



Encontro Internacional sobre Gestão  
Empresarial e Meio Ambiente

ISSN: 2359-1048  
Dezembro 2016

## **DEPENDÊNCIA ESPACIAL DA ECO-EFICIÊNCIA DA AGRICULTURA EM SÃO PAULO.**

**CARLOS ROSANO PEÑA**  
gmcrosano@gmail.com

**CARLOS ALEKSANDR ROSANO DE ALMEIDA**  
carloleksandr@hotmail.com

# DEPENDÊNCIA ESPACIAL DA ECO-EFICIÊNCIA DA AGRICULTURA EM SÃO PAULO. SPATIAL DEPENDENCY OF ECO-EFFICIENCY OF AGRICULTURE IN SÃO PAULO.

## Resumo

No intuito de subsidiar a sustentabilidade ambiental da agropecuária do estado de São Paulo, este trabalho calculou um índice de ecoeficiência, que aponta em quanto é possível maximizar os objetivos econômicos e ambientais, tendo como referência as melhores práticas nos municípios da região. Para isto, utilizou o método Análise Envoltória de Dados com funções distância direcionais a partir das variáveis clássicas da função produção, multiproduto e da internalização de duas externalidades (uma positiva e outra negativa). Houve uso também das técnicas de análise exploratória de dados espaciais para verificar a autocorrelação espacial e a heterogeneidade espacial do índice calculado. Os resultados indicam que, em média, os municípios analisados podem elevar a produção e as áreas de floresta em 59%, bem como reduzir as áreas degradadas e os insumos na mesma proporção. A análise espacial demonstrou a existência de autocorrelação espacial entre os municípios e a formação de dois grandes *clusters* significativos do tipo baixa-baixa e um do tipo alta-alta ecoineficiência. Estes resultados indicam que as estratégias de desenvolvimento sustentável da agropecuária do estado devem, por um lado, considerar a dependência espacial no planejamento geral, mas, por outro lado, ponderar a heterogeneidade local na definição de políticas específicas para cada região.

**Palavras-chave:** Análise Envoltória de Dados, Análise espacial, Agricultura, São Paulo.

## Abstract

In order to support the environmental sustainability of agriculture in the state of São Paulo, this study calculated an eco-efficiency index, indicating how much is possible to maximize the economic and environmental objectives, taking into account the best practices in the municipalities of this region. In this vein, we used the data envelopment analysis method with directional distance functions based on the classic variables of multiproduct production function and on internalization of two externalities (one positive and one negative). The study also used the tools of exploratory spatial data analysis to verify the spatial autocorrelation and spatial heterogeneity of the calculated index. The results indicate that, on average, the analyzed municipalities are able to expand the production and forest areas by 59% and also to reduce degraded areas and inputs in the same proportion. Spatial analysis had demonstrated the existence of spatial autocorrelation between municipalities and the formation of two large and significant clusters of type low-low and one of type high-high eco-inefficiency. These results indicate that the sustainable development strategies of the state agriculture should, on the one hand, consider the spatial dependence in the overall planning, but on the other hand, considering the local heterogeneity in the definition of specific policies for each region.

**Keywords:** Data envelopment analysis, Spatial data analysis, Agriculture, São Paulo

## 1. Introdução

O crescimento da produtividade e eficiência agropecuária tem sido um fator relevante para o desenvolvimento socioeconômico. É responsável pelo aumento da produção de alimentos e matérias-primas com custos relativamente menores, pela expansão do mercado interno, ofertando mais e novos produtos e demandando uma quantidade maior de insumos e equipamentos agrícolas. Isto permitiu a liberação de recursos humanos, materiais e financeiros para setores não agropecuários, fortalecendo o modo de produção urbano-industrial e o crescimento da qualidade e cobertura dos serviços públicos. Assim, o aumento

da produtividade e eficiência da agricultura e pecuária provocou mudanças no espaço econômico e cultura campestre, bem como a ruptura das velhas estruturas de poder político da aristocracia rural. Um bom ritmo de crescimento da produtividade e eficiência agropecuária segue sendo um elemento-chave para que países como o Brasil consigam alcançar, de forma sustentada, o nível de vida dos países mais desenvolvidos.

No entanto, a intensificação agropecuária tem causado impactos ambientais significativos sobre os ecossistemas terrestres e aquáticos do mundo (TILMAN, 1999). Por exemplo, a mecanização aumentou o consumo de energias não renováveis; a monocultura gerou a erosão dos solos, a destruição das florestas e da biodiversidade genética; a intensificação da aplicação de inseticidas, pesticidas e fertilizantes nitrogenados aumentou a concentração de gases de efeito estufa na atmosfera e, junto com os sistemas de irrigação, deu origem à eutrofização, poluição e esgotamento de recursos hídricos (IPCC, 2006).

Na agropecuária do estado mais rico e populoso do Brasil, São Paulo, o problema ambiental não é diferente. O desmatamento, a contaminação das águas e do solo e as emissões de gases de efeito estufa (GEE) no setor agropecuário são problemas crescentes. Das emissões acumuladas de GEE da agropecuária brasileira (12.970 Mt CO<sub>2</sub>) entre 1970 e 2013, o estado de São Paulo responde por cerca de 9% (IMAFLOA, 2015). Essas emissões foram e têm sido predominantemente derivadas da pecuária de corte e leite (56%), fertilizantes sintéticos (19%), cana-de-açúcar (10%).

Neste sentido, ficam em aberto as seguintes questões: a) É possível aumentar a produção e reduzir, ao mesmo tempo, os impactos ambientais e o uso de recursos naturais não renováveis? b) Como tornar a agropecuária regional mais ecoeficiente?

Para responder estas questões têm-se desenvolvido diversas ferramentas capazes de medir o impacto ambiental das atividades produtivas (VAN PASSEL et al., 2007, e VAN PASSEL et al., 2009). Uma delas é o método *life cycle accounting* (LCA), que mapeia os processos de produção e os impactos (pegadas de carbono) nas distintas fases, desde a produção até o consumo e a reciclagem. No entanto, este método tem algumas limitações, entre as quais se destacam as dificuldades de estimar as emissões de carbono em cada contexto regional e quantificação monetária desse valor.

Outros métodos utilizam as populares técnicas de fronteiras eficientes (LAMPE e HILGERS, 2015). Estas partem da hipótese da existência de falhas de mercado inibidoras do comportamento eficiente, e da modelagem de uma fronteira tecnológica multiprodutos (com *outputs* desejados e indesejados). Assim, é possível encontrar as possibilidades de aumentar a oferta de produtos desejados e minimizar, simultaneamente, o impacto ambiental e a utilização dos fatores produtivos, o que, na terminologia inglesa, é chamado resultado *win-win*.

Suas aplicações empregam tanto métodos paramétricos quanto não paramétricos, que, partindo de pressupostos diferentes, apresentam vantagens e desvantagens. O primeiro utiliza a ferramenta Análise de Fronteira Estocástica (Stochastic Frontier Analysis – SFA). Parte da escolha de uma função distância paramétrica que expresse a relação funcional entre os produtos e insumos, para representar a fronteira do conjunto de possibilidades de produção e decompor o desvio da fronteira em ruído estocástico e ineficiência técnica. Essa função é estimada usando-se métodos de programação linear ou máxima verossimilhança.

O segundo método utiliza a Análise Envoltória de Dados (Data Envelopment Analysis - DEA) e o Índice de Produtividade de Malmquist (IPM), que facilmente modelam as tecnologias multiprodutos e a internalização de externalidades associadas ao processo produtivo. Representa a tecnologia por meio de funções distância, aferidas com problemas de programação matemática, sem a necessidade de definir previamente uma função estocástica de produção e um tipo de distribuição (comportamento) dos erros desconhecidos, ficando

livre das possíveis falhas decorrentes dessas especificações. Contudo, esse método, sendo determinístico, ignora as perturbações aleatórias do processo produtivo.

Uma extensa revisão da literatura evidenciou que o emprego das técnicas de fronteiras eficientes no estudo da ecoeficiência da agricultura brasileira ainda é incipiente. Com o uso de fronteiras estocásticas multiproduto, apenas foi encontrado o trabalho de Rosano-Peña et al. (2015), que utilizaram funções distância hiperbólicas para estimar a ecoeficiência da agricultura amazônica. Dentre os trabalhos que empregam métodos não paramétricos, vale citar os trabalhos de Padrão et al. (2012), que comparam a eficiência técnica e ambiental da produção agrícola na Amazônia Legal e estimam o custo de oportunidade do Código Florestal usando a modelagem DEA; Rosano-Peña et al. (2014) e Rosano-Peña e Daher. (2015), que avaliam a ecoeficiência e a sustentabilidade da agricultura dos estados brasileiros usando funções distância direcionais com DEA; e Campos et al. (2014), que estudam o desempenho econômico e ambiental dos produtores de leite em Minas Gerais usando o modelo DEA combinado com a abordagem por balanço de materiais.

Neste contexto, o presente trabalho busca preencher uma importante lacuna na literatura sobre ecoeficiência da agropecuária paulista. Mais precisamente, tem como objetivo estimar um indicador de ecoeficiência que, satisfazendo o conceito ótimo de Pareto, maximiza concomitantemente os objetivos econômicos e ambientais, tendo como referência as melhores práticas nos municípios paulistas. Para tanto, utiliza-se do método DEA com funções distância direcionais, a partir das variáveis clássicas da atividade agropecuária e da internalização de duas externalidades (uma positiva e outra negativa). Além disso, para o exame dos resultados verifica-se a autocorrelação e heterogeneidade espacial do índice calculado, a partir do uso de técnicas de análise exploratória de dados espaciais (AEDE).

Assim, acredita-se que os resultados do trabalho podem se transformar em importantes subsídios para a definição de políticas públicas regionais integradas e consistentes com a maximização do bem-estar social, com a finalidade de otimizar a sustentabilidade da agropecuária de São Paulo.

O trabalho está organizado em cinco seções. Além desta introdução, é apresentado na segunda seção um quadro teórico, conceitual e metodológico sobre o tema. Na terceira, sucintamente é caracterizada a econômicas agropecuária de São Paulo e as variáveis selecionadas. Na quarta seção, analisam-se os resultados da pesquisa. E, por fim, na quinta seção o artigo traz as conclusões.

## **2. Referencial teórico e metodológico**

Conforme Zhang et al. (2008), o conceito de ecoeficiência vem da década de 1970, tendo sido utilizado por Freeman, M. A. e McIntyre, J. R. como o termo que expressa a eficiência econômica ambiental. Posteriormente, o conceito de ecoeficiência é popularizado pelo World Business Council for Sustainable Development (WBCSD, 2000), que a define como a capacidade de uma unidade produtiva (fazenda, indústria, setor, país, etc.) de produzir mais e melhor, com menor uso de recursos e com mínimo impacto ambiental buscando, dessa forma, construir uma sociedade mais sustentável.

Do ponto de vista teórico, as unidades ecoeficientes formam a fronteira do conjunto de possibilidade de produção (CPP). Portanto, a ecoeficiência é a habilidade de uma empresa de produzir uma dada quantidade de produto desejado com a menor quantidade de insumos e impacto ambiental; ou, equivalentemente, como a competência de maximizar a produção com uma dada quantidade de insumos e subprodutos indesejados. Em outras palavras, a ecoeficiência ótima associada a uma dada combinação de insumos é atingida na fronteira do produto potencial, num ponto ótimo de Pareto, quando não existir outro processo produtivo ou combinação de processos que consiga produzir o mesmo nível de produto, impactando menos o ambiente e consumindo menos insumos. Isto significa que as unidades produtivas ecoineficientes colocam-se abaixo da fronteira do CPP. Consequentemente, o

nível de ecoineficiência de uma firma pode ser medido pela distância que a separa da fronteira. Ou seja, pode-se mensurar a ecoineficiência de uma organização por meio da comparação do seu desempenho com as melhores práticas.

Um dos métodos mais populares para estimar a ecoeficiência é a função distância direcional desenvolvida por Chung, Färe e Grosskopf (1997), Färe e Grosskopf (2000) e Färe et al. (2006) para incluir subprodutos indesejados. Segundo Rosano-Peña, e Daher (2015), este método surge como uma alternativa às funções de distância radiais de Shephard para tratar os *outputs* desejáveis e indesejáveis simultaneamente de forma assimétrica. Além disso, permite definir *a priori* diferentes direções de projeção na fronteira eficiente por meio de um vetor direcional ( $g = -g_x, g_y, -g_b$ ), ofertando um conjunto de opções para atingir a ecoeficiência que podem, inclusive, melhorar um grupo de variáveis sem afetar o comportamento de outras. A função distância direcional pode ser expressa da seguinte forma:

$$\vec{D}[x,y,b;(-g_x, g_y, -g_b)] = \text{Max} \{ \beta : (x - \beta g_x, y + \beta g_y, b - \beta g_b) \in \text{CPP} \} \quad (1)$$

em que  $\beta$ , o valor ótimo a ser estimado, indica o percentual em que a unidade produtiva avaliada poderia incrementar todos os produtos desejáveis ( $y$ ) e reduzir, concomitantemente, os insumos ( $x$ ) e as externalidades negativas ( $b$ ) quando a direção, *a priori* definida pelo pesquisador, do vetor direção é ( $-g_x = 1, g_y = 1, -g_b = 1$ ). Portanto,  $\beta$  é maior ou igual a zero:  $\beta = 0$  significa que a unidade avaliada é eficiente e  $\beta > 0$  ineficiente.

Arandia e Aldanondo-Ochoa (2011), seguindo Färe et al. (2006), afirmam que as funções distância direcionais e os  $\beta$  para cada unidade avaliada podem ser estimados a partir do cálculo do seguinte problema de programação linear (PPL):

$$\begin{aligned} \vec{D}_o(x,y,b; -g_x, g_y, -g_b) &= \text{Max } \beta & (2) \\ \text{s.t.} & \\ (1 + \beta g_y) * y^i - s_y^i &= Yz & (2.1) \\ (1 - \beta g_b) * b^i + s_b^i &= Bz & (2.2) \\ (1 - \beta g_x) * x^i + s_x^i &= Xz & (2.3) \\ z &\geq 0 & (2.4) \end{aligned}$$

Em que  $x^i$ ,  $y^i$  e  $b^i$  denotam, respectivamente, o vetor de insumos, produção desejada e produção indesejada da  $i$ -ésima firma avaliada;  $s^i$  são as folgas das respectivas variáveis;  $X$  é a matriz de ordem  $n$  dos insumos,  $Y$  denota a matriz de produtos desejados de ordem  $p$  das firmas e  $B_{(q \times i)}$  é a matriz de produtos indesejados das unidades produtivas;  $z$  é o vetor de intensidade de cada firma na definição da fronteira eficiente, ou seja, na formação das combinações lineares das melhores práticas.

O problema de programação linear (2) caracteriza-se por trata os produtos indesejados como *inputs* para evitar os problemas de congestão destes subprodutos. Para maiores detalhes, pode-se consultar Arandia e Aldanondo-Ochoa (2011).

## 2.1 Análise Exploratória de Dados Espaciais (AEDE)

A análise exploratória de dados espaciais é uma moderna e útil ferramenta para a análise de variáveis socioeconômicas. Para Anselin, Syabri e Smirnov (2002), a AEDE pode ser definida como o conjunto de técnicas estatísticas e gráficos que descrevem e visualizam distribuições espaciais de variáveis, identificando pontos locais atípicos, formas de associação (autocorrelação espacial) e estruturas no espaço geográfico (heterogeneidade espacial).

Os efeitos de correlação e heterogeneidade espacial são relevantes para o estudo de indicadores. A correlação espacial pode ser definida como a existência de uma relação funcional entre o que acontece em um determinado ponto no espaço e no que acontece em

outros lugares; ou seja, quando o valor de uma variável de interesse numa certa região  $i$  depende do valor dessa variável nas regiões vizinhas  $j$ . Isto pode explicar, por exemplo, impactos das comunicações, transporte, infraestrutura, agroindústria, economia de escala; os efeitos do processo de difusão, quando a inovação realizada num município é imitada e popularizada em outros, ou os efeitos *spillover*, que faz referência ao momento em que o desenvolvimento de uma região transborda, induzindo o desenvolvimento da região vizinha e a convergência regional; entre outras influências que determinam o desenvolvimento agropecuário (COSTA et al., 2013). A heterogeneidade espacial, por sua vez, busca os efeitos relacionados com a diferenciação espacial ou regional e é definida pela ausência de agrupamentos no espaço de variáveis de interesse (MORENO e VAYA, 2000). É interessante ressaltar também, conforme Almeida (2004), que nos processos espaciais existe uma imbricação entre estes dois efeitos, pois a heterogeneidade espacial gera dependência espacial e, por sua vez, a dependência espacial pode levar à heterogeneidade.

Para analisar a correlação espacial e a heterogeneidade, o primeiro passo é a definição da matriz de pesos ( $W$ ) que define a conectividade espacial entre nossas observações e pondera a variável de interesse. Cada observação na referida matriz está ligada a um conjunto de observações vizinhas, em conformidade com um padrão espacial definido exogenamente (BAUMONT et al. 2004). Esta matriz também é conhecida como matriz de vizinhança ou contiguidade.

A partir desta matriz é possível extrair medidas de associação espacial global e local.

A associação espacial global é definida como a coincidência de ubiquação espacial de valores e se manifesta quando os valores altos e baixos de uma variável tendem a agrupar-se no espaço. Ela pode ser avaliada pela estatística  $I$  de Moran, que estima o grau de associação linear no conjunto como um todo entre os valores observados e a média ponderada dos valores da vizinhança, chamada de valor defasado (ANSELIN, SYABRI e SMIRNOV, 2002).

O  $I$  de Moran é definido como:

$$I_i = \frac{N \sum_i \sum_j w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{(\sum_i \sum_j w_{ij}) \sum_i (x_i - \bar{x})} \quad (3)$$

em que:  $n$  é o total de áreas,  $w_{ij}$  é a medida de peso espacial de vizinhança,  $x_i$  e  $x_j$  denotam os valores observados para os municípios  $i$  e  $j$  respectivamente, e  $\bar{x}$  é a média dos valores observados.

Um valor do  $I$  de Moran maior (menor) que o valor esperado  $E(I) = -1/(N-1)$  sugere autocorrelação espacial positiva (negativa), indicando uma similitude (diferença) entre os vizinhos. Isto significa que, quando existe um  $I$  de Moran positivo, os valores altos da variável de interesse estão rodeados por áreas com valores altos e valores baixos estão rodeados por áreas de valores baixos. O valor de  $I$  de Moran varia de  $-1$  a  $1$ , ratificando que valores próximos de zero indicam a inexistência de autocorrelação espacial significativa entre os valores dos objetos e seus vizinhos. Desta forma, um valor próximo a um ( $1$ ) indica similitude entre os vizinhos enquanto  $-1$  indica diferença.

Obtido o índice de Moran, é necessário testar a hipótese de o resultado ser diferente de zero. Existem dois métodos para testar a hipótese. Caso a variável de interesse possua distribuição normal, padroniza-se a variável índice de Moran. O segundo método, vale para dados assimétricos, como os índices de ecoeficiência, que utiliza o teste de permutação de Monte Carlo.

Uma das formas de interpretar a estatística  $I$  de Moran é por meio do diagrama de dispersão. Conforme a Figura 1, ele apresenta, no plano cartesiano, o valor padronizado de uma variável  $z$  para cada uma das unidades nas abscissas e, no eixo das ordenadas, a média do valor padronizado da mesma variável para os vizinhos desta unidade  $W_z$ . O diagrama é

complementado pela representação de uma linha de regressão, cuja inclinação indica o valor de I de Moran, que, para o exemplo da Figura 1, é 0,86. Assim, quanto maior for a inclinação da linha em relação ao eixo horizontal, maior será o valor de autocorrelação espacial e vice-versa.

No entanto, quando muitos municípios são analisados é provável que ocorra diferentes regimes de autocorrelação espacial na região estudada e desta forma. Isto pode camuflar vários padrões locais de autocorrelação espacial. Nesses casos, os índices globais de Moran não seriam suficientes para explicar a distribuição espacial da região estudada. Portanto, Anselin (1995) sugerem um novo indicador que tem a capacidade de observar os padrões locais de associação linear, estatisticamente significativa, indicando a existência de cluster espacial local e regiões que mais contribuem para a existência de autocorrelação espacial. O indicador LISA (Local Indicator of Spatial Association) faz a decomposição do indicador global de autocorrelação na contribuição local de cada observação em quatro categorias, cada uma individualmente correspondendo a um quadrante no diagrama de dispersão de Moran.

Assim, de acordo com Almeida (2004), o diagrama Moran pode ser dividido em quatro quadrantes, que correspondem a quatro padrões de associação local espacial entre as regiões e seus vizinhos.

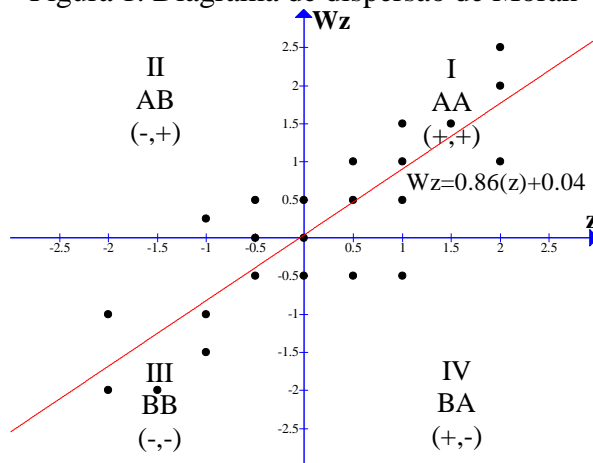
O quadrante I (localizado na parte superior direita) mostra as regiões que apresentam altos valores para a variável em análise, cercados por regiões que também apresentam valores acima da média para a variável em análise. Este quadrante é classificado como alto-alto (AA).

O quadrante II (localizado na parte superior esquerda) mostra as regiões com valores altos, cercados por vizinhos que apresentam valores baixos. Este quadrante é geralmente classificado como alto-baixo (AB).

O quadrante III (localizado no canto inferior esquerdo) é constituído pelas regiões com valores baixos para as variáveis em análise, cercados por regiões com baixos valores. Este quadrante é classificado como baixo-baixo (BB).

O quadrante IV (localizado no canto inferior direito) é formado pelas regiões com baixos valores para as variáveis em análise cercados por regiões de altos valores. Este quadrante é classificado como baixo-alto (BA).

Figura 1. Diagrama de dispersão de Moran .



A estatística I de Moran local pode ser obtida pela seguinte fórmula:

$$I_i = \frac{(x_i - \bar{x}) \sum_j w_{ij} (x_j - \bar{x})}{(\sum_i (x_i - \bar{x})^2) / n} \quad (4)$$

Um valor positivo e estatisticamente significativo do I de Moran local revela a existência de um *cluster* (municípios similares, alto-alto ou baixo-baixo). Pelo contrário, um valor negativo sugere um *outlier*, um município é contornado por municípios diferentes (alto-baixo ou baixo-alto).

### 3. Objeto de estudo e variáveis

São Paulo tem 645 municípios agrupados em 15 mesorregiões e gera o maior PIB do Brasil. Grande parte de seu PIB vem da indústria, serviços, finanças e, em menor escala, da agropecuária. Mesmo assim, o estado ocupa, desde 2010, o segundo lugar no ranking do PIB agropecuário brasileiro, gerando mais do 11% do total. O principal produto agropecuário paulista é a laranja, que atinge 80% da produção nacional. Em segundo lugar vem a cana-de-açúcar, que chega a ser 60% da produção do país. As mesorregiões com maior PIB agropecuário são: Ribeirão Preto, São José do Rio Preto, Campinas e Bauru.

Para realizar esta pesquisa foram tomadas as informações do último censo agropecuário, realizado em 2006 (IBGE, 2010) para os 645 municípios paulistas, considerando-se os *inputs* e *outputs* clássicos da produção agropecuária, mas inovou-se incorporando ainda uma externalidade positiva e outra negativa. Como na maioria dos casos (GOMES, 2008), os *inputs* usados na modelagem foram:  $x_1$  - Mão de obra nas propriedades em número de pessoas;  $x_2$  - Capital estimado pela depreciação (10% do valor dos ativos fixos);  $x_3$  - Área total dos estabelecimentos em ha;  $x_4$  - Outras despesas correntes realizadas pelos produtores, chamadas de custeio. Os *outputs* consideram três tipos de produtos:  $y_1$  - Produto desejável - Valor total da produção;  $y_2$  - Produto desejável ambiental - Áreas de matas e florestas naturais preservadas nas propriedades em ha;  $b_1$  - Produto indesejável ambiental - Áreas das terras degradadas nas propriedades em ha (o censo não inclui as terras abandonadas).

### 4. Resultados

Com base nas variáveis selecionadas e nos métodos descritos, chegou-se a resultados cujo exame foi realizado em duas partes. Na primeira, analisam-se os índices de ecoeficiência. Na segunda, avalia-se a distribuição espacial.

#### 4.1 Índices de ecoeficiência

Para os 645 municípios paulistas foram estimados os índices de ecoeficiência  $\beta$ . Na Tabela 1, registra-se o resumo estatístico dos municípios. Observa-se que o índice médio é 0,59. Isto indica que, em média, os municípios paulistas podem elevar o valor da produção total e as áreas destinadas em 58%, assim como reduzir as áreas degradadas e os insumos nesta mesma proporção, apenas imitando as melhores práticas, ou seja, tendo como referência os 26 municípios ecoeficientes destas regiões (com  $\beta=0$ ).

Tabela 1: Resumo dos índices de ecoeficiência,  $\beta$  (beta)

1º Quartil	0.4820	3º Quartil	0.7702
Média	0,5917	Desvio padrão	0,2369
Erro padrão	0,0093	Valor Mínimo (26 municípios)	0
Mediana	0,6633	Valor Máximo (1 município)	0,9617


Nota-se também que 75% dos municípios de São Paulo possuem um índice de ecoeficiência acima de 48,20% e 25% têm os piores índices, acima de 77%. A mediana está em 66%, ou seja, 50% dos municípios do estado de São Paulo possuem um nível de ecoineficiência igual ou maior a 66%. A amplitude dos resultados evidencia uma grande heterogeneidade na região, sendo os 26 municípios ecoeficientes caracterizados *outliers*, conforme se observa na Figura 2.



A Tabela 2, também revela o desempenho das macrorregiões. Ditos resultados identificam o Litoral Sul Paulista como a região mais ecoeficiente e Presidente Prudente e Marília como as mais ecoineficientes. Observa-se ainda que Ribeirão Preto é a macrorregião com maior número de municípios ecoeficientes, com aproximadamente 31% dos municípios *benchmarks* de São Paulo.

Com mais detalhes isto é observado na Figura 3, que georeferencia os índices de ecoeficiência Beta dos municípios. Quanto mais claro é o verde, maior é o beta. Neste mapa, intuitivamente, já se observa a presença de autocorrelação espacial em diversas regiões. Por um lado, nota-se a homogeneidade da ecoeficiência da mesorregião do Litoral Sul Paulista. Por outro, verifica-se a relativa homogeneidade da ecoineficiência nas regiões oeste do estado, principalmente em Presidente Prudente.

Figura 2: Boxplot de  $\beta$  dos municípios paulistas



Na Tabela 3, revelam-se os valores absolutos das melhorias necessárias para a ecoeficiência dos municípios paulistas. Esses resultados foram obtidos considerando-se tanto os índices de ecoeficiência ( $\beta$ ) quanto às folgas (slacks) estimadas pelo PPL (2). Fica evidente que a economia de recursos econômicos e ambientais é substancial e o potencial de crescimento da produção não é menos importante (R\$ 15 bilhões). Ribeirão Preto destaca-se nesta tabela, uma vez que é a mesorregião com maior nível de produção e com 58 municípios ecoineficientes. No sentido oposto, sobressai a mesorregião metropolitana, visto que é a menos agrícola.

#### 4.2 Análise exploratória de dados espaciais

Os índices de ecoeficiência municipais foram ainda analisados usando-se as técnicas de análise exploratória de dados.

O índice de global Moran, baseado numa matriz de vizinhança Queen normalizada para os 645 municípios, foi positivo, 0,2271, e estatisticamente significativo via simulação de Monte Carlo ( $p=0.0000$ ) e distribuição normal ( $p=0.0000$ ). O índice também foi superior ao valor esperado  $-0,0015$ . Isto indica a existência de autocorrelação positiva entre os índices de ecoeficiência dos municípios paulista. Em outras palavras, os municípios e seus vizinhos, no conjunto como um todo, apresentam valores de ecoeficiência próximos.

Para a análise dos índices de ecoeficiência com mais detalhes, utilizou-se o índice local de Moran (LISA). Os resultados estão registrados nas Figuras 4 e 5.

Na Figura 4, cada município é classificado conforme sua posição em relação aos quadrantes do diagrama de Moran. A cor vermelha representa o quadrante I (alto-alto), que reúne 273 municípios, equivalentes a 42,3% do total. A verde representa Q3 (baixo-baixo), congregando 155 municípios (24%). A soma de ambos confirma a maioria e a dependência

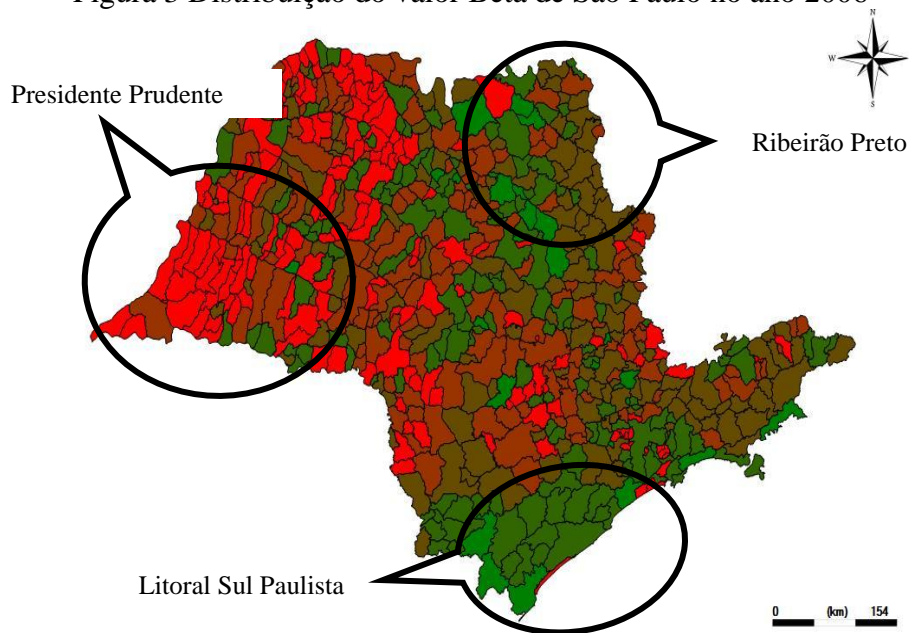
espacial positiva global. Os restantes dos municípios caracterizam-se com a cor laranja, representando Q2 (alto-baixo), e com a cor roxa, representando o quadrante Q4 (baixo-alto). Estes últimos municípios são chamados de áreas anômalas (*outliers*), já que não seguem o mesmo processo de dependência espacial apresentado pela maioria.

Na Figura 5, são visualizados os *clusters* mais significativos ( $>p=0,05$ ) das medidas de associação local (LISA).

É possível verificar a presença de dois grandes *clusters* do tipo baixo-baixo, ou seja, conglomerados que possuem níveis de ecoineficiência baixos em relação à média estadual e estão contornados por vizinhos também com baixa ecoineficiência. O maior é formado por alguns municípios das mesorregiões de Litoral Sul Paulista, Itapetininga e Metropolitana de São Paulo. A explicação deste comportamento deve estar no fato de que, nesta região, está concentrada a maior área de florestas e vegetação nativa de São Paulo, segundo o Inventário Florestal da Vegetação Natural do Estado de São Paulo (SÃO PAULO, 2005). O segundo maior cluster é formado pelas mesorregiões de Ribeirão Preto e Araraquara, economias fortemente voltadas para o agronegócio, com grandes agroindústrias e infraestrutura logística, onde encontram-se os municípios de maior produção de cana-de-açúcar do Estado e do Brasil.

O mapa apresenta também, um grande cluster ecoineficiente do tipo alto-alto, formado pela mesorregião de municípios de Presidente Prudente. Segundo SEADE (2016), a economia desta região está baseada praticamente na criação de gado, sector de grande impacto ambiental. Além disso, esta é uma das regiões de menor cobertura vegetal nativa do estado (SÃO PAULO, 2005).

Figura 3 Distribuição do valor Beta de São Paulo no ano 2006



Legenda.

Intervalo  $\beta$

0 – Ecoeficiência

[0,005 – 0,5199) Quartil com a inferior ecoineficiência

[0,52 – 0,6685) Quartil com média ecoineficiência

[0,6685 - 0,772) Quartil com alta ecoineficiência

[0,772 – 0.962] Quartil com a superior ecoineficiência

Cor



Figura 4. Distribuição da classificação da dependência espacial da ecoeficiência


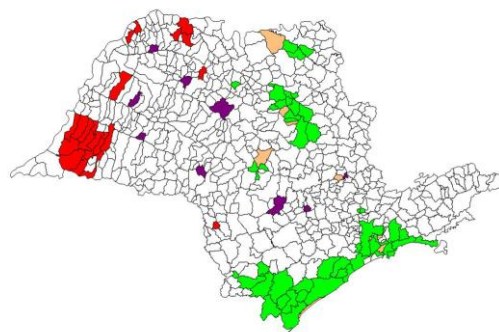


Figura 5. Clusters espaciais para o índice de ecoeficiência



Legenda. Metodologia: LISA

Classificação  
Não significativo  
Alto-Alto  
Alto-Baixo  
Baixo-Baixo  
Baixo-Alto




Tabela 2. Média dos índices  $\beta$  e número de municípios ecoeficientes por Mesorregião

Mesorregião	Media	Ecoeficientes	Mesorregião	Media	Ecoeficientes	Mesorregião
Litoral Sul Paulista	0,3097	3	Vale do Paraíba Paulista	0,5554	1	Piracicaba
Ribeirão Preto	0,4835	8	Bauru	0,5854	2	São José do Rio Preto
Araraquara	0,5032	2	Campinas	0,5911	2	Araçatuba
Metropolitana de São Paulo	0,5126	2	Itapetininga	0,6039	1	Marília
Macro Metropolitana Paulista	0,5437	2	Assis	0,6277	0	Presidente Prudente

Tabela 3. Melhoras para a ecoeficiência dos municípios por mesorregiões

Mesorregião	$x_4$ – Custeio (R\$ 1000)	$x_2$ – Capital (R\$ 1000)	$x_1$ – Mão de obra	$x_3$ – Área (ha)	$b_1$ – Áreas degradadas (ha)
São José do Rio Preto	-1093298,52	-385593,7674	-121113,31	-1501945,244	-2818,20
Ribeirão Preto	-2024594,158	-291400,0873	-76799,41	-1224187,28	-2727,76
Araçatuba	-499939,4213	-192328,3032	-40178,20	-842780,6204	-769,27
Bauru	-2369549,61	-325219,3954	-61455,41	-1308267,347	-1590,63
Araraquara	-363072,148	-106119,7609	-25515,39	-332278,1061	-242,72
Piracicaba	-644422,3557	-128956,0915	-20021,51	-346609,1077	-270,48
Campinas	-584445,3004	-347637,6772	-68574,81	-602350,3322	-883,30
Presidente Prudente	-926674,7411	-242686,3095	-72928,17	-1587731,487	-772,02
Marília	-173592,9446	-91427,7073	-17167,59	-444737,9349	-728,55
Assis	-542317,5049	-157226,0469	-38271,74	-665007,6009	-485,30
Itapetininga	-549819,333	-206426,2561	-45265,15	-769526,032	-1916,94
Macro Metropolitana	-225236,2114	-148101,3339	-46572,07	-352233,8848	-865,86
Vale do Paraíba Paulista	-175652,2231	-96874,22393	-26220,49	-435660,3017	-1127,04
Litoral Sul Paulista	-47502,6781	-20262,67816	-11120,44	-109981,4008	-360,77
Metropolitana de S.P.	-41927,77478	-30748,20555	-13322,90	-59184,60794	-258,71
Total para o estado	-10262044,92	-2771007,844	-684526,58	-10582481,29	-15817,50

## 5. Conclusões

A presente pesquisa estimou um índice de ecoeficiência para o estado de São Paulo, a partir da teoria da produção, do método não paramétrico Análise Envoltória de Dados com funções distância direcionais e das técnicas Análise Exploratória de Dados Espaciais. Desta forma, atende-se uma importante demanda no que diz respeito ao estudo da eficiência econômico-ambiental e sua distribuição espacial.

Os resultados indicam que, em média, os municípios paulistas podem elevar a produção e as áreas de floresta em 59%, bem como reduzir as áreas degradadas e os insumos na mesma proporção, apenas tendo como referência as melhores práticas da região. Esses indicadores reforçam a hipótese de que é possível a formulação de políticas consistentes com a maximização do bem-estar social, com a finalidade de otimizar, simultaneamente, os objetivos econômicos e ambientais. Portanto, pode-se concluir que a discussão das questões econômicas e ambientais não resulta necessariamente em um *trade-off* ou um jogo de soma zero.

Os resultados da análise espacial da ecoeficiência demonstraram que existe autocorrelação espacial entre os municípios como um todo. As melhores práticas se encontram nos municípios situados nas mesorregiões de Litoral Sul Paulista e Ribeirão Preto e as piores concentram-se na região Oeste do estado.

Mediante o índice local de Moran, verificou-se também a existência de dois grandes *clusters* significativos do tipo BB e um do tipo AA. O primeiro do tipo BB está situado nas mesorregiões de Litoral Sul Paulista, Itapetininga e Metropolitana de São Paulo e o outro nas mesorregiões de Ribeirão Preto e Araraquara. O *cluster* do tipo AA situa-se na mesorregião de Presidente Prudente.

Estes resultados indicam que as estratégias de desenvolvimento sustentável regional da agropecuária do estado devem, por um lado, considerar a dependência espacial no planejamento geral, mas, por outro lado, precisam ponderar a heterogeneidade local na definição de políticas específicas para cada região.

## Referências

ALMEIDA, E. S. (2004), **Curso de Econometria Espacial Aplicada**. Piracicaba.

ANSELIN, Luc (1995). Local Indicators of Spatial Association *lisa*. **Geographical Analysis**, vol. 27, pp. 93-115.

ANSELIN, Luc, IBNU, Syabri y OLEG Smirnov (2002), **Visualizing Multivariate Spatial Correlation with Dynamically Linked Windows**, Urbana, Regional Economics Application Laboratory (real), University of Illinois.

ARANDIA, A.; ALDANONDO-OCHOA, A. (2011). Pollution shadow prices in conventional and organic farming: An application in a mediterranean context. **Spanish Journal of Agricultural Research**, 9, 363-376.

BAUMONT, C.; CEM, E.; JULIE, L. G. (2004). Spatial Analysis of Employment and Population Density: The Case of the Agglomeration of Dijon 1999. **Geographical Analysis**, vol. 36, núm. 2, pp. 146-176.

CAMPOS, S. A. B.; COELHO, A. B.; GOMES, A. P.; MATTOS, L. B. (2014). Eficiência e custos associados à adequação ambiental para a produção láctea em Minas Gerais. **Organizações Rurais & Agroindustriais**, v. 16, n. 3, p. 324-342.

CHUNG, Y.; FARE, R.; GROSSKOPF, S. (1997). Productivity and Undesirable Outputs: A Directional Distance Function Approach. **Journal of Environmental Management**, 229-24.

COSTA, Caio César de Medeiros et al . Determinantes do desenvolvimento do setor agropecuário nos municípios. **Rev. Adm. (São Paulo)**, São Paulo, v. 48, n. 2, p. 295-309, June 2013.

FARE, R.; V, S. (2000). Theory and application of directional distance functions. **Journal of Productivity Analysis**, v. 13, p. 93-103.

FARE, R; GROSSKOPF, S.; WEBER , W. L. (2006). Shadow prices and pollution costs in US agriculture. **Ecol Econ.**, 56, p. 89-103.

INSTITUTO DE MANEJO E CERTIFICAÇÃO FLORESTAL E AGRÍCOLA (IMAFLOA), (2015). **Documento de análise: evolução das emissões de gases de efeito estufa no Brasil (1970-2013):** setor agropecuário. São Paulo. Observatório do Clima.

IPCC, 2006. NO<sub>2</sub> emission from managed soil and CO<sub>2</sub> emission from lime and urea application. In: **Guidelines for National Greenhouse Gas Inventories. Agriculture, Forestry and Other Land Use. Geneva, Switzerland**, vol. 4.

LAMPE, H. W.; HILGERS, D. Trajectories of efficiency measurement: A bibliometric analysis of DEA and SFA. **European Journal of Operational Research**, 240, Issue 1, 1, January, 2015.

MORENO, R.; VAYÁ, E. (2000), **Técnicas econométricas para el tratamiento de datos espaciales: la econometría espacial.** Edicions Universitat de Barcelona, colecció UB 44, manuals.

PADRÃO, G. A. et al. (2012). Environmental efficiency and opportunity cost of the Forest Code for the Amazon. **RIO+20 - International Society for Ecological Economics Conference.** Rio de Janeiro: [s.n.].

ROSANO-PEÑA, C. et al. (2014). A measure of sustainability of Brazilian agribusiness using directional distance functions and data envelopment analysis. **International Journal of Sustainable Development and World Ecology**, v. 21, p. 210-222.

ROSANO-PEÑA, C.; DAHER, C. E. (2015). The Impact of Environmental Regulation and Some Strategies for Improving the Eco-Efficiency of Brazilian Agriculture. In: GUARNIERI, P. **Decision Models in Engineering and Management.** London: Springer, p. 295-322.

ROSANO-PEÑA, C; SERRANO, A. L. M.; BRITTO, P. A. P. Uma medida da Sustentabilidade Ambiental da Agropecuária Amazônica Utilizando Fronteiras Estocásticas Multiprodutos. **Anais.** Belo Horizonte/MG, XXXIX ENANPAD, Set, 2015.

SÃO PAULO. **Inventário Florestal da Vegetação Natural do Estado de São Paulo.** São Paulo: Secretaria do Meio Ambiente / Instituto Floresta, Imprensa Oficial, 2005.

SEADE – FUNDAÇÃO SISTEMA ESTADUAL DE DADOS. **ECONOMIA.** Disponível em <http://produtos.seade.gov.br/produtos/anuario>. Acesso em 10 Julho de 2016.

TILMAN, D. (1999). Global environmental impacts of agricultural expansion: the need for sustainable and efficient practices. **Proc. Natl. Acad. Sci. USA.** 96, 5995 e 6000.

VAN PASSEL, S. et al (2007). Measuring farm sustainability and explaining differences in sustainable efficiency. **Ecological Economics.** 62: 149-161.

VAN PASSEL, S. et al (2009). Sustainable value assessment of farms using frontier efficiency benchmarks. **Journal of Environmental Management.** 90: 3057–3069.

WORLD BUSINESS COUNCIL FOR SUSTAINABLE DEVELOPMENT  
WBCSD. **Measuring ecoefficiency**, A guide to reporting company performance.  
Geneva: WBCSD, 2000.

ZHANG, B. et al (2008). Eco-efficiency analysis of industrial system in China:  
A data envelopment analysis approach. **Ecological Economics**, 68(1-2), 306- 316.