

ANÁLISE ECONOMÉTRICA DOS FERTILIZANTES E DEFENSIVOS NA PRODUTIVIDADE DA SOJA NO RIO GRANDE SUL

JANEQUE, Ricardina António¹

COSTA, Nilson Luiz²

RHODEN, Angélica Cristina³

GABBI, Maiara Thaís Tolfo⁴

RESUMO. O objetivo deste artigo foi estimar a função da produtividade da soja no Rio Grande do Sul, a partir do modelo geral de regressão linear múltipla. Antes da análise dos dados, testou-se as hipóteses clássicas do modelo de regressão e para confirmar-se a não violação destas foram feitos teste de White para avaliar a heterocedasticidade dos resíduos, teste LM para avaliar a autocorrelação dos resíduos e teste de FVI para avaliar a multicolinearidade dos resíduos. A análise dos resíduos permitiu constatar que o termo de erro estocástico possui distribuição normal, com média igual a zero, variância constante, o que afasta a possibilidade de heteroscedasticidade, não existe autocorrelação entre os erros, as variáveis explicativas X_i possuem observações fixas e não correlacionadas com o termo de erro, os erros possuem distribuição normal, e que não existe exata combinação linear entre as variáveis explicativas. O teste F de significância do modelo ($F=0,000028$) mostrou evidências estatísticas de que pelo menos uma variável no modelo está relacionada com a produtividade de soja. As quantidades de fertilizantes e as de defensivos explicam, simultaneamente, 72% das variações do Valor Bruto da Produtividade de Soja nos anos 1999 á 2016.

Palavras-Chave: Produtividade de soja. Rio grande do Sul. Fertilizantes. Defensivos.

ABSTRACT. The objective of this article was to estimate the soybean productivity function in Rio Grande do Sul, based on the general multiple linear regression model. Before the analysis of the data, we tested the classical hypotheses of the regression model and to confirm the non-violation of these were made White test to evaluate the heteroscedasticity of the residues, LM test to evaluate the autocorrelation of the residues and FVI test for to evaluate the multicollinearity of the waste. The analysis of the

¹ Engenheira Agrônoma pela UniZambeze. Mestranda do Programa de Pós-Graduação em Agronegócio-PPGAGR-UFSM. E-mail: ricardinajaneque17@gmail.com

² Docente e Coordenador do PPGAGR/UFSM. E-mail: nilson.costa@ufsm.br

³ Tecnóloga em Agronegócio. Mestranda do PPGAGR/UFSM. E-mail: angelicarhoden.iff@gmail.com

⁴ Economista. Mestranda do PPGAGR/UFSM. E-mail: maiaratolfo@gmail.com

residuals allowed to verify that the term of stochastic error has normal distribution, with average equal to zero, constant variance, which removes the possibility of heteroscedasticity, there is no autocorrelation between the errors, the explanatory variables X_i have fixed and uncorrelated observations with the error term, the errors have normal distribution, and that there is no exact linear combination between the explanatory variables. The F test of significance of the model ($F = 0.000028$) showed statistical evidence that at least one variable in the model is related to soybean yield. The amounts of fertilizers and pesticides account for 72% of the changes in the Gross Value of Soya Productivity between 1999 and 2016.

Keywords: Soybean yield. Rio Grande do Sul. Fertilizers. Defensive.

1.INTRODUÇÃO

A produção brasileira de soja tem aumentado, nas últimas décadas, em razão da utilização de novas tecnologias, das políticas do governo e dos investimentos da iniciativa privada, resultando em melhoria da produtividade e da competitividade da soja nacional. Os produtores passaram a adotar, em suas propriedades, a mecanização, os insumos modernos e as novas técnicas de plantio e colheita, como técnicas de semeadura, controle de pragas, adubação e sistema mecanizado de colheita (MUNDSTOCK, 2013).

A partir dos anos 1990, a produção agrícola do Rio Grande do Sul apresentou ganhos de produtividade, resultado das pesquisas realizadas pela Embrapa e também dos maiores níveis de mecanização (LANDGRAF, 2005, p.1). A produção de soja vem aumentando nas lavouras brasileiras e gaúchas, em termos de área e produtividade. Mesmo afetado pelas condições climáticas, o Rio Grande do Sul estava como terceiro maior produtor de soja brasileiro em 2010. Isso foi possível, graças a pesquisas, novas tecnologias e sementes geneticamente modificadas utilizadas nas lavouras gaúchas. Além destes fatores, o aumento da produtividade foi para atender a demanda mundial pelo grão, que já não estava sendo suprida pelos grandes produtores, como China e EUA, por apresentarem áreas limitadas para expansão das lavouras (ANHOLETO e MASSUQUETTI, 2014).

A expressão do potencial produtivo da soja depende do meio ambiente (incidência de luz solar, temperatura, etc.), de técnicas adequadas de cultivo (preparo do solo, controle de pragas e doenças, sistema de plantio, cultivares, etc.), dos fatores físicos do solo (matéria orgânica, umidade, temperatura, textura, etc.), dos fatores

químicos do solo (excesso de acidez, Al e Mn ou deficiência de P, K, Ca, Mg, S, micronutrientes, etc.) e, principalmente, do suprimento do nitrogênio (N) para a planta, que é o nutriente mais exigido pela cultura (CAMPO e HUNGRIA, 2000).

Neste contexto, o objetivo deste artigo é estimar a função da produtividade da soja no Rio Grande do Sul. O estudo busca encontrar respostas das quantidades de fertilizantes e de defensivos na produtividade de soja, pois estes factores são de tamanha importância, contudo, para que uma cultivar apresente respostas do seu potencial produtivo é necessário que no solo tenha nutrientes necessários para que a planta possa absorver e também é de imprescindível importância a isenção de pragas e doenças, isso tudo para garantir bom crescimento, desenvolvimento e sobretudo uma produtividade potencial.

2. REFERENCIAL TEÓRICO – METODOLÓGICO

A soja [*Glycine max* (L.) Merrill], originária da Ásia Oriental, é uma oleaginosa cultivada em quase todo mundo e faz parte do conjunto de atividades agrícolas com maior destaque no mercado mundial (EMBRAPA, 2014). A produção de soja está concentrada, principalmente, em três países: Estados Unidos, Brasil e Argentina, que respondem por cerca de 71,5% e 81,5%, respectivamente, da área e da produção mundial da oleaginosa (USDA, 2011). Ressalta-se que o Brasil e Argentina são responsáveis por 46,2% dessa produção global.

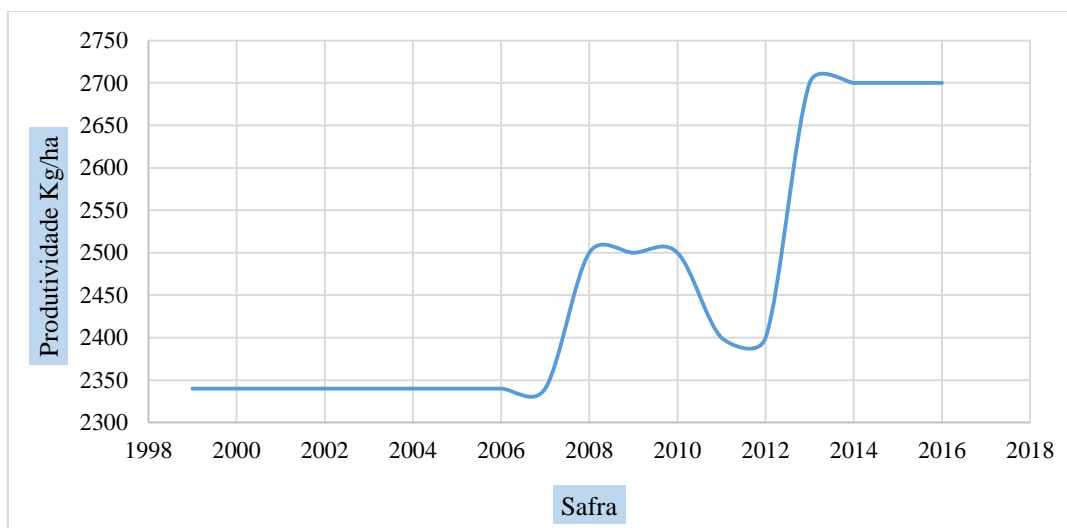
O crescimento da cultura da soja no país esteve sempre associado aos avanços científicos e a disponibilização de tecnologias ao setor produtivo. A mecanização e a criação de cultivares altamente produtivas adaptadas às diversas regiões, o desenvolvimento de pacotes tecnológicos relacionados ao manejo de solos, ao manejo de adubação e calagem, manejo de pragas e doenças, além da identificação e solução para os principais factores responsáveis por perdas no processo de colheita, são fatores promotores desse avanço (FREITAS, 2011).

Esta percepção do papel das inovações tecnológicas no processo desenvolvimento das atividades econômicas foi objecto de análise de SCHUMPETER (1988), o qual concluiu que as mudanças tecnológicas provocaram modificações na utilização dos recursos naturais, na elevação da produtividade, nos custos produtivos, e na geração de renda.

No Rio Grande Sul, os fertilizantes e correctivos da acidez do solo são factores que exercem influência significativa na produtividade final das culturas, pelas características naturais dos solos da região (SIQUEIRA, 1988). A forte demanda por soja e seus derivados ao redor do mundo sinalizam alertas quando a importância de melhorar cada vez mais os níveis de produtividade e, para tanto, os fertilizantes tem papel fundamental. Além da relação direta com a nutrição mineral das plantas e sua produção, estes insumos representam cerca de 25% do custo de produção da oleaginosa (CONAB, 2012).

Redução no processo de rotação de lavouras, que criam condições favoráveis a determinadas pragas e desfavoráveis para outras; desequilíbrios ecológicos; e até mesmo a expansão do comércio internacional de produtos agrícolas são factores que contribuem para a ocorrência de pestes na atividade agrícola (YUDELMAN *et al.*, 1998). Dentre os diversos mecanismos destinados a controlar as pestes é o emprego de produtos químicos, como os defensivos agrícolas. Os defensivos agrícolas, também conhecidos como agrotóxicos, pesticidas ou praguicidas, são substâncias ou misturas de substâncias químicas utilizadas para prevenir, destruir, repelir ou inibir a ocorrência ou efeito de organismos vivos capazes de prejudicar as lavouras agrícolas (NATIONAL RESEARCH COUNCIL, 2000).

FIGURA 1: Evolução da produtividade da soja no Rio Grande Sul (1999-2016).



Fonte: Elaboração própria, com base nos dados a CONAB/DIGEM/SUINF/GECUP.

2.1. PROCEDIMENTO METODOLÓGICO

Segundo RUDORFF (1985), os modelos de estimativa de produtividade visam representar de forma simplificada a relação existente entre a cultura, os factores de produção e o ambiente.

O presente estudo é baseado na análise de dados em forma de séries temporais (dados anuais de 1999 à 2015) relacionadas às atividades agrícolas da cadeia produtiva da soja no Rio Grande Sul. As variáveis utilizadas foram: quantidade de fertilizante e quantidade de defensivos. Os dados referentes a essas variáveis foram obtidos na *CONAB/DIGEM/SUINF/GECUP* (2017).

Modelo geral de regressão linear múltipla (RLM) é uma técnica econométrica que pode ser utilizada para analisar a relação entre uma variável dependente e duas ou mais variáveis independentes. O objetivo do modelo de RLM é utilizar variáveis independentes cujos valores são conhecidos para prever os valores da variável dependente selecionada (SANTANA, 2003).

O modelo econométrico foi definido seguindo a lógica do modelo proposto por (SOLOW, 1956; BARBOSA, 1985; SOARES, SILVA e LIMA, 2007; SILVA, 1996; GUJARATI, 2006; e SAENS, LOBOS e RIVERA, 2008 *apud* COSTA *et al.*, 2015), em que adaptou-se uma função de produção do tipo Cobb-Douglas (Equação 1), para representar a forma como os fatores de produção são combinados para gerar a produtividade agrícola no Estado do Rio Grande Sul.

$$Y = \beta_0 X_1^{\beta_1} X_2^{\beta_2} X_3^{\beta_3} \dots X_k^{\beta_k} \epsilon \quad (\text{Equação 1})$$

Em que: Y = Produtividade agrícola (soja); X₁, X₂, X₃...X_k = factores de produção; $\beta_0, \beta_1, \beta_2, \beta_3 \dots \beta_k$ = parâmetros a serem estimados; ϵ = termo de erro aleatório.

A partir da Equação 1, estimou-se a equação da produtividade da soja no Rio Grande Sul (Equação 2) que permite analisar, segundo BARBOSA (1985) *apud* COSTA *et al.* (2015), “a relação técnica que associa a cada dotação de factores de produção a máxima quantidade de produto obtida a partir da utilização desses factores”.

$$PROD = \beta_0 + \beta_1 * FER + \beta_2 * DEF + \epsilon_i \quad (\text{Equação 2})$$

Onde: **PROD** = é a Produtividade da Soja no Rio Grande Sul; β_0 = é a constante da primeira parte do modelo; β_1 e β_2 = são os parâmetros estimados pelo modelo; **FER** = é a quantidade de fertilizantes; **DEF** = é a quantidade de defensivos; e ϵ_i – é o termo de erro aleatório.

Segundo SANTANA (2003) o emprego do modelo de regressão linear clássico (RLC- simples ou múltipla) para a análise de fenômenos reais da economia prescinde da aceitação das hipóteses clássicas, que são impostas à construção do modelo. Ou seja, as hipóteses intrínsecas ao modelo de RLC devem ser atendidas para que os resultados

obtidos da estimação do modelo sirvam de base para outros estudos, para a orientação de políticas ou para a tomada de decisão.

É sobre o termo de erro que as hipóteses do modelo de regressão são construídas, o que justifica uma análise mais detalhada dos principais problemas, que podem levar à violação de tais hipóteses e, em consequência, comprometer os resultados gerados a partir da estimação por MQO (SANTANA, 2003). As hipóteses clássicas são:

- a) a de que os parâmetros são lineares;
- b) a de que a média do termo de erro é nula, $E(\mathcal{E}_i) = 0$;
- c) a de que a variância do termo de erro é constante, $E(\mathcal{E}_i^2) = \sigma^2$, ou seja, os dados são homoscedásticos;
- d) a de que não existe autocorrelação entre os erros, $cov(\mathcal{E}_i, \mathcal{E}_h) = 0, \forall(i \neq h)$;
- e) a de que as variáveis explicativas X_i possuem observações fixas e não correlacionadas com o termo de erro (\mathcal{E}_i);
- f) a de que os erros possuem distribuição normal, $\mathcal{E}_i \sim N(0, \sigma^2)$; e
- g) a de que não existe exata combinação linear entre as variáveis explicativas, ou seja, não existe colinearidade entre as variáveis.

Para se confirmar a não violação das hipóteses clássicas foram realizados o teste de White para avaliar a heterocedasticidade dos resíduos, o teste LM para avaliar a autocorrelação dos resíduos e teste de FVI para avaliar a multicolinearidade dos resíduos. O estudo contou com o auxílio do Software *Microsoft Excel 2013* e *EViews* versão 9 (x64).

A multicolinearidade diz respeito ao caso em que duas ou mais variáveis explicativas, no modelo de regressão múltipla, são altamente correlacionadas (colineares), tornando difícil ou impossível separar seus efeitos individuais sobre a variável dependente (SANTANA, 2003).

Neste estudo foi usado método do fator de variância inflacionária (FVI) e o teste de matriz de correlação. O FVI, para uma dada variável explicativa X_i , é definido pela fórmula abaixo (SNEE, 1973; MARQUARDT, 1980 *apud* SANTANA, 2003):

$$FVI = \frac{1}{1-R_i^2}$$

Onde: R_i^2 é o coeficiente de determinação da variável explicativa i , regressada contra todas as demais variáveis explicativas.

Se o conjunto de variáveis explicativas for não-correlacionado, o FVI é igual a um. Entretanto, se as variáveis apresentarem intercorrelação forte, o FVI pode exceder o valor 5. Um FVI superior a 5 indica que existe alta correlação entre as variáveis explicativas.

Para o teste de matriz de correlação (que mede o grau de correlação entre as variáveis explicativas) compara-se os valores do coeficiente de determinação múltipla da regressão, com o valor do coeficiente de correlação da matriz de correlação elevado ao quadrado. Então para aceitar-se a hipótese de ausência de multicolinearidade, o valor de R-squared deve ser maior que o valor do coeficiente de correlação ao quadrado.

A heteroscedasticidade, situação em que a variância do termo de erro das variáveis explicativas não é constante e afeta os parâmetros β associados às variáveis X_i (COSTA *et al.*, 2015), foi analisada pelo teste proposto por White (1980). Este método consiste em corrigir os dados com base em uma matriz de covariância consistente, que gera estimativas corretas para os coeficientes de covariância, na presença de heteroscedasticidade. Desse modo, consideraram-se as relações cruzadas de todas as variáveis explicativas, conforme pode ser observado na Equação 4.

$$\varepsilon_i^2 = \sigma_0 + \sigma_1 * X_1 + \sigma_2 * X_2 + v_i \quad (\text{Equação 3})$$

Em que: ε_i^2 é o termo de erro estocástico da regressão da Equação 2 elevado ao quadrado; σ_i são os parâmetros da regressão ($i = 1, 2$); v_i é o termo de erro aleatório.

A Autocorrelação, fenômeno comum em análises de séries temporais e que pode conduzir a desvios padrão viesados, ocorre quando o termo de erro (ei) em um período de tempo é positivamente, ou negativamente, correlacionado com o termo de erro do período de tempo anterior (SANTANA, 2003).

Geralmente, o teste mais empregado é o de Durbin-Watson para a identificação da autocorrelação serial de primeira ordem. Neste estudo, aplicando o teste de Durbin-Watson, os resultados obtidos encontram-se na “zona de indecisão” tendo-se recorrido ao teste de Breusch-Godfrey, também conhecido como teste LM.

3. RESULTADOS E DISCUSSÕES

Tabela 1. Resultados do modelo econométrico (estimação da Equação 2)

Dependent Variable: PROD
Included observations: 18

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	2060.007	73.12854	28.16967	0.0000
FERT	0.673178	0.152126	4.425126	0.0005
DEFEN	0.544622	0.287806	1.892326	0.0779
R-squared	0.753380	Mean dependent var		2453.333
Adjusted R-squared	0.720497	S.D. dependent var		147.7677
S.E. of regression	78.12192	Akaike info criterion		11.70543
Sum squared resid	91545.52	Schwarz criterion		11.85383
Log likelihood	-102.3489	Hannan-Quinn criter.		11.72589
F-statistic	22.91110	Durbin-Watson stat		1.264699
Prob (F-statistic)	0.000028			

Fonte dos dados brutos: CONAB/DIPAI/SUINF/GECUP (2017).

3.1. ANÁLISE DOS RESÍDUOS

A análise dos resíduos permitiu constatar que o termo de erro estocástico possui distribuição normal, com média igual a zero, $E(\mathcal{E}_i) = 0$, variância constante (Figura 2), o que afasta a possibilidade de heteroscedasticidade, não existe autocorrelação entre os erros, $cov(\mathcal{E}_i, \mathcal{E}_h) = 0$ (Tabela 2), as variáveis explicativas X_i possuem observações fixas e não correlacionadas com o termo de erro (\mathcal{E}_i), os erros possuem distribuição normal, $\mathcal{E}_i \sim N(0, \sigma^2)$ e que não existe exata combinação linear entre as variáveis explicativas, ou seja, não existe colinearidade entre as variáveis.

Ao analisar a Figura 2 abaixo, constata-se que a regressão não possui *outliers*, pois não ocorre de os resíduos passarem de -2 e de 2.

A ausência de heteroscedasticidade foi confirmada pelo Teste de Heteroscedasticidade de White, no qual se observa que todos os parâmetros da equação foram estatisticamente iguais a zero ao nível de 5% de probabilidade (Tabela 2). As estatísticas F-statistic e Obs*R-squared, iguais a 0.850208 e 4.708541, respectivamente, permitem aceitar a terceira hipótese nula do modelo de regressão de que não existe heteroscedasticidade nos dados, pois F-statistic e Obs*R-squared são maiores que 5%, e a probabilidade também não possui valores menores que 0,10, confirmando-se que os resíduos são homoscedásticos ou seja não há heteroscedasticidade nos resíduos.

A ausência de multicolinearidade foi confirmada pelo Teste de Fator de Variância Inflacionária (FVI), no qual se observa que o FVI é menor que 5, indicando

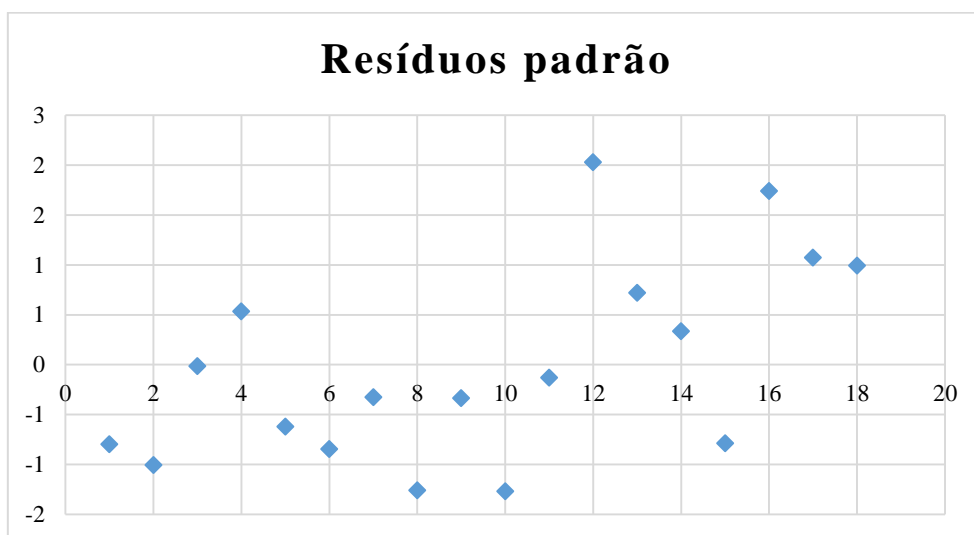
pois, que não há forte intercorrelação entre as variáveis explicativas, ou seja, a multicolinearidade não constitui um problema sério para essa regressão (Tabela 3).

Também utilizou-se a matriz de correlação para testar a multicolinearidade onde comparou-se os valores de R-squared com o valor do coeficiente de correlação da matriz de correlação elevado ao quadrado (Tabela 4). Observa-se que o valor da correlação (0,543827) entre as variáveis FERT e DEFEN é menor que o coeficiente de determinação múltipla da regressão (0.753380) levando a aceitar-se a hipótese de ausência de multicolinearidade.

Pelo teste de Durbin-Watson, na regressão linear Múltipla, temos $D=1.264699$, $du=1,53$ e $dl=1,05$ ($n=18$ e $k=2$); Para obter uma conclusão deste teste, é necessário comparar a estatística exibida aos limites inferiores (du) e superiores (dl). Observa-se que o D está entre os dois limites, logo, o teste é inconclusivo. Como o teste de Durbin-Watson deu inconclusivo, recorreu-se ao teste LM, em que, os resultados tanto da estatística F quanto do $n \cdot R^2$ (Tabela 5), indicam que não há problemas de autocorrelação serial de primeira ordem na regressão. Ou seja, o $F\text{-statistic}=0.4540$ e o $Obs \cdot R\text{-squared}=0.3571$ não possuem valores menores que 0,05, indicando portanto a não existência da autocorrelação.

Por tudo isso, admite-se que os resultados da regressão estão livres de vieses e robustos o suficiente para subsidiar a análise do modelo do presente estudo.

Figura 2. Resíduos da regressão estimada pela Equação 2



Fonte dos dados brutos: CONAB/DIPAI/SUINF/GECUP (2017).

Tabela 2. Teste de heteroscedasticidade de White

Heteroskedasticity Test: White				
F-statistic	0.850208		Prob. F(5,12)	0.5404
Obs*R-squared	4.708541		Prob. Chi-Square(5)	0.4525
Scaled explained SS	2.063986		Prob. Chi-Square(5)	0.8402
Test Equation: Dependent Variable: RESID^2 Included observations: 18				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	26745.09	30711.66	0.870845	0.4009
FERT^2	-0.038329	0.064384	-0.595316	0.5627
FERT*DEFEN	-0.222402	0.215114	-1.033880	0.3216
FERT	118.5289	81.84530	1.448206	0.1732
DEFEN^2	0.590801	0.353329	1.672099	0.1204
DEFEN	-299.2447	202.4440	-1.478161	0.1651
R-squared	0.261586		Mean dependent var	5085.862
Adjusted R-squared	-0.046087		S.D. dependent var	5880.074
S.E. of regression	6014.045		Akaike info criterion	20.50278
Sum squared resid	4.34E+08		Schwarz criterion	20.79957
Log likelihood	-178.5251		Hannan-Quinn criter.	20.54371
F-statistic	0.850208		Durbin-Watson stat	2.383035
Prob(F-statistic)	0.540426			

Fonte dos dados brutos: CONAB/DIPAI/SUINF/GECUP (2017).

Tabela 3. Factor de Variância Inflacionária

Variance Inflation Factors			
Included observations: 18			
Variable	Coefficient Variance	Uncentered VIF	Centered VIF
C	5347.783	15.77250	NA
FERT	0.023142	9.710702	1.419945
DEFEN	0.082832	22.16622	1.419945

Fonte dos dados brutos: CONAB/DIPAI/SUINF/GECUP (2017).

Tabela 4. Matriz de correlação

	FERT	DEFEN
FERT	1	
DEFEN	0,543827	1

Fonte dos dados brutos: CONAB/DIPAI/SUINF/GECUP (2017).

Tabela 5. Teste Breusch-Godfrey (ou teste LM)

Breusch-Godfrey Serial Correlation LM Test:

F-statistic	0.839743	Prob. F(2,13)	0.4540	
Obs*R-squared	2.059388	Prob. Chi-Square(2)	0.3571	
Test Equation:				
Dependent Variable: RESID				
Included observations: 18				
Presample missing value lagged residuals set to zero.				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	16.18561	76.54498	0.211452	0.8358
FERT	-0.028603	0.157764	-0.181304	0.8589
DEFEN	-0.016890	0.291479	-0.057946	0.9547
RESID(-1)	0.361097	0.283629	1.273132	0.2253
RESID(-2)	-0.019578	0.300450	-0.065163	0.9490
R-squared	0.114410	Mean dependent var	-2.01E-13	
Adjusted R-squared	-0.158079	S.D. dependent var	73.38277	
S.E. of regression	78.97018	Akaike info criterion	11.80615	
Sum squared resid	81071.75	Schwarz criterion	12.05348	
Log likelihood	-101.2554	Hannan-Quinn criter.	11.84025	
F-statistic	0.419872	Durbin-Watson stat	1.818234	
Prob(F-statistic)	0.791544			

Fonte dos dados brutos: CONAB/DIPAI/SUINF/GECUP (2017).

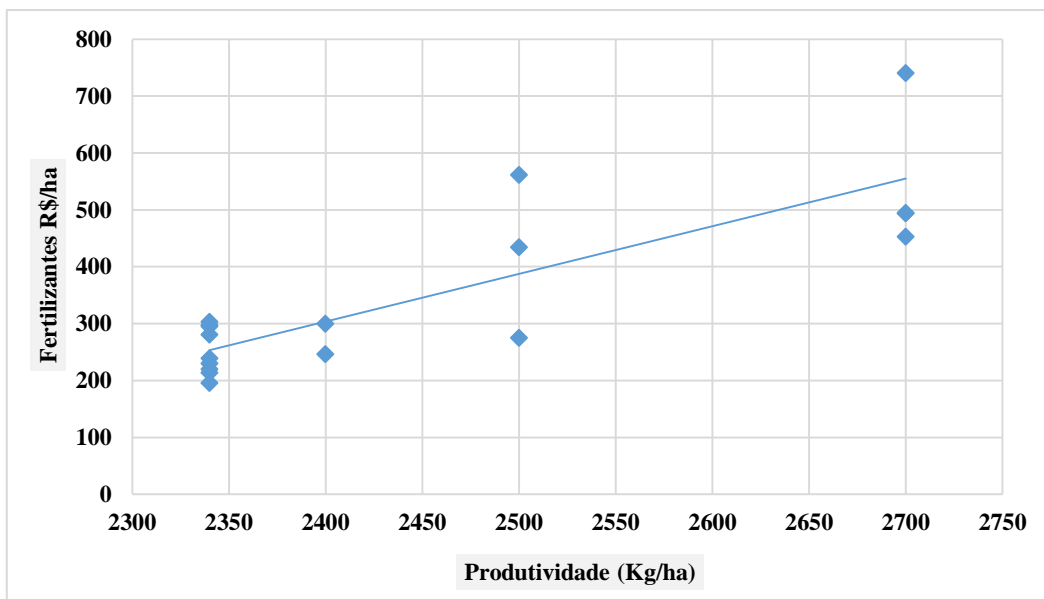
3.2. ANÁLISE ECONOMÉTRICA

Pela análise de Regressão Linear Múltipla, o teste F de significância do modelo ($F=0,000028 < 0,05$) mostra existir evidências estatísticas de que pelo menos uma variável no modelo está relacionada com a produtividade de soja. Então, o modelo é útil para estudar a produtividade da soja no Rio Grande Sul.

A análise da dispersão dos dados confirma o pressuposto teórico de que as relações entre a produtividade e os fatores (fertilizantes e defensivos) não são decrescentes. Nesse caso, a relação é positiva e direta, conforme observado nas Figuras 3 e 4.

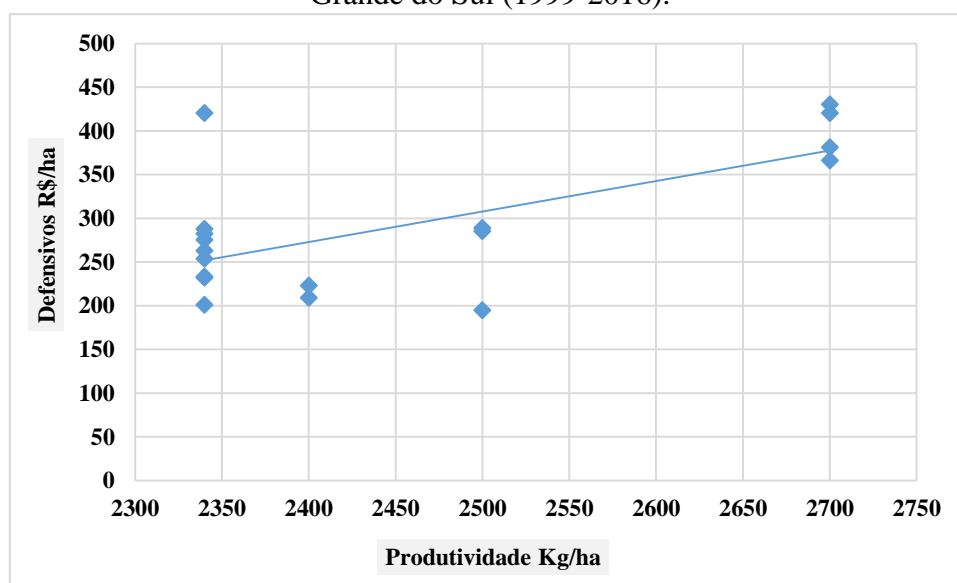
Com isso, observa-se que as maiores produtividades de soja no Rio Grande Sul se dão em resposta no uso de fertilizantes e uso de defensivos. Sendo que o consumo destes factores de produção se elevam cada vez mais no seio dos produtores, conduzindo também no aumento da produtividade.

Figura 3. Relação entre a quantidade de fertilizantes e a produtividade de Soja do Rio Grande do Sul (1999-2016).



Fonte dos dados brutos: CONAB/DIPAI/SUINF/GECUP (2017).

Figura 4. Relação entre a quantidade de fertilizantes e a produtividade de Soja do Rio Grande do Sul (1999-2016).



Fonte dos dados brutos: CONAB/DIPAI/SUINF/GECUP (2017).

A importância de cada fator, para a produtividade, foi analisada a partir da estimação econométrica. Os resultados (Tabela 1) mostram que os parâmetros associados às variáveis FER e DEFEN foram estatisticamente significativos ao nível 5%, e o sinal dos coeficientes associados às variáveis indica que ambas exercem influência positiva sobre a produtividade da soja. Logo, existem evidências estatísticas de que a produtividade de soja no Rio Grande Sul está relacionada com as quantidades de fertilizantes e as quantidades de defensivos, pois ambas possuem probabilidade $< 0,10$. A equação do modelo é:

$$PROD=2060.007 + 0.673178*FER + 0.544622*DEF + \varepsilon_i \quad (\text{Equação 5})$$

As quantidades de fertilizantes (FERT) e as quantidades de defensivos (DEFEN) explicam, simultaneamente, 72% (coeficiente de determinação ajustado por graus de liberdade 0,720497) das variações do Valor Bruto da Produtividade de Soja (PROD) nos anos 1999 á 2016.

O valor do intercepto (2060,007) indica a produtividade quando não são aplicados os fertilizantes e os defensivos. Como os dados do presente estudo não apresentam valores da produtividade com ausência dos factores de produção (fertilizantes e defensivos) não faz sentido a sua interpretação.

O parâmetro $\beta_1=0.673178$ associado a variável fertilizante, indica que a cada alteração de uma unidade nas quantidades de fertilizantes haverá aumento em 0,673178 na produtividade de soja, *ceteris paribus*.

O parâmetro $\beta_2=0.544622$ associado a variável defensivo, indica que para cada alteração de uma unidade nas quantidades de defensivo haverá incremento de 0,544622 na produtividade de soja, *ceteris paribus*.

Os sinais dos coeficientes da regressão estão coerentes com os resultados dos estudos apresentados no referencial teórico-metodológico, indicando que aumento do consumo de fertilizantes é um vetor fundamental para o aumento da produtividade de soja, um incremento do uso de defensivos induz a um aumento da produtividade de soja, *ceteris paribus*. Ou seja, para que uma cultivar possa dar seu potencial produtivo deve ter nutrientes necessários e estar isenta de pragas, doenças e infestantes durante sua fase de estabelecimento.

4. CONCLUSÃO

A produtividade é uma das medidas mais importantes para avaliar o desempenho de uma cultivar, pois, mede o nível de eficiência na utilização de factores de produção. O modelo econométrico neste estudo mostrou que os factores de produção, fertilizantes e defensivos, influenciaram, significativamente, de forma positiva e directa na produtividade de soja no Rio Grande Sul nos anos 1999 á 2016.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ANHOLETO, Carla Daiana; MASSUQUETTI, Angélica. 2011. **A Soja Brasileira E Gaúcha No Período 1994-2010: Uma Análise Da Produção, Exportação, Renda E Emprego**. Revista Economia e Desenvolvimento, v. 13, n. 2, p. 379-404, 2014.
- CAMPO, Rubens José; HUNGRIA, Mariangela. **Cultivar Grandes culturas**. Embrapa Soja. Edição número 20. Setembro de 2000.
- CONAB. Companhia Nacional de Abastecimento. **Intenção de plantio – primeiro levantamento**, outubro 2012.
- COSTA, Nilson Luiz; SANTANA, António Cordeiro de; MATTOS, Carlos André Corrêa de. 2015. **Análise dos determinantes da produção agropecuária do Rio Grande do Sul**. Ensaio FEE, Porto Alegre, v. 36, n. 1, p. 159-178, jun. 2015
- EMBRAPA. **O agronegócio da soja nos contextos mundial e brasileiro**. 2014.
- FREITAS, M.C.M. **A cultura da soja no brasil: o crescimento da produção brasileira e o surgimento de uma nova fronteira agrícola**. 2011.
- GUJARATI, D.N. **Basic econometrics**. 3 Ed. New York: McGraw-Hill. 1995.
- HOFFMANN, R.; VIEIRA, S. **Análise de regressão: uma introdução à econometria**. São Paulo: Hucitec. 1977.
- HORVAT, Renata Alves. **Estudo Do Consumo De Fertilizantes Na Região Do Matopiba E Seus Reflexos Na Produção De Soja No Brasil**. Trabalho de conclusão de curso de pós-graduação em Agronegócios da Universidade Federal do Paraná. 2012.
- LANDGRAF, Lebna. **Embrapa soja lança 22 cultivares em solenidade de aniversário de 30 anos**. Londrina, 2005.
- MUNDSTOCK, Claudio M. 2013. **A cultura da soja como fator de transformação e viabilização das propriedades agrícolas produtoras de grãos do RS: Uso de tecnologia e os efeitos na inclusão social e conservação ambiental**. In: Jornadas Fee-Fundação De Economia E Estatística, 2., Porto Alegre (RS). Anais...Porto Alegre: FEE, 2013.
- NATIONAL RESEARCH COUNCIL. **The future role of pesticides in US agriculture**. Washington, D.C., National Academy Press, 2000.
- RUDORFF, B. F. T. **Dados Landsat na estimativa da produtividade agrícola da cana-de-açúcar**. 100p. (INPE-3744-TDL/202). Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos. 1985.
- SANTANA, A. C. de. **Métodos quantitativos em economia: elementos e aplicações**. Belém: UFRA, 2003.
- SCHUMPETER, Joseph. **Teoria do desenvolvimento econômico**. São Paulo: Nova Cultural, 1988. (Os Economistas).
- SIQUEIRA, J.O. **Biotechnology do solo: fundamentos e perspectivas**. Lavras, MEC/ABEAS, 1988. 235 p.

SOARES, N. S.; SILVA, M. L. da; LIMA, J. E. de. **A função de produção da indústria brasileira de celulose, em 2004**. Revista *Árvore*, Viçosa, MG, v. 31, n. 3, p. 495-502, 2007.

SOLOW, R. M. A Contribution to the Theory of Economic Growth. **The quarterly journal of economics**, Cambridge, MA, v. 70, n. 1, p. 65-94, 1956.

USDA - UNITED STATES DEPARTMENT OF AGRICULTURE. 2011. **Production, Supply and Distribuiton** Online. Disponível em:
<<http://www.fas.usda.gov/psdonline/psdQuery.aspx>>.

WHITE, H. **A heteroskedasticity-consistent covariance matrix and a direct test for heteroskedasticity**. *Econometrica*, v. 48, n.6, p.817-838, 1980.

YUDELMAN, M.; RATTA, A.; NYGAARD, D. 1998. **Pest Management and Food Production: Looking to the Future**. Food, Agriculture, and the Environment Discussion Paper 25. International Food Policy Research Institute (IFPRI). Washington, D.C.