

UNIVERSIDADE FEDERAL DE SANTA CATARINA – UFSC
CENTRO SOCIOECONÔMICO - CSE
DEPARTAMENTO DE ECONOMIA E RELAÇÕES INTERNACIONAIS
CURSO DE CIÊNCIAS ECONÔMICAS

IMPACTOS DE EVENTOS CLIMÁTICOS NO PREÇO DA SOJA EM CBOT
ENTRE 1988 E 2016

FELIPE KILLING SCHEMES

Florianópolis, 2018.

FELIPE KILLING SCHEMES

**IMPACTOS DE EVENTOS CLIMÁTICOS NO PREÇO DA SOJA EM
CBOT ENTRE 1988 E 2016**

Monografia submetida ao curso de Ciências
Econômicas da Universidade Federal de Santa
Catarina como requisito parcial para a obtenção do
grau de Bacharel em Ciências Econômicas.

Orientador: Prof. Dr. Guilherme de Oliveira.

Florianópolis, 2018.

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CURSO DE GRADUAÇÃO EM CIÊNCIAS ECONÔMICAS

A Banca Examinadora resolveu atribuir a nota 9 ao aluno Felipe Killing Schemes na disciplina CNM 7107 – Monografia, pela apresentação deste trabalho.

Banca Examinadora:

Prof. Dr. Guilherme de Oliveira
Orientador

Prof. Dr. Arlei Luiz Fachinello
Membro da Banca

Prof. Dr. Milton Biage
Membro da Banca

AGRADECIMENTOS

Gostaria de agradecer aos contribuintes da União Federativa do Brasil e a minha família por me financiarem nesta meia década na academia. A minha família também agradeço o carinho e o trabalho de criação. Um agradecimento especial ao meu orientador Guilherme de Oliveira e a minha colega Nicole Kormann por toda dedicação e ajuda especial.

RESUMO

O presente trabalho visa estimar como um El Niño ou um La Niña afetam o preço *spot* da soja na Bolsa de Mercadorias de Chicago (CBOT). Foi realizada uma breve revisão da literatura na área de economia agrícola e do meio ambiente, principalmente na literatura que tange assuntos relevantes à formação de preços do mercado da soja. A partir de uma análise quantitativa, que foi feita utilizando a técnica de Vetores Autoregressivos (VAR), foi possível estimar funções impulso resposta e a decomposição da variância da taxa de crescimento do preço da soja. Os resultados obtidos por estes métodos revelaram que a taxa de crescimento dos futuros dos subprodutos da soja, óleo e farelo, têm o maior efeito sobre o preço do grão. O preço do milho impacta o mercado da soja somente na safra seguinte. A leguminosa revelou-se um bem inelástico no curto prazo a choques de variáveis macroeconômicas. O La Niña influenciou a variância da soja significativamente e causou choques positivos no preço de quase 1 p.p (ponto percentual). Já o fenômeno oposto, o El Niño, não obteve resultados tão expressivos. Choques com defasagem de seis meses gera respostas positivas dos preços de até 0,3 p.p.

Palavras-Chave: Mercado da Soja; El Niño; La Niña; CBOT; Economia do Meio Ambiente.

ABSTRACT

The present work aims to estimate how an El Niño or a La Niña change soybean spot prices on Chicago Board Trade (CBOT). A briefly related literature review was made. Specifically approaching agricultural economics, environmental economic focus on soybean price making matters. Starting with a quantitative analysis which was made using a VAR model it was possible to estimate a impulse response function and make a variance decomposition table of the soybean price growth ratio. Results showed that the futures of soybean oil and meal have the biggest impact on soy prices. Maize price growth has influence on soybean prices during the next harvest period while world product proved to have a small role in this product explanation on the short term. La Niña events influenced soybean price volatility and cause significant impulses near 1p.p. Other way for El Niño events results were less expressive, even that those events causes shocks on the sixth lag as big as 0,3p.p.

Keywords: Soy Market; El Niño; La Niña; CBOT; Environmental Economics.

LISTA DE FIGURAS

Figura 1: Destinos da soja produzida.	15
Figura 2: Produção e preços da soja	19
Figura 3: Formação de preço da soja.....	20
Figura 4: Impactos do El Niño.	24
Figura 5: Impactos do La Niña.....	25
Figura 6: Área colida de soja em 2000.....	26
Figura 7: Área aproximada produtora de soja na América do Sul.	26
Figura 8: Área aproximada produtora de soja na América do Norte	27
Figura 9: Houck parameters 1983-2016	34
Figura 10: Região 3,4; El Niño de 2015.....	35
Figura 11: Logaritmo do preço da soja mensal 1984-2016.....	39
Figura 12: Logaritmo do PIB mundial (anual interpolado).....	40
Figura 13: Logaritmo do preço futuro do farelo de soja (multiplicado por 0,474).	40
Figura 14: Logaritmo do preço futuro do óleo de soja (multiplicado por 0,109).....	41
Figura 15: Logaritmo do preço do milho.	42
Figura 16: Logaritmo da produtividade mundial de soja hg/ha (anual interpolado).....	42
Figura 17: El Niño e La Niña (com <i>dummy</i>).	43
Figura 18: Logaritmo do <i>National Association of Purchasing Managers Index</i> (PMI)	44
Figura 19: Teste de estabilidade do modelo	46
Figura 20: Função impulso resposta do preço da soja.....	49
Figura 21: Função impulso resposta do preço da soja em relação a produtividade	49
Figura 22: Função impulso resposta do preço da soja em relação ao preço do milho	50
Figura 23: Função impulso resposta do preço da soja em relação ao preço futuro do óleo de soja multiplicado pelo seu respectivo coeficiente de esmagamento.....	51
Figura 24: Função impulso resposta do preço da soja em relação ao preço futuro do farelo de soja multiplicado pelo seu respectivo coeficiente de esmagamento.....	51
Figura 25: Função impulso resposta do preço da soja em relação à atividade econômica dos EUA.....	52
Figura 26: Função impulso resposta do preço da soja em relação ao El Niño.....	53
Figura 27: Função impulso resposta do preço da soja em relação ao La Niña.	53
Figura 28: Função impulso resposta do preço da soja em relação ao PIB mundial.	54

LISTA DE TABELAS

Tabela 1: Hectares colhidos no principais produtores	27
Tabela 2: Hipóteses nulas dos testes DF e ADF.....	38
Tabela 3: Resultados dos testes de raiz unitária (Schwarz Info Criterion para o teste ADF)..	44
Tabela 4: Resultados dos testes de raiz unitária (Schwarz Info Criterion para o teste Phillips Perron)	45
Tabela 5: Estrutura das defasagens ótimas	46
Tabela 6: Teste de autocorrelação residual.....	47
Tabela 7: Resultados do modelo VAR	48
Tabela 8: Decomposição da variância	56
Tabela 9: Causalidade de Granger	64
Tabela 10: Normalidade dos resíduos.....	65
Tabela 11: Teste de heteroscedasticidade.....	66
Tabela 12: Coeficientes do modelo VAR	67

LISTA DE SIGLAS E ABREVIACOES

ADF -	Augmented Dickey Fuller
BM&F -	Bolsa de Mercadorias e Futuros
CBOT -	Chicago Board of Trade
DDGS -	Distillers Dried Grains with Solubles
DF -	Dickey Fuller
ENSO -	El Nio Southern Oscillation
EL -	El Nio
FAO -	Food and Agriculture Organization
HP -	Houck Parameters
LA -	La Nia
MQO -	Mtodo dos Mnimos Quadrados
NOAA -	National Oceanic and Atmospheric Administration
PMI -	Purchasing Managers Index
PP -	Phillips and Perron
SOI -	Southern Oscillation Index
SST -	Sea Surface Temperature
USDA -	United States Department of Agriculture
USA -	United States of America
VAR -	Vetores Autoregressivos

SUMÁRIO

1 INTRODUÇÃO.....	11
1.1 Objetivos.....	12
1.2.1 Objetivo geral	12
1.2.2 Objetivos específicos.....	12
1.3 Estrutura da monografia	13
2 REVISÃO DE LITERATURA	14
2.1 Aspectos teóricos da formação de preços da soja.....	14
2.2 Literatura empírica relacionada aos eventos climáticos extremos	21
2.3 Literatura empírica relacionada ao impacto dos ENSO no mercado da soja	30
3 PROCEDIMENTOS METODOLÓGICOS	31
3.1 Modelo teórico.....	32
3.2 Dados	34
3.3 Modelo empírico	36
3.4 Modelo VAR (Vetores Auto Regressivos).....	37
4 RESULTADOS E DISCUSSÃO	39
5 CONCLUSÃO.....	58
REFERÊNCIAS	60
APÊNDICE	64

1 INTRODUÇÃO

As variações de temperatura na superfície do sudeste do Oceano Pacífico, próximo à costa da América do Sul, causam eventos climáticos distintos por todo o globo. Estas anomalias térmicas são conhecidas com El Niño no caso de um aumento de temperatura e La Niña quando há esfriamento nas águas superficiais desta região. Estes eventos também são conhecidos como *El Niño Southern Oscillation* (ENSO) (NOAA, 2017).¹

Especificamente, esta mudança de frequência inevitavelmente causa outras mudanças de frequência ao redor do globo, já que uma variação de temperatura, nada mais é que uma transferência de calor, ou alteração de frequência de moléculas. O calor perdido no sudeste do Pacífico é transferido para outra localidade no espaço estático. O calor por sua vez causa mudanças na matéria e no seu estado físico. Em um de seus desdobramentos, mais calor aumenta o nível de evaporação da água; o que (tudo mais constante), aumenta as precipitações (NOAA, 2017).

A agricultura, como o próprio nome sugere é uma cultura, ou seja, é uma ação do homem. Esta ação que ocorre em um espaço e em um tempo, está sujeita aos eventos climáticos. A produtividade da agricultura depende da quantidade de energia despendida por parte do homem no manejo da terra; do estoque de capital na forma de equipamentos, fertilizantes, pesticidas; do acúmulo de conhecimento das técnicas de colheita; dos recursos minerais e orgânicos presentes na terra; e das condições temporais na forma de temperatura e quantidade de água no solo (ARAÚJO, 2012).

O preço dos produtos agrícolas é diretamente afetado pelas variáveis que influenciam a oferta e a demanda. O produto da produtividade média da terra e do total da área produtora resulta na oferta global de produtos agrícolas. A demanda por sua vez, também exerce influência nos preços, dependendo praticamente do tamanho da população humana mundial e de seus rebanhos, mais seus gastos e preferências, por exemplo: preferências por vestuários ou alimentos (MARGARIDO; FERNANDES; TUROLLA, 2002).

Na safra 2016/2017, os maiores produtores de soja do mundo foram os Estados Unidos (com 40% da produção mundial), o Brasil (com 40% da produção mundial) e a Argentina (8% da produção mundial do grão). Esta concentração do mercado permite focar os estudos da produção de soja nestas três regiões, pois um choque climático que venha a afetar a produção de qualquer uma destas áreas traria fortes retrações de oferta em todo mundo (USDA, 2017). É

¹ Irregularidade de temperatura nas águas do Pacífico (*El Niño* ou *La Niña*).

nesse contexto que o presente trabalho se insere, procurando contribuir para essa literatura, por meio da estimação do efeito de choques climáticos, mais especificamente do ENSO, sobre o preço da soja no mercado americano. Em especial, busca-se compreender qual é o tamanho e a duração do choque de preços.

A soja é uma das principais mercadorias negociadas no mundo. Esta oleaginosa é a matéria prima de uma infinidade de outros produtos como a carne bovina, suína, de aves, molho shoyo, tofu, tintas, vernizes, biodiesel e até energia elétrica. O grão em estado natural, primeiro é rachado para extrair sua casca e depois é esmagado em diferentes processos de prensa. Na prensa quente com solventes são extraídos o farelo (70%) e o óleo degomado (30%) (USDA, 2017). Quando esmagado em prensa fria sem solventes, são extraídos a torta e após o refino se tem o óleo refinado. O farelo e a torta são a base de muitos tipos de ração animal e de outros alimentos humanos devido ao seu alto valor proteico. Os óleos por sua vez, tem suas utilizações na indústria química, na fabricação de biodiesel, tintas e solventes por exemplo.

Portanto, compreender os efeitos destas anomalias de temperatura no Pacífico nas regiões produtoras de soja, principalmente no *Corn Belt* americano e no Brasil é relevante, sobretudo, para questões relacionadas à segurança alimentar mundial (PERI, 2017).

Motivado por todas essas considerações, o presente trabalho visa responder a seguinte questão: Qual foi o impacto econômico das variações de temperatura no Oceano Pacífico (ENSO) no preço da soja na Bolsa de Mercadorias de Chicago (CBOT) no período 1988-2016?

1.1 Objetivos

A presente seção descreve os objetivos desta monografia.

1.2.1 Objetivo geral

A monografia analisará como um El Niño ou um La Niña, afetou preço da soja na Bolsa de Mercadorias de Chicago (CBOT) no período 1988-2016.

1.2.2 Objetivos específicos

Como objetivos específicos citam-se:

- I) Revisar como a literatura da economia agrícola e a economia do meio ambiente abordam a questão da formação de preços da soja, ressaltando o papel dos eventos climáticos;
- II) Estimar, por meio de um modelo econométrico, o impacto do El Niño e do La Niña no preço da soja spot na Bolsa de Mercadorias de Chicago;
- III) Analisar os resultados obtidos na pesquisa respaldado pela teoria econômica, sobretudo, inspecionando o tamanho e a duração de cada choque no curto prazo.

1.3 Estrutura da monografia

Além da introdução, o presente trabalho de conclusão de curso se desdobra na seguinte forma: O Capítulo 2 faz uma revisão da literatura de economia agrícola, economia do meio ambiente e finanças agrícolas referenciando como a oferta e a demanda do grão variam, afetando os preços. O Capítulo 3 apresenta os métodos, dados e técnicas que foram utilizados para alcançar os resultados do trabalho. O Capítulo 4 apresenta os resultados obtidos pela monografia. Por fim, o trabalho elenca as Referências utilizadas.

2 REVISÃO DE LITERATURA


Neste capítulo será feita uma revisão bibliográfica acerca do mercado e da formação de preço da soja, desde a produção até a comercialização desta *commodity* agrícola. Na segunda seção do capítulo explora-se como o clima afeta o desenvolvimento da planta da soja e se discute o que são os eventos climáticos extremos ENSO. Finalmente na Seção 2.3, faz-se uma união das seções anteriores, citando autores que fizeram trabalhos empíricos semelhantes relacionados ao presente estudo.

2.1 Aspectos teóricos da formação de preços da soja

Nesta seção será apresentado de que maneira a planta da soja se integra com o clima e de como esta relação afeta o mercado internacional desta importante *commodity*.

A soja é matéria prima para diversos produtos como a carne bovina, o tofú e tintas industriais. Na Figura 1, os retângulos destacados correspondem ao valor médio de soja produzido nos Estados Unidos e consumido por diversos setores nos anos de 1947 a 1949. Os retângulos em branco, mais a área dos retângulos listrados corresponde também ao destino da soja produzida nos EUA, para os anos de 1967 a 1969. Dos dois principais produtos extraídos do grão, o óleo de soja apresenta uma diversificação maior de possíveis utilizações, enquanto o farelo é usado praticamente só para ração animal, que é, em volume, o principal destino do grão.

Figura 1: Destinos da soja produzida.



Fonte: HOUCK, J. (1968).

A soja americana é colhida principalmente entre setembro e novembro, enquanto a soja brasileira é colhida em março e abril. No Quadro 1 também é possível ver os meses de florescimento e plantio do EUA, Brasil, Argentina e China. O período de plantio é escolhido sobretudo em razão da latitude (LLANA, M. P; ET AL., 2011).

Quadro 1: Meses de safra.

	January	February	March	April	May	June	July	August	September	October	November	December
Corn												
Arg.	■	■	■	■	■				■	■	■	■
Bra.	■	■	■	■	■	■					■	■
USA				■	■	■	■	■	■	■	■	
Chi. N.				■	■	■	■	■	■	■		
Chi. S		■	■	■	■	■	■	■				
Soya bean												
Arg.	■	■	■	■	■						■	■
Bra.	■	■	■	■	■	■					■	■
USA					■	■	■	■	■	■	■	
Chi.				■	■	■	■	■	■	■		
	Planting	■		Flowering	■		Harvest	■				

Fonte: LLANA, M. P *et al.* (2011).

Dada a área total da safra que é determinada durante os meses de plantio pelos produtores, o que no Quadro 1 corresponde aos meses preenchidos por traços verticais; o nível da produção só depende da produtividade. Como o progresso técnico na forma de utilização e equipamentos agrícolas e do uso de fertilizantes e pesticidas têm um crescimento mais ou menos constante, boa parte das expectativas da safra giram em torno das condições climáticas. Desta maneira produtores, *traders* e consumidores especulam o preço da soja spot e principalmente os futuros, observando relatórios meteorológicos (SUMMER, D. A; MUELLER, R.A.E, 1989). Ainda os autores dão significativa importância aos relatórios mensais da USDA (*United States Department of Agriculture*) que relatam a qualidade das lavouras dos EUA.

A soja em geral, pode ser estocada por até 2 anos, porém os produtores costumam comercializá-la nos primeiros seis meses após a colheita, justo no período de entre safra do hemisfério oposto. Para minimizar o risco, os soja-cultores tendem a vender sua produção ao longo de todo este período, diversificando contratos *spot* e futuros em suas carteiras (ROCHA ET AL., 2010). O mercado de hedge funciona como um seguro contra o risco de mercado (BM&F, 2008). Assim, os *hedgers* minimizam o impacto das variações de preços.² No entanto, o mercado nesta complexidade não será modelado nesta monografia.

Como observaram Margarido e Sousa (1998), o preço da soja é transmitido de forma instantânea, sem defasagem para todo mundo, tendo como principal sinalizador de preço, a

² Quem faz *hedge*.

CBOT. A partir desta bolsa de altíssima liquidez, onde se negociam grandes volumes de contratos futuros e *spot*, formam-se os preços internacionais do grão. Ainda neste estudo, os mesmos autores concluíram que a variação da cotação da oleaginosa em Chicago é transmitida parcialmente para o Brasil. Os brasileiros são tomadores de preços no mercado internacional, sendo a variável preço (CBOT), responsável por 70,6% da formação do preço doméstico. A elasticidade Chicago/Argentina é ainda maior, pois o mercado interno argentino é relativamente pequeno, quando comparado ao brasileiro.

Bertrand *et al.* (1987) *apud* Malfioletti (2003) revela que até 1973 a formação de preços do grão dependia, a grosso modo, apenas da oferta e da estratégia da indústria esmagadora americana. A partir da segunda metade da década de 1970, surgiram novos produtores no cenário mundial, modificando a estratégia da indústria e levando os países a adotarem novas políticas protecionistas. A partir de então, a formação de preços da oleaginosa passou a levar em consideração a dinâmica das safras dos EUA, Brasil e Argentina. A safra americana, no entanto, ainda é a mais determinante, devido a sua produção extensiva e grande produtividade.

No Brasil parte da produção é perdida em estradas, armazéns e portos, o que é conhecido como Custo Brasil.

O “Custo Brasil” vem sendo apontado como uma das principais causas de perda de competitividade da soja brasileira frente à dos Estados Unidos e Argentina. Dentro destas ineficiências, destaca-se o setor de transportes, que apresenta-se muito mal dimensionado e bastante precário para as necessidades nacionais. Portanto, pode-se afirmar que a infraestrutura de transportes é um importante fator diferenciador dos preços da soja no mercado interno, prejudicando as regiões de fronteira que possuem estrutura mais precária. (CAIXETA, 1996 *APUD* MAFIOLETTI, 2003, p.32).

As perdas logísticas e reservas para sementes chegam aos 1/20 de uma safra no Brasil.

Bertrand *et al.* (1987) ainda sugerem que o preço do grão também é afetado pelo câmbio, frete, preço dos produtos do complexo da soja (farelo e óleo) que dependem da indústria esmagadora (oferta). Pelo lado da demanda, depende do nível de consumo de rações animais, de alimentos industrializados para humanos e da indústria química. As políticas públicas adotadas pelos governos dos EUA, Brasil e União Europeia, que incluem tarifas protecionistas e construção de silos, também podem afetar a dinâmica dos preços.

O comércio, transporte e o processamento da soja são regidos por grandes empresas conhecidas como o ABCD da soja. A *Archer Daniels Midland Company* - ADM - (EUA), Bunge & Born (Argentina e Brasil), Cargill (EUA), e Louis Dreyfus (França), são as principais *tradings* desta *commodity*. Contudo recentemente outras empresas asiáticas do mesmo tipo ganharam espaço no mercado como a COFCO (China) e a Marubeni (Japão). Estas empresas tem grande importância para o mercado, pois atuam verticalmente, às vezes, desde a produção

do grão, passando pelo armazenamento, comercialização indo até o processamento de alimentos em alguns casos,

No entanto, o presente trabalho visa compreender quais fatores formam os preços internacionais, tendo como *proxy* destes preços CBOT. Seguindo a lei do preço único das commodities, no modelo desenvolvido por Mundlack e Larson (1992), em que preço da commodity depende da razão do preço internacional e do câmbio, segue-se que na Equação 1:

$$P_{it} = P^*_{it} E_t \quad (1)$$

Assim, os tomadores de preço de todo mundo, desde o Chaco Argentino, até o porto de Rotterdam compram e vendem soja utilizando suas moedas locais, amparados na Bolsa de Chicago utilizando esta simples equação. A partir do sinalizador CBOT, os *traders*, produtores e industriais negociam prêmios positivos e negativos, dependendo de suas necessidades logísticas, de *fobbings*, custos alfandegários e de outros custos.³

A formação de preços da maioria das commodities agrícolas ocorre nas bolsas de mercadorias e futuros internacionais e através da dedução dos custos de transporte, armazenamento e impostos chega-se aos preços nas várias regiões de comercialização do mercado físico (Spot). No caso da soja a expectativa é de que os preços sejam formados na Chicago *Board of Trade* (CBOT). (MAFIOLETTI, 2000, p.20).

Ainda, segundo o mesmo autor, os preços de commodities agrícolas dependem:

- (i) ao nível do produtor – mudanças tecnológicas, preços dos fatores e produtos alternativos, financiamento, clima, etc.;
- (ii) ao nível do intermediário – variações nos custos dos insumos de comercialização (transporte, armazenamento, condições de financiamento, etc.);
- (iii) ao nível do consumidor – variações na renda, população, preços de outros bens, etc. (MAFIOLETTI, 2000, p.21).

Contudo estas três considerações ainda estão sujeitas a variáveis intertemporais, aleatoriedades diversas, sazonalidades e eventos cíclicos. Uma escassez de capital, por exemplo, pode afetar os custos dos cerealistas no armazenamento do grão, além de dificultar a aquisição de insumos; podendo obrigar os produtores a realizarem operações de *barter* desvantajosas, com prêmios negativos.⁴

O mercado de *commodities* funciona como um mercado de concorrência perfeita, onde todos os produtores e consumidores são tomadores de preços. Nesse mercado, os produtores maximizam lucros e os consumidores maximizam utilidade (MILLER, 2003).

³ Custo da empresa de *trading*.

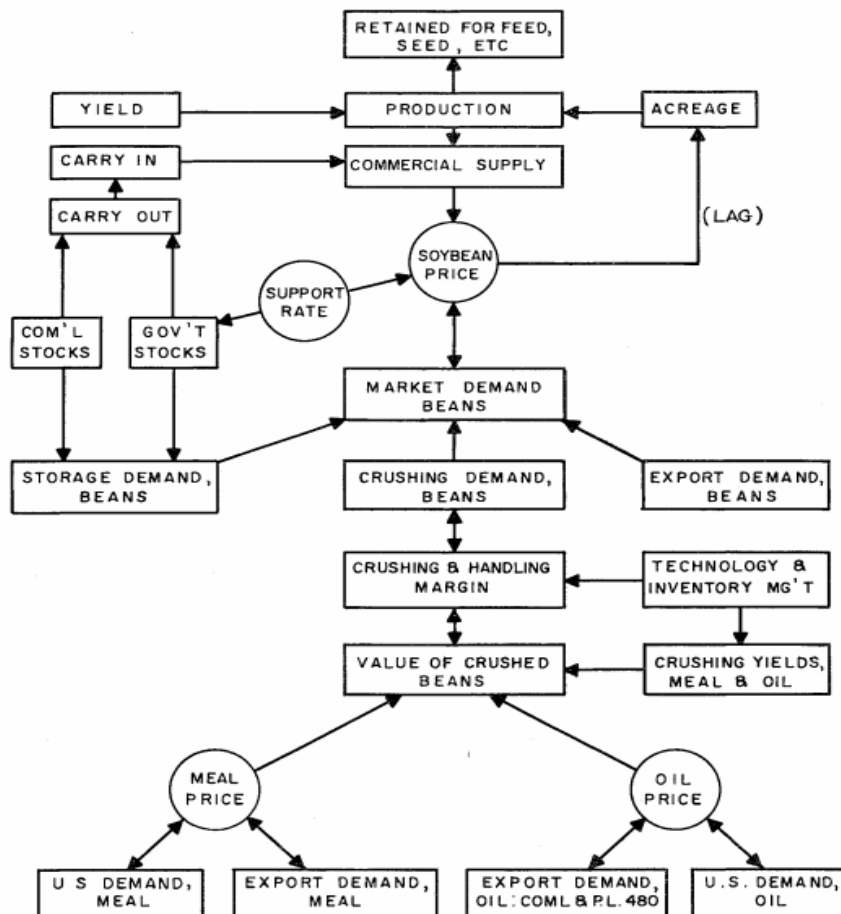
⁴ Escambo, troca de grão por fertilizantes ou pesticidas.

A área de plantio da soja depende do preço esperado da soja e do preço esperado do milho, já que estes são produtos substitutos na maioria dos espaços. É importante lembrar que a soja é uma cultura mais resistente ao clima do que o milho.

Corn and soybean compete on multiple grounds. They compete in the cooking oil industry. They compete in the animal feed industry. They also compete in the biofuel industry. Therefore, the production of one does affect the other. In general, if the production of corn falls, soybean prices are expected to rise. (ADEYANJU, 2014).

Uma expectativa de condições mais avessas pode causar um aumento da área de soja em detrimento da área de milho. Como se observa na Figura 2, a área de soja impacta a oferta do grão, que por sua vez impacta o preço.

Figura 2: Produção e preços da soja



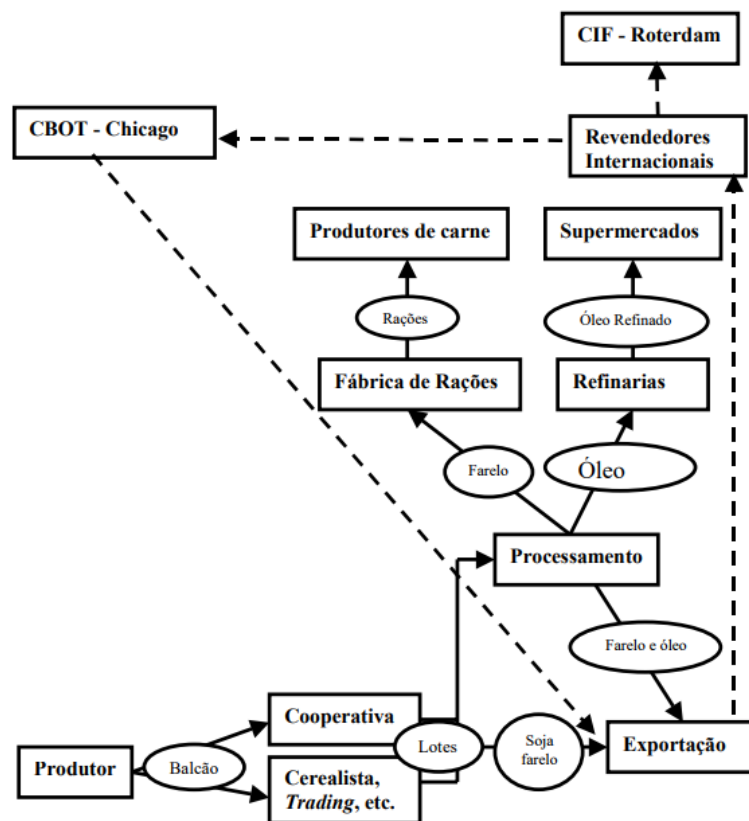
Fonte: HOUCK(1968).

Pelo lado da demanda, o preço da soja processada na forma de óleo e farelo impacta os preços do grão *in natura*. Para além das forças de mercado, no caso desta figura, o governo americano traça um preço suporte, demandando soja para seus estoques que existem, no caso dos EUA, por razões econômicas e por motivos de segurança nacional. Assim a soja é:

Um dos produtos agrícolas mais comercializados no mundo, provavelmente devido à variedade de formas de consumo, que se estendem desde alimentação (humana e animal) até a indústria farmacêutica e siderúrgica. Essa diversidade é possível porque as indústrias de processamento de soja produzem subprodutos, farelo e óleo, que se constituem em importante matéria-prima para diferentes setores industriais. (FREITAS *et AL.*, 2001, p.2).

Tal diversidade garante a *commodity* uma liquidez relativamente elevada, fazendo deste, um mercado muito consolidado e importante para o mercado financeiro internacional. Na Figura 3, observa-se o caráter internacional deste produto, a partir de CBOT, os importadores e exportadores do grão tomam a principal referência de preço, transmitindo este marco, cadeia a baixo, através das cooperativas e cerealistas e cadeia acima em direção aos pecuaristas, granjeiros, industriais em geral e supermercados.

Figura 3: Formação de preço da soja



Fonte: Mafioletti (2000).

O mercado agrícola, em geral, possui uma volatilidade de preços maior que o mercado de bens industriais. Ao contrário de ambientes industriais mais controlados, a lavoura está sujeita a choques de oferta maiores. Pragas, El Niños, La Niñas e outros eventos meteorológicos causam estes choques de produção exógenos no setor primário, afetando em menor medida o

secundário (SANTIAGO; *ET AL.*, 1996). Na cadeia produtiva, a variância de preços tende a diminuir à medida que o produto é mais processado. Por exemplo:

$$S^2(\text{soja}) > S^2(\text{óleo de soja degomado}) > S^2(\text{óleo de soja refinado}) \quad (2) \\ > S^2(\text{tintas e vernizes}).$$

O processo de transformação industrial tende a absorver as variações de preços de matérias primas como a soja, pois o custo com insumos é apenas parte do custo total, assim, na margem, o custo do bem final da cadeia aumenta menos (tudo mais constante) (SILVA; KADOTA, 1980).

Dentre os fatores mais exógenos e imprevisíveis à produção está o clima. O clima é uma variável importante, no que diz respeito à formação de preços no mercado de commodities agrícolas, pois como toda planta, as variações da soja possuem condições de iluminação, calor e disponibilidade de água, ótimas, para seu desenvolvimento máximo. (FARIAS; NEPOMUCENO; NEUMAIER, 2007).

A volatilidade dos preços causadas pelo clima, pode afetar toda a cadeia desta planta que tem uma grande participação na matriz alimentícia do planeta. (PERI, 2017). Eventos como o La Niña causam consideráveis choques negativos na oferta mundial do grão (ARAÚJO, 2012).

2.2 Literatura empírica relacionada aos eventos climáticos extremos

O desenvolvimento da soja, em todos os seus estádios vegetativos e reprodutivos depende de condições físico-hídricas, exigindo para o seu amadurecimento condições hídricas, térmicas, foto periódicas e geológicas ideais (FEHR, CAVINESS, 1977). A maior ou menor intensidade de um destes fatores culmina em um maior ou menor rendimento da planta em sementes, tendo cada variável um ponto ótimo. Atributos físicos, como a densidade, porosidade, estabilidade de agregados, infiltração e retenção de água do solo; e atributos hídricos como precipitação e irrigação, alteram a produtividade da planta (CAMARA; KLEIN, 2005). Para Beutler *et al.* (2006, p. 640):

O desenvolvimento adequado das plantas, dentre outras variáveis, é função da disponibilidade de água, contato solo-raízes, espaço poroso suficiente ao movimento de água, nutrientes e gases e resistência à penetração que não comprometa o crescimento radicular.

Como a produtividade de uma fazenda é função direta do desenvolvimento das plantas (CAMARA; KLEIN, 2005), as variáveis citadas por Beutler *et al.* (2006), impactam diretamente no nível produção das lavouras. Variáveis relacionadas ao solo, estão diretamente relacionadas a geologia da região e ao manejo do solo (ações antrópicas). Já a disponibilidade de água no solo depende principalmente do clima (exigências hídricas). Além deste fator, o clima modifica as condições térmicas a qual a planta está sujeita. A foto periodicidade, por sua vez, é função, principalmente, da latitude e da época do ano a qual é realizado o plantio.

A necessidade total ótima de precipitações ao longo da safra varia entre os 450mm/ciclo e os 800mm/ciclo. Em estudos realizados em Londrina PR, observou-se que os maiores rendimentos se situam entre os 650mm/ciclo e os 700mm/ciclo (FARIAS; NEPOMUCENO; NEUMAIER, 2007). No entanto estas condições variam conforme a correlação entre a hidro disponibilidade com as outras variáveis, e com o estágio fenológicos da planta.⁵ Quanto maior a estatura, maior a demanda por água. Segundo os mesmos autores, a soja, planta de origem do leste da Ásia, domesticada entre o século XI e XII, na região da Manchúria, China; se adapta melhor a regiões com temperaturas do ar de oscilam entre os 20°e os 30°. Sendo a temperatura ideal próxima aos 30°. Temperaturas inferiores a 10° são impróprias para esta cultura, pois o crescimento vegetativo passa a ser nulo. A temperatura do solo durante a semeadura também deve oscilar entre esta mesma faixa para um bom rendimento. Esta leguminosa é conhecida por ser uma planta de dia curto, ou seja, está se desenvolve melhor em regiões equatoriais e tropicais, devido a serem regiões com dias mais curtos durante o período de safra. Variações transgênicas e a postergação do plantio, no entanto, podem corrigir o período juvenil da planta, tornando-o mais longo. Ampliando assim a faixa latitudinal viável ao plantio, sendo o limite geográfico igual a latitude onde o período de colheita (ou estágios de maturação plena), possuiu temperaturas maiores que 10°.

Variações climáticas que impactam na produção de alimentos são causadas por uma série de eventos, dentre estes se destaca o *El Niño Southern Oscillation* (ENSO).

Considerations of the potential impacts of climate change on agriculture should be based not only on the mean values of expected climatic parameters but also on the probability, frequency, and severity of possible extreme events. Temporal and spatial variance of meteorological conditions and storms can affect soil conditions, water availability, agricultural yields and susceptibility to pest and pathogen infestations.(ROSENZWEIG; IGLESIAS; YANG; EPSTEIN; CHIVIAN, 2001, p. 91).

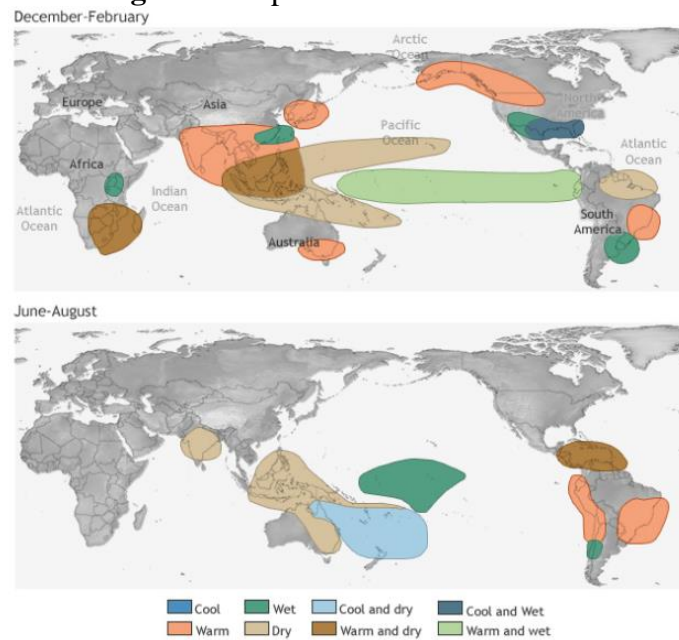
⁵ Estágio de desenvolvimento.

Os eventos ENSO são anomalias de temperatura no Oceano Pacífico. A maior ou menor intensidade de ventos alísios pode causar uma mudança de temperatura na faixa superficial deste Oceano. Segundo pesquisadores da NOAA, esta é a origem de muitas anomalias climáticas ao redor de todo o globo (NOAA, 2017). O fenômeno conhecido como *teleconnection* associa eventos de escala globais a anomalias de escala regional (ROPELEWSKI; HALPERT, 1987). O *Southern Oscillation* medido na forma do seu índice (SOI) é a mudança de pressão atmosférica entre o Taiti e a cidade de Darwin no norte da Austrália

“The Southern Oscillation Index, or SOI, gives an indication of the development and intensity of El Niño or La Niña events in the Pacific Ocean. The SOI is calculated using the pressure differences between Tahiti and Darwin.”(AUSTRALIAN BUREAU OF METEOROLOGY, 2016).

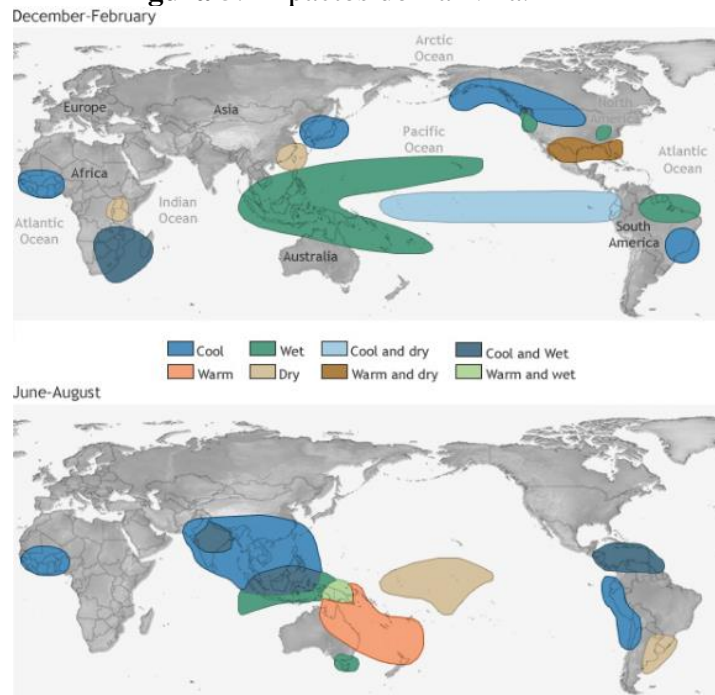
Walker e Bliss (1932) encontraram uma forte relação entre o SOI e o ENSO, já que as oscilações de pressão causam deslocamento de massas de ar (ventos) que, por sua vez, modificam a temperatura da superfície do Oceano Pacífico. Segundo Peri (2017) os métodos mais comuns para mensurar eventos ENSO são o *Southern Oscillation index* (SOI), o *Surface SeaTemperature* (SST) e o *Multivariate ENSO Index* (MEI). Ainda, segundo o autor, estes índices têm uma volatilidade muito parecida.

Nas Figuras 4 e 5 é possível observar os efeitos de *teleconnection* decorrentes do ENSO. O El Niño atinge a maior parte do Brasil elevando a temperatura tanto durante o verão quanto no inverno; na Argentina e no Sul do Brasil há um aumento das precipitações durante os meses de verão; o Sul dos Estados Unidos fica mais frio e também existe um aumento das precipitações entre dezembro e fevereiro. Durante o La Niña entre os meses de dezembro e fevereiro causa secas e temperaturas acima da média nas regiões produtoras de soja da América do Norte e frio em algumas regiões produtoras da América do Sul.

Figura 4: Impactos do El Niño.

Fonte: NOAA.

Nos meses de verão boreal correspondentes ao plantio e safra, o La Niña não exerce um padrão de desvio climático no continente Norte Americano, porém há incidência de secas entre a Argentina e a região Sul do Brasil. Apesar de algumas destas consequências de *teleconnection* dos ENSO afetarem as regiões produtoras em meses não correspondentes a safra, regiões de menor relevância para a produção de soja como China e Índia também sofrem desvios de precipitação e temperatura com os ENSO, possivelmente beneficiando ou prejudicando suas safras de soja.

Figura 5: Impactos do La Niña.

Fonte: NOAA.

Algumas das áreas afetadas pelo El Niño e La Niña, como o A foz do Rio Mississippi, o Meio Oeste americano, o Sul do Brasil, o Centro-Oeste brasileiro e os países platinos são produtoras da cultura da soja, bem como de alguns de seus substitutos mais habituais. Assim fica geograficamente suspeita uma noção de causalidade entre a temperatura do Pacífico Sul e a produção mundial de soja e consequentemente com o preço (CBOT).

The El Niño-Southern Oscillation (ENSO) refers to a quasi-periodic redistribution of heat and momentum in the tropical Pacific Ocean. In broad terms, one can characterize ENSO as a varying shift between a normal phase and two extreme phases: El Niño and El Viejo (sometimes called La Niña). In recent years, the ability to forecast ENSO, in particular, the occurrence of so-called El Niño events has improved (Barnett et al., 1988; Cane et al., 1986; Bengtsson et al., 1993). These forecasts have economic value because they can inform decision makers in vulnerable sectors of the economy (ADAMS ET AL., 1995).

Nas figuras 6, 7 e 8, em verde se destacam às áreas produtoras de soja ao redor do globo. A intensidade do cultivo não aparece nas imagens a seguir.

Figura 6: Área colida de soja em 2000.



Fonte: Australian Centre for International Agricultural Research (ANO).

Ao observar a Figura 6, se nota uma grande área verde dentro do território da Índia e da China, contudo estes países produzem menos soja do que os EUA, Brasil e Argentina (Tabela 1). Para Llana *et al.* (2011), a influência do clima em um cultivo específico depende da distribuição geográfica das lavouras e das condições de produção das mesmas, assim é difícil estimar o impacto direto do clima na produção total.

Figura 7: Área aproximada produtora de soja na América do Sul.



Fonte: Australian Centre for International Agricultural Research (ANO).

Na América do Sul a cultura da soja têm grande presença nas planícies banhadas pelos rios da Bacia Hidrográfica do Rio da Prata, que inclui rios como o Paraná, Uruguai e Paraguai

Figura 8: Área aproximada produtora de soja na América do Norte

Fonte: Australian Centre for International Agricultural Research (ANO).

Na América do Norte, apesar do Canadá produzir o grão, os Estados Unidos compreendem a grande parte do território em verde na Figura 8. O chamado *Cornbelt* ou *Soybelt*, é a região ao redor dos Montes Apalaches e também toda Bacia Hidrográfica do Rio Mississipi, inclui também a região dos Grandes Lagos ao norte.

Tabela 1: Hectares colhidos nos principais produtores.

Área colida de soja em 2016	EUA	Brasil	Argentina	China
Hectares	33482430	33153679	19504648	6640882

Fonte: Elaboração própria com dados do Banco Mundial (ANO).

Muitos autores, como Keppen (1995), Adams *et al.* (1995) e Araújo (2012), principalmente nos Estados Unidos e no Brasil, já fizeram trabalhos procurando estimar o impacto dos eventos ENSO na economia agrícola. Para Araújo (2012, p.8), por exemplo:

Eventos climáticos extremos podem ser compreendidos como ocorrências, num determinado ano, tempestades, geadas, ondas de calor e até mesmo secas prolongadas. A frequência desses eventos é atribuída na maioria das vezes aos fenômenos El Niño e La Niña, que por sua vez, são decorrentes das variações nos níveis de temperatura da superfície do mar do Oceano Pacífico.

Estes fenômenos ocorrentes no Pacífico Sul, acabam por impactar em diversos setores da economia global dependentes do clima, já que desdobram diversos outros fenômenos naturais em diversas regiões do globo. A cadeia da soja, assim como a maioria de seus substitutos mais usuais (milho, trigo, canola etc.), é diretamente afetada pelos fenômenos.

Ainda, os dois fenômenos causam choques tanto negativos como positivos nas diferentes regiões produtoras de soja, afetando a sazonalidade dos preços quando, por exemplo, um evento climático causa um aumento da produção da safra boreal, e uma diminuição da produção na safra austral, seis meses depois.

O El Niño e La Niña, assim como na soja, afetam outros produtos agrícolas substitutos à soja, como o milho (óleo e DDGS), algodão (caroço e torta) e trigo (avariado). Uma péssima colheita de trigo ou cevada acarretaria em uma oferta maior de ração animal, já que os consumidores destes cereais exigem um padrão de qualidade mínimo e assim não são usados para o consumo humano; levando, tudo mais constante, o preço do farelo de soja para baixo devido a oferta adicional de substitutos.

Barley differs from most bulk cereal markets because barley is used for special purposes that are very sensitive to quality. The most common example is beer manufacturers who contract specific acreage or have their own elevators to buy the quality of barley they need. If the quality is insufficient, the barley can be used for animal feed or alcohol, both commanding a significantly lower price than high quality barley used for beer. The key risk to the quality of the crop occurs once the plant is mature. Once the crop is nearing harvest, excessive rain and humidity create both test weight problems and damage to the color (SKEES, 2001, p.2).

Existe um padrão histórico dos efeitos causados pelos eventos ENSO. No Rio Grande do Sul, durante o El Niño (muito forte) de 1982/83, houve uma quebra de safra de 4.888.775 toneladas, causando prejuízos suficientemente elevados (BERLATO ET AL., 2005). Variabilidade interanual climática impõe o maior risco a fazendeiros. Até muito pouco tempo atrás previsões meteorológicas de longo prazo eram muito imprecisas. Em razão dos avanços recentes da ciência, alguns modelos de circulação oceânica são agora capazes de realizarem previsões com razoável grau de precisão (PHILLIPS ET AL., 2001).

Por isto “*Given the strong relationship between crop growth and climate, this predictability carries significant implications for improved efficiency of agricultural production [...]*” (PHILLIPS ET AL., 2001, p.2). Ainda, segundo o mesmo autor, enquanto em algumas regiões a associação entre o clima e o EL-LA está bem definida; em outras ainda há dúvidas quanto ao potencial de causalidade, porque o espaço de influência de um ENSO é mal definido.

Letson e McCullough (2001) sugerem que:

If a meaningful relationship exists between ENSO and the price of a major commodity such as soybeans, the implications could be profound for buyers and sellers of the commodity and for public sector investments in climate forecasting capabilities.”(...)”for an ENSO soybean price signal to have economic value lot-private and public decision makers, it should satisfy conditions Tor economic causality.”(...)”Since supply and demand also affect the spot price, there should also be an ENSO signal observable in the spot price of soy.”(...)” Because of its status as a major commodity whose price fluctuations have been less influenced by U.S.

government intervention, soybean prices have been the focus of research investigating whether an ENSO price relationship might exist (KEPPENNE, 1995 APUD LETSON; MCCULLOUGH, 2001, p.514).

O efeito Keppenne tem sido observado em diversos estudos. Existe correlação entre os ENSO e os preços futuros e *spot* da soja. No entanto Letson e McCullough (2001) não encontraram evidências de causalidade de Granger, pois o teste de Granger exige a inclusão de todos os *lags* na regressão, enquanto há motivos para acreditar que somente alguns *lags* são significantes. A inclusão de todas as defasagens irrelevantes e desnecessárias pode enviesar o resultado de não causalidade (LETSON; MCCULLOUGH, 2001). O próprio teste de Granger não prova causalidade, pois é somente um teste precedência temporal.

Um modelo de periodicidade mensal seria de pouca aplicação no mercado de commodities, caso as intenções sejam de obter lucros. A maioria das operações de compra e venda de opções de soja (futuro) não é feita ao estilo compra média mensal. Na verdade, são realizadas diversas operações *long* e *short* ao longo do mês, mas é claro que, realizar mais operações, implicam em maiores custos de corretagem (KEPPENNE; GHIL, 1992).

Entender e modelar a relação entre a economia e o clima é fundamental para a tomada de decisão de produtores, *traders*, exportadores, industriais e para toda a população que, de alguma forma, consome produtos com elevada elasticidade climática. A soja se destaca neste contexto, sendo uma das principais fontes de calorias para os rebanhos e para o próprio homem, se trata de uma questão de segurança alimentar (PERI, 2017). Segundo FAO (2011) a volatilidade dos preços dos grãos e óleos vegetais vem aumentando nos últimos 50 anos, uma característica não compartilhada por outras famílias de *commodities*. Um dos atributos ligados a isto é o clima. Seguros, contratos de derivativos climáticos e *hedges* são algumas das formas que os *players* deste mercado encontram para se proteger destes eventos naturais, mas o risco de desabastecimento causado pelo clima é real e opções financeiras não o anulam (SKEES, 2001).

Understanding and modeling the relationship between economic losses and weather events will be critical in designing tailored weather products that meet the needs for various agricultural users. (SKEES, 2001).

A primeira transição de derivativos climáticos ocorreu durante o forte El Niño no inverno de 1997-1998 que foi um dos mais fortes já registrados. Muitas empresas então decidiram fazer um *hedge* referente ao seu risco climático com este produto financeiro. Contudo opções de temperatura ainda não formam um mercado completo, pois estas opções não têm muita liquidez (ALATON; DJEHICHE; STILLBERGER, 2002).

2.3 Literatura empírica relacionada ao impacto dos ENSO no mercado da soja

Keppenne (1995) utilizou o SST para estimar o impacto dos ENSO no preço futuro da soja. O autor obteve resultados semelhantes ao deste trabalho, porém usando os futuros do grão. Onde o EL (El Niño) não definiu um impacto único nos preços, enquanto o LA (La Niña) elevou os preços via restrição de oferta.

EL are clearly discernible. During the LA years that followed those EL events, fishing conditions in the equatorial Pacific were not negatively affected, but dry weather over the Midwest led to poor harvest, which drove the supply down and the prices up. (Keppenne, 1995).

Brunner (2000) estimou um VAR (vetores autoregressivo) com dados trimestrais incluindo o preço de diversas *non-oil commodities* que constituem um único índice e concluíram que um ENSO pode inflar os preços destes produtos em cerca de 3-1/2 a 4 pontos percentuais, cifras parecidas com as encontradas neste trabalho.⁶ O autor também concluiu que o SOI (*Southern Oscillation Index*) tem impacto e significância maiores do que o SST (*Sea Surface Temperature*) sobre o índice de preços, porém quando os preços das commodities agrícolas são filtrados o SST tem um desempenho melhor. O SOI não foi testado no presente trabalho.

Peri (2017) estimando um modelo VIRF (Modelo Fuzzy de Avaliação de Investimentos Reais) com o preço da soja e do milho expostos a impulsos do SOI, obteve resultados mais expressivos e positivos para os preços do milho do que o da soja, principalmente para o EL durante os meses de primavera e verão, mas também para o LA. Para todos choques estimados por este autor, houve incremento de volatilidade nos preços.

Both events increase expected price volatility of maize, showing the strongest impact during the El Niño phase in Spring-Summer. Soybean price volatility tends to slightly decrease during Autumn-Winter meteorological seasons and to increase during the Spring-Summer period.(PERI, 2017, p.673).

⁶Commodities que não derivam do petróleo.

3 PROCEDIMENTOS METODOLÓGICOS

Caracterizando a natureza do presente trabalho, este estimou o impacto dos eventos El Niño e La Niña no preço da soja spot. Amparando-se em uma pesquisa de caráter descritivo, o que, segundo Gil (2002, p.42): “têm como objetivo primordial a descrição das características de determinada população ou fenômeno ou, então, o estabelecimento de relações entre variáveis.”; pretende-se contribuir marginalmente para a literatura relacionada.

O método utilizado para a busca dos resultados foi o indutivo. Conforme Gil, (2008, p.10) “nesse método, parte-se de observação de fatos ou fenômenos cujas causas se deseja conhecer”. Tal método justifica-se quando o pesquisador está interessado no caráter de relacionamento de duas ou mais variáveis entre si, e quando há uma ampla disponibilidade de dados e literatura sobre o tema. O nível de complexidade é o descritivo, já que outros trabalhos já exploraram essa questão.

A pesquisa caracteriza-se ainda como sendo aplicada quantitativa, já que utilizou um modelo econométrico por meio da técnica de mínimos quadrados ordinários (MQO) vetores auto regressivos (VAR). Nesse último, trata-se de uma “[...] forma de estimar relacionamentos dinâmicos entre variáveis endógenas conjuntas sem a necessidade de impor *a priori* fortes restrições (tais como relacionamentos estruturais particulares e/ou a exogeneidade de algumas das variáveis)” (HARRIS, 1995, p.77).

Para dar sustentação ao trabalho, num primeiro momento, foi realizada uma pesquisa bibliográfica na área de teoria econômica, mais especificamente, na subárea de economia agrícola e do meio ambiente, com a finalidade de compreender as variáveis que determinam teoricamente o comportamento de commodities agrícolas, em especial a soja.

Em seguida, foi realizada uma pesquisa de dados secundários para o período 1988-2016 com periodicidade mensal em bases como a *National Oceanic and Atmospheric Administration* (NOAA), órgão norte-americano que monitora a temperatura dos oceanos; e a Bolsa de Mercadorias de Chicago (CBOT), principal bolsa de negociação de soja do mundo.

Devido ao caráter de causalidade de médio prazo entre os ENSO e o mercado agrícola e pela limitação dos dados climáticos, cujo tem divulgação mensal; a amostra utilizada possui periodicidade mensal. O *Southern Oscillation Index* (SOI) e o *SeaSurfaceTemperature* (SST) foram as variáveis utilizadas para a identificação EL-LA. Esses índices medem as variações de temperatura no Pacífico Sul, por meio de termômetros distribuídos no oceano, e de satélites equipados com câmeras térmicas.

3.1 Modelo teórico

A presente seção descreve o modelo teórico usado como suporte para as estimativas empíricas do trabalho. O mercado de soja é um mercado de competição perfeita, onde a demanda se iguala a oferta via preços. A oferta de soja, Q_s , é função do preço, PS ; da área plantada, A ; da tecnologia aplicada no cultivo, T ; do preço do milho, PC , como proxy para o bem substituto; do fator ENSO medido pelo SST; e da produção do período anterior. Essa derivação está baseada no trabalho de Houck (1968) incluindo as variáveis climáticas sugeridas por Keppenne (1995)

$$Q_s = f(PS, A, T, PC, SST, Q_t - 1). \quad (3)$$

Ao seu turno, a demanda do grão, Q_d , depende inversamente do preço; da renda mundial, Y , da população mundial, L ; do preço do óleo de soja, PO ; e do preço do farelo de soja, PM .

$$Q_d = g(P, Y, L, PO, PM). \quad (4)$$

Adicionando parâmetros angulares e uma constante, que confere ao preço mínimo ou o preço de suporte do governo americano (HOUCK, 1968), o sistema de oferta e demanda pode ser escrito como:

$$Q_s = a + b_1(PS) + b_2(A) + b_3(T) + b_4(PC) + b_5(SST) + b_6(Q_t - 1), \quad (5)$$

$$Q_d = c + b_7(h(Pd)) + b_8(Y) + b_9(L). \quad (6)$$

$$Pd = 0,474PM + 0,109PO - W. \quad (7)$$

A Equação (7) foi derivada do estudo de Houck (1968). O autor estimou que para cada 60 libra-bushel de soja esmagada, em média, se extrai 47,4 libras de farelo e 10,9 libras de óleo; desta maneira estes parâmetro de quantidade multiplicam o preço do farelo e do óleo respectivamente. A equação (7) depende ainda do *markup* do esmagador, W . Por essa razão, o presente estudo trabalhou com essa estimativa paramétrica.

Em um spread de esmagamento, o operador toma uma posição comprada em Futuros de Soja contra posições vendidas em Futuros de Farelo e Óleo de Soja. Isso também é conhecido como "board crush". O valor do esmagamento é igual ao preço dos Futuros do Óleo de Soja mais o preço dos Futuros do Farelo de Soja, menos o preço dos Futuros de Soja. (CME GROUP, 2018)

A condição de equilíbrio do modelo de oferta e demanda de soja pode ser escrita como:

$$Pd = Ps, \quad (8)$$

$$Qs = Qd. \quad (9)$$

Assim, igualando as equações de oferta e demanda, obtém-se:

$$\begin{aligned} a + b_1(Ps) + b_2(A) + b_3(T) + b_4(PC) + b_5SST) + b_6(Qt - 1) \\ = c + b_7(0,474PM + 0,109PO - W) + b_8(Y) + b_9(L) \end{aligned} \quad (10)$$

em que, somando-se as duas constantes:

$$k = c - a \quad (11)$$

Resolvendo (10) para o preço a equação tem-se:

$$P = [k - b_1(Ps) - b_2(A) - b_3(T) - b_4(PC) - b_5(SST) - b_6(Qt - 1) + b_7(Y) + b_8(L)] / -b_1b_7(0,474PM + 0,109PO - W). \quad (12)$$

O parâmetro esperado para para b_1 maior que zero, pois o preço no tempo t-1 impacta o preço no tempo t positivamente. b_2 é positivo já que a razão (-1) e o coeficiente da área impactam o preço negativamente. O coeficiente da tecnologia, assim como o da área relacionam-se positivamente com a oferta da soja e negativamente com o preço, logo também é positivo. O parâmetro do milho (b_4), é ambíguo, pois o preço elevado do milho pode influenciar a tomada de decisão da área da soja, afetando a oferta, por outro lado baixos preço desta *commodity* podem deslocar a curva da demanda da soja para baixo, via substituição de produtos, baixando o preço da leguminosa.

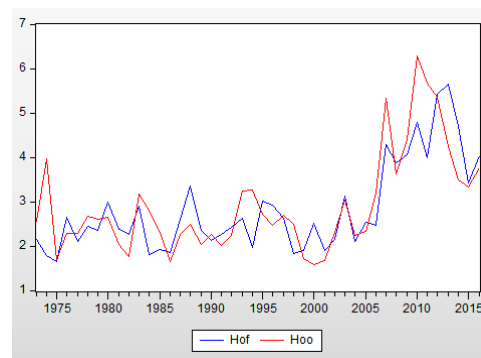
Espera-se que anomalias climáticas causem choques negativos na oferta do grão e positivos nos preço, contudo os ENSO podem beneficiar certas lavouras em certos lugares; então o sinal do parâmetro de SST é ambíguo, podendo variar com o tipo de ENSO e com a época do ano. A produção da safra passada, causa expectativas na safra presente; maiores expectativas na safra diminuem o preço do grão *cetiris paribus*.⁷ As variáveis de demanda como o PIB e a população, deslocam a curva de e demanda da soja para cima, logo os parâmetros esperados desta variáveis são positivos.

⁷ Tudo mais constante.

3.2 Dados

A amostra começa em março de 1988 e vai até dezembro de 2016, o que corresponde a 346 observações. Os dados do preço da soja foram obtidos no Indexmundi (ANO), e são contratos de: *Soybeans (US)*, c.i.f. Rotterdam de CBOT. O preço do milho foi obtido na mesma fonte, mas são contratos de: *Maize (US)*, no. 2, *yellow*, f.o.b. US Gulf ports. O preço futuro (6 meses) farelo de soja assim com o preço futuro (6 meses) óleo de soja vêm do site Investing.com, ambas bases de dados foram normalizadas para que ficassem na unidade dólares por *bushell* e então foram multiplicados por 0,474 e por 0,109 respectivamente, que são os parâmetros de esmagamento. Os *Houckparameters* (HP) resultam da quantidade de farelo e óleo extraídos do processo de esmagamento da soja *in natura*. Para cada libra de soja esmagada se tem em média 0,474 libras de farelo e 0,109 de óleo. Os outros 0,17lb são desperdiçados ou constituem resíduos como a casca.

Figura 9: Houck parameters 1983-2016



Fonte: elaboração própria com dados do investing

Como se observa, os HP's apresentam forte correlação, possivelmente causada por tendências de equilíbrio do mercado de derivados da soja (*supplieside*). A diferença entre os parâmetros se dá a demanda de cada um dos produtos, óleo e farelo. Por exemplo, um aumento repentino dos rebanhos animais causa um choque positivo nos preços do farelo de soja (linha azul), enquanto longos períodos de seca diminuem a demanda por tintas; causando um choque negativo nos preços do óleo de soja (linha azul). O valor da correlação entre as variáveis no dado período foi de 0,7797.

O PIB mundial foi obtido através da base de dados do Banco Mundial, porém não avia a disponibilidade destes dados com periodicidade mensal, somente anual. Foi aplicada uma técnica de interpolação de dados. A produtividade da área produtora de soja do mundo origina-

se da base de dados da *Food and Agricultural Organization of the United Nations*, e assim como no caso do PIB, aplicou-se uma técnica de interpolação de dados.

A técnica de interpolação aritmética utilizada para as variáveis PIB mundial e produtividade média da soja, transformou as series anuais em mensais como é possível ver nas equações 13, 14 e 15. Estas variáveis são divulgadas apenas com periodicidade anual, por isto aplicou-se:

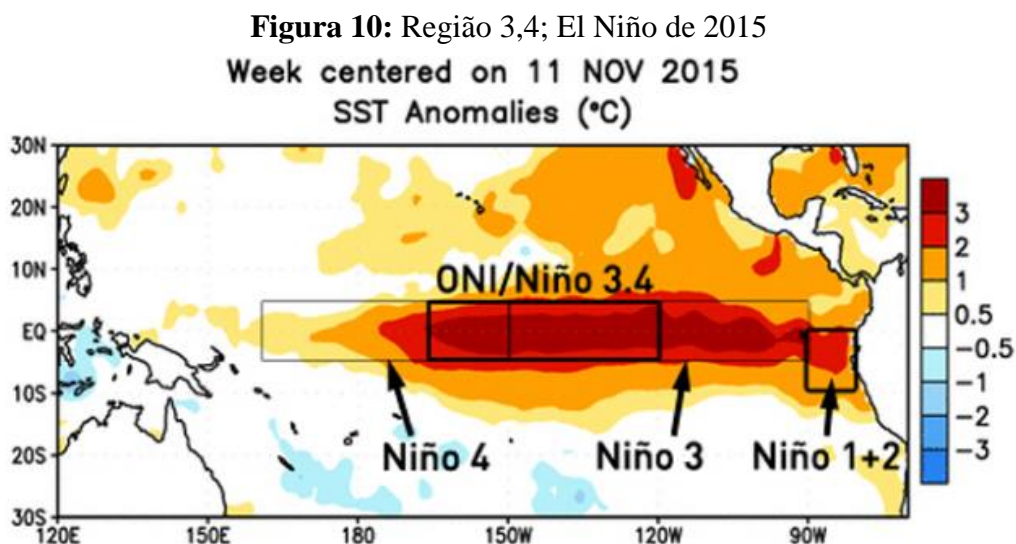
$$y = \frac{x_{12} - x_1}{12}, \quad (13)$$

$$x_2 = x_1 + y, \quad (14)$$

$$x_n = x_{n-1} + y. \quad (15)$$

O índice *Purchasing Managers Index* (PMI) foi obtido através do site *economy.com*, e representa a variação da atividade econômica dos Estados Unidos.

As variáveis climáticas EL-LA foram coletadas em bases de dados da NOAA, na forma do SST. Quando a variação do SST, que é medida em graus celsius foi maior que +0,5° em relação à média, por cinco ou mais meses consecutivos, o valor em temperatura foi multiplicado pela *dummy* El Niño. Para o fenômeno oposto, quando a variação foi maior que -0,5° Celsius, por cinco ou mais meses consecutivos o mesmo ocorre com a *dummy* La Niña. O tempo de cinco meses é o mínimo período que caracteriza um ENSO (NOAA, 2018). O local de medição de temperatura é a região 3,4 (5°N-5°S, 120°-170°W).



Fonte: The Weather Network.

3.3 Modelo empírico

Como a presente monografia partiu de um modelo estilizado do comportamento real do mercado da soja, suas eventuais limitações podem ser classificadas em dois blocos. O primeiro, teórico, refere-se à suposição de que as hipóteses de competição perfeita e, portanto, eficiência do mercado, permanecem válidas no “mundo real”. O segundo, relacionado ao modelo empírico, refere-se a dificuldade inerente aos modelos econométricos de séries temporárias, em especial, a violação da hipótese de erros independentes e identicamente distribuídos e a dificuldade de obtenção de relações teóricas de longo prazo significativas, típicas de modelos VAR. O período ainda foi escolhido levando em consideração as características desta série temporal e da disponibilidade dos dados.

Por se tratar de um efeito de médio prazo com dados mensais, deseja-se uma série que abranja um número considerável de eventos ENSO. A equação estimada pelo modelo estatístico tem o seguinte formato:

$$Y = a + b1(DummyLA) + b2(DummyEL) + b3(Xs) + bS + e, \quad (16)$$

A equação (16) trata-se de uma linearização da equação (12), onde algumas variáveis do modelo teórico não foram incluídas por diferentes motivos. Ao invés de utilizar uma variável para a tecnologia, uma para área e outra para a produção (t-1); foi usada uma variável para a produtividade, que faz parte do conjunto Xs . A variável dependente, Y representa a taxa de crescimento do preço da soja em natura *spot* em CBOT, a é uma constante com valor >0 , as variáveis *dummies* representam a ocorrência ou não de um EL-LA, Xs é um conjunto de variáveis de controle, que inclui a taxa de crescimento do preço do milho, a taxa de crescimento do preço futuro do óleo de soja, a taxa de crescimento do preço futuro do farelo de soja, a taxa de crescimento da produtividade, a taxa de crescimento do PIB mundial e a taxa de crescimento da atividade econômica dos EUA.

Utilizaram-se diversas variáveis *dummies* para controlar quebras de séries e sazonalidades. Testaram-se uma *dummy* para cada mês do ano e mais quatro *dummies* para quebras. Várias combinações foram testadas, mas o modelo ótimo foi o que incluía todas estas variáveis binárias, com exceção da *dummy* dezembro, que tinha o menor nível de significância e foi selecionada para sair do modelo, para este não cair em uma armadilha da *dummy*. Também foi testada uma variável binária para todos os meses com safra, porém esta variável aumentava a autocorrelação residual do modelo.

3.4 Modelo VAR (Vetores Auto Regressivos)

Sims (1980) desenvolveu a metodologia dos vetores autoregressivos com o fim de diminuir as restrições impostas por outros modelos estruturais. Assim criou um modelo matricial dinâmico cuja as únicas restrições são as impostas pela teoria econômica e pelas variáveis utilizadas. O modelo examina relações lineares dentre todas variáveis endógenas e suas defasagens. Geralmente o número de defasagens é determinado pelos critérios de Schwarz, Akaike e LR. Este último foi o critério utilizado para a escolha da defasagem ótima do modelo deste trabalho.

Como todo modelo estatístico, os Vetores Autoregressivos tem suas limitações. Duas limitações são frequentemente lembradas pela literatura. A primeira aponta que o excesso de parâmetros estimados por esta regressão, demanda grandes amostras para compensar isto, fato que levou a escolha de utilizar dados mensais ao invés de anuais neste trabalho. A segunda limitação do modelo segundo o Banco Central do Brasil é que:

(...) cada modelo VAR é simplesmente uma forma reduzida, ou seja, as mesmas relações entre as variáveis e suas defasagens são simultaneamente compatíveis com vários diferentes modelos que descrevem também as relações contemporâneas entre as variáveis. (BANCO CENTRAL DO BRASIL; 2004).

O modelo estatístico VAR trata as variáveis endógenas do modelo em um sistema de equações matemáticas somadas ao ruído branco estatístico na forma do desvio padrão, este sistema é conhecido como VAR primitivo. Aplicando álgebra matricial ao sistema e invertendo-o se obtém o VAR padrão. A estabilidade do modelo depende de que todas raízes inversas polinômiais sejam menores que 1. Se a estabilidade for atingida, existe uma solução e o modelo converge ao equilíbrio (ENDERS; 2012).

O primeiro passo do procedimento de estimar um VAR é testar a presença de raiz unitária. O teste *Augmented Dickey-Fuller* (ADF) é uma expansão do teste de raiz unitária Dickey-Fuller convencional que testa a não estacionariedade da série analisando se há presença de raiz unitária baseado em um modelo auto regressivo AR(1). O ADF então adiciona defasagens na variável dependente para eliminar possíveis auto correlações (ASTERIOU, HALL; 2006). Este teste supõe que os erros são estatisticamente independentes que eles têm variância constante. Pode-se testar a raiz unitária sem constante, com constante e com constante e tendência como pode se ver na Tabela 2.

$$y = \theta y_{t-1} + u_t. \quad (20)$$

Tabela 2: Hipóteses nulas dos testes DF e ADF

	Sem intercepto	Com intercepto	Com intercepto + <i>drift</i>
H0	Tendência estocástica	Tendência estocástica	Tendência determinística + tendência estocástica
H1	Sem tendência	Sem tendência	Tendência determinística

Fonte: elaboração própria com informações de Enders (2012).

O teste Phillips-Perron (PP) utiliza um modelo AR(1) e parte das hipóteses:

$H_0: \vartheta = 0$ (Processo não estacionário/uma raiz unitária)

$H_1: \vartheta = 1$ (Processo estacionário/sem raízes unitárias)

Enquanto o teste ADF corrige correlações de series mais longas, o teste PP corrige a estatística t do coeficiente que multiplica a variável defasada para o erro da regressão (ASTERIOU, HALL; 2006).

Como o a pesquisa busca resultados de curto prazo, já que se acredita que choques de oferta causados pelo clima tem efeito transitório e não permanentes; não foram realizados testes de cointegração. A cointegração é quando um conjunto de variáveis guarda uma relação de equilíbrio de longo prazo, ou seja há uma tendência estocástica em todas as variáveis usadas no modelo. Eliminada a hipótese de cointegração da série utilizada pelo trabalho, a estratégia adotada para obter os resultados é a metodologia VAR através de suas funções de impulso resposta e da decomposição da variância.

Por meio de funções de impulso resposta, foi possível calcular a intensidade e a duração de choques de variáveis endógenas do sistema. A função impulso resposta filtra o choque de qualquer variável endógena do modelo em outra variável endógena, podendo até regredir o choque a ela mesma. Para estimar esta função, se introduz um delta hipotético de 1 desvio padrão sobre o parâmetro angular da variável do impulso; após isso se faz o mesmo procedimento no mesmo parâmetro para o período anterior. Filtrando estes impulsos para uma variável ou para um conjunto de variáveis, é possível plotar as respostas em um gráfico, que mostra a trajetória do choque introduzido (ZIVOT, WANG; 2005).

A outra forma utilizada para extrair resultados do Vetor Autoregressivo estimado foi a decomposição da variância é a porcentagem do erro de previsão do modelo que é devida ao choque estrutural de um conjunto de variáveis endógenas em um certo tempo (BUENO; 2012).


4 RESULTADOS E DISCUSSÃO

O presente capítulo apresenta e discute os resultados da pesquisa. Primeiramente, apresentam-se as séries e os testes de detecção do modelo econométrico. Em seguida, apresentam-se as estimativas dos parâmetros e suas implicações relacionadas à literatura empírica.

Como discutido anteriormente, foram utilizadas no modelo as seguintes variáveis: preço da soja, preço do milho, preço do óleo de soja futuro multiplicado por seu parâmetro de esmagamento, preço do farelo de soja futuro multiplicado por seu parâmetro, atividade econômica dos EUA, produtividade mundial de soja (interpolada) e renda mundial (interpolada). Ainda, foram adicionadas variáveis *dummies* para absorver quebras de nível e sazonalidades da variável preço da soja (Figura 11). Ao invés de usar *dummies* convencionais para as variáveis climáticas, estas foram multiplicadas pela variação média da temperatura do Oceano Pacífico (sul), região 3,4 (5°N-5°S, 120°-170°W) (NOAA, 2018).

O preço da soja (Figura 11) em nível entre 1988 e 2016 apresenta comportamento sazonal. Apenas em períodos relativamente curtos é possível observar certa estacionariedade. A partir de 2001 há uma clara tendência de elevação dos preços do grão. Ademais, há um aumento significativo da volatilidade até 2012, quando os preços tomam uma trajetória descendente até o fim da amostra. Tal período foi caracterizado pelo declínio relativo de várias *commodities*.


Figura 11: Logaritmo do preço da soja mensal 1984-2016.



Fonte: elaboração própria com dados do indexmundi.com.

O PIB mundial cresceu consideravelmente no período de 1988 a 2016. A curva da Figura 12 é claramente mais inclinada nos períodos de 1988-1995 e 2002-2008. Em 2008 e 2014 houve recessão e a curva regrediu.


Figura 12: Logaritmo do PIB mundial (anual interpolado).
LOGGDP



Fonte: elaboração própria com dados do banco mundial.

O preço do futuro de farelo de soja (Figura 13) no período acompanhou em grande medida o preço de sua matéria prima, o grão. No entanto, por se tratar do preço futuro 6 meses, este ativo antecipa o *spot* da soja em certa medida.

Figura 13: Logaritmo do preço futuro do farelo de soja (multiplicado por 0,474).
LOGHOF




Fonte: elaboração própria com dados do investing.com.

Como se vê na Figura 9 da página 41 que usa dados anuais, o preço do farelo de soja e do óleo de soja são intimamente correlacionados já que ambas *commodities* estão sujeitas a

exatamente mesma função de produção. Assim, as diferenças entre as curvas da Figura 13 e 14 se devem a função de demanda de cada curva. O preço futuro do óleo de soja (Figura 14), apesar de possuir características e tendências semelhantes à Figura 13, se comportou diferentemente em muitos anos, principalmente pelo fato de estar inserido em uma cadeia influenciada pelo preço do petróleo. Não gratuitamente, seu declínio relativo foi mais acentuado a partir de 2012.


Figura 14: Logaritmo do preço futuro do óleo de soja (multiplicado por 0,109).
LOGHOO



Fonte: elaboração própria com dados do investing.com.

Como citado no Capítulo 2, o milho e a soja são produtos substitutos em muitas utilidades. Estas commodities agrícolas concorrem diretamente pelo espaço de produção, já que possuem necessidades dafoclimáticas semelhantes. Por isto, a Figura 15 é relativamente parecida com a Figura 11. O nível desta curva, no entanto é mais baixo do que o da curva do preço da soja, pois a tonelada do milho é relativamente mais barata.

Figura 15: Logaritmo do preço do milho.
LOGPMILHO

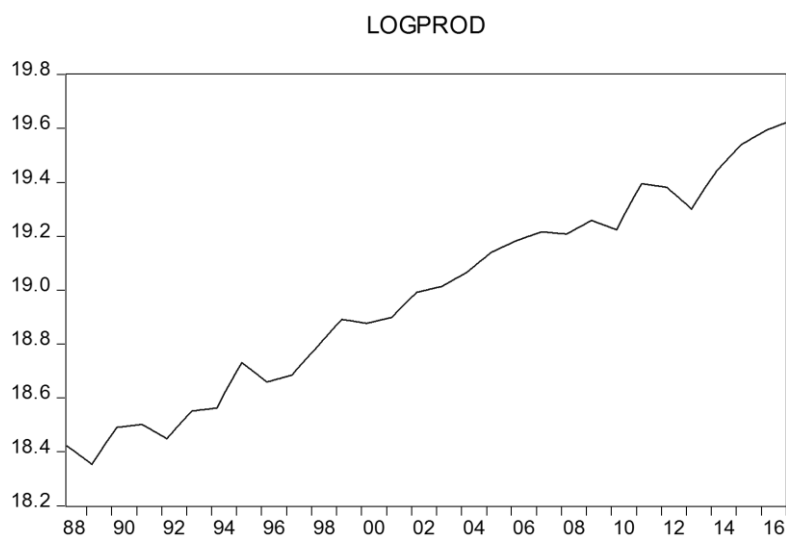


Fonte: elaboração própria com dados do indexmundi.com.

Nas Figuras 11, 13, 14 e 15 é possível notar uma grande quebra de nível em 2006. A partir deste ano, os preços destas *commodities* soja, farelo de soja, óleo de soja e milho respectivamente, se elevou consideravelmente. Em 1995, também houve uma elevação simultânea nos preços destes produtos, porém ao contrário de 2006, os preços retomaram seu patamar já em 1997.

A produtividade interpolada (Figura 16) da soja não teve grandes quebras estruturais e teve um crescimento mais ou menos constante durante o período 1988-2016. Fazendo uma correlação superficial, apenas comparando com a Figura 17, a produtividade só caiu em anos cujo houve a decorrência do fenômeno La Niña.


Figura 16: Logaritmo da produtividade mundial de soja hg/ha (anual interpolado).



Fonte: elaboração própria com dados da FAO.

A incidência de eventos EL e LA foi relativamente homogênea no período 1988-2016, porém nesta amostra houveram dois El Niños muito fortes, um em 1997 e outro em 2015. Neste último, a temperatura média esteve mais alta que $2,6^{\circ}$ nesta região. Não se observou eventos opostos de mesma intensidade para este período, sendo o desvio da média de $-1,8^{\circ}$ a temperatura média mais baixa registrada. Ademais na Figura 17, quando a curva é igual a 0, significa que a temperatura da região 3,4 teve um desvio dentro de $-0,5^{\circ}$ e $0,5^{\circ}$; não caracterizando um ENSO. Períodos como o de março a junho de 1993, que apesar de terem ocorrido temperaturas maiores do que $0,5^{\circ}$, não constituem um ENSO, pois duraram menos que 5 meses. Com a exceção do La Niña de 1998-2001, a maioria destes eventos duraram entre 6 meses e um ano.


Figura 17: El Niño e La Niña (com *dummy*).



Fonte: elaboração própria com dados da NOAA (ANO).

Na Figura 18 se destaca o PMI, um índice de atividade econômica norte americana, que pode ser uma *proxy* pertinente para explicar a demanda da soja. Nota-se que em 2008 o índice alcançou o menor nível histórico da série. O final de 2008 foi marcado pela emergência da recessão econômica mundial, originada com a crise do *subprime* americano. O índice só retomou o nível anterior de flutuação próximo ao ano de 2010. Claramente, o padrão sazonal da série também é destacável.

Figura 18: Logaritmo do *National Association of Purchasing Managers Index (PMI)*
LOGATIVIDADE



Fonte: elaboração própria com dados da Moodys.

De posse das séries, foram conduzidos dois testes de raiz unitária, ADF e PP. A Tabela 3 apresenta os resultados do teste ADF para as variáveis em nível e em primeira diferença. Nota-se que com exceção do índice de atividade econômica dos EUA e do ONI, todas as variáveis não são estacionárias em nível.

Tabela 3: Resultados dos testes de raiz unitária (*Schwarz Info Criterion* para o teste ADF).

Modelo Mensal		<i>Nível</i>	
variavel/valor(prob %)	ADF com constante	ADF com tendencia e contante	ADF sem nada
logPsoja	0,4232	0,2624	0,7597
logPmilho	0,2470	0,3315	0,7493
logHof	0,1926	0,0925	0,5405
logHoo	0,3459	0,3593	0,5976
logGDP	0,7531	0,3784	0,9934
logProdutividade	0,9626	0,0064	0,9997
ONI	0,0000	0,0000	0,0000
logAtividade	0,0000	0,0001	0,6503
		<i>Primeira diferença</i>	
variavel/valor(prob %)	ADF com constante	ADF com tendencia e contante	ADF sem nada
d_logPsoja	0,0000	0,0000	0,0000
d_logPmilho	0,0000	0,0000	0,0000
d_logHof	0,0000	0,0000	0,0000
d_logHoo	0,0000	0,0000	0,0000
d_logGDP	0,0122	0,0487	0,0100
d_logProdutividade	0,0006	0,0039	0,0050
d_ONI	0,0000	0,0000	0,0000
d_logAtividade	0,0000	0,0000	0,0000

Fonte: elaboração própria.

Ao seu turno, a Tabela 4 apresenta os resultados do teste Phillips-Perron. Nota-se que os resultados corroboram com os do teste ADF. A maioria das variáveis não foi estacionária em nível à 99% de confiança.

Tabela 4: Resultados dos testes de raiz unitária (*Schwarz Info Criterion* para o teste Phillips Perron).

Modelo Mensal		Nível		
variavel/valor(prob %)	PP com constante	PP com tendencia e constante	PP sem nada	
logPsoja	0,4619	0,3562	0,7829	0,7829
logPmilho	0,3297	0,4625	0,7850	0,7850
logHof	0,2395	0,1085	0,6074	0,6074
logHoo	0,3533	0,3678	0,6142	0,6142
logGDP	0,5124	0,8994	1,0000	1,0000
logProdutividade	0,9709	0,0363	1,0000	1,0000
ONI	0,0017	0,0103	0,0001	0,0001
logAtividade	0,0004	0,0024	0,6471	0,6471
		Primeira diferença		
variavel/valor(prob %)	PP com constante	PP com tendencia e constante	PP sem nada	
d_logPsoja	0,0000	0,0000	0,0000	0,0000
d_logPmilho	0,0000	0,0000	0,0000	0,0000
d_logHof	0,0000	0,0000	0,0000	0,0000
d_logHoo	0,0000	0,0000	0,0000	0,0000
d_logGDP	0,0068	0,0279	0,0090	0,0090
d_logProdutividade	0,0000	0,0001	0,0000	0,0000
d_ONI	0,0000	0,0000	0,0000	0,0000
d_logAtividade	0,0000	0,0000	0,0000	0,0000

Fonte: elaboração própria.

Com base nos resultados dos testes de raiz unitária, todas as variáveis com exceção do ONI (*Oceanic Niño Index*) e das variáveis *dummies* foram usadas em primeira diferença do logaritmo, o que corresponde a taxa de crescimento.

Constatada a não estacionariedade das séries em questão, o estimador de mínimos quadrados ordinários deixa de ser aplicável. Torna-se necessário, migrar para uma abordagem de séries de tempo, baseada no VAR. Nesse sentido, o primeiro passo é a definição da defasagem do modelo autorregressivo. Isso é feito por meio da análise dos critérios de informação descritos na Tabela 5.

Tabela 5: Estrutura das defasagens ótimas.


Lag	LogL	LR	FPE	AIC	SC	HQ
0	4935.234	NA	3.62e-24	-28.43462	-26.80230	-27.78400
1	6389.437	2692.648	1.05e-27	-36.58419	-34.03369*	-35.56760*
2	6511.202	218.9600	8.26e-28*	-36.82612*	-33.35744	-35.44356
3	6579.633	119.3994	8.96e-28	-36.75153	-32.36467	-35.00299
4	6631.719	88.09845	1.07e-27	-36.57994	-31.27490	-34.46542
5	6683.969	85.58409	1.29e-27	-36.40931	-30.18609	-33.92883
6	6749.179	103.3292*	1.45e-27	-36.31560	-29.17420	-33.46914
7	6811.659	95.66804	1.65e-27	-36.20569	-28.14611	-32.99326
8	6878.087	98.16261	1.86e-27	-36.11921	-27.14145	-32.54080

Fonte: elaboração própria.

Todos os *logs* indicados pelos testes citados na tabela acima foram testados. No entanto a defasagem que apresentou os melhores resultados foi a AR(6). Este foi o modelo escolhido para este trabalho. A defasagem de 6 meses inclui o período de uma safra hemisférica, isto influencia o preço *spot*. Portanto, além de confirmada pelo teste de razão de verossimilhança, possui uma justificativa teórica robusta.

Com todas as variáveis em taxa de crescimento e mais estas quinze variáveis de controle exógenas binárias, o modelo ficou estável, pois todas as raízes se encontram dentro do círculo unitário. O teste das raízes inversas AR mede a estabilidade do modelo. A Figura 19 ilustra o resultado.

Figura 19: Teste de estabilidade do modelo
Inverse Roots of AR Characteristic Polynomial



Fonte: elaboração própria.

Constatada a estabilidade, passou-se para análise da existência de autocorrelação serial nos resíduos. O teste adequado neste contexto é o LM, apresentado na Tabela 6. Percebe-se que no nível de 95% de confiança, não se rejeita a hipótese nula de ausência de autocorrelação serial. Adicionalmente, foram analisadas as questões relacionadas à normalidade dos resíduos e a existência de heterocedasticidade, testes estes que estão disponíveis na seção do Apêndice.

Os respectivos testes arreeitam a hipótese nula de homocedasticidade. Esse resultado é persistente mesmo quando o modelo é controlado pelas *dummies* sazonais e de quebra. Pode ser que a elevação da ineficiência do estimado seja resultado da característica das séries de preço de *commodities* agrícolas, que envolve a elevação da volatilidade ao longo do tempo. Embora, as variâncias do modelo sejam potencialmente instáveis, os resultados continuam não viesados.

Tabela 6: Teste de autocorrelação residual LM

Null hypothesis: No serial correlation at lag h

Lag	LRE* stat	df	Prob.	Rao F-stat	df	Prob.
1	93.28854	81	0.1654	1.156450	(81, 1637.5)	0.1658
2	96.86392	81	0.1103	1.202065	(81, 1637.5)	0.1106
3	88.43847	81	0.2678	1.094728	(81, 1637.5)	0.2682
4	92.40933	81	0.1816	1.145248	(81, 1637.5)	0.1820
5	100.3725	81	0.0712	1.246923	(81, 1637.5)	0.0714
6	96.24032	81	0.1188	1.194102	(81, 1637.5)	0.1190
7	89.23068	81	0.2489	1.104798	(81, 1637.5)	0.2493
8	84.01780	81	0.3873	1.038626	(81, 1637.5)	0.3877
9	86.22369	81	0.3249	1.066602	(81, 1637.5)	0.3254
10	72.99585	81	0.7251	0.899389	(81, 1637.5)	0.7255
11	69.81784	81	0.8077	0.859412	(81, 1637.5)	0.8080
12	157.0787	81	0.0000	1.985083	(81, 1637.5)	0.0000

Fonte: elaboração própria.

Realizados todos os testes de detecção, partiu-se para a análise do ajustamento do modelo proposto. Os dados são apresentados na Tabela 7. Os resultados indicam uma boa qualidade de ajuste do VAR, uma vez que o R^2 ajustado foi de 0,2717. O critério do R^2 ajustado foi escolhido dado que penaliza o modelo pelo excesso de repressores na equação empírica. Diversos modelos, com diferentes defasagens e variáveis foram testados, mas este foi o que demonstrou o mais elevado nível de ajuste, via R^2 ajustado, e também os diagnósticos relativamente mais robustos.


Tabela 7: resultados do modelo VAR para a variável Preço da Soja.

R-squared	0.42121224...
Adj. R-squared	0.27274995...
Sum sq. resids	0.51196500...
S.E. equation	0.04362585...
F-statistic	2.83716660...
Log likelihood	619.966937...
Akaike AIC	-3.2446426...
Schwarz SC	-2.4546131...
Mean dependent	0.00064947...
S.D. dependent	0.05115665...

Fonte: elaboração própria.


Uma das críticas existentes aos modelos do tipo VAR é a de que os coeficientes estimados tendem a ser relativamente instáveis, devido ao excesso de variáveis endógenas no sistema. Em geral, são muitos parâmetros a serem estimados. A existência de heterocedasticidade eleva essa instabilidade. Nesse contexto, existe um relativo consenso em econometria, de que a análise deve partir da exploração das funções impulso resposta e dos análises de decomposição da variância, ao invés de focar na significância de todos os parâmetros endógenos da matriz do VAR. Assim, parte-se para a análise da intensidade e duração do choque de cada uma das variáveis no modelo econométrico.

A Figura 20 representa a função impulso resposta da taxa de crescimento do preço da soja sobre ela mesma. Nota-se um forte elemento autoregressivo nesta série de preço, que corresponde a um choque positivo de cerca de 4p.p. O choque da defasagem dura aproximadamente 4 meses, quando então converge ao equilíbrio novamente. A partir do quarto mês há pequenos choques negativos de cerca de 0,2 p.p nos meses 4, 7 e 9. Este resultado atesta o esperado de que o preço passado influencia o preço presente com sinal positivo, pela sua própria natureza inercial.

Figura 20: Função impulso resposta do preço da soja

Fonte: elaboração própria.

O choque da taxa de crescimento da produtividade no preço da soja (Figura 21) não é bem definido e não é estatisticamente significativo. Acreditasse que a produtividade causa choques permanentes de longo prazo. Deste modo, o modelo mensal não capta o verdadeiro impacto da produtividade na taxa de crescimento do preço da soja. A interpolação aplicada nesta variável ainda pode ter enviesado este resultado em certa medida. Apesar dos problemas, o modelo de melhor ajuste testado incluiu esta variável que exerce um papel de controle para a identificação dos parâmetros climáticos.

Figura 21: Função impulso resposta do preço da soja em relação a produtividade


Fonte: elaboração própria.

O milho, como visto no Capítulo 2, é um produto substituto da soja. Assim, estas commodities agrícolas concorrem diretamente tanto por área de plantio, quanto por mercado. Na Figura 22, nota-se que nos primeiros meses a taxa de crescimento do preço do milho não define um choque sobre a taxa de crescimento do preço da soja. No entanto, a partir do quarto

mês esta variável influencia o mercado da soja negativamente, em um choque que chega à casa dos 0,8 p.p. (pontos percentuais) no mês -5.

A influência negativa do milho sobre a soja dura do sétimo mês até ao quarto mês anterior à data em questão. Esta defasagem temporal de influência entre estes grãos, possivelmente se deve a influência que o preço do milho tem na tomada de decisão sobre a área plantada de soja e de milho dos produtores do hemisfério oposto. A ambiguidade da função impulso resposta certifica o duplo efeito que o milho tem sobre a soja, afetando-a tanto na curva de oferta quanto na da demanda.


Figura 22: Função impulso resposta do preço da soja em relação ao preço do milho



Fonte: elaboração própria.

Como era esperado, o preço dos futuros dos dois subprodutos da leguminosa geram os maiores choques relativos. Na Figura 23 observa-se a função impulso resposta da taxa de crescimento do preço futuro do óleo de soja sobre a taxa de crescimento do preço *spot* de sua matéria prima. Há um choque positivo muito robusto nos primeiros 3 meses. O valor máximo chega a 1,8 p.p. entre o mês -1 e -2. É importante destacar que o choque se dá dentro do período de uma safra. Após o choque inicial, a taxa de crescimento do preço da soja converge ao equilíbrio condicionalmente. Esta representa, depois do elemento AR da soja, a função impulso resposta relativamente mais expressiva dentre as todas testadas neste trabalho. Os períodos de oscilação entre choques positivos e negativos é bastante homogêneo, durando sempre entre 2 e 3 meses.


Figura 23: Função impulso resposta do preço da soja em relação ao preço futuro do óleo de soja multiplicado pelo seu respectivo coeficiente de esmagamento



Fonte: elaboração própria.

Apesar do futuro do farelo e do óleo estarem representados pelas mesmas unidades e estejam relativizados por seus respectivos parâmetros de esmagamento; a taxa de crescimento do preço futuro do farelo de soja reflete um choque relativamente mais ameno do que o óleo, sobre a taxa de crescimento do preço da soja. A duração de cerca de três meses e velocidade com a qual o choque converge ao equilíbrio, no entanto são muito parecidas, assim, a grosso modo a Figura 23 e 24 se assemelham em muitos aspectos. O choque da Figura 24 alcança a marca de 1,2 p.p. e assim como o óleo de soja, converge ao equilíbrio condicionalmente. A força com que os futuros dos derivados do grão impactam o seu mercado corrobora com os resultados esperados e com a literatura acerca do tema.


Figura 24: Função impulso resposta do preço da soja em relação ao preço futuro do farelo de soja multiplicado pelo seu respectivo coeficiente de esmagamento



Fonte: elaboração própria.

A taxa de crescimento do índice de atividade econômica dos Estados Unidos, na Figura 25, aparentemente não define a presença de um grande choque como os das figuras anteriores e não é estatisticamente significativa. Em um primeiro momento, há um curto choque negativo nos preços da soja, ou seja, o aumento da taxa de crescimento da atividade econômica daquele país, influencia negativamente a taxa de crescimento do preço do grão. O choque é relativamente curto, durando cerca de 1 mês, revertendo-se no mês 3 e convergindo ao equilíbrio a partir daí. Apesar de, teoricamente a atividade econômica deslocar a curva de demanda da economia para cima, o preço da soja reagiu negativamente a choque positivo na taxa de crescimento desta variável, resultado que diverge ao esperado. Isso pode ser explicado pela própria inelasticidade-renda de curto prazo da oleaginosa.

Figura 25: Função impulso resposta do preço da soja em relação à atividade econômica dos EUA.




Fonte: elaboração própria.

A Figura 26 apresenta os resultado para o impacto do El Niño. Nota-se que o mesmo não influencia a variação do preço da soja nos primeiros meses e não é estatisticamente significativa durante todos os meses analisados pela função. A partir do quinto mês há um choque positivo na curva da função impulso resposta. O choque atinge os 0,4 p.p no mês 6 e dura até o sétimo mês. Possivelmente, este resultado se deve a hipótese de que o EL afeta negativamente as lavouras de apenas um dos hemisférios do globo. A segunda hipótese é que os *players* dos mercados não internalizam os danos que este ENSO causa nas lavouras durante os estádios de desenvolvimento da planta. Assim, a anomalia climática afetaria o preço apenas após a colheita. O impacto do El Niño com tal defasagem temporal, cumpre com a hipótese que eventos extremos do tipo ENSO provocam o mercado agrícola de maneira bastante

indeterminada, já que distribuem diferentes tipos de desvios climáticos ao longo das zonas produtoras de soja.


Figura 26: Função impulso resposta do preço da soja em relação ao El Niño



Fonte: elaboração própria.

Ao contrário do que acontece com o EL Niño, o La Niña impõe à taxa de crescimento do preço da soja um choque claro e mais contemporâneo. O impulso de um LA, infere uma resposta do preço da soja de até 0,8 p.p. dois meses e meio após o evento durando até o mês 6, quando converge para o equilíbrio. Portanto, o impacto do La Niña sobre os preços ocorre dentro do período de uma safra. Os efeitos secundários de *teleconnection* dos ENSO demoram certo tempo para acontecerem após o ENSO em si (SST). Por sua vez, o desenvolvimento da planta também toma certo tempo para reagir a um choque climático. Por isto, o auge do choque das variáveis climáticas apresentam certas defasagens.

Figura 27: Função impulso resposta do preço da soja em relação ao La Niña.

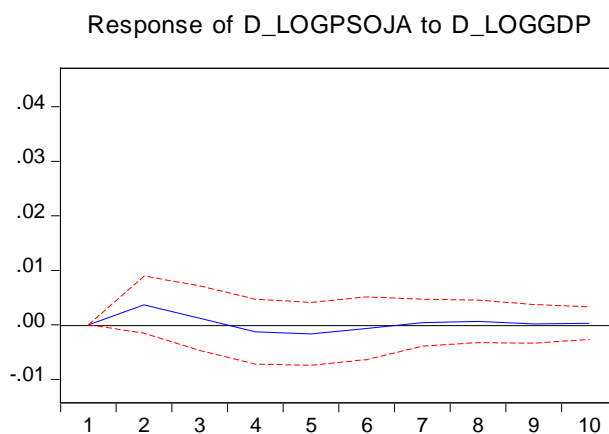


Fonte: elaboração própria.

O choque do La Niña no preço da soja na Figura 27 aparece como negativo pois a variável de temperatura está em valores negativos, já que o LA é a variação negativa de temperatura da Região 3,4. Logo, o choque desta anomalia climática no preço da soja é positivo. O resultado do La Niña corrobora com os resultados encontrados pela literatura, que apontam que este evento prejudica lavouras e safras, deslocando a curva de oferta para baixo e aumentando o preço por exemplo em Keppen (1995).

Ao seu turno, a taxa de crescimento do PIB mundial relaciona-se positivamente com a Taxa de crescimento do preço da soja embora não seja estatisticamente significativa. Contudo, a relação preço/renda da soja e do produto mundial é relativamente singela quando comparada com a de outros produtos. Com base na Figura 28, é possível afirmar que a soja é um bem inelástico no curto prazo, apesar de o PIB mundial exercer um choque positivo nos primeiros meses de até 0,35 p.p. O choque dura até metade do terceiro mês. Ao contrário do choque da variável de demanda interna na Figura 25, o PIB impactou o preço positivamente, corroborando com o resultado esperado, de que a renda desloca a curva de demanda para cima, elevando o preço, mesmo que marginalmente.

Figura 28: Função impulso resposta do preço da soja em relação ao PIB mundial.



Fonte: elaboração própria.

Na Tabela 8 estão os dados referentes a decomposição da variância. Os números acima, sem parênteses, representam a porcentagem que cada variável (coluna) e cada defasagem (linha) explica a variância da taxa de crescimento do preço da soja. Abaixo, entre parênteses, está o erro padrão de cada estimativa. Na primeira coluna encontra-se a própria taxa de crescimento do preço da soja, ou seja, esta coluna representa o fator auto regressivo na decomposição da variância. O AR desta série é um elemento muito significativo, apesar de

perder potência ao longo dos 10 meses observados pelo teste, algo esperado para a maioria das séries de preços. Por volta do mês 8 a participação do AR se estabiliza por volta dos 69%.

A produtividade das áreas produtoras de soja, por se tratarem de um fator que impacta os preços no longo prazo, ganha peso na explicação ao longo do período analisado, crescendo principalmente entre o mês 3 e 4 e chegando, no décimo mês a 1,97%.

A taxa de crescimento do preço do principal substituto da soja, o milho; participa da decomposição da variância de seu homólogo timidamente. No mês 5, todavia a um abrupto salto de participação relativa desta variável, indo 1,13% para mais de 2% de participação relativa. No mês 8, então, esta se estabiliza na casa dos 3,5%. O resultado da decomposição da variância da soja frente ao milho, corrobora com o resultado da função impulso resposta das mesmas variáveis, em que o maior choque se deu durante um período mais longo do que de uma safra. Provavelmente isto está relacionado a tomada de decisão de área plantada de cada cultura.

Os subprodutos da soja ganham imediata participação na decomposição da variância a partir do primeiro mês. Em ambas variáveis, não houve um grande ganho de participação relativa a partir de então. Assim como na Figura 23, onde a taxa de crescimento do preço futuro do óleo de soja representou o choque mais expressivo depois do AR, a decomposição da variância revelou a forte influência deste derivado no preço de sua matéria prima. O nível de explicação chega a 12,57%. A taxa de crescimento do preço futuro do farelo de soja, representou um valor menor do que o óleo de soja na decomposição da variância da soja, porém ainda que este produto seja menos significativo, este é terceiro fator mais expressivo do teste, representando valores de quase 6,5%.

As variáveis macroeconômicas utilizadas no modelo, o PIB mundial e o índice de atividade econômica dos Estados Unidos, estão entre as variáveis com menor grau de explicação da variância. Contudo, ambas ganham participação relativa nesta decomposição. O índice de atividade econômica americana (PMI), ganha participação no mês 2 e 3, quando então se estabiliza, posteriormente há um novo choque de participação, mais precisamente entre o mês 6 e 8, quando atinge a marca de 1,72%, estabilizando-se novamente no mês seguinte. O PIB mundial, é, dentre todas as variáveis utilizadas no modelo, o elemento com o menor peso na decomposição da variância. No mês 2 a sua participação é de 0,54% e chega a 0,70% no mês 4, quando têm seu peso estabilizado.

As variáveis climáticas demonstraram resultados diferentes. O La Niña nos primeiros meses não é uma variável significativa quanto a explicação da variância da taxa de crescimento do preço da soja. No entanto, o evento climático é a variável que teve o maior ganho de

representação relativa durante o período de 10 meses. No segundo mês, o LA representou apenas 0,037% da variância do preço da leguminosa, porém no mês 3 a participação deste ENSO salta para 2,77% e continua crescendo até o mês 10, quando alcança 3,38% de participação. O El Niño têm uma participação mais branda do que o seu evento inverso. Esta variável explica 0,54% da decomposição no mês 2 e chega a 0,69% no mês 10. Assim como nas funções impulso resposta das anomalias sobre a soja (Figuras 26 e 27), o teste da decomposição da variância revelou que o La Niña representa impactos mais expressivos que o El Niño.

O esfriamento da superfície das águas da região 3,4 do Oceano Pacífico, segundo os resultados obtidos pelas funções impulso resposta e pela decomposição da variância, é um elemento mais representativo do que variáveis macroeconômicas como o PIB mundial, a atividade econômica americana e de variáveis microeconômicas como a produtividade das áreas produtoras de soja; também o LA obteve resultados quase de mesmo peso que a taxa de crescimento do preço milho. A medida que a defasagem aumenta a participação das variáveis na decomposição da variância passa a ser estatisticamente significativa para as variáveis taxa de crescimento do preço da soja, taxa de crescimento do preço do milho, taxa de crescimento do preço do óleo de soja, taxa de crescimento do preço do farelo de soja e La Niña.

Tabela 8: Decomposição da variância.

Period	S.E.	D_LOGPS...	D_LOGPROD	D_LOGPMI...	D_LOGHOO	D_LOGHOF	D_LOGATIV...	IN_EL_NINO	IN_LA_NINA	D_LOGGDP
1	0.043626	100.0000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)	0.000000 (0.00000)
2	0.049882	80.90505 (3.83860)	0.194125 (0.71041)	0.087090 (0.51116)	12.22038 (2.97127)	5.360550 (2.32626)	0.651490 (0.86492)	0.000245 (0.42590)	0.037655 (0.44852)	0.543412 (0.71446)
3	0.050875	77.81938 (4.09482)	0.191785 (0.82383)	0.139718 (0.79577)	11.74861 (2.88519)	5.579864 (2.29559)	1.115965 (1.17235)	0.059142 (0.68946)	2.765281 (2.18945)	0.580260 (1.10612)
4	0.051564	76.07914 (4.21185)	1.066492 (1.40240)	0.138425 (0.81579)	11.87999 (2.93889)	5.584672 (2.26234)	1.211053 (1.21197)	0.058789 (0.82760)	3.356286 (2.23393)	0.625152 (1.18571)
5	0.052297	73.96414 (4.03921)	1.193995 (1.45833)	2.158677 (1.67015)	11.68055 (2.83972)	5.506898 (2.22687)	1.214703 (1.23272)	0.179506 (1.14661)	3.392877 (2.12944)	0.708657 (1.16734)
6	0.053168	71.55934 (4.25837)	1.686856 (1.51278)	2.822549 (1.87853)	11.69016 (2.83417)	6.475272 (2.36550)	1.195559 (1.24754)	0.523768 (1.31316)	3.346371 (2.03110)	0.700125 (1.23818)
7	0.053571	70.65395 (4.16277)	1.795288 (1.47846)	3.306553 (2.11432)	11.66106 (2.83408)	6.460163 (2.37509)	1.534483 (1.27752)	0.597506 (1.26621)	3.296307 (1.99520)	0.694681 (1.27765)
8	0.054083	69.32446 (4.14889)	1.885398 (1.46976)	3.491917 (2.05278)	12.47692 (2.97674)	6.354850 (2.29615)	1.727743 (1.42649)	0.798780 (1.27726)	3.244706 (1.96017)	0.695229 (1.27609)
9	0.054170	69.14241 (4.14512)	1.935433 (1.51209)	3.496285 (2.03906)	12.47263 (2.96239)	6.334349 (2.26283)	1.726372 (1.39880)	0.900945 (1.28871)	3.297701 (1.93879)	0.693882 (1.29567)
10	0.054270	68.88792 (4.15745)	1.967388 (1.53254)	3.499388 (2.01290)	12.56525 (2.96376)	6.354981 (2.25738)	1.749766 (1.39453)	0.897686 (1.27270)	3.383434 (1.89584)	0.694187 (1.31228)

Cholesky Ordering: D_LOGPSOJA D_LOGPROD D_LOGPMILHO D_LOGHOO D_LOGHOF D_LOGATIVIDADE IN_EL_NINO IN_LA_NINA D_LOGGDP
Standard Errors: Monte Carlo (100 repetitions)

Fonte: elaboração própria.

Por limitações da metodologia VAR, as duas variáveis climáticas foram tratadas como endógenas, apesar de provavelmente serem exógenas. Contudo não há nada que prove que o preço da soja, o PIB mundial e a atividade econômica americana não causem mudanças de

temperatura oceânica. Isto permite tratá-las de tal forma. Assim, foi possível calcular a função impulso resposta e a decomposição da variância com os ENSO. Evidentemente, tal limitação poderia ser contornada com o uso de um VAR estrutural, em que restrições poderiam ser impostas ao modelo.⁸

As seis defasagens utilizadas pelo modelo justificam-se, pois, o período de seis meses abrange uma safra inteira; ainda os ENSO duram em média este período também, assim um El Niño em novembro pode afetar a oferta da soja nos meses da colheita no ano seguinte. O mercado costuma internalizar estes efeitos no momento em que ocorrem os choques climáticos antes mesmo da safra, já que falta de água ou anomalias térmicas podem causar danos irreversíveis a planta em qualquer estágio de desenvolvimento afetando a sua produtividade.

Um resultado semelhante ocorreu quando o furacão Irma assumiu uma direção que afetaria as fazendas de soja no delta do Rio Mississippi em 2017, mas então mudou de direção, não causando danos para a oferta de soja (FARMLEAD, 2017). Nesta ocasião, os preços reagiram positivamente e rapidamente voltaram ao equilíbrio.

Com os ENSO a retomada ao equilíbrio é um pouco mais lenta e indefinida, por se tratar de um choque de curto para médio prazo, podendo atingir duas safras, uma no norte e outra no sul. Ademais, eventos climáticos secundários, possivelmente causados por desvios térmicos na região 3,4, como furacões, pragas e tormentas, podem causar choques de curto prazo, não captados por este modelo mensal. A antecipação do mercado em relação ao clima pode aumentar o erro da equação, já que as especulações climáticas não podem ser consideradas precisas, isto pode superestimar ou subestimar o real impacto sobre o preço, dependendo da situação.

O sinal e a intensidade em que o SST impacta o preço da soja corroboram com Keppenne (1995) que obteve resultados semelhantes para o mercado futuro e com Brummer (2000) que trabalhou com outras variáveis dependentes. Peri (2017) encontrou resultados mais expressivos para o milho, porém conclui que o El Niño impacta o preço da soja positivamente durante a safra boreal. Em direção oposta ao resultado deste trabalho, o mesmo autor conclui que o La Niña diminui o preço durante a safra austral.

⁸ Essa extensão, entretanto, está além dos objetivos deste trabalho.

5 CONCLUSÃO

Esta monografia realizou uma pesquisa de caráter descritivo sobre o impacto de eventos *El Niño Southern Oscillation* no preço da soja, utilizando dados mensais para o período de 1988 até 2016. Realizou-se uma revisão bibliográfica acerca do tema da economia agrícola e da economia do meio ambiente. Mais especificamente, sobre o mercado internacional da soja e sobre os efeitos de *teleconnection* dos ENSO, relacionando estas duas literaturas por meio de autores que já realizaram pesquisas semelhantes à esta. Essa revisão ajudou na construção do modelo teórico e da estratégia de identificação do modelo empírico.

Por meio de dados sobre o mercado de *commodities*, macroeconômicos, do SST e de técnicas econométricas como o VAR, estimou-se um modelo onde a variável explicada foi a taxa de crescimento do preço da soja. O VAR possui uma série de limitações, mas para o presente propósito foi útil na construção das estimativas de médio prazo dos choques climáticos. O modelo encontrado passou no teste de autocorrelação residual e teve sua estabilidade comprovada.

Dentre os principais resultados, destaca-se que o preço dos futuros dos derivados da soja (óleo e farelo) são o fator que mais explica a taxa de crescimento do preço da matéria prima, além do seu próprio componente autoregressivo. Foi encontrado que estas variáveis são um importante elemento explicativo da variância deste ativo financeiro, podendo causar forte volatilidade no mercado de soja.

A partir do modelo estatístico estimado conclui-se que de fato o desvio de mais de $-0,5^{\circ}$ Celsius na superfície da região Niño 3,4, explicam mudanças de preço positivas de preço do grão, em geral, durante o período de uma safra. Resultado esperado e parecido ao obtido por Keppenne (1995). Quanto ao El Niño, ficou evidente que é preciso estimar seu choque no mercado, separando as duas safras, pois a defasagem de 6 meses com a qual impacta a taxa de crescimento do preço da soja pode ser explicada por impactos em apenas um hemisfério, assim como concluiu Peri (2017).

Cruzando as características físico-hídricas da soja, com a geografia das regiões produtoras e suas condições daofoclimáticas com as consequências do *EL* e do *LA*, percebe-se uma possível interpolação, ou área em comum em um conjunto de vetores causados ou afetados por três dimensões levadas em conta no trabalho: planta, espaço produtor e planeta terra.

Como sugestão para trabalhos futuros, sugere-se o uso de variáveis semelhantes a deste trabalho para analisar o impacto dos ENSO no preço de outras *commodities* como a energia elétrica no Brasil por exemplo, cujo a principal fonte de geração depende de chuvas. O El Niño

e o La Niña são elementos que causam distúrbio na incidência de precipitações em bacias hidrográficas geradoras de eletricidade, logo acredito que trabalhos nesta linha poderiam ter resultados expressivos; tanto no âmbito macroeconômico do preço a nível nacional, quanto para previsões das próprias usinas geradoras. Trabalhos futuros também devem utilizar modelos mais robustos que o VAR primitivo, que considerem elementos de teoria econômica em sua formulação.

REFERÊNCIAS

- ADAMS, R.M.; BRYANT, K. J.; MCCARL, B. A.; LEGLER, D. M.; O'BRIEN, J; SOLOW, A; WEIHER, R. Value of Improved Long-Range Weather Information. *Contemporary Economic Policy*, v.13, 1995, p. 10-19.
- ADEYANJU, C. The Top Factors that Move the Price of Soybeans. *Future Knowledge*, 2014.
- ALATON, P; DJEHICHE, B; STILLBERGER, D. On Modelling and Pricing Weather Derivatives. *Applied Mathematical Finance*, v. 9, 2002, p.1-20.
- ARAÚJO, P. H. C. *Eventos climáticos Extremos: Os Efeitos dos Fenômenos El Niño e La Niña Sobre a Produtividade Agrícola das Regiões Nordeste e Sul do Brasil*. Dissertação (Mestrado em Economia Aplicada). Viçosa, MG: Universidade Federal de Viçosa, 2012.
- ASTERIOU, D; HALL, S. G. *Applied Econometrics*. Palgrave Mcmillan, p.295-320, 2006.
- ATLAS OF ECONOMICS COMPLEXITY. *What did Brazil export in 2016?* Disponível em: <<http://atlas.cid.harvard.edu/explore/?country=32&partner=undefined&product=undefined&productClass=HS&startYear=undefined&target=Product&year=2016>>. Acesso em: 26 de novembro de 2017.
- AUSTRALIAN BUREAU OF METEOROLOGY, *Southern Oscillation Index*, 2016. Disponível em: <<http://www.bom.gov.au/climate/glossary/soi.shtml>>. Acesso em 22 de maio de 2018.
- AUSTRALIAN CENTRE FOR INTERNATIONAL AGRICULTURAL RESEARCH. *Soybean progress*. Disponível em: <http://aci.gov.au/files/mn-158/s6_1-soybean-progress.htm>. Acesso em: 03 de maio de 2018.
- BANCO CENTRAL DO BRASIL. Vetores Auto-Regressivos. *Relatório de Inflação*, 2004, p. 106-109.
- BANCO MUNDIAL. *PIB a preços correntes*. Disponível em: <<https://data.worldbank.org/indicator/NY.GDP.MKTP.CD>>. Acesso em 13 de janeiro de 2018.
- BEUTLER, A.N; CENTURION, J. F; DA SILVA, A. P; BARBOSA, J. C. Intervalo hídrico ótimo e produtividade de cultivares de soja. *Revista Brasileira de Engenharia Agrícola e Ambiental* v. 10, n. 3, 2006, p. 639–645.
- BM&F. *Bolsa de Mercadorias e Futuros*. Disponível em: <http://www.bmfbovespa.com.br/pt_br/>. Acesso em 04 de abril de 2018.
- BRUNNER, A. D. El Niño and World Primary Commodity Prices: Warm Water or Hot Air. *IMF Institute*, 2000, p. 1-35.
- BUENO, R. L. S. *Econometria de Séries Temporais*. Cengage Learning, São Paulo, v.2, 2012, p. 195-246.

CAIXETA-FILHO, J.V. Transporte e logística no sistema agroindustrial. *Preços Agrícolas*, n. 119, set. 1996, p. 1996.

CAMARA, R. K; KLEIN, V. A. Propriedades físico-hídricas do solo sob plantio direto escarificado e rendimento da soja. *Ciência Rural*, Santa Maria, v. 35, n. 4, 2005, p. 813-819.

CHAVAS, J-P; HOLT, M. T. Acreage Decisions Under Risk: The Case of Corn and Soybeans. *American Journal of Agricultural Economics*, v.72, 1990, p. 529–538.

DICKEY, D. A.; FULLER, W. A. *Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root*. *Econometrica*, v. 49, n. 4, 1981, p. 1057-1-72.

ENDERS, W. *Applied Econometric Time Series*. University of Alabama: Wiley, 2012.

FARIAS, J. R. B; NEPOMUCENO, A. L; NEUMAIER, N. Ecofisiologia da soja. *Circular Técnica*, Londrina, v. 48, set. 2007, p.1-9.

FARIAS, H. P. *Função resposta a impulso e decomposição da variância do erro de previsão aplicados às principais bolsas de valores*. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) - Universidade Federal de Lavras, Lavras, 2008.

FARMLEAD. *Soybeans slide in friday trading as hurricane irma fuels sell-off*. Disponível em: <<https://farmlead.com/blog/grain-markets-today/september-9-2017-soybeans-slide-in-friday-trading/>>. Acesso em: 23 de maio de 2018.

FEHR, W. R.; CAVINESS, C. E. Stages of soybeans development. *Ames, Iowa State University of Science and Technology*, 1977, v. 80, p. 11.

FREITAS-FILHO, F. Aspectos operacionais do mercado cambial brasileiro. *Agricultura em São Paulo*, São Paulo, v.40, t.2, 1933, p.67-93.

FOOD AND AGRICULTURE ORGANIZATION (FAO). *The state of food insecurity in the world. How does international price volatility affect domestic economies and food security?* Roma, Itália, 2011.

FOOD AND AGRICULTURE ORGANIZATION (FAO). *Soybean productivity*. Disponível em: <<http://www.fao.org/faostat/en/#search/soybean%20productivity>>. Acesso em: 02 de fevereiro de 2018.

GIL, A.C. *Como Elaborar Projetos de Pesquisa*. 4. ed. São Paulo: Atlas, 2002.

GIL, A.C. *Métodos e técnicas de pesquisa social*. 6. ed. São Paulo: Atlas, 2008.

HARRIS, R. I. D. *Cointegration analysis in econometric modelling*. London: Prentice Hall, 1995. p.176.

HOUCK J. P; MANN J. S." *An Analysis of Domestic and Foreign Demand for US Soybeans and Soybean Products*, Technical Bulletin, 1968.

HOUCK, J. P; RYAN, M. E; SUBOTNIK, A. *Soybeans and Their Products Markets, Models, and Policy*. Minneapolis: University of Minnesota Press, 1972.

INDEXMUNDI. *Soybeans*. Disponível em:

<<https://www.indexmundi.com/commodities/?commodity=soybeans&months=360>>. Acesso em 13 de janeiro de 2018.

INDEXMUNDI. *Corn*. Disponível em:

<<https://www.indexmundi.com/commodities/?commodity=corn&months=360>>. Acesso em 13 de janeiro de 2018.

INVESTING. *US soybean meal*. Disponível em: <<https://www.investing.com/commodities/us-soybean-meal>>. Acesso em 13 de janeiro 2018.

INVESTING. *US soybean oil*. Disponível em: <<https://www.investing.com/commodities/us-soybean-oil>>. Acesso em 13 de janeiro de 2018.

KEPPENNE, C.L. An ENSO Signal in Soybean Futures Prices. *Journal of Climates*, v. 8, 1995, p. 1685-1689.

KEPPENNE, C.L.; GHIL, M. Forecasting extreme weather events. *Nature*, n.358, 1992, p.547. 1992.

LETSON, D; MCCULLOUGH, B.D. ENSO and Soybean Prices: Correlation without Causality. *Journal of Agricultural and applied Economics*, 2001, p.13-52.

LLANA, M. P; VARGAS, W; NAUMANN, G. Climate variability in areas of the world with high production of soya beans and corn: its relationship to crop yields. *Meteorological Applications*, v. 19, n. 4, 2012, p. 385-396.

MAFIOLETTI. R. L, *Formação de Preços na Cadeia Agroindustrial da Soja na Década de 90*, Dissertação (Mestrado em economia aplicada) – Universidade de São Paulo, Escola Superior de Agricultura Luiz de Queiroz, 2000, p. 20.

MARGARIDO, M. A.; TUROLLA, F. A.; FERNANDES, J. M. Análise da formação de preços no mercado internacional de soja: o caso do Brasil. São Paulo, SP: *Agricultura em São Paulo*, v. 49, n. 2, 2002, p. 71-85.

MILLER, N.H. *Notes on Microeconomic Theory*, 2003, p. 5- 189.

MOODY'S ANATICS. Disponível em: <<https://www.economy.com/confirmation.aspx&rid>>. Acesso em: 05 mai 2018.

NOAA. Global impacts of El Niño and La Niña. <<https://www.climate.gov/news-features/featured-images/global-impacts-el-nino-and-la-nina>>. Acesso em: 30 de janeiro de 2018.

NOAA. Historical Maps and Charts audio podcast. National Ocean Service website. Disponível em: <<https://oceanservice.noaa.gov/podcast/july17/nop08-historical-maps-charts.html>>. Acesso em: 13 de agosto de 2017.

PERI, M. Climate variability and the volatility of global maize and soybean prices. *Food security*, v.9, 2017, p.673–683.

PHILLIPS, G. P; ROSENZWEIG, C; CANE, M. Exploring the Potencial for Using ENSO Forecast in the U.S. Corn Belt. *Drought Network News*, v.68; 2001, p.1-3.

RITCHIE, S.; HANWAY, J.J.; THOMPSON, H.E. How a Soybean Plant Develops. *Ames, Iowa State University of Science and Technology*, 1982. p. 20.

ROCHA, D. T; CORSO, J. M; PEDRO, J. J; SILVA, W. V. Relação entre os preços do grão de soja nos mercados à vista e futuro: uma análise a partir da razão ótima de Hedge. *ReFAE – Revista da Faculdade de Administração e Economia*, v. 1, n. 2, 2010, p. 113-137.

ROPELEWSKI, C. F., & HALPERT, M. S. Global and Regional Scale Precipitation Patterns Associated with the El Nino/Southern Oscillation. *Monthly Weather Review*, v. 115, n. 8, 1987, p. 1606–1626.

ROSENZWEIG, C; IGLESIAS, A; YANG, X.B.; EPSTEIN, P.R; CHIVIAN, E. Climate Change and Extreme Weather Events; Implications for Food Production, Plant Diseases, and Pests. *Global Change and Human Health*, v. 2, 2001, p. 90–104.

SANTIAGO, M. M. D; CAMARGO, M. L. B; MARGARIDO, M. A. Detecção e Análise de Outliers em Séries Temporais de Índices de Preços Agrícolas no Estado de São Paulo. São Paulo, SP. *Agricultura em São Paulo*, v. 43, n. 2, 1996, p.89-115.

SILVA, A. M; KADOTA, D. K. Inflação e preços relativos no Brasil. São Paulo, SP. *FEA/USP (trabalho de discussão interna)*, 1980, p.66.

SIMS, C. A. Macroeconomics and Reality. *Econometrica*. v.48-1, 1980, p. 1-48.

SKEER, J. R. The Potential Role of Weather Markets for U.S. Agriculture. Lexington, KY, *University of Kentucky*, 2001.

SUMMER, D. A; MUELLER, R.A.E. Are Harvest Forecasts News? USDA Announcements and Futures Market Reactions. *American Journal of Agricultural Economics*, v.71-1, 1989, p. 1–8.

THE WEATHER NETWORK. *El Niño 2015 sets new heat record. Here's what it means*. Disponível em: <<https://www.theweathernetwork.com/us/news/articles/el-nino-2015-sets-new-heat-record-what-does-this-mean/60009/>>. Acesso em: 03 de maio de 2018.

USDA. *Foreign Agricultural Service*. United States Department of Agricultural website. Disponível em: <<https://www.fas.usda.gov/data/search>>. Acesso em: 27 de novembro de 2017.

ZIVOT, E; WANG, J. Modeling Financial Time Series with S-Plus. *Springer*. New York, v.2, 2005, p.409-416.

APÊNDICE

A pesar de uma regressão relacionar variáveis, ela não prova existência de causalidade entre elas. Para amparar a presença de causalidade entre variáveis usa-se o Teste de causalidade de Granger. Este teste define causalidade em termos de previsão, ou seja se uma variável Y causa X esta última pode ser prevista mais eficientemente se regredirmos com Y. Se Y granger causa X, Y deve preceder X e melhorar os resultados da regressão de X. Na Tabela 9 vê-se os resultados do Teste de Granger do modelo estimado neste modelo. Na coluna direita da tabela está a probabilidade de rejeitar a hipótese de causalidade de Granger. Ao nível de confiança de 90%, pode-se dizer que as variáveis taxa de crescimento do preço do milho, taxa de crescimento do preço futuro do farelo de soja, taxa de crescimento do preço futuro do óleo de soja e a taxa de crescimento da atividade econômica dos EUA granger causam a taxa de crescimento do preço da soja.

Tabela 9: Causalidade de Granger

Dependent variable: D_LOGPSOJA			
Excluded	Chi-sq	df	Prob.
D_LOGPROD	7.269667	6	0.2966
D_LOGPMILHO	13.66398	6	0.0336
D_LOGHOO	41.49199	6	0.0000
D_LOGHOF	20.92201	6	0.0019
D_LOGATIVIDADE	10.99692	6	0.0885
IN_EL_NINO	3.483131	6	0.7462
IN_LA_NINA	7.536164	6	0.2741
D_LOGGDP	4.753978	6	0.5757
All	129.0376	48	0.0000

Fonte: Elaboração própria.

O teste de normalidade dos resíduos da Tabela 10, indica que os resíduos da regressão feita por este trabalho não são normais.

Tabela 10: Normalidade dos resíduos

Component	Skewness	Chi-sq	df	Prob.*
1	-0.516058	15.04687	1	0.0001
2	0.525224	15.58611	1	0.0001
3	-0.320439	5.801482	1	0.0160
4	-0.074869	0.316706	1	0.5736
5	0.095399	0.514202	1	0.4733
6	-0.136469	1.052249	1	0.3050
7	0.907047	46.48448	1	0.0000
8	-0.934410	49.33135	1	0.0000
9	0.645121	23.51426	1	0.0000
Joint		157.6477	9	0.0000

Component	Kurtosis	Chi-sq	df	Prob.
1	5.348022	77.87403	1	0.0000
2	19.35017	3776.009	1	0.0000
3	5.487502	87.40081	1	0.0000
4	4.474844	30.72420	1	0.0000
5	3.240133	0.814500	1	0.3668
6	3.958114	12.96649	1	0.0003
7	8.246004	388.7278	1	0.0000
8	8.981814	505.4221	1	0.0000
9	19.85346	4012.050	1	0.0000
Joint		8891.989	9	0.0000

Fonte: Elaboração própria.

Na Tabela 11 está o teste de heteroscedasticidade. A pesar de na maioria dos casos de quando se cruza os resíduos entre as variáveis e defasagens; não haver presença de heteroscedasticidade o teste agregado não exclui a hipótese de presença da mesma.

Tabela 11: Teste de heteroscedasticidade

Chi-sq	df	Prob.
5835.872	5535	0.0024

Individual components:

Dependent	R-squared	F(123,215)	Prob.	Chi-sq(123)	Prob.
res1*res1	0.397324	1.152378	0.1826	134.6930	0.2220
res2*res2	0.601593	2.639421	0.0000	203.9399	0.0000
res3*res3	0.499557	1.744873	0.0002	169.3498	0.0036
res4*res4	0.402638	1.178178	0.1479	136.4943	0.1914
res5*res5	0.444799	1.400384	0.0160	150.7869	0.0450
res6*res6	0.390121	1.118122	0.2373	132.2510	0.2683
res7*res7	0.381019	1.075977	0.3180	129.1655	0.3339
res8*res8	0.490742	1.684417	0.0004	166.3617	0.0056
res9*res9	0.602562	2.650119	0.0000	204.2685	0.0000
res2*res1	0.376298	1.054601	0.3642	127.5650	0.3707
res3*res1	0.453451	1.450222	0.0089	153.7198	0.0316
res3*res2	0.398873	1.159851	0.1720	135.2180	0.2128
res4*res1	0.412526	1.227427	0.0959	139.8462	0.1422
res4*res2	0.435124	1.346458	0.0291	147.5070	0.0654
res4*res3	0.428884	1.312648	0.0416	145.3915	0.0821
res5*res1	0.424600	1.289861	0.0526	143.9393	0.0954
res5*res2	0.357716	0.973519	0.5608	121.2657	0.5273
res5*res3	0.459683	1.487113	0.0057	155.8327	0.0242
res5*res4	0.427450	1.304982	0.0451	144.9054	0.0864
res6*res1	0.346950	0.928654	0.6722	117.6161	0.6201
res6*res2	0.332526	0.870814	0.8006	112.7265	0.7361
res6*res3	0.341307	0.905724	0.7261	115.7032	0.6671
res6*res4	0.406420	1.196819	0.1261	137.7762	0.1713
res6*res5	0.377458	1.059823	0.3526	127.9582	0.3615
res7*res1	0.377940	1.061999	0.3478	128.1217	0.3577
res7*res2	0.311706	0.791597	0.9234	105.6683	0.8684
res7*res3	0.388743	1.111660	0.2487	131.7838	0.2778
res7*res4	0.337255	0.889499	0.7620	114.3295	0.6997
res7*res5	0.403481	1.182314	0.1428	136.7802	0.1868
res7*res6	0.281287	0.684113	0.9896	95.35635	0.9694
res8*res1	0.406615	1.197790	0.1250	137.8426	0.1703
res8*res2	0.315767	0.806672	0.9054	107.0451	0.8466
res8*res3	0.383213	1.086023	0.2975	129.9093	0.3174
res8*res4	0.378534	1.064683	0.3420	128.3229	0.3531
res8*res5	0.332559	0.870942	0.8003	112.7375	0.7359
res8*res6	0.441144	1.379791	0.0202	149.5477	0.0520
res8*res7	0.367394	1.015155	0.4568	124.5466	0.4441
res9*res1	0.507719	1.802787	0.0001	172.1169	0.0023
res9*res2	0.348235	0.933930	0.6595	118.0516	0.6092
res9*res3	0.484984	1.646037	0.0007	164.4095	0.0075
res9*res4	0.399181	1.161343	0.1699	135.3225	0.2110
res9*res5	0.386372	1.100612	0.2690	130.9802	0.2944
res9*res6	0.353613	0.956245	0.6042	119.8749	0.5629
res9*res7	0.341981	0.908441	0.7199	115.9315	0.6616
res9*res8	0.421232	1.272183	0.0627	142.7976	0.1071

Fonte: Elaboração própria.

A pesar de Bueno (2012) escrever que os parâmetros do VAR estrutural terem pouco poder interpretativo; os resultados (parâmetros) da regressão se encontram na tabela que segue, em baixo, entre parênteses está o erro padrão, e na última linha a estatística t :

Tabela 12: Coeficientes do modelo VAR

	D_LOGPSOJA
D_LOGPSOJA(-1)	-0.096506 (0.08100) [-1.19142]
D_LOGPSOJA(-2)	-0.087501 (0.08198) [-1.06733]
D_LOGPSOJA(-3)	-0.056078 (0.08197) [-0.68409]
D_LOGPSOJA(-4)	0.037386 (0.08148) [0.45882]
D_LOGPSOJA(-5)	-0.097281 (0.08018) [-1.21328]
D_LOGPSOJA(-6)	-0.071523 (0.06789) [-1.05356]
D_LOGPROD(-1)	-1.259497 (0.95177) [-1.32332]
D_LOGPROD(-2)	1.348642 (1.27441) [1.05825]
D_LOGPROD(-3)	-2.006574 (1.27014) [-1.57981]
D_LOGPROD(-4)	1.224564 (1.27505) [0.96041]
D_LOGPROD(-5)	1.568384 (1.28129) [1.22406]
D_LOGPROD(-6)	-1.249607 (0.94327) [-1.32476]

D_LOGPMILHO(-1)	-0.088428 (0.05811) [-1.52179]
D_LOGPMILHO(-2)	0.040345 (0.05850) [0.68968]
D_LOGPMILHO(-3)	0.006809 (0.05885) [0.11569]
D_LOGPMILHO(-4)	-0.172337 (0.05849) [-2.94655]
D_LOGPMILHO(-5)	-0.075774 (0.05821) [-1.30182]
D_LOGPMILHO(-6)	-0.018303 (0.05652) [-0.32382]
D_LOGHOO(-1)	0.273242 (0.04531) [6.03008]
D_LOGHOO(-2)	0.117911 (0.05141) [2.29333]
D_LOGHOO(-3)	-0.031720 (0.05228) [-0.60675]
D_LOGHOO(-4)	-0.000388 (0.05350) [-0.00725]
D_LOGHOO(-5)	0.055226 (0.05375) [1.02739]
D_LOGHOO(-6)	0.062216 (0.04914) [1.26605]

D_LOGHOF(-1)	0.180525 (0.04268) [4.22941]
D_LOGHOF(-2)	0.031134 (0.04707) [0.66137]
D_LOGHOF(-3)	-0.019733 (0.04677) [-0.42193]
D_LOGHOF(-4)	0.021030 (0.04717) [0.44586]
D_LOGHOF(-5)	0.086434 (0.04775) [1.81006]
D_LOGHOF(-6)	0.041115 (0.04491) [0.91555]
D_LOGATIVIDADE(-1)	-0.120012 (0.07519) [-1.59606]
D_LOGATIVIDADE(-2)	0.110146 (0.07439) [1.48065]
D_LOGATIVIDADE(-3)	0.107671 (0.07460) [1.44340]
D_LOGATIVIDADE(-4)	0.010448 (0.07437) [0.14050]
D_LOGATIVIDADE(-5)	-0.051109 (0.07443) [-0.68665]
D_LOGATIVIDADE(-6)	-0.141635 (0.07455) [-1.89981]

IN_EL_NINO(-1)	0.000805 (0.01890) [0.04257]
IN_EL_NINO(-2)	0.007220 (0.03054) [0.23636]
IN_EL_NINO(-3)	-0.016650 (0.03031) [-0.54939]
IN_EL_NINO(-4)	0.026731 (0.03030) [0.88208]
IN_EL_NINO(-5)	0.001338 (0.03036) [0.04405]
IN_EL_NINO(-6)	-0.014126 (0.01898) [-0.74440]
IN_LA_NINA(-1)	-0.006815 (0.02113) [-0.32246]
IN_LA_NINA(-2)	-0.031811 (0.03358) [-0.94736]
IN_LA_NINA(-3)	0.020753 (0.03370) [0.61584]
IN_LA_NINA(-4)	0.017457 (0.03301) [0.52887]
IN_LA_NINA(-5)	-0.018978 (0.03241) [-0.58558]
IN_LA_NINA(-6)	0.010847 (0.01985) [0.54637]

D_LOGGDP(-1)	2.684055 (1.90930) [1.40578]
D_LOGGDP(-2)	-1.550352 (2.50673) [-0.61847]
D_LOGGDP(-3)	-2.494769 (2.49455) [-1.00009]
D_LOGGDP(-4)	0.362372 (2.49326) [0.14534]
D_LOGGDP(-5)	0.897913 (2.49423) [0.36000]
D_LOGGDP(-6)	1.192845 (1.87530) [0.63608]
C	-0.007611 (0.01170) [-0.65033]
DUMMY_ABR	-0.012763 (0.01350) [-0.94544]
DUMMY_AGO	-0.007506 (0.01417) [-0.52988]
DUMMY_FEV	0.002365 (0.01274) [0.18559]
DUMMY_JAN	-0.002523 (0.01344) [-0.18773]
DUMMY_JUL	0.007441 (0.01446) [0.51476]

DUMMY_JUN	0.012361 (0.01407) [0.87841]
DUMMY_MAI	-0.004545 (0.01383) [-0.32868]
DUMMY_MAR	-0.012292 (0.01360) [-0.90378]
DUMMY_NOV	0.006467 (0.01325) [0.48826]
DUMMY_OUT	-0.015194 (0.01259) [-1.20727]
DUMMY_Q1	0.005383 (0.00645) [0.83483]
DUMMY_Q2	0.011187 (0.00862) [1.29809]
DUMMY_Q3	-0.005335 (0.01028) [-0.51903]
DUMMY_Q4	-0.000355 (0.00740) [-0.04801]
DUMMY_SET	-0.006713 (0.01389) [-0.48332]

Fonte: Elaboração própria.