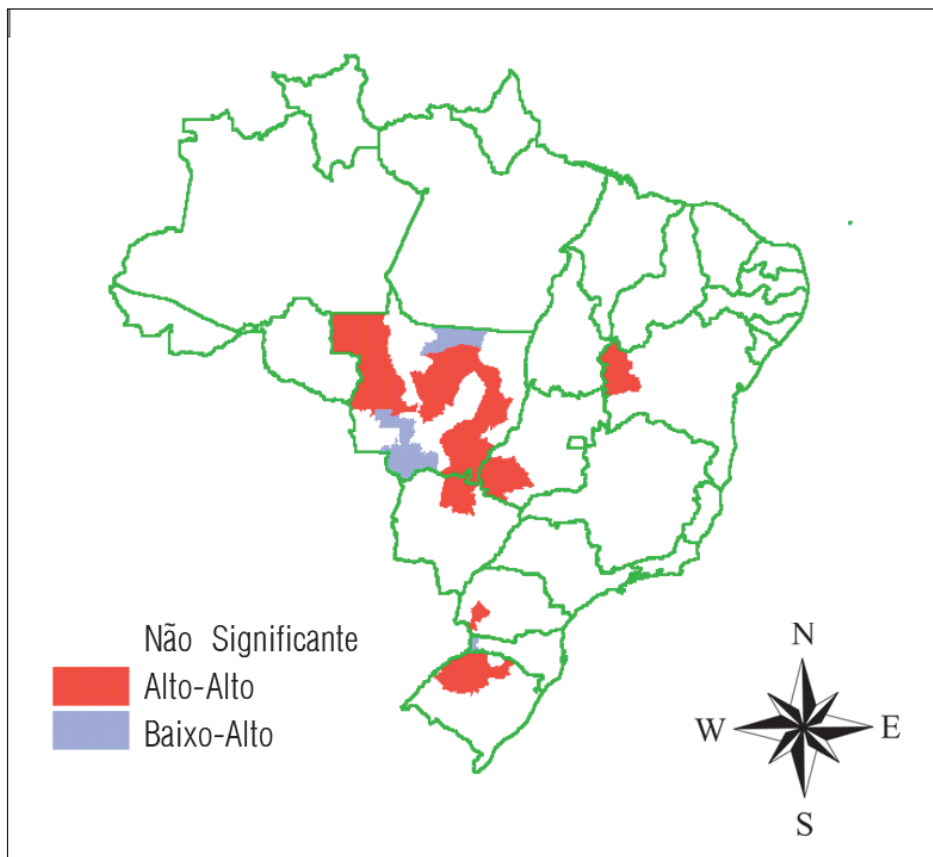
Figura 1 – Soja – Diagrama de Dispersão de Moran (1991, 1997 e 2003)

Fonte: Elaboração Própria dos Autores com Base no Programa GeoDA.

Obs: S1991, S1997 e S2003 = quociente locacional para soja para os anos de 1991, 1997 e 2003

W_S1991, W_S1997 e W_S2003 = defasagem espacial do quociente locacional para soja para os anos 1991, 1997 e 2003.





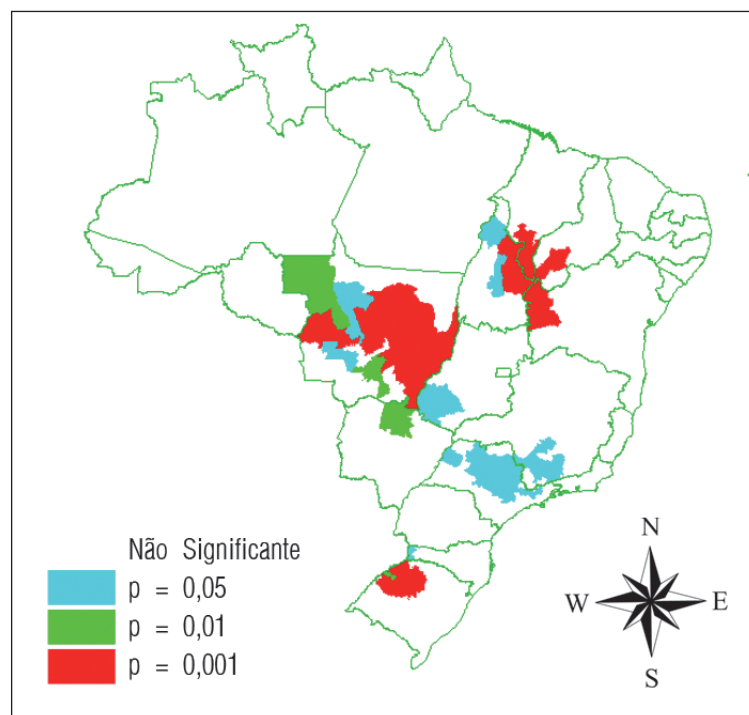
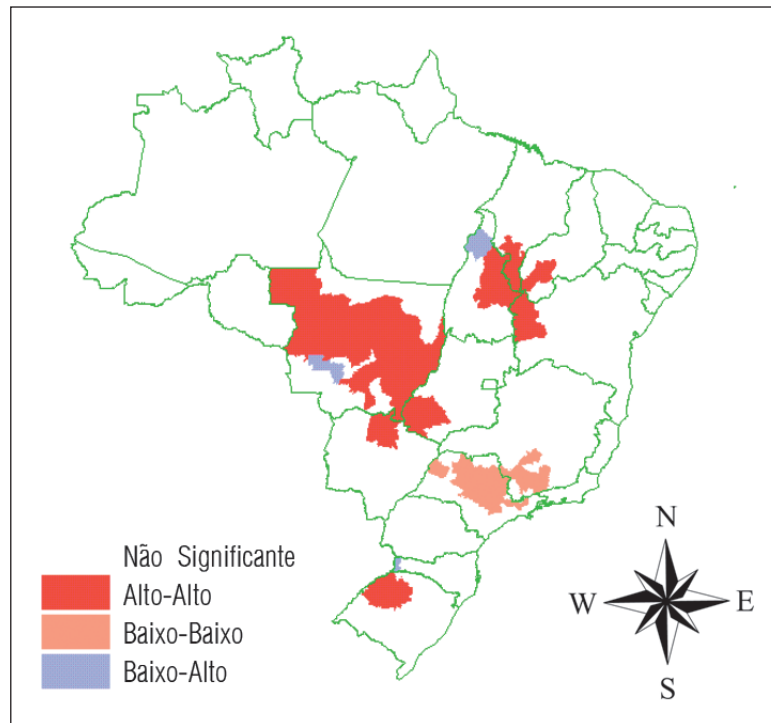


Tabela 2 - Análise de Robustez das Estatísticas LISA

1991		k=10 para k=15				
		NS	AA	BB	AB	BA
	NS	98,37	0,00	0,54	0,00	1,10
	AA	0,00	95,45	0,00	0,00	4,55
	BB	0,00	0,00	100,00	0,00	0,00
	AB	0,00	0,00	0,00	100,00	0,00
	BA	0,00	0,00	0,00	0,00	100,00
1991		k=10 para k=20				
		NS	AA	BB	AB	BA
	NS	84,78	0,00	11,95	0,54	2,72
	AA	0,00	100,00	0,00	0,00	0,00
	BB	0,00	0,00	100,00	0,00	0,00
	AB	0,00	0,00	0,00	100,00	0,00
	BA	0,00	0,00	0,00	0,00	100,00
1997		k=10 para k=15				
		NS	AA	BB	AB	BA
	NS	86,11	0,56	11,11	0,56	1,67
	AA	0,00	100,00	0,00	0,00	0,00
	BB	0,00	0,00	100,00	0,00	0,00
	AB	0,00	0,00	0,00	100,00	0,00
	BA	0,00	0,00	0,00	0,00	100,00
1997		k=10 para k=20				
		NS	AA	BB	AB	BA
	NS	80,00	1,11	16,67	1,36	1,36
	AA	0,00	100,00	0,00	0,00	0,00
	BB	0,00	0,00	100,00	0,00	0,00
	AB	0,00	0,00	0,00	100,00	0,00
	BA	0,00	0,00	0,00	0,00	100,00
2003		k=10 para k=15				
		NS	AA	BB	AB	BA
	NS	91,16	2,04	4,08	1,36	1,36
	AA	0,00	100,00	0,00	0,00	0,00
	BB	0,00	0,00	100,00	0,00	0,00
	AB	0,00	0,00	0,00	100,00	0,00
	BA	0,00	0,00	0,00	0,00	100,00
2003		k=10 para k=20				
		NS	AA	BB	AB	BA
	NS	86,39	2,72	6,80	0,68	3,40
	AA	0,00	100,00	0,00	0,00	0,00
	BB	0,00	0,00	100,00	0,00	0,00
	AB	0,00	0,00	0,00	100,00	0,00
	BA	0,00	0,00	0,00	0,00	100,00

Fonte: Elaboração própria dos autores a partir das estatísticas LISA calculadas pelo SpaceStat.

que possuam baixa produção de soja obterem crescimento em sua produção de forma mais acentuada que as microrregiões que já possuem uma alta produção.

Ao analisar os resultados da equação (5), verificou-se a existência de autocorrelação espacial, indicando que a utilização do Método de Mínimos Quadrados Ordinários (MQO) não é por si só suficientemente adequada para a estimação do modelo desejado. Esta afirmação pode ser corroborada pelos resultados obtidos nas seções anteriores (I de Moran), nas quais, através deles, a autocorrelação espacial já era passível de identificação. Após seguir os passos referidos na sessão 3.6.1, obtêm-se os resultados demonstrados na Tabela 3:

Para identificar o modelo econométrico espacial mais adequado a ser utilizado, fez-se uso do Multiplicador de Lagrange e do Multiplicador de Lagrange Robusto, sendo que a escolha do melhor

modelo dependerá do nível de significância de cada multiplicador.

No entanto, é importante salientar a existência de dois problemas que podem ocorrer nos modelos estimados. O primeiro indica que os erros não são normais, podendo ser verificados através do teste Jarque-Bera. O segundo é a existência de heterocedasticidade, que pode ser constatada através da análise do teste Breusch-Pagan. A ocorrência de quaisquer destes problemas coloca em suspeita as inferências realizadas.

Foi identificado como melhor escolha o modelo de erro espacial (equação 6), resultado que pode ser corroborado pelos valores de *Akaike Information Criterion (AIC)*, *Schwarz Criterion (SC)*, verificados na Tabela 3. Todavia, ao realizar a estimação destes modelos, foi constatada a ocorrência dos problemas citados acima (não normalidade dos erros e heterocedasticidade).

Tabela 3 – Resultado dos Testes de Especificação para o Modelo de Convergência Absoluta

	I - Equação (5)	II - Equação (6)	III - Equação (7)	IV - Equação (8)
Constante	-0,10142 0,00198	-0,07738 0,35979	-0,05601 0,06823	-0,04951 0,11810
b	-0,16607 0,00000	-0,25781 0,00000	-0,16690 0,00000	-0,27548 0,00000
r			0,52098 0,00000	
l		0,66045 0,00000		
t				0,32121 0,00000
LM – Erro	211,74284 0,00000			109,68238 0,00000
LM - Lag	111,22509 0,00000			110,63048 0,00000
LR - Erro	144,86241 0,00000			2,59708 0,10706
LR - Lag	44,34466 0,00000			3,54518 0,05972
BP Heterocedasticidade	0,21391 0,64372	2,05047 0,15216	1,79305 0,18056	0,21626 0,64190
Jarque Bera	30195,78000 0,00000			
AIC	1284,13000	1151,44000	1227,90000	1225,96000
SC	1292,78000	1160,09000	1240,88000	1238,93000

Fonte: Elaboração Própria dos Autores com Base no Space Stat.

Para corrigir a ausência de homocedasticidade, a especificação do modelo de erro espacial foi modificada, a fim de acomodar a heterocedasticidade na forma de grupos (*groupwise heteroskedasticity*).

No que diz respeito ao problema da ausência de normalidade nos erros, adotou-se o Método de Momentos Generalizados (GMM), proposto por Kelejian e Prucha, para estimar o modelo de *erro espacial*. Esse método prescinde da normalidade dos erros.

Após seguir todos os critérios explicitados acima, é possível estimar os modelos de β convergência de forma consistente, como segue na Tabela 4.

Portanto, ao verificar a estimativa do parâmetro β através do modelo de erro espacial, pode-se observar que há ocorrência de convergência em relação ao quociente locacional da produção de soja brasileira, ou seja, indica que os valores do QL da produção de soja no Brasil estão convergindo para uma mesma média. A despeito disso, a taxa de convergência é de 0,093892, indicando uma rápida convergência.

Assim, cabe questionar quais são as implicações deste resultado, se comparado com a taxa de convergência das principais regiões produtoras da cultura analisada. Portanto, ao realizar a inferência de tais taxas para os três principais *clusters* verificados na sessão 4.2 e 4.3, pôde-se obter os seguintes resultados: 0,098582 para o *cluster* formado

Tabela 4 – Modelo de Erro Espacial – Estimado por GMM

Variável	Coefficiente	Desvio Padrão	Probabilidade
Constante	-0,16894	0,05113	0,00095
Ln91	-0,22059	0,02051	0,00000
λ	0,04111	0,00000	0,00000

Tabela 5 – Modelos de Convergência para os Principais Clusters de QL de Soja

Modelo de erro espacial (Centro) - Estimado por GMM			
Variável	Coefficiente	Desvio Padrão	Probabilidade
Constante	0,05323	0,26307	0,83969
LN91	-0,33295	0,07391	0,00007
	0,05479	0,00000	0,00000
Modelo de erro espacial (Sul) - Estimado por GMM			
Variável	Coefficiente	Desvio Padrão	Probabilidade
Constante	-0,15031	0,18194	0,40872
ln91	-0,28156	0,06388	0,00001
	0,10860	0,00000	0,00000
Modelo de lag espacial (Norte/Nordeste) - Estimado por GMM			
Variável	Coefficiente	Desvio Padrão	Probabilidade
Constante	0,06060	0,05846	0,01448
ln91	-0,64640	0,06419	0,29996
W_ln03_91	0,22187	0,13666	0,00000

Fonte: Elaboração Própria dos Autores com Base no *SpaceStat*.

por microrregiões do Rio Grande do Sul; 0,102534 para o *cluster* formado por microrregiões do Centro-Oeste; e 0,126646 para as microrregiões dos Estados do Tocantins, Maranhão, Piauí e Bahia.

Ao comparar tais taxas de convergência, pode-se verificar a existência de disparidade entre a velocidade de convergência inerente ao país e entre os principais *clusters* produtores de soja, sendo possível observar que, quanto mais recente é a formação do *cluster*, maior é a velocidade da convergência. O avanço em pesquisas realizadas essencialmente pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa) ao longo da década de 1990 e o início do cultivo direto vêm tornando possível a disseminação da cultura de soja para outras regiões do país, além de proporcionar a proliferação de tal cultura internamente em cada região.

5 – CONSIDERAÇÕES FINAIS

Após a aplicação dos métodos citados nas seções anteriores, é possível concluir que:

- a) Conforme pôde ser verificado na Tabela 4, o *I* de Moran está se elevando ao longo do período analisado (1991–2003), indicando a existência de autocorrelação espacial e mostrando que, conforme se passam os anos, maior é a incidência de *clusters* do padrão AA e BB.
- b) Foram identificados também três *clusters* exportadores principais, sendo que as exportações podem ser em caráter inter-regional. O primeiro destes *clusters* está localizado na região Sul do país, englobando microrregiões essencialmente do Rio Grande do Sul, um segundo localizado na região Centro-Oeste, com microrregiões do Mato Grosso, Mato Grosso do Sul e Goiás, região esta que possui a maior produtividade média do país. E um terceiro localizado mais no Norte/Nordeste. É importante destacar que este último *cluster* surgiu a partir da análise do ano de 2003, mostrando a crescente difusão da cultura da soja na década. Este terceiro *cluster* engloba, principalmente, microrregiões do Tocantins, Piauí e Maranhão.

c) Através da construção da matriz de robustez, foi possível efetuar a comprovação de que os dados são robustos. De forma que, à medida que se altera o número de vizinhos mais próximos (10, 15, 20), os dados permanecem consistentes.

d) Foi possível também identificar através de métodos econométricos espaciais que o QL da soja está convergindo para uma mesma média. Assim como verificado para o QL nacional, foi realizada uma análise do QL da soja de forma regional, buscando identificar a existência de convergência também nos três *clusters* identificados. Pôde-se verificar através do parâmetro β a incidência de convergência também nestes *clusters*, sendo que quanto mais recente se dá a inserção da cultura na região, mais veloz se torna sua taxa de convergência.

Em síntese, o trabalho permitiu verificar que:

- a) a produção de soja não é distribuída de forma homogênea por todo o território nacional; b) há certo espraiamento da cultura no período recente (*cluster* da região Nordeste); c) a taxa de convergência nacional é menor que as taxas de convergência regionais; d) a região que apresenta maior taxa de convergência é o *cluster* formado pelas unidades da Federação produtoras localizadas nas regiões Norte e Nordeste.

Abstract

The main aim of this paper is analyze the spatial distribution of the soybeans among the 558 Brazilian micro regions during the period 1991-2003. It can be pointed as secondary objectives: a) analyze the time evolution of spatial dynamic; b) identify the cluster's formation; classify the productive base of the micro regions; c) verify the incidence of local quotient of soybeans. In other words, we verify if the soybeans production is homogeneously distributed in the country. To reach the goal of this paper, it will be implemented: a) exploratory spatial data analysis (ESDA) to identify significant clusters and the time evolution of spatial dynamic; b) a

convergence analysis to infer if the less productive regions are growing faster than the more productive ones and vice-versa. The paper allows to verify that: a) the soybean production is not homogeneously distributed within the country; b) there is a small spreading at the soybean production in the recent period (e.g. cluster at the northeast region); c) the national convergence index is smaller than the regional convergence; and d) the cluster formed by the north and northeast regions presents the bigger convergence index.

Key words:

Territorial development; Spatial Analysis;
Convergence; Agriculture economy; Soybeans
Complex.

REFERÊNCIAS

ALMEIDA, E. S.; HADDAD E. A.; HEWINGS G. J. D. The spatial pattern of crime in Minas Gerais: an exploratory analysis. **Economia Aplicada**, São Paulo, v. 9, n. 1, p. 39-55, 2005.

ALMEIDA, E. S.; PEROBELLI, F. S.; FERREIRA, P. G. C. **Existe convergência espacial da produtividade agrícola no Brasil?**. [S.l.], 2006. Mimeografado.

ALVIM, M. I. S. A. Competitividade da produção de soja nos sistemas de plantio direto e plantio convencional em Mato Grosso do Sul. 2003. 148 f. Tese (Doutorado em Economia Aplicada) – Universidade Federal de Viçosa, Viçosa, 2003.

ANSELIN, L. Local Indicators of Spatial Association: LISA. *Geographical Analysis*, v. 27, n. 2, p. 93-115, Apr. 1995.

_____. **Spatial econometrics**. Dallas: University of Texas, 1999.

_____. **Spatial econometrics: methods and models**. Boston: Kluwer Academic, 1988.

ANSELIN, L.; BERA, A. Spatial dependence in linear regression models with an introduction

to spatial econometrics. In: ULLAH, A. D. (Ed). **Handbook of applied economic statistics**. Giles: Marcel Dekker, 1998.

BAUMOL, W. J. Productivity growth, convergence, and welfare: what the long-run data show.

American Economic Review, v. 76, n. 5, p. 1072-85, 1986.

BRANDÃO, A. S. P.; REZENDE, G. C.; MARQUES, R. W. C. Crescimento agrícola no período 1999/2004: explosão da área plantada com soja e meio ambiente no Brasil. Brasília, DF: IPEA, 2005. (Texto para Discussão, n. 1962).

BRASIL. Ministério da Agricultura. **Agronegócio brasileiro: uma oportunidade de investimentos**. Disponível em: <<http://www.agricultura.gov.br>>. Acesso em: 27 abr. 2005.

CARVALHO, M. A.; SILVA, C. R.; GHILARDI, A. A. Competitividade da soja e a geração de divisas. In: CONGRESSO DA SOCIEDADE BRASILEIRA DE ECONOMIA E SOCIOLOGIA RURAL, 43., 2005, Ribeirão Preto. Anais... Ribeirão Preto: SOBER, 2005.

DALL'ERBA, S. **Productivity convergence and spatial dependence among Spanish regions**. Urbana-Champaign: University of Illinois, 2004. (Real Discussion Paper).

EMBRAPA. **Cadeias produtivas no Brasil: análise da competitividade**. Brasília, DF, 2001. 468 p.

FLORAX, R. J. G. M.; FOLMER, H.; REY, S. J. Specification searches in spatial

econometrics: the relevance of hendry's methodology. **Regional Science and Urban Economics**, v. 33, n. 5, p. 557-79, Sept. 2003.

GONÇALVES, E. **A distribuição espacial da atividade inovadora brasileira: uma análise exploratória**. Belo Horizonte: UFMG, 2005. 33 p. (Texto para discussão CEDEPLAR, n. 246).

HADDAD P. R. et al. **Economia regional: teoria e métodos de análise**. Fortaleza: BNB, 1985.

IBGE. **SIDRA**: Sistema IBGE de Recuperação Automática. Brasília, DF, 2005. Disponível em: <<http://www.sidra.ibge.gov.br/bda/>>. Acesso em: 5 fev. 2005.

LE GALLO, J.; ERTHUR, C. Exploratory spatial data analysis of the distribution of regional per capita: GDP in Europe: 1980-1995. **Papers in Regional Science**, v. 82, n. 2, p. 175-201, 2003.

LOPES, J. L. **Avaliação do processo de convergência da produtividade da terra na agricultura brasileira no período de 1960 a 2001**. 2004. 193 f. Tese (Doutorado em Economia Aplicada) – Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, São Paulo, 2004.

MAGALHÃES, A.; HEWINGS, G.; AZZONI, C. **Spatial dependence and regional convergence in Brazil**. Urbana-Champaign: University of Illinois, 2000. (Working Paper Real, 11).

OLIVEIRA, S. J. M.; FERREIRA FILHO, J. B. S. Impactos da expansão da União Européia no agronegócio da soja no Brasil. In: CONGRESSO DA SOCIEDADE BRASILEIRA DE ECONOMIA E SOCIOLOGIA RURAL, 43., 2005, Ribeirão Preto. Anais... Ribeirão Preto: SOBER, 2005.

PEROBELLI, F. S.; HADDAD, E. A. Padrões de comércio interestadual no Brasil, 1985 e 1997.

Revista de Economia Contemporânea, v. 10, n. 1, p. 61-88, jan./abr. 2006.

QUAH, D. Regional convergence clusters across Europe. **European Economic Review**, v. 40, p. 951-958, 1996.

REY, S. J.; MONTOURI, B. D. U. S. Regional income convergence: a spatial econometric perspective. **Regional Studies**, v. 33, p. 143-156, 1999.

SILVA, S. S. et al. Estimativa da função de produção de soja no Brasil no período de 1994 a 2003. In: CONGRESSO DA SOCIEDADE BRASILEIRA DE ECONOMIA E SOCIOLOGIA RURAL, 43., 2005, Ribeirão Preto. Anais... Ribeirão Preto: SOBER, 2005.

TOBLER, W. R. A computer model simulation of urban growth in the Detroit region. **Economic Geography**, v. 46, p. 234-240, 1970.

VARGA, A. **University research and regional innovation: a spatial econometric analysis of academic technology transfers**. Boston: Kluwer Academic Publishers, 1998.

Recebido para publicação em 16.03.2007.