

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
DEPARTAMENTO DE ECONOMIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA

AROLDO COPELLI

PREVISÃO E ANÁLISE DOS PREÇOS DE FERTILIZANTES COM FORMULAÇÃO
NPK PARA ESTRATÉGIA DE COMPRA DOS PRODUTORES DE SOJA E MILHO DO
PARANÁ

PONTA GROSSA

2020

AROLDO COPELLI

PREVISÃO E ANÁLISE DOS PREÇOS DE FERTILIZANTES COM FORMULAÇÃO
NPK PARA ESTRATÉGIA DE COMPRA DOS PRODUTORES DE SOJA E MILHO DO
PARANÁ

Dissertação apresentado para obtenção do título de Mestre em
Economia na Universidade Estadual de Ponta Grossa. Área de
Economia Aplicada.

Orientador: Prof. Dr. Renato Alves de Oliveira.

PONTA GROSSA

2020

Copelli, Aroldo
C782 Previsão e análise dos preços de fertilizantes com formulação NPK para
estratégia de compra dos produtores de soja e milho do Paraná / Aroldo Copelli.
Ponta Grossa, 2020.
43 f.

Dissertação (Mestrado em Economia - Área de Concentração: Economia),
Universidade Estadual de Ponta Grossa.

Orientador: Prof. Dr. Renato Alves de Oliveira.

1. Fertilizantes. 2. SARIMA. 3. VAR. I. Oliveira, Renato Alves de. II.
Universidade Estadual de Ponta Grossa. Economia. III.T.

CDD: 330.9



UNIVERSIDADE ESTADUAL DE PONTA GROSSA
Av. General Carlos Cavalcanti, 4748 - Bairro Uvaranas - CEP 84030-900 - Ponta Grossa - PR - <https://uepg.br>

TERMO

AROLDO COPELLI

PREVISÃO E ANÁLISE DOS PREÇOS DE FERTILIZANTES COM FORMULAÇÃO NPK PARA ESTRATÉGIA DE COMPRAS DOS PRODUTORES DE SOJA E MILHO DO PARANÁ

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Economia, da Universidade Estadual de Ponta Grossa, pela seguinte banca examinadora:

Ponta Grossa, 14 de abril de 2020.

Prof. Dr. Renato Alves de Oliveira - Universidade Estadual de Ponta Grossa

Prof. Dr. Carlos Eduardo Caldarelli - Universidade Estadual de Londrina

Prof. Dr. Hermes Yukio Higachi - Universidade Estadual de Ponta Grossa



Documento assinado eletronicamente por **Renato Alves de Oliveira, Professor(a)**, em 14/04/2020, às 16:15, conforme art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **Hermes Yukio Higachi, Professor(a)**, em 14/04/2020, às 16:46, conforme art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **Carlos Eduardo Caldarelli, Usuário Externo**, em 16/04/2020, às 10:07, conforme art. 1º, III, "b", da Lei 11.419/2006.



A autenticidade do documento pode ser conferida no site <https://sei.uepg.br/autenticidade> informando o código verificador **0202127** e o código CRC **229C4B0E**.

Dedico aos meus pais, Valdir e Marta.

AGRADECIMENTOS

A Deus por ter me dado saúde e força para superar as dificuldades.

Ao Prof. Dr. Renato Alves de Oliveira, pela contribuição de seus conhecimentos e sugestões na orientação desta dissertação.

A todos os meus professores do curso de pós-graduação em economia da Universidade Estadual de Ponta Grossa pela excelência e qualidade técnica de cada um.

A todos meus amigos do curso de graduação que compartilharam dos inúmeros desafios que enfrentamos, sempre com o espírito colaborativo.

A Cristiane Gery de Souza, por ter me ajudado nessa jornada.

Por último, mas não menos importante aos meus pais Valdir e Marta e minha irmã Elki que sempre me incentivaram e apoiaram em todas as fases da minha vida.

No fundo, é um paradoxo: sou um perfeccionista que sabe que a perfeição jamais será atingida. E, se isso fosse possível, também não gostaria de alcançá-la. Seria o fim dos objetivos e eu não conseguiria viver sem eles.

(Bernardo Rocha de Rezende)

RESUMO

O trabalho se propôs analisar e prever o comportamento do preço dos fertilizantes com formulação NPK para o estado do Paraná durante o período de janeiro de 2014 a dezembro de 2018. Para as variáveis analisadas foram testados a presença de raiz unitária através do teste de Dickey-Fuller aumentado e Phillips-Perron. Na previsão da série temporal utilizou-se a modelagem ARIMA Integrado Sazonal (SARIMA), e em uma comparação entre valores observados e estimados, verificou-se que o modelo adotado se aproxima dos valores reais com um erro de previsão de no máximo 10%. Já para analisar a relação entre as variáveis utilizadas, optou-se pelo modelo de vetor autoregressivo (VAR), analisando as funções de impulso-resposta e decomposição da variância. Os resultados desse último modelo revelaram uma baixa relação das commodities com o preço dos fertilizantes, mas as flutuações do dólar podem ser repassadas em partes para os fertilizantes. Os dados encontrados servem como baliza para os agricultores na tomada de decisão.

Palavras-chave: Fertilizantes. SARIMA. VAR.

ABSTRACT

The work proposes to analyze and forecast the behavior of price of fertilizers with NPK formulation for the state of Paraná during the period between January 2014 and December 2018. For the analyzed variables, the presence of unit root was tested through the augmented Dickey-Fuller and the Phillips-Perron tests. During the forecast of the time series, the seasonal integrated ARIMA model (SARIMA) was used, and in one comparison between observed and estimated values, it was observed that the adopted model approaches real values with a maximum error of forecast of 10%. For analyzing the relation between the selected variables, the vector autoregressive model (VAR) was preferred, also analyzing the impulse response and the variance decomposition. The results of this last model revealed a small connection between the commodities and the fertilizer prices, however, the dollar fluctuation might be partially passed onto the fertilizers. The discovered data works as a beacon for agriculturists when making decisions.

Keywords: Fertilizers. SARIMA. VAR.

LISTA DE FIGURAS

Figura 1 -Produção de grãos e área plantada por safra no Brasil	13
Figura 2 - Produção de grãos por safra e venda de fertilizantes no Brasil	14
Figura 3 - Produção, Importação e venda de fertilizantes no Brasil.....	15
Figura 4 - Média preços fertilizantes com formulação NPK, preço do milho e preço da soja	16
Figura 5- Resposta da variável fertilizante a um choque não antecipado nas variáveis analisadas.....	33
Figura 6 - Resposta das variáveis analisadas a um choque não antecipado na variável fertilizantes	34

LISTA DE TABELAS

Tabela 1 - Tabela descritiva dos dados adotados na pesquisa.....	19
Tabela 2 - Teste de raiz unitária	29
Tabela 3 - Critério de escolhas dos modelos	29
Tabela 4 - Estimativa dos parâmetros do modelo 1 - SARIMA (0,2,1)(1,2,1)	29
Tabela 5 - Previsão do modelo SARIMA (0,2,1)(1,2,1)	30
Tabela 6 - Teste de raiz unitária	30
Tabela 7 - Resultado do teste de cointegração de Jhoansen.....	31
Tabela 8 - Critério de seleção da ordem de defasagem do modelo VAR.....	31
Tabela 9 - Coeficientes estimados do modelo VAR	32
Tabela 10 - Decomposição da variância dos erros de previsão em porcentagem da variável fertilizantes para a soja, milho, petróleo e dólar.....	35
Tabela 11 - Decomposição da variância dos erros de previsão em porcentagem da variável soja para o fertilizante, milho, petróleo e dólar	35
Tabela 12 - Decomposição da variância dos erros de previsão em porcentagem da variável milho para os fertilizantes, soja, petróleo e dólar	36

SUMÁRIO

1. INTRODUÇÃO	11
2. REVISÃO DE LITERATURA.....	13
2.1. O MERCADO DE FERTILIZANTES.....	13
2.2 ESTUDOS EMPÍRICOS.....	16
3. MATERIAL E MÉTODOS	19
3.1. MATERIAL	19
3.2. MÉTODOS ADOTADOS NA PESQUISA	20
3.2.1. Teste de raiz unitária de Dickey-Fuller aumentado	20
3.2.2. Teste de raiz unitária de Phillips-Perron	21
3.2.3. Método adotado para o modelo 1	22
3.2.3.1. Modelo Autoregressivo Integrado de Médias Móveis (ARIMA)	22
3.2.3.2. Modelos ARIMA Integrado Sazonal (SARIMA).....	23
3.2.4. Método adotado para o modelo 2	23
3.2.4.2 Vetor Autorregressivo (VAR)	24
3.2.4.2.1 Função resposta ao impulso	25
3.2.4.2.2 Decomposição da variância.....	27
4. RESULTADOS E DISCUSSÕES	28
4.1. RESULTADO MODELO SARIMA.....	28
4.2 RESULTADOS MODELO VAR.....	30
5. CONSIDERAÇÕES FINAIS.....	37
REFERÊNCIAS	38
BIBLIOGRAFIAS.....	40
ANEXOS	41

1. INTRODUÇÃO

A produção agrícola brasileira aumentou consideravelmente nos últimos anos impulsionada pela forte demanda internacional. Conforme Cella e Rossi (2010), o agronegócio brasileiro é um setor em constante crescimento e adaptação. Projeções apontam para a expansão das áreas cultiváveis, e atrelando a isso os avanços tecnológicos tendem a aumentar a produtividade e consequentemente a produção total. O agronegócio, sempre foi uma peça chave na economia brasileira, segundo dados do CEPEA (2019), o mesmo representava 21,1% do total do PIB em 2018.

Porém, existem alguns fatores que podem influenciar na produção e no lucro. A volatilidade do preço dos insumos, é uma variável importante, uma vez que custos altos podem diminuir lucros e assim desincentivando a produção, ou até mesmo encarecer o produto perante o mercado internacional.

Assim como o preço final das commodities, o preço dos insumos utilizados deve ser analisado, pois na diferença entre o custo de produção e o preço final encontra-se o lucro. Conforme Cella e Rossi (2010), em razão dos fertilizantes serem de grande importância para o desenvolvimento da produção, o aumento dos preços afeta fortemente o custo de produção.

Grande parte da produção de fertilizantes é dependente do mercado internacional, sendo, Rússia, Canadá, Marrocos, Estados Unidos e China os principais exportadores dos insumos para o Brasil. Segundo Horvat (2012), a partir dos anos 90, em decorrência de algumas privatizações, o Brasil conseguiu aumentar a produção nacional de fertilizantes, mesmo assim, a produção dos dias atuais supre aproximadamente 23% da demanda interna total.

A china é atualmente a maior demandante de fertilizantes no mundo, seguida pela Índia, Estados Unidos e Brasil. Ao contrário dos outros países, o Brasil vem se destacando no consumo de fertilizantes, uma vez que as áreas agricultáveis estão aumentando ano após ano.

Os fertilizantes são utilizados nas mais diversas culturas, mas segundo Horvat (2012) e Pignati et al. (2017) a soja e o milho consomem aproximadamente 50% das vendas totais de fertilizantes no Brasil, onde desse total a soja demanda 35% do total de fertilizantes entregues no país.

O objetivo desse trabalho é estudar os preços dos fertilizantes com a formulação NPK (Nitrogênio, Fósforo e Potássio) para o estado do Paraná durante o período de janeiro de 2014 a dezembro de 2018, de maneira mais específica: encontrar o melhor modelo para previsão dos preços dos fertilizantes através de um modelo ARIMA integrado sazonal (SARIMA); analisar a interdependência dos preços dos fertilizantes com os preços da soja, milho, petróleo e dólar

através de um modelo de vetor autorregressivo (VAR), apresentando também a relação de curto prazo através da decomposição da variância de erros de previsão e da função de impulso resposta.

Para tal análise, se utilizará dos preços por toneladas de seis formulações de composição NPK (nitrogênio, fósforo e potássio) para o estado do Paraná, disponibilizada pela Companhia Nacional de Abastecimento (CONAB), juntamente com os preços da saca de 60 Kg da soja e do milho para o estado do Paraná, a taxa de câmbio comercial (R\$/U\$), disponibilizados pelo IPEADATA e o preço do barril de petróleo disponibilizado pelo FMI.

O trabalho se justifica, uma vez que os métodos de previsão e análise da variável fertilizante, podem servir como baliza para decisão de compras dos fertilizantes para os produtores de soja e milho no Paraná, ajudando no entendimento dos movimentos dos preços no curto prazo.

O trabalho está dividido em cinco partes. Na introdução encontra-se o contexto inicial, onde é exposto o objetivo geral e específico do trabalho. A segunda parte se encontra a revisão de literatura, e nela é contextualizada o mercado de fertilizantes juntamente com alguns estudos empíricos relacionados. Na sequência são apresentados os dados e os dois métodos adotados no trabalho. Já a quarta parte, encontram-se os resultados dos dois modelos analisados. Por último são feitas as considerações finais.


2. REVISÃO DE LITERATURA

2.1. O MERCADO DE FERTILIZANTES

O Brasil é um dos grandes produtores internacionais de produtos agropecuários, cuja a participação desse segmento na economia é de grande importância. Em 2018 a agropecuária representou 5,1% do PIB brasileiro, enquanto que o agronegócio representou 21,1% (CEPEA, 2019). Embora a importância desse segmento atualmente seja bastante relevante na economia, algumas projeções para o agronegócio revelam um grande potencial, apontando um crescimento para áreas plantadas, para a produtividade e consequentemente a produção total (CELLA; ROSSI, 2010).

A figura 1, demonstra a evolução da produção de grãos e a área total plantada por safra. Nos anos 2000 a área plantada correspondia a aproximadamente 37,8 milhões de hectares, já a produção de grão era de aproximadamente 83 milhões de toneladas, desse modo cada hectare produzia na média 2,20 toneladas de grãos. Já em 2018 a área plantada e a produção de grãos foi de 61,7 milhões de hectares e 227,8 milhões de toneladas respectivamente, assim, a média produzida por hectare aumentou para aproximadamente 3,69 toneladas.

Figura 1 -Produção de grãos e área plantada por safra no Brasil




Fonte: Gráfico elaborado a partir de dados do IPEADATA (2019)

Alcarde, Guidolin e Lopes (1998), enumeram seis fatores que podem determinar a produção agrícola, tais como: clima, solo, planta, práticas culturais, incidências de pragas e doenças. De todos os fatores, o clima e o solo são os que ditam boa parte da capacidade produtiva. O Brasil se beneficia do clima, uma vez que possui grande parte do território em uma zona tropical, porém, algumas regiões possuem solos considerados pobres em nutrientes, necessitando assim da correção do mesmo através de fertilizantes.

A demanda por fertilizantes foi intensificada em meados das décadas de 1980 e 1990, dada pelo avanço em estudos voltadas a essa área e principalmente ao crédito rural. Conforme Nicolella, Dragone e Bacha (2005), o consumo médio de fertilizante por hectare, passou de 18,5 kg em 1970 para 146 kg em 2002. Já em 2019, levando em consideração a área plantada disponibilizada pelo IBGE (2020), o consumo médio de fertilizante por hectare se aproxima dos 450 kg.

A figura 2, demonstra a venda de fertilizantes e a produção de grãos por safra. Nota-se que em 2000 a venda de fertilizantes era de aproximadamente 16,3 milhões de toneladas, já em 2018 esse volume passou para aproximadamente 35,5 milhões de toneladas, um aumento em torno de 116%.

Figura 2 - Produção de grãos por safra e venda de fertilizantes no Brasil



Fonte: Gráfico elaborado a partir de dados do IPEADATA (2019)

Atualmente o mercado de fertilizantes é bem diversificado para suprir as necessidades do solo, dentre todos eles, os mais utilizados são os compostos com nitrogênio (N), fósforo (P) e potássio (K) conhecidos pela sua fórmula básica NPK. A formulação NPK é responsável pelo ganho de produtividade, onde seus benefícios são diversos, tais como: crescimento das raízes, acelerar o amadurecimento do fruto, equilíbrio das cargas no interior das células vegetais, melhora na qualidade dos grãos, controle de hidratação e doenças, entre outras (DIAS; FERNANDES, 2006).


Segundo a ANDA (2019), existiam duas commodities que consumiam aproximadamente 57% das vendas totais de fertilizantes no Brasil em 2004, a soja correspondia a 40% enquanto que o milho detinha 17% do total do consumo (DIAS; FERNANDES, 2006). Já em 2009 a soja

correspondia a 33% e o milho 17% do total do consumo de fertilizantes no Brasil (CELLA; ROSSI, 2010).

Conforme Dias e Fernandes (2006), o mercado brasileiro de fertilizantes possui características sazonais em relação as vendas, onde quase 70% das vendas ocorrem no segundo semestre quando acontece o plantio da safra de verão.

As vendas de fertilizantes no Brasil, se mostram crescentes ao decorrer dos anos em consequência do aumento das áreas cultivadas e também pelo aumento da utilização dos insumos para o melhoramento da produção. A figura 3 confirma esse crescimento no consumo, juntamente com os resultados da produção interna e das importações de fertilizantes.

Figura 3 - Produção, Importação e venda de fertilizantes no Brasil



Fonte: Gráfico elaborado a partir de dados da ANDA (2018)


Observa-se que a capacidade de produção nacional de fertilizantes vem se mantendo estável desde o ano de 2000, enquanto que a demanda e as importações seguem em ritmo crescente, onde em 2018 as vendas e as importações alcançaram aproximadamente 35 milhões e 27 milhões de toneladas respectivamente, enquanto que a produção nacional se manteve em 8 milhões de toneladas.

Conforme Horvat (2012), a produção de insumos agrícolas, depende de uma planta industrial com certa tecnologia embarcada, o que pode ter levado o Brasil a ser tornar um grande dependente do mercado internacional.

A dependência com o mercado de fertilizantes internacionais, pode deixar os preços mais sensíveis a alterações do dólar e do petróleo. O dólar por ser a moeda de negociação dos fertilizantes e o petróleo por estar atrelado aos custos de transportes nacionais e internacionais.

A figura 4, mostra a evolução dos preços nominais das commodities soja e milho e o preço nominal médio dos fertilizantes com formulação NPK. Nota-se que os preços dos fertilizantes e do milho possuem tendências parecidas, dado suas proporções.

Figura 4 - Média preços fertilizantes com formulação NPK, preço do milho e preço da soja



Fonte: Gráfico elaborado a partir de dados da IPEADATA (2019), FMI (2019).

2.2 ESTUDOS EMPÍRICOS

Nessa seção, serão apresentados alguns dos trabalhos em nível nacional relacionados ao mercado e aos preços dos fertilizantes. A maior parte dos trabalhos analisados, fazem uma análise onde consideram o preço dos fertilizantes como dependentes dos preços da soja, milho, petróleo e dólar.

Bini et al. (2016), elaboraram um estudo voltado para a transmissão de preço do petróleo para o preço de três fertilizantes básicos (cloreto de potássio, superfosfato simples e sulfato de amônia) e das commodities (milho, soja e frango). Utilizou-se uma modelagem VAR, onde perceberam que os preços dos fertilizantes e os preços das commodities apresentam uma baixa dependência ao preço do petróleo. Outra constatação dos autores está relacionada as variações dos preços do milho e da soja, que são parcialmente repassados para os preços dos fertilizantes.

Os resultados de causalidade Granger disponíveis no trabalho de Bini et al. (2016), revelaram significância do petróleo para o preço do frango, assim como o sulfato de amônia e cloreto de potássio é para o milho. Já a soja causa no sentido Granger o preço do superfosfato simples e do cloreto de potássio.

Já para a variância do erro de previsão os autores Bini et al. (2016), não encontraram um percentual grande de importância entre as variáveis estudadas e os fertilizantes. Sendo na maior parte a própria variável tendo a maior porcentagem de explicação da variância do erro de previsão.

Os autores Bini et al. (2016), concluem que há sim uma certa dependência entre os preços dos fertilizantes estudados e o preço do milho e da soja. Essa relação se mostrou mais forte dos grãos para os fertilizantes.

Cella e Rossi (2010), realizaram um estudo voltado para o mercado nacional, no qual, verificam quais são os principais produtores e consumidores de fertilizantes formulados com a base NPK. Entre os anos de 1990 a 2007, foi verificado que as entregas de fertilizantes realizadas no segundo semestre são mais expressivas que o primeiro. Uma provável justificativa se dá em razão da liberação de financiamento que no Brasil ocorrem nesses períodos. Segundo a pesquisa dos autores, a soja é a cultura que mais demanda fertilizante no país em um total de 33%, seguido do milho com 17% e da cana de açúcar com 15%.

Cella e Rossi (2010), em 2010 já mostravam evidências que o Brasil não seria autossuficiente na produção de matéria prima para a produção dos fertilizantes. Os autores concluíram que o país necessita implantar estratégias para diminuir a dependência de importação dos outros países.

Boteon e Lacerda (2009), analisaram os impactos dos preços de fertilizantes no setor hortifruti. Os autores argumentam que o lucro dos agricultores pode estar relacionado com as oscilações do petróleo, uma vez que isso está relacionado com o transporte nacional, internacional. Outra relação dos fertilizantes, especialmente os que possuem formulação NPK (nitrogênio, fosforo e potássio), é em decorrência que o petróleo é utilizado como matéria-prima para produção do nitrogênio. No trabalho, foram analisados os impactos dos fertilizantes em 11 produtos hortifrutícolas, e verificou-se certa dificuldade em repassar as decorrentes oscilações dos preços dos fertilizantes para o consumidor final.

Horvat (2012), através do índice CAGR (Compounded Annual Growth Rate) ou, taxa composta de crescimento anual, projetou o consumo de fertilizantes para a região de Matopiba que engloba os estados de Maranhão, Piauí, Tocantins e Bahia. As projeções, que levaram em consideração o aumento da área cultivada, apontam para um crescimento na demanda dos fertilizantes, onde em 2022 o volume esperado da demanda nessa região, pode ultrapassar as 11 milhões de toneladas, no qual o estado da Bahia será o maior consumidor desses insumos na região.

Já Nicolella, Dragone e Bacha (2005), adotaram o modelo de mínimos quadrados ordinários (MQO), para verificar as elasticidades na demanda de fertilizantes no Brasil para o período de 1970 a 2002. Verificou-se que a demanda de fertilizantes se mostrou elástica para o índice de preço recebido pelo agricultor (IPR/FGV) e inelástica para o crédito rural e a variação no preço dos fertilizantes. A inelasticidade para o crédito rural, segundo os autores, pode estar relacionada aos outros meios adotados para a aquisição dos insumos, como por exemplo algumas relações de troca de fertilizantes por commodities. Já a inelasticidade da demanda dos fertilizantes para a sua variação de preço, pode estar relacionada a essencialidade dos fertilizantes para a produção.

Goffredo (2018), analisa a balança comercial do agronegócio brasileiro no período de 1997 a 2017, onde verifica que o grupo de fertilizantes contribui durante esse período negativamente para a balança comercial. Um dos motivos apontado pelo autor se deve da necessidade de média-alta intensidade tecnológica para a produção nacional, no qual o Brasil é deficitário.

3. MATERIAL E MÉTODOS

3.1. MATERIAL

O presente trabalho contará com duas análises econométricas. Na primeira análise, será adotado um modelo SARIMA para previsão dos preços dos fertilizantes. Já em um segundo momento, será adotado um modelo VAR. Para a estimação dos modelos foram utilizados os softwares Eviws 7 e Gretl. Em seguida, será apresentada as descrições de todas as variáveis adotadas no trabalho.

As séries das variáveis utilizadas pertencem ao período de janeiro de 2014 até dezembro de 2018, totalizando 60 observações mensais. O objetivo desse trabalho, é estudar os preços dos fertilizantes (R\$/tonelada) com a formulação NPK (Nitrogênio, Fósforo e Potássio) para o estado do Paraná, para isso, utilizou-se do preço de seis formulações fornecidas pela CONAB (Companhia Nacional de Abastecimento) para o estado do Paraná. A CONAB se utiliza dos mesmos dados para o cálculo do custo de produção do estado. Já os preços da soja e milho, correspondem ao preço médio recebido pelos agricultores do paraná (R\$/sc) disponibilizado pelo IPEADATA (2019). O preço do petróleo disponibilizado pelo FMI (2019) e transformado para reais por barril. E o dólar que corresponde a taxa de câmbio comercial (R\$/US\$) disponibilizada pelo IPEADATA (2019). A tabela a seguir apresenta as características das variáveis que serão utilizadas no modelo 1 e 2.

Tabela 1 - Tabela descritiva dos dados adotados na pesquisa

Variável	N	Média	Desvio-Padrão	Mínimo	Máximo	Mediana	Curtose
Formulação 00-20-20	60	1250,40	126,04	913,00	1450,00	1320,00	0,19529
Formulação 02-20-18	60	1196,40	133,17	987,28	1522,80	1180,70	1,39950
Formulação 08-20-20	60	1431,70	155,28	1225,00	1817,30	1413,30	-0,13330
Formulação 08-30-20	60	1353,00	47,13	1196,10	1397,40	1363,00	2,59050
Formulação 12-15-15	60	1286,60	185,07	1013,70	1666,60	1227,30	-0,71354
Formulação 08-28-16	60	1343,40	122,33	1150,00	1562,40	1277,70	-1,32580
Soja	60	64,46	7,01	52,27	80,96	63,55	-0,58040
Milho	60	25,20	5,94	17,41	39,98	23,08	-0,62966
Petróleo	60	197,91	47,77	124,81	324,63	182,57	-0,36349
Dólar	60	3,20	0,53	2,22	4,12	3,22	-0,68454

Fonte: Elaborado a partir dos dados da CONAB (2019); FMI (2019); IPEADATA (2019).

3.2. MÉTODOS ADOTADOS NA PESQUISA

3.2.1. Teste de raiz unitária de Dickey-Fuller aumentado

O teste de Dickey-Fuller aumentado, tem por objetivo determinar se a série possui tendência estocástica ou tendência determinística. Desse modo o teste a seguir demonstrado é uma adaptação para o modelo de Dickey-Fuller clássico, onde a diferença consiste em excluir o erro do ruído branco, que por sua vez poderia causar distorções no teste. Diante disso, e supondo que y_t seja um processo auto-regressivo de ordem p , com raiz unitária, temos:

$$y_t = \mu + \phi_1 y_{t-1} + \dots + \phi_{p-1} y_{t-p+1} + \phi_p y_{t-p} + \varepsilon_t \quad (1)$$

Segundo Bueno (2011), se torna necessário incorporar quantas variáveis forem necessárias para que o teste de resíduo não rejeite a hipótese de um ruído branco. Assim, adicionando e subtraindo a expressão $\phi_p y_{t-p+1}$, na equação anterior, podemos entender melhor o teste:

$$y_t = \mu + \phi_1 y_{t-1} + \dots + \phi_{p-1} y_{t-p+1} + \phi_p y_{t-p} + \phi_p y_{t-p+1} - \phi_p y_{t-p+1} + \varepsilon_t$$

$$y_t = \mu + \phi_1 y_{t-1} + \dots + (\phi_{p-1} + \phi_p) y_{t-p+1} - \phi_p \Delta y_{t-p+1} + e_t$$

Substituindo por $(\phi_{p-1} + \phi_p) y_{t-p+2}$, e refazendo, temos:

$$\begin{aligned} y_t &= \mu + \phi_1 y_{t-1} + \dots + (\phi_{p-1} + \phi_p) y_{t-p+2} - (\phi_{p-1} + \phi_p) y_{t-p+2} + (\phi_{p-1} + \phi_p) y_{t-p+1} \\ &\quad - \phi_p \Delta y_{t-p+1} + \varepsilon_t \\ &= \mu + \phi_1 y_{t-1} + \dots + (\phi_{p-2} + \phi_{p-1} + \phi_p) y_{t-p+2} - (\phi_{p-1} + \phi_p) \Delta y_{t-p+2} \\ &\quad - \phi_p \Delta y_{t-p+1} + \varepsilon_t \end{aligned}$$

Repetindo isso por p vezes, encontramos a seguinte equação:

$$\Delta y_t = \mu + \alpha y_{t-1} + \sum_{i=1}^{p-1} \Delta y_{t-i} + \varepsilon_t \quad (2)$$

onde,

$$\alpha = -(1 - \sum_{i=1}^{p-1} \phi_i); \quad \lambda_i = -\sum_{i=1}^{p-1} \phi_{j+1}$$

Desse modo, desde que se faça a correção do modelo, considerando as variáveis defasadas, os valores críticos e a interpretação do modelo não se altera, mantendo assim as mesmas premissas do anterior.

3.2.2. Teste de raiz unitária de Phillips-Perron

O teste de Phillips-Perron é um método mais abrangente do teste de Dickey-Fuller, de modo que a equação estimada e os testes são similares.

Assim temos:

$$\begin{aligned}\Delta y_t &= \alpha y_{t-1} + u_t \rightarrow z_t, \\ \Delta y_t &= \mu + \alpha y_{t-1} + u_t \rightarrow z_{t\mu}, \\ \Delta y_t &= \mu + \delta t + \alpha y_{t-1} + u_t \rightarrow z_{t\mu},\end{aligned}$$

onde μ_t é um processo estacionário.

Conforme Bueno (2011), Phillips e Peron definiram o teste z_t . Esse teste é uma correção para t_μ . Assim temos o seguinte procedimento para estimação:

1. Estimando as médias:

$$\bar{y} = \frac{\sum_{t=1}^T y_t}{T}, \bar{y}_{-1} = \frac{\sum_{t=1}^T y_{t-1}}{T};$$

2. Estimando o parâmetro de maior interesse:

$$\alpha^\wedge = \frac{\sum_{t=1}^T (y_{t-1} - \bar{y}_{-1})(y_t - \bar{y})}{\sum_{t=1}^T (y_{t-1} - \bar{y}_{-1})^2} - 1;$$

3. Estimando a constante:

$$\hat{\mu} = \bar{y} - (\hat{\sigma} + 1)\bar{y}_{-1};$$

4. Estimando a variância populacional:

$$\hat{\sigma}^2 = \frac{\sum_{t=1}^T \hat{\mu}^2 t}{T} = \frac{\sum_{t=1}^T (\Delta y_t - \hat{\mu} - \sigma y_{t-1})^2}{T};$$

5. Calculando o desvio-padrão dos parâmetros:

$$s(\hat{\sigma}) = \frac{\hat{\sigma}}{\sqrt{\sum_{t=1}^T y_{t-1}^2}}$$

6. Calculando a estatística de Dickey-Fuller:

$$\hat{t}_\mu = \frac{\sigma^\wedge}{s(\sigma^\wedge)}$$

7. Estimando a variância de longo prazo:

$$v^{\wedge^2} = \hat{\sigma}^2 + \frac{2}{T} \sum_{j=1}^M \omega\left(\frac{j}{M+1}\right) \sum_{t=j+1}^T \hat{\mu}_t \hat{\mu}_{1-t}$$

8. E por fim calculando a estatística de Phillips-Perron:

$$\hat{z}_{t,\mu} = \hat{\tau}_\mu \left(\frac{\hat{\sigma}}{\hat{v}} \right) - \frac{1}{2} \left(\frac{\hat{v}^2 - \hat{\sigma}^2}{\hat{v} \sqrt{T^{-2} \sum_{t=1}^T y_{t-1}^2}} \right) \quad (3)$$

A variância de longo prazo é definida pelo termo $v^{\wedge^2}$, onde são incluídas todas as autocovariâncias do processo v_t .

3.2.3. Método adotado para o modelo 1

O modelo 1 é um sistema de equação para a previsão da variável analisada. Para tal se utilizará dos modelos autorregressivos integrados de média móvel (ARIMA) e o modelo ARIMA sazonal (SARIMA).

3.2.3.1. Modelo Autoregressivo Integrado de Médias Móveis (ARIMA)

Os modelos autoregressivos integrados de média móvel (ARIMA), partem do pressuposto que as séries temporais são não estacionárias, ou seja, são integradas. O modelo ARIMA (p,d,q) é um modelo não sazonal, onde p se refere ao número de termos autoregressivos, d representa o número de vezes que a série foi diferenciada para se tornar estacionária e q denota o número de termos de média móvel (GUJARATI, 2006).

Segundo Morettin e Tolo (2004), para se encontrar a expressão matemática que descreve o modelo ARIMA, precisa-se considerar um modelo ARIMA (p,d,q) com parâmetros $p+q+1$ no vetor,

$$\xi = (\phi, \theta, \sigma_\alpha^2)$$

Onde, $\phi = (\phi_1, \dots, \phi_p)$ e $\theta = (\theta_1, \dots, \theta_q)$. Supondo que quando $d > 0$ temos $\mu_\omega = 0$. Caso contrário, teremos $p+q+2$ parâmetros e μ será incluído como um parâmetro a ser estimado.

Se utilizando do método de máxima verossimilhança, dada as N observações e considerando a função, $L(\xi|Z_1, \dots, Z_n)$ sendo uma função de ξ , então os estimadores de ξ , serão os valores que maximizam $\ell = \log L$.

Sabendo que o modelo ARIMA é utilizado em variáveis não estacionárias, e assim diferenciando em d vezes para torna-las estacionárias, teremos $n = N - d$ observações, onde teremos,

$$W_t = \Delta^d Z_t$$

Desse modo, o modelo ARIMA (p,d,q) é descrito da seguinte forma,

$$a_t = \tilde{w}_t - \phi_1 \tilde{w}_{t-1} - \dots - \phi_p \tilde{w}_{t-p} + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} \quad (4)$$

onde,

$$\tilde{w}_t = w_t - \mu_w.$$

3.2.3.2. Modelos ARIMA Integrado Sazonal (SARIMA)

Determinadas séries econômicas apresentam comportamentos sazonais ao passar do tempo. Conforme Morettin e Toloi (2004), os fenômenos sazonais são características das séries que acontecem frequentemente ano a ano.

O método mais utilizado para previsão em séries que possuem comportamento sazonal, é o modelo ARIMA sazonal, mais conhecido como SARIMA. O modelo SARIMA é constituído por uma parte não sazonal, com parâmetros iguais ao do modelo $ARIMA(p,d,q)$, acrescentando-o uma parte sazonal com parâmetros (P,D,Q) (ESPINOSA; PRADO; GHELLERE, 2010).

Desse modo, adotando um modelo com sazonalidade de período $s = 5$, semelhante ao adotado por Espinosa, Prado e Ghellere (2010) em seu trabalho, temos o seguinte modelo:

$$\varphi(B)\phi(B^5)(1 - B^5)^D(1 - B)^dZ_t = \theta(B)\Theta(B^5)a_t \quad (5)$$

onde,

- B é o operador de translação para o passado definido como $B^n Z_t = Z_{t-n}$;
- $\varphi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ é a parte autoregressiva não sazonal ou estacionária de ordem p ;
- $\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ é a parte não sazonal de médias móveis de ordem q ;
- $(1 - B)^d$ é a parte de integração não sazonal de ordem d ;
- $\phi(B^5) = 1 - \phi_1 B^5 - \dots - \phi_p B^{p5}$ é a parte autoregressiva sazonal de ordem P e ordem sazonal 5;
- $\Theta(B^5) = 1 - \theta_1 B^5 - \dots - \theta_q B^{q5}$ é a parte sazonal de médias móveis de ordem Q e estação sazonal de ordem 5;
- $(1 - B^5)^D$ é a parte de integração sazonal de ordem D e estação sazonal 5.

3.2.4. Método adotado para o modelo 2

O modelo 2 é um sistema de equação para analisar as relações entre as variáveis analisadas. Para tal análises, será adotado o modelo de vetor autorregressivo (VAR) descrito abaixo.

3.2.4.2 Vetor Autorregressivo (VAR)

Segundo Bueno (2011), um modelo de vetor autorregressivo de ordem p por um vetor com n variáveis endógenas, X_t , ligadas por uma matriz A , pode ser representado pela seguinte forma:

$$AX_t = B_0 + \sum_{i=1}^p B_i X_{t-i} + B\varepsilon_t \quad (6)$$

Onde, A é uma matriz nxn que representam as restrições contemporâneas entre as variáveis, B_0 é um vetor de constantes, B_i são matrizes nxn , B é uma matriz diagonal nxn de desvio padrão e ε_t é um vetor de perturbações aleatórias não correlacionadas entre si contemporâneas ou temporalmente.

Em consequência da endogeneidade das variáveis, o modelo é estimado em sua forma compactada, assim tem-se:

$$X_t = A^{-1}B_0 + \sum_{i=1}^p A^{-1}B_i X_{t-i} + A^{-1}B\varepsilon_t = \Phi_0 + \sum_{i=1}^p \Phi_i X_{t-i} + e_t \quad (7)$$

Onde: $\Phi_i \equiv A^{-1}B_i, i = 0, 1, \dots, p, B\varepsilon_t \equiv Aet$

De acordo com Enders (2009) citado por Bueno (2011, p. 196), a melhor forma de se visualizar esse modelo, é através de um bivariado de ordem 1. Assim, partindo dessa simplificação, se torna mais acessível o entendimento. Partindo de um modelo bivariado temos:

$$\begin{aligned} y_t &= b_{10} - \alpha_{12}Z_t + b_{11}y_{t-1} + b_{12}Z_{t-1} + \sigma_y \varepsilon_{yt} \\ z_t &= b_{20} - \alpha_{21}y_t + b_{21}y_{t-1} + b_{22}Z_{t-1} + \sigma_z \varepsilon_{zt} \end{aligned}$$

Conforme Bueno (2011), nesse modelo, as variáveis sofrem influência entre si nos valores contemporâneo e defasados. Sabendo que as variáveis z_t e y_t possuem os erros correlacionados, não se pode estimar esse modelo diretamente. De modo geral, o método VAR tem como objetivo evitar esse problema e encontrar a trajetória da série de interesse através de um choque nos erros, conhecido como choque estrutural.

Para tal, temos as seguintes hipóteses:

1. y_t e z_t são estacionários;
2. $\varepsilon_{yt} \sim RB(0, 1)$ e $\varepsilon_{zt} \sim RB(0, 1)$;
3. $\varepsilon_{yt} \perp \varepsilon_{zt} \Rightarrow Cov(\varepsilon_{yt}, \varepsilon_{zt}) = 0$.

Além da forma estrutural, o modelo pode ser apresentado da seguinte forma matricial:

$$\begin{bmatrix} 1 & a_{21} \\ a_{21} & 1 \end{bmatrix} \begin{bmatrix} y_t \\ z_t \end{bmatrix} = \begin{bmatrix} b_{10} \\ b_{20} \end{bmatrix} + \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix} \begin{bmatrix} y_{t-1} \\ z_{t-1} \end{bmatrix} + \begin{bmatrix} \sigma_y & 0 \\ 0 & \sigma_z \end{bmatrix} \begin{bmatrix} \varepsilon_{yt} \\ \varepsilon_{zt} \end{bmatrix} \Rightarrow$$

$$AX_t = B_0 + B_1X_{t-1} + B_{\varepsilon t}$$

E a sua forma reduzida é:

$$\begin{aligned} X_t &= \Phi_0 + \Phi_1 X_{t-1} + e_t \\ \Phi_0 &\equiv A^{-1}B_0 \\ \Phi_1 &\equiv A^{-1}B_1 \\ A_{\varepsilon t} &\equiv B_{\varepsilon t} \end{aligned} \tag{8}$$

Para identificar melhor os parâmetros que ainda faltam, precisa-se entender os erros compostos dados por:

$$\begin{bmatrix} e_{1t} \\ e_{2t} \end{bmatrix} \equiv A^{-1}B_{\varepsilon t} = \begin{bmatrix} \frac{\sigma_y \varepsilon_{yt} - a_{12} \sigma_z \varepsilon_{zt}}{1 - a_{12} a_{21}} \\ \frac{\sigma_z \varepsilon_{zt} - a_{21} \sigma_y \varepsilon_{yt}}{1 - a_{12} a_{21}} \end{bmatrix}$$

Assim, percebe-se que:

$$\begin{aligned} E(e_t) &= 0 \\ Cov(e_t) &\equiv \sum = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{21} & \sigma_2^2 \end{bmatrix} = \begin{bmatrix} \frac{\sigma_y^2 + \sigma_{12}^2 \sigma_z^2}{(1 - a_{12} a_{21})^2} & -\frac{a_{21} \sigma_y^2 + a_{12} \sigma_z^2}{(1 - a_{12} a_{21})^2} \\ -\frac{a_{21} \sigma_y^2 + a_{12} \sigma_z^2}{(1 - a_{12} a_{21})^2} & \frac{\sigma_z^2 + \sigma_{12}^2 \sigma_y^2}{(1 - a_{12} a_{21})^2} \end{bmatrix} \end{aligned}$$

Onde os erros não são auto correlacionados, pois temos:

$$Cov(e_{it}, e_{i(t-j)}) = E \left[\left(\frac{\sigma_i \varepsilon_{it} - a \sigma_{\sim i} \varepsilon_{-it}}{1 - a_{12} a_{21}} \right) \left(\frac{\sigma_i \varepsilon_{i(t-j)} - a \sigma_{\sim i} \varepsilon_{-i(t-j)}}{1 - a_{12} a_{21}} \right) \right] = 0$$

$i = y, z; j \neq 0; a = a_{12}, a_{21}; \sim$ significa negação.

3.2.4.2.1 Função resposta ao impulso

Sims (1980) citado por Bueno (2011, p.216), aconselha um modelo com um sistema recursivo, ou seja, necessita-se determinar alguns coeficientes que sejam iguais a zero. Assim dado as equações:

$$y_t = b_{10} - \alpha_{12} Z_t + b_{11} y_{t-1} + b_{12} Z_{t-1} + \sigma_y \varepsilon_{yt} \tag{9}$$

$$z_t = b_{20} - \alpha_{21} y_t + b_{21} y_{t-1} + b_{22} Z_{t-1} + \sigma_z \varepsilon_{zt} \tag{10}$$

Determinando $a_{12} = 0$, temos:

$$y_t = b_{10} + b_{11} y_{t-1} + b_{12} Z_{t-1} + \varepsilon_{yt}$$

$$z_t = b_{20} - a_{21}y_t + b_{21}y_{t-1} + b_{22}z_{t-1} + \varepsilon_{zt}$$

A restrição adotada torna os parâmetros estruturais identificáveis, onde:

$$A^{-1} = \begin{bmatrix} 1 & 0 \\ -a_{21} & 1 \end{bmatrix} \Rightarrow$$

$$\begin{bmatrix} y_t \\ z_t \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ -a_{21} & 1 \end{bmatrix} \begin{bmatrix} b_{10} \\ b_{20} \end{bmatrix} + \begin{bmatrix} 1 & 0 \\ -a_{21} & 1 \end{bmatrix} \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix} \begin{bmatrix} y_{t-1} \\ z_{t-1} \end{bmatrix} + \begin{bmatrix} 1 & 0 \\ -a_{21} & 1 \end{bmatrix} \begin{bmatrix} \sigma_y & 0 \\ 0 & \sigma_z \end{bmatrix} \begin{bmatrix} \varepsilon_{yt} \\ \varepsilon_{zt} \end{bmatrix}$$

Considerando que $a_{12} = 0$, tem-se os seguintes erros reduzidos:

$$\begin{bmatrix} e_{1t} \\ e_{2t} \end{bmatrix} = \begin{bmatrix} \sigma_y \varepsilon_{yt} \\ \sigma_z \varepsilon_{zt} - a_{21} \sigma_y \varepsilon_{yt} \end{bmatrix}$$

assim:

$$var(e_1) = \sigma_y^2$$

$$cov(e_1, e_2) = -a_{21} \sigma_y^2$$

$$var(e_2) = \sigma_z^2 + a_{21}^2 \sigma_y^2$$

E seus parâmetros estruturais são dados por:

$$\phi_{10} = b_{10}; \quad \phi_{20} = b_{20} - b_{10}a_{21};$$

$$\phi_{11} = b_{11}; \quad \phi_{12} = b_{12};$$

$$\phi_{21} = -a_{21}b_{11} + b_{21}; \quad \phi_{22} = -a_{21}b_{12} + b_{22}$$

Segundo Bueno (2011), adotando n variáveis endógenas, teremos uma matriz de covariância de dimensão $n \times n$, e levando em consideração a *decomposição de Cholesky*, que se trata de uma maneira triangular de decompor os resíduos, tem-se:

$$X_t = \bar{X} + \sum_{i=0}^{\infty} \Phi_1^i e_{t-i} = \bar{X} + \sum_{i=0}^{\infty} \frac{\phi_1^i}{1 - a_{12}a_{21}} \begin{bmatrix} 1 & -a_{12} \\ -a_{21} & 1 \end{bmatrix} \begin{bmatrix} \sigma_y \varepsilon_{yt-i} \\ \sigma_z \varepsilon_{zt-i} \end{bmatrix},$$

Onde, $\bar{X} \equiv (I - \Phi_1)^{-1} \Phi_0$ é a média de longo prazo.

Assim a matriz:

$$\Psi_i = \frac{\Phi_1^i}{1 - a_{12}a_{21}} \begin{bmatrix} 1 & -a_{12} \\ -a_{21} & 1 \end{bmatrix}$$

Logo:

$$X_t = \bar{X} + \sum_{i=0}^{\infty} \Psi_i B \varepsilon_{t-i} = \quad (11)$$

$$= \bar{X} + \sum_{i=0}^{\infty} \begin{bmatrix} \psi_{i,11} & \psi_{i,12} \\ \psi_{i,21} & \psi_{i,22} \end{bmatrix} \begin{bmatrix} \sigma_y \varepsilon_{yt-i} \\ \sigma_z \varepsilon_{zt-i} \end{bmatrix} \quad (12)$$

Onde, Ψ_i são os multiplicadores de impacto de um choque sobre as variáveis endógenas, o choque de ε_{yt} sobre y_{t+h} é dado pela soma dos coeficientes $\psi_{i,11}$, $i = 0, 1, 2, \dots, h$. Desse modo, os coeficientes gerados em gráfico versus i , originam a função impulso resposta.

3.2.4.2.2 Decomposição da variância

Dado um modelo VAR de ordem 1 com duas variáveis endógenas, y e z , temos:

$$X_{t+h} = \bar{X} + \sum_{i=0}^{\infty} \Psi_i \varepsilon_{t+h-i} \quad (13)$$

Calculando o erro de previsão:

$$X_{t+h} - E_t(X_{t+h}) = \sum_{i=0}^{h-1} \Psi_i \varepsilon_{t+h-i}$$

Detalhando apenas y_{t+h} :

$$y_{t+h} - E_t(y_{t+h}) = \psi_{0,11} \varepsilon_{yt+h} + \psi_{1,11} \varepsilon_{yt+h-1} + \dots + \psi_{h-1,11} \varepsilon_{yt+1} + \psi_{0,12} + \psi_{1,12} \varepsilon_{zt+h-1} + \dots + \psi_{h-1,12} \varepsilon_{zt+1}$$

Logo:

$$\sigma_y^2(h) = \sigma_y^2(\psi_{0,11}^2 + \psi_{1,11}^2 + \dots + \psi_{h-1,11}^2) + \sigma_z^2(\psi_{0,12}^2 + \psi_{1,12}^2 + \dots + \psi_{h-1,12}^2)$$

Dado um modelo bivariado, a decomposição da variância é dada por:

$$1 = \frac{\sigma_y^2(\psi_{0,11}^2 + \psi_{1,11}^2 + \dots + \psi_{h-1,11}^2)}{\sigma_y^2(h)} + \frac{\sigma_z^2(\psi_{0,12}^2 + \psi_{1,12}^2 + \dots + \psi_{h-1,12}^2)}{\sigma_y^2(h)} \quad (14)$$

4. RESULTADOS E DISCUSSÕES

4.1. RESULTADO MODELO SARIMA

Neste capítulo é apresentada o exercício de previsão para os preços de fertilizantes para o estado do Paraná, durante o período de janeiro de 2014 a dezembro de 2018, utilizando-se de um modelo SARIMA.

Algumas variáveis que compõe a média dos preços dos fertilizantes não se encontram disponíveis a partir de 2019, sendo assim, as variáveis dos últimos cinco meses de 2018, foram deixadas de fora do modelo estimado para que fosse possível verificar a capacidade de previsão do modelo, através de uma comparação entre o valor observado e o previsto.

A variável utilizada para esse modelo corresponde a média dos preços das seis formulações de NPK comentadas acima, deflacionadas pelo IGP-DI (Índice Geral de Preços – Disponibilidade Interna) para janeiro de 2014. Primeiramente, se deflacionou as seis séries de preços e em seguida foi aplicada uma média simples entre as variáveis no intuito de ter uma média dos fertilizantes com formulação NPK para o estado do Paraná.

A figura 5 mostra o comportamento da série analisado dos fertilizantes. Nota-se um topo histórico no ano de 2015, onde sua provável causa estaria relacionada com a dependência do mercado internacional e consequentemente ao dólar. Nesse período o dólar se encontrava no patamar mais elevado da série estudada.

Figura 5 - Série histórica da média deflacionada do preço dos fertilizantes (NPK) para o estado do Paraná (R\$/tonelada)



Fonte: Elaborado a partir dos dados da CONAB (2019)

Os resultados de raiz unitária de Dickey-Fuller e de Phillips-Perron são apresentados na tabela 2, os testes foram feitos com o número máximo de 10 defasagens e sem tendência. Os testes foram realizados com as variáveis em nível e em primeira diferença. Percebe-se que as variáveis em nível apresentam evidências de não estacionariedade para os dois testes. Diante disso, aplicou-se a primeira diferença na série e verificou-se que tanto o teste de Dickey-Fuller quanto Phillips-Perron apontam para característica estacionária, levando em consideração a significância de 1%.

Tabela 2 - Teste de raiz unitária

Variáveis	Teste ADF (Estatística-t e p-valor)	Teste de Phillips-Perron (estatística-t e p-valor)
FERTILIZANTES	-1,219567 e 0,6597	-1,253454 e 0,6446
FERTILIZANTES (1º DIFERENÇA)	-6,631183 e 0,0000	-6,631183 e 0,0000

Fonte: Resultado da pesquisa.

Para a escolha do melhor modelo de previsão, foram considerados os critérios de Schwarz, critério de Akaike e critério de Hannan-Quinn. Rodou-se diversos modelos e pelo critério da parcimônia, os dois que obtiveram menores critérios são apresentados na tabela 3.

Tabela 3 - Critério de escolhas dos modelos

Modelos	Critério de Schwarz	Critério de Akaike	Critério de Hannan-Quinn
1 - SARIMA (0,2,1)(1,2,1)	329,19	323,72	325,43
2 - SARIMA (1,2,1)(1,2,1)	331,58	324,74	326,88

Fonte: Resultado da pesquisa.

Como observado na tabela 3, o modelo SARIMA (0,2,1)(1,2,1), possui menores valores dos critérios, sendo assim o indicado para previsão da variável. Os parâmetros estimados para o modelo 1 são apresentados na tabela a seguir. Todas as variáveis desse modelo se apresentam significantes a 1%.

Tabela 4 - Estimativa dos parâmetros do modelo 1 - SARIMA (0,2,1)(1,2,1)

Coeficiente	Estimativa	Erro Padrão	p-valor
Π	-0,3650	0,1203	0,0024
θ	-0,7452	0,1032	<0,0001
Θ	-0,9971	0,2949	0,0007

Fonte: Resultado da pesquisa.

A tabela 5 apresenta o valor real e o previsto dos preços dos fertilizantes estudados para os cinco últimos meses de 2018, como também os limites inferiores e superiores da previsão e os erros de previsão para o modelo SARIMA (0,2,1)(1,2,1). Observa-se que os valores previstos

se aproximam dos valores nos primeiros quatros período com uma tolerância de 5% de erro. Já no último período essa tolerância se aproxima dos 10%.

Tabela 5 - Previsão do modelo SARIMA (0,2,1)(1,2,1)

Ano	Mês	Valor Previsto	Limite Inferior	Limete Sperial	Valor Observado	Erro de Previsão (%)
2018	Agosto	1053,52	979,10	1127,93	1108,44	-4,95
2018	Setembro	1034,65	915,25	1154,05	1088,96	-4,99
2018	Outubro	1040,48	876,54	1204,41	1086,10	-4,20
2018	Novembro	1051,20	841,18	1261,23	1098,65	-4,32
2018	Dezembro	1048,62	790,38	1306,85	1154,07	-9,14

Fonte: Resultado da pesquisa.

Diante do exposto, os resultados se apresentaram satisfatórios para a previsão da tendência dos preços dos fertilizantes, uma vez que a margem de erro de previsão ficou abaixo de 10%.

4.2 RESULTADOS MODELO VAR

Neste capítulo é apresentada os resultados do modelo VAR juntamente com o exercício do teste de impulso resposta e decomposição da variância. Diferentemente do modelo anterior, o modelo apresentado a seguir considerou a série temporal mensal com início em janeiro de 2014 até dezembro de 2018. Foram utilizados os mesmos dados analisados no modelo anterior para os fertilizantes, acrescentando a série preço da soja, preço do milho, preço do petróleo e dólar, deflacionadas pelo IGP-DI (Índice Geral de Preços – Disponibilidade Interna) para janeiro de 2014. Para facilitar a interpretação dos resultados, todas as variáveis foram logaritimizadas.

Os resultados de raiz unitária de Dickey-Fuller e Philips-Perron são apresentados na tabela a seguir. Os testes foram realizados com as variáveis em nível e em primeira diferença. Percebe-se que todas as variáveis em nível apresentadas, possuem evidencias de não estacionariedade. Já quando observamos os valores do teste de Dickey-Fuller e de Phillips-Perron para as variáveis em primeira diferença, nota-se que as variáveis apresentaram características estacionárias, levando em consideração a significância de 1%.

Tabela 6 - Teste de raiz unitária

(continua)

Variáveis	Teste ADF (estatística-t e p-valor)	Teste de Phillips-Peron (estatística-t e p-valor)
Fertilizantes	-1,344210 e 0,6032	-1,377263 e 0,5874
Dólar	-1,820037 e 0,3674	-1,550477 e 0,5013
Soja	-2,377115 e 0,1526	-2,407101 e 0,1442
Milho	-2,099708 e 0,2456	-2,003106 e 0,2848

Tabela 7 - Teste de raiz unitária

(conclusão)

Variáveis	Teste ADF (estatística-t e p-valor)	Teste de Phillips-Peron (estatística-t e p-valor)
Petróleo	-2399517 e 0,1463	-2,107654 e 0,2425
Fertilizantes (1ª diferença)*	-7,046745 e 0,0000	-7,045174 e 0,0000
Dólar (1ª diferença)*	-5,447014 e 0,000	5,347857 e 0,0000
Soja (1ª diferença)*	-6,615820 e 0,0000	-8,51897 e 0,0000
Milho (1ª diferença)*	-5,188154 e 0,0001	-5,155462 e 0,0001
Dólar (1ª diferença)*	-5,447014 e 0,0000	-5,347857 e 0,0000
Petróleo (1ª diferença)*	-5,693799 e 0,0000	-5,504377 e 0,0000

Fonte: Resultado da pesquisa.

Nota: *Significativo a 1%.

Na tabela 7, é apresentando o teste de cointegração de Jhoansen através do teste de estatística-traço para verificar a relação de longo prazo entre as variáveis. O teste foi gerado com as variáveis em nível e percebe-se que a hipótese nula que o numero R de vetores é igual a zero não é rejeitada em favor da hipótese alternativa R igual a um, ou seja, tem-se indícios que as séries não são cointegradas, sugerindo uma relação de curto prazo, assim, as variáveis não são estáveis no longo prazo, desse modo, o modelo de Vetor Autorregressivo em primeira diferença se torna apropriado para a análise dos dados.

Tabela 8 - Resultado do teste de cointegração de Jhoansen

Hipótese nula	Hipótese alternativa	Estatística de traço (0.05)	Valores crítico
R=0	R=1	62,72812	69,81889
R≤1	R=2	28,26275	47,85613
R≤2	R=3	15,188	29,79707
R≤3	R=4	8,113489	15,49471
R≤4	R=5	3,47632	3,841466

Fonte: Resultado da pesquisa.

A tabela 8, ilustra os resultados dos testes para a seleção de defasagens para o modelo VAR. Os critérios de Schwarz, Akaike e Hannan-Quinn apontam para utilização de uma defasagem para o modelo.

Tabela 9 - Critério de seleção da ordem de defasagem do modelo VAR

Nº Defasagens	Akaike	Schwarz	Hannan-Quinn
0	-9.008906	-8.826421	-8.938338
1	-16.80156*	-15.70666*	-16.37815*
2	-16.79049	-14.78315	-16.01424
3	-16.53723	-13.61747	-15.40814
4	-16.15230	-12.32012	-14.67036

Fonte: Resultado da pesquisa.

Na tabela 9, tem-se a regressão para o modelo VAR com uma defasagem. Os valores entre parênteses indicam o desvio padrão e os valores entre colchetes indicam o teste t calculado. Os coeficientes apresentados são os valores das elasticidades, dado um impacto de 1% sobre as variáveis independentes, mantendo as demais variáveis constantes. Levando em consideração a significância estatística, nota-se que a variável fertilizante é influenciada positivamente pela variável dólar defasada uma vez (2,23%). Já as outras variáveis são influenciadas pelas suas respectivas variáveis defasadas uma vez, sendo os impactos todos positivos.

Tabela 10 - Coeficientes estimados do modelo VAR

Variáveis	D(FERT)	D(SOJA)	D(MILHO)	D(DÓLAR)	D(PETRO)
D(FERT(-1))	-0.0106860 (0.14514) [-0.73625]	-0.241666 (0.27261) [-0.88648]	0.215578 (0.41373) [0.52106]	0.114828 (0.22777) [0.50413]	0.640998 (0.56428) [1.13595]
D(SOJA(-1))	-0.022930 (0.08704) [-0.26344]	0.035507 (0.16348) [0.21719]	-0.111643 (0.24811) [-0.44997]	-0.112470 (0.13659) [-0.82340]	-0.224547 (0.33840) [-0.66356]
D(MILHO(-1))	-0.061500 (0.05074) [-1.21214]	0.136411 (0.09530) [1.43144]	0.384920 (0.14463) [2.66146]*	-0.022402 (0.07962) [-0.28135]	0.164286 (0.19726) [0.83286]
D(DÓLAR(-1))	0.209991 (0.09380) [2.23867]**	0.230715 (0.17618) [1.30951]	0.250350 (0.26739) [0.93628]	0.358476 (0.14720) [2.43522]**	0.126470 (0.36469) [0.34679]
D(PETRO(-1))	-0.031068 (0.03507) [-0.88600]	0.034323 (0.06586) [0.52113]	-0.124965 (0.09996) [-1.25018]	-0.077884 (0.05503) [-1.41530]	0.269955 (0.13633) [1.98015]***
C	-0.000729 (0.00307) [-0.23729]	-0.003259 (0.00577) [-0.56451]	-0.001613 (0.00876) [-0.18416]	0.002177 (0.00482) [0.45132]	-0.006710 (0.01195) [-0.56155]

Fonte: Resultado da pesquisa.

* Significativo a 1%, ** significativo a 5%, *** significativo a 10%.


Os gráficos de impulso-resposta do modelo VAR se encontram na figura 5 e 6. Na figura 5, encontram-se as respostas dos fertilizantes dado um impulso não antecipado nas variáveis analisadas. Os choques dos fertilizantes sobre a sua própria variável exerce influência positiva até o segundo período. Já a resposta dos fertilizantes dado um choque não antecipado na soja

foi nulo. Bini et al. (2016), verificaram que os preços do cloreto de potássio e do sulfato de amônia, reagiram de forma negativa ao impulso não antecipado no preço da soja, não ultrapassando -0,5% nos doze meses analisados.

A resposta dos fertilizantes dado um choque não antecipado no milho e petróleo, tiveram resultados semelhantes. Percebe-se que a resposta dos fertilizantes em um primeiro momento é nula, mas a partir do segundo período se mantem negativa até o quarto período, e após esse voltando a ser nulo o efeito. Nota-se que se considerarmos o intervalo de confiança nessa análise, pode-se concluir que o efeito é zero. Os resultados encontrados por Bini et al. (2016), não demonstraram uma forte relação entre o petróleo e os fertilizantes, onde um choque não antecipado no preço do petróleo não é repassado totalmente para os preços dos fertilizantes. No trabalho dos autores um aumento de 1% no preço petróleo, leva uma variação menor que 0,25% nos fertilizantes analisados.

Um choque não antecipado no dólar, induz uma leve alta nos preços dos fertilizantes entre o primeiro e o terceiro período. Sabe-se que as importações de fertilizantes representam aproximadamente 77% do consumo total no Brasil, tornando assim o dólar uma variável importante na formação dos preços interno dos fertilizantes, ou seja, uma alta no dólar pode levar a um aumento nos preços dos fertilizantes.


Figura 5- Resposta da variável fertilizante a um choque não antecipado nas variáveis analisadas



Fonte: Resultado da pesquisa.

Já quando o choque não antecipado acontece nos fertilizantes, nota-se que todas as variáveis ficaram com intervalo de confiança consideravelmente grande para os primeiros períodos. Os resultados de um choque não antecipado nos fertilizantes para a soja e o milho se destacam, uma vez que os fertilizantes possuem representatividade nos custos de produção dessas commodities. Mesmo sabendo que os intervalos de confianças levam em consideração uma resposta nula, dado o choque não antecipado, os resultados induzem para uma leve diminuição no primeiro momento no preço do milho, mas no segundo momento já se torna positivo até o quarto período onde se torna nulo. Já os resultados para o preço da soja, em um primeiro momento induz para um aumento dos preços, entrando em declínio até o segundo momento e voltando a aumentar até o quarto momento.

Figura 6 - Resposta das variáveis analisadas a um choque não antecipado na variável fertilizantes



Fonte: Resultado da pesquisa.

As tabelas de 10 a 12 expõem as decomposições das variâncias dos erros de previsão dos fertilizantes, soja e milho. Para todas as variáveis, o maior percentual da variância do erro de previsão é explicado pela própria variável.

Na tabela 10 é apresentada a decomposição da variância dos erros de previsão para os fertilizantes. Observa-se que a variável dólar se destaca perante as outras variáveis. Essa relação era esperada, uma vez que aproximadamente 77% dos insumos para a produção dos fertilizantes são importados, sofrendo assim, influência do dólar. No trabalho de Bini et al. (2016), a relação encontrada entre o dólar e os fertilizantes não se mostraram fortes.

Tabela 11 - Decomposição da variância dos erros de previsão em porcentagem da variável fertilizantes para a soja, milho, petróleo e dólar

Variável	Período	Fertilizante	Soja	Milho	Petróleo	Dólar
Fertilizantes	1	100,0000	0,0000	0,0000	0,0000	0,0000
	2	89,3953	0,0028	2,4061	1,0595	7,1363
	3	88,4420	0,1996	2,8717	1,3046	7,1822
	4	88,2827	0,2275	3,0081	1,3128	7,1689
	5	88,2581	0,2298	3,0243	1,3156	7,1723
	6	88,2519	0,2298	3,0247	1,3196	7,1739
	7	88,2506	0,2298	3,0247	1,3208	7,1741
	8	88,2504	0,2298	3,0247	1,3210	7,1741
	9	88,2504	0,2298	3,0247	1,3210	7,1741
	10	88,2504	0,2298	3,0247	1,3210	7,1741

Fonte: Resultado da pesquisa

Os resultados da decomposição da variância dos erros de previsão da soja mostraram que, decorridos 10 períodos, após um choque não antecipado nessa variável, aproximadamente 91% de seu comportamento decorre dela mesma, e aproximadamente 9% é atribuído as demais variáveis. Essa baixa relação com as outras variáveis, pode estar atrelado a formação de preço da soja que atualmente tem como referencia a bolsa de Chicago e Nasdaq, onde os preços dependem da oferta e demanda mundial.

Tabela 12 - Decomposição da variância dos erros de previsão em porcentagem da variável soja para o fertilizante, milho, petróleo e dólar

Variável	Período	Fertilizante	Soja	Milho	Petróleo	Dólar
Soja	1	1,0312	98,9688	0,0000	0,0000	0,0000
	2	1,6615	92,8468	2,5608	0,4984	2,4324
	3	1,9432	91,4770	3,3236	0,5838	2,6724
	4	1,9711	91,1204	3,3333	0,7801	2,7951
	5	1,9709	91,0484	3,3323	0,8403	2,8081
	6	1,9708	91,0393	3,3344	0,8474	2,8081
	7	1,9711	91,0384	3,3348	0,8475	2,8082
	8	1,9711	91,0382	3,3348	0,8476	2,8083
	9	1,9711	91,0382	3,3348	0,8476	2,8083
	10	1,9711	91,0382	3,3348	0,8476	2,8083

Fonte: Resultado da pesquisa.

Já a tabela 12, apresenta os resultados da decomposição da variância para o milho, onde percebe-se que após 10 períodos decorridos de um choque não antecipado na soja, explica em torno de 19% da variância do erro de previsão do milho. Bini et al. (2016) também encontraram uma relação forte entre a soja e o milho, onde um choque no preço da soja explicava aproximadamente 25% da variância de previsão do milho.

Tabela 13 - Decomposição da variância dos erros de previsão em porcentagem da variável milho para os fertilizantes, soja, petróleo e dólar

Variável	Período	Fertilizante	Soja	Milho	Petróleo	Dólar
Milho	1	0,4401	22,0677	77,4922	0,0000	0,0000
	2	1,0797	20,1807	75,3205	2,2387	1,1804
	3	1,1856	19,5905	73,5075	3,9166	1,7997
	4	1,1838	19,4729	73,0669	4,3914	1,8849
	5	1,1840	19,4590	73,0141	4,4565	1,8865
	6	1,1853	19,4578	73,0106	4,4595	1,8867
	7	1,1857	19,4576	73,0100	4,4595	1,8872
	8	1,1857	19,4576	73,0098	4,4596	1,8873
	9	1,1857	19,4576	73,0098	4,4596	1,8873
	10	1,1857	19,4576	73,0098	4,4596	1,8873

Fonte: Resultado da pesquisa.

5. CONSIDERAÇÕES FINAIS

O presente trabalho teve como objetivo encontrar um modelo de previsão e analisar variáveis que possam interferir no preço dos fertilizantes no estado do Paraná. Para tal proposta foram adotados dois modelos, o SARIMA para previsão dos preços e a modelagem VAR para verificar as relações entre as variáveis estudadas.

Ao verificar os dados encontrados para o modelo SARIMA, percebe-se que o modelo escolhido não se distancia da realidade, ficando dentro de um limite de erro de 10% dos valores originais, sendo assim um bom indicador para previsão dos preços futuros.

O modelo VAR, através do impulso-resposta e decomposição da variância, refletiram a sensibilidade dos preços dos fertilizantes com o preço do dólar. De maneira geral os resultados dos testes empregados nessa pesquisa sugeriram uma dependência dos preços dos fertilizantes com o câmbio, que pode ser justificada parcialmente, pelo fato que a produção nacional de fertilizantes não supre a demanda interna. Atualmente no Brasil, 77% dos insumos para a produção dos fertilizantes são importados. O principal motivo para isso se deve em decorrência da baixa tecnologia disponível para a produção desses insumos.

Em relação a transmissões entre o preço da soja e do milho com o preço dos fertilizantes, os resultados mostraram fraca transmissão nesse elo. Muito provavelmente isso acontece em consequência que os preços dos fertilizantes serem comercializados no tempo $t-1$ enquanto que o preço das commodities é no tempo t . Outra provável justificativa é em decorrência que grande parte dos insumos para a produção dos fertilizantes serem cotados em bolsa, sendo assim dependente da demanda e oferta mundial para formação dos preços.

O foco principal do presente trabalho foi encontrar ferramentas econométricas para facilitar o entendimento do comportamento dos preços dos fertilizantes com formulação NPK para o estado do Paraná voltado para os custos de produção da soja e do milho. Esperava-se que as commodities e o petróleo tivessem uma relação mais forte com os preços dos fertilizantes, mas os resultados mostraram que essa relação acontece do câmbio para os fertilizantes.

Os levantamentos feitos no trabalho mostraram que o mercado interno de fertilizantes se manteve na mesma capacidade de produção a anos, enquanto que a demanda interna vem aumentando. Essa insuficiência da produção interna a médio e longo prazo pode se tornar amargas para um país que adota um regime de câmbio flutuante, tornando assim o preço dos fertilizantes sensíveis ao mercado internacional e conseqüentemente ao câmbio.

REFERÊNCIAS

- ALCARDE, J. C. ; GUIDOLIN, J. A.; LOPES, A. S. Adubos e a eficiência das adubações. **ANDA Associação Nacional para Difusão de Adubos**. 5. ed. São Paulo, 1998.
- BINI, D. A.; CANEVER, M. D.; SOUZA, M. O.; ELY, R. A. Transmissão de preços ao longo das cadeias produtivas do Brasil. **Revista de Economia**, 43, jan./abr 2016.
- BUENO, R. L. S. **Econometria de séries temporais**. 2. ed. São Paulo: Cengage Learning, 2011.
- BOTEON, M.; LACERDA, M. P. Análise do Impacto dos preços de fertilizantes no setor hortifrutícola. **Sociedade Brasileira de Economia, Administração e Sociologia Rural**, Porto Alegre, Julho 2009.
- CELLA, D.; ROSSI, M. C. D. L. Análise do mercado de fertilizantes no Brasil. **Revista Interface Tecnológica**, v. 7, n. 1, p. 41-50, 2010.
- CEPEA. Centro de Estudos Avançados em Economia Aplicada, 2008. Disponível em: <https://www.cepea.esalq.usp.br/br>. Acesso em: 18 Maio 2019.
- CONAB. Companhia Nacional de Abastecimento. Disponível em: <https://www.conab.gov.br/info-agro/precos>. Acesso em: 11 Junho 2019.
- DIAS, P.; FERNANDES, E. Fertilizantes: uma visão global sintética. **BNDES Setorial**, Rio de Janeiro, n. 24, p. 97-138, set. 2006.
- ESPINOSA, M. M.; PRADO, S. M.; GHELLERE, M. Uso do modelo Sarima na previsão do número de focos de calor para os meses de junho a outubro no Estado de Mato Grosso. **Ciência e Natureza**, v. 32, n. 2, p. 7-21, 2010.
- FMI. Fundo Monetário Internacional. Disponível em: <https://www.imf.org/external/index.htm>. Acesso em: 11 Junho 2019.
- GOFFREDO, M. M. **A balança comercial do agronegócio brasileiro no período de 1997 a 2017: uma proposta de revisão**. 2018. Dissertação (Mestrado em Economia Aplicada) – Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2018.
- GUJARATI, D. N. **Econometria Básica**. 3. ed. São Paulo: Makron Books, 2000.
- GUJARATI, N. **Econometria Básica**. 4ª. ed. Rio de Janeiro: Elsevier Editora, 2006.
- IPEADATA. Instituto de Pesquisa Econômica Aplicada. Disponível em: <http://www.ipeadata.gov.br/Default.aspx>. Acesso em: 07 de junho 2019.
- IBGE. Sistema IBGE de Recuperação Automática – SIDRA. Disponível em: <https://sidra.ibge.gov.br/tabela/1618>. Acesso em 02 de fevereiro de 2020.
- HORVAT, A. **Estudo do consumo de fertilizantes na região do Matopiba e seus reflexos na produção de soja do Brasil**. 2012. Trabalho de Conclusão de Curso (Pós-Graduação em Agronegócio, Universidade Federal do Paraná, Curitiba, 2012.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. São Paulo: Editora Edgard Blücher LTDA, 2004.

NICOLELLA, C.; DRAGONE, D. S.; BACHA, J. C. Determinantes da demanda de fertilizantes no Brasil no período de 1970 a 2002. **Revista de Economia e Sociologia Rural**, Rio de Janeiro, v. 43, n. 1, Jan./Mar. 2005.

PIGNATI, W. A. et al. Distribuição espacial do uso de agrotóxicos no Brasil: uma ferramenta para a vigilância em saúde. **Ciência e Saúde Coletiva**, Rio de Janeiro, v. 22, n. 10, p. 3281-3293, out. 2017.

BIBLIOGRAFIAS

- ALVES, E.; CONTINI, E.; HAINZELIN, É. Transformações da agricultura brasileira e pesquisa agropecuária. **Caderno de Ciência e Tecnologia**, Brasília, 22, v. 22, n. 1, p. 37-51, jan./abr. 2005.
- ANDA. Associação Nacional de Difusão de Adubos. Disponível em: <http://anda.org.br/>. Acesso em: 07 Junho 2019.
- BARBALHO JUNIOR, C. G. P.; CALLADO, A. C. Análise da competitividade do setor de fertilizantes da região Nordeste. **Revista Brasileira de Estratégia**, Curitiba, v. 1, n. 3, p. 307-318, Set./Dez. 2008.
- CALDARELLI, ; CAMARA, R. G. D.; BACCHI, R. P. Análise da interdependência dos mercados de soja e milho no Brasil e Paraná: uma aplicação da metodologia VEC. **Sociedade Brasileira de Economia Administração e Sociologia Rural**, Porto Alegre, v. 47, jul. 2009.
- CARVALHO, L. D. C.; SÁFADI, T.; FERREIR FERRAZ, M. I. Sazonalidade nos índices de preços setoriais agrícolas do município de Lavras, MG. **Revista Brasileira de Biometria**, São Paulo, v. 26, n. 4, p. 83-101, 2008.
- IBGE. Instituto Brasileiro de Geografia e Estatística. Disponível em: <https://www.ibge.gov.br/>. Acesso em: 18 Maio 2019.
- MARGARIDO, M. A.; SOUSA, L. L. Formação de preços da soja no Brasil. **Agricultura em São Paulo**, São Paulo, v. 45, n. 2, p. 52-61, 1998.
- OGINO, M. **Fertilizantes minerais: análise da dinâmica na economia agrícola do Centro - Oeste brasileiro**. 2018. Dissertação (Mestrado em Economia Aplicada) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2018.
- SAAB, A. A.; PAULA, R. D. A. O mercado de fertilizantes no Brasil diagnósticos e propostas políticas. **Revista de Política Agrícola**, v. 17, n. 2, abr./mai./jun. 2008.
- SANTANA, L. D. **Previsões para arrecadação de ICMS no Ceará: uma análise com modelo de correção de erros**. 2009. Dissertação (Mestrado Profissional em Economia do Setor Público – Sobral) – Programa de pós graduação em Economia, Fortaleza, 2009.
- TIDRE, V.; BIASE, G.; SILVA, M. I. D. S. Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região norte brasileira. **Revista Eletrônica Matemática e Estatística em Foco**, Uberlândia, v. 1, n. 1, p. 57-66, Jun. 2013.
- WALTER, M. F. C.; HENNING, E.; MORO, G.; SAMOHYL, R. W.; Aplicação de um modelo Sarima na previsão de vendas de motocicletas. **Revista Exacta**, São Paulo, v. 11, n. 1, p. 77-88, 2013.
- ZYLBERSZTAJN, D; IANK, M. S.; AZEVEDO, P. F.; BACHA, C. J. C.; HERRMANN, L. **Complemento do relatório sobre o setor de fertilizantes contido na página 154 do relatório final enviado em novembro de 2000**. Fundação Instituto de Administração. São Paulo. Set. 2002.

ANEXOS

Anexo A – Decomposição das Variâncias

Decomposição da variância dos erros de previsão em porcentagem da variável petróleo para os fertilizantes, soja, milho e dólar

Variável	Período	Fertilizante	Soja	Milho	Petróleo	Dólar
Petróleo	1	0,4567	3,7806	0,2420	95,5208	0,0000
	2	2,2322	3,4832	0,9609	93,1497	0,1740
	3	2,6227	3,4538	0,9805	92,3247	0,6184
	4	2,6663	3,4590	0,9907	92,1582	0,7257
	5	2,6662	3,4632	1,0069	92,1294	0,7343
	6	2,6662	3,4640	1,0120	92,1236	0,7343
	7	2,6663	3,4641	1,0126	92,1225	0,7345
	8	2,6663	3,4640	1,0127	92,1224	0,7346
	9	2,6663	3,4640	1,0127	92,1224	0,7346
	10	2,6663	3,4640	1,0127	92,1224	0,7462


Fonte: Resultado da pesquisa.


Decomposição da variância dos erros de previsão em porcentagem da variável dólar para os fertilizantes, soja, milho e petróleo

Variável	Período	Fertilizante	Soja	Milho	Petróleo	Dólar
Dólar	1	7,3438	18,8438	0,2263	0,0777	73,5085
	2	8,8989	16,3615	0,3576	2,8183	71,5637
	3	8,7811	16,1042	0,9046	4,0730	70,1372
	4	8,7420	16,0893	1,1476	4,2023	69,8189
	5	8,7447	16,0854	1,1893	4,1998	69,7809
	6	8,7456	16,0831	1,1917	4,2039	69,7757
	7	8,7455	16,0826	1,1916	4,2062	69,7742
	8	8,7454	16,0825	1,1917	4,2066	69,7738
	9	8,7454	16,0825	1,1917	4,2066	69,7738
	10	8,7454	16,0825	1,1917	4,2066	69,7738

Fonte: Resultado da pesquisa.

Anexo B – Impulso resposta





Fonte: Resultado da pesquisa.