



UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
ESCOLA DE ADMINISTRAÇÃO E NEGÓCIOS
CURSO DE CIÊNCIAS ECONÔMICAS

TÂMILY LAIS HOFFMANN

**Transmissão de Preços na Comercialização da Soja e seus
Derivados em Goiás: 2014-2023**

Orientador: Prof. Dr. Adriano Marcos
Rodrigues Figueiredo.

Campo Grande - MS
2024

TÂMILY LAIS HOFFMANN

**Transmissão de Preços na Comercialização da Soja e seus
Derivados em Goiás: 2014-2023**

Trabalho de Conclusão de Curso apresentado
ao Curso de Ciências Econômicas da
Universidade Federal de Mato Grosso do Sul,
como exigência parcial para obtenção do título
de Bacharel em Ciências Econômicas.

Orientação: Prof. Dr. Adriano Marcos Rodrigues
Figueiredo.

Campo Grande - MS
2024

TERMO DE APROVAÇÃO

Trabalho de Conclusão de Curso intitulado: Transmissão de preços na comercialização de soja e seus derivados no estado de Goiás, apresentado por TÂMILY LAIS HOFFMANN como exigência parcial para aprovação na disciplina de Trabalho de Conclusão de Curso e demais requisitos para obtenção do título de Bacharel em Ciências Econômicas ao Professor Orientador, dentro do prazo legal e com as formalidades exigidas, foi considerado

_____.

Campo Grande – MS, ____ de _____ 2024.

BANCA EXAMINADORA:

Prof. Dr. Adriano Marcos Rodrigues Figueiredo – ESAN UFMS (orientador)

Prof. Dr. Wladimir Machado Teixeira – ESAN UFMS

Prof. Dr. Leonardo Francisco Figueiredo Neto – ESAN UFMS

AGRADECIMENTOS

Gostaria de agradecer primeiramente à Deus, que fez com que meus objetivos fossem alcançados, durante todos os meus anos de estudos. Aos meus pais e namorado, que me incentivaram nos momentos difíceis, e me deram todo o apoio que precisei. Ao professor Adriano Figueiredo, por ter sido meu orientador e ter desempenhado tal função com dedicação, e a todos aqueles que contribuíram, de alguma forma, para a realização deste trabalho.

RESUMO

No presente estudo será tratado sobre a soja e seus derivados de primeiro processamento (grão, farelo e óleo) e as transmissões de seus preços para o produtor rural na Praça de Rio Verde – GO, comparativamente com o Porto de Paranaguá, e preço internacional da Bolsa de Chicago, no período de 2014 a 2023. Será avaliado como as variações nos preços de um nível de mercado afeta os demais, para que o produtor possa conhecer quais os produtos e mercados que mandam nos preços do grão da soja, e com base nisso, tomar a melhor decisão para a comercialização/venda do seu produto. O método utilizado para obter os resultados dessa correlação entre os preços da soja, foi a Série Temporal com causalidade de Granger, para verificar quais preços ajudam a prever os outros. Os resultados obtidos, indicaram que as indústrias de óleo de soja por serem poucas e gigantes, são oligopolistas, tendo o poder de controlar o preço do seu produto. Assumindo o papel de principais balizadores na formação de preço de mercado da cultura da soja, rebatendo o preço para os outros níveis, ou seja, para o farelo e para o grão. Portanto, o produtor rural do Estado de Goiás deve ficar atento aos preços do óleo de soja, que influenciam diretamente no valor de seu grão. Além disso, deve monitorar também as variações nos preços da soja, principalmente na Bolsa de Chicago, que é o mercado de referência Global, e no Porto de Paranaguá, que é maior porto exportador da soja no Brasil.

Palavras-chave: soja, grão, óleo, farelo, Causalidade de Granger, Série Temporal, Porto de Paranaguá, Bolsa de Chicago, Praça de Rio Verde GO.

ABSTRACT

The present study will address soybeans and their first-processed derivatives (grain, meal, and oil), focusing on the transmission of their prices to rural producers in the Rio Verde market – GO, compared to the Port of Paranaguá and the international price at the Chicago Board of Trade from 2014 to 2023. It will evaluate how price variations at one market level affect others, enabling producers to understand which products and markets influence soybean grain prices. Based on this understanding, they can make better decisions regarding the marketing/sale of their products. The method used to obtain results regarding the correlation between soybean prices was Granger causality time series analysis to determine which prices help predict others. The results indicated that soybean oil industries, being few and large, operate as oligopolists with the power to control their product prices. They play a crucial role in setting market prices for soybeans, impacting prices at other levels, such as meal and grain. Therefore, rural producers in Goiás must pay attention to soybean oil prices, which directly influence the value of their grain. Additionally, they should monitor price variations in soybeans, particularly at the Chicago Board of Trade, which serves as a global reference market, and at the Port of Paranaguá, Brazil's largest soybean export port.

Keywords: soybeans, grain, oil, meal, Granger causality, time series, Port of Paranaguá, Chicago Board of Trade, Rio Verde GO

LISTA DE FIGURAS

Figura 1 – Destinos e Uso da Soja Brasileira – FPA Agropecuária, 2021.....	13
Figura 2 – Fluxos do resultado do Teste de Causalidade de Granger das relações de preços com 10% de significância ou menos.....	33

LISTA DE ILUSTRAÇÕES

Gráfico 1 – Tendência dos preços de soja em grão, farelo e óleo na Bolsa de Chicago, no Porto de Paranaguá e na Praça de Rio Verde GO, na década de 2014 a 2023.....	25
--	----

LISTA DE TABELAS

Tabela 1 – Significado das siglas.....	25
Tabela 2 – Estatística Descritiva das correlações entre os preços, contando com valor mínimo, média e valor máximo.....	26
Tabela 3 – Resultados do Teste de Causalidade de Granger nos preços, 2014-2023.....	28
Tabela 4 – Relações dos preços que foram significativos a 0,1%, com probabilidade entre 0 e 0,001.....	29
Tabela 5 – Relações dos preços que foram significativos a 1%, com probabilidade entre 0,001 e 0,01.....	29
Tabela 6 – Relações dos preços que foram significativos a 5%, com probabilidade entre 0,01 e 0,05.....	30
Tabela 7 – Relações dos preços que foram significativos a 10%, com probabilidade entre 0,05 e 0,1.....	31
Tabela 8 – Relações dos preços que não foram considerados significativos, ou seja, os preços que não se transmitem para o outro, com probabilidade entre 0,1 e 1.....	32

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Cadeia Agroindustrial da Soja.....	13
2	EMBASAMENTO TEÓRICO.....	16
2.1	Transmissão de Preço.....	16
2.2	Teoria dos Preços	18
2.3	Preço e Valor	20
3	MÉTODOS E DADOS	21
3.1	Teste F	23
4	RESULTADOS E DISCUSSÃO.....	27
4.1	Série Temporal	27
4.2	Causalidade de Granger, Teste F.....	30
5	CONSIDERAÇÕES FINAIS.....	37
	REFERÊNCIAS BIBLIOGRÁFICAS.....	39
	APÊNDICE	43

1 INTRODUÇÃO

O cultivo da soja é importantíssimo para o Brasil, sendo considerada a principal cultura da agricultura brasileira desde 1970. E com o crescimento da indústria de óleo aliada ao desenvolvimento de novas tecnologias, o seu cultivo foi ainda mais estimulado. Sendo o principal produto brasileiro exportado, é responsável por alavancar o PIB do país. A cadeia produtiva da soja movimenta US\$ 100 bilhões/ano no Brasil (FPA AGROPECUÁRIA, 2021).

Um dos principais motivos da soja ter essa liderança na agricultura brasileira, é por conta do seu retorno econômico e pela versatilidade de seu grão. Podendo ser aproveitada pela indústria de diversas formas, como fonte de proteína para a alimentação animal, na produção de óleo vegetal ou até mesmo para a fabricação de biocombustíveis. Além disso, é uma alternativa nutricionalmente rica para dietas que restringem lactose, bem como para dietas vegetarianas e veganas, devido ao seu alto teor proteico e valor nutricional (FPA AGROPECUÁRIA, 2021).

Dados de literatura indicam que a soja apresenta em torno de 40% de proteína e 20% de óleo, em base seca, além de contar com um alto teor de aminoácidos essenciais em sua composição. (FPA AGROPECUÁRIA, 2021)

Estima-se que a cadeia produtiva da soja reúna no país mais de 243 mil produtores, e um mercado de 7,5 milhões de empregos. A soja proporciona rentabilidade e lucratividade para as plantações de grãos, sendo a cultura mais importante de verão, desde o Norte até o Sul do país (FPA AGROPECUÁRIA, 2021).

De acordo com o Departamento de Agricultura dos Estados Unidos, o USDA, com a produção próxima de 156 milhões de toneladas de soja, o Brasil ocupa a liderança nas exportações desse grão, respondendo por aproximadamente 42% de toda a soja produzida no planeta. Além da produção, cerca de 7,8% de toda a exportação de grãos mundialmente é feita pelo Brasil, o que lhe dá o título de maior exportador de soja do mundo (VERTICE, 2024).

Dos 8% da área destinada à produção de grãos, a soja representa 3,5%, o equivalente a 33 milhões de hectares. Ao utilizar 74 milhões de hectares de pastagens degradadas, a produção de soja pode crescer até 50% até a safra de 2024/2025, ocupando apenas 5% do território. Ela ocupa 9,8% do bioma Cerrado e 0,7% do bioma Amazônia (dados da Conab e MMA). Do total de 61% de vegetação nativa no Brasil, 11% estão em propriedades rurais. (FPA AGROPECUÁRIA, 2021).

Questiona-se: considerando o grão de soja, o farelo e o óleo de soja, como se dá a transmissão de choques entre os preços de Chicago, Paranaguá e Goiás?

Esse tema foi escolhido dada a importância da soja para o estado de Goiás, além de uma escolha pessoal, pois venho de uma fazenda de plantação, no Estado de Goiás, onde o produto principal produzido é a soja e a profissão que quero exercer quando me formar é voltada ao sistema financeiro da fazenda, na compra e venda de produtos (soja, principalmente). Esse estudo ajuda a conhecer um pouco mais desse mercado e a compreensão de como ele funciona, mostrando o produto que se deve analisar e quais mercados observar, a fim de se vender a soja na melhor época e obter maior lucro, visto que o produtor rural é pequeno e tomador de preço.

Vários trabalhos foram realizados no Brasil para verificar o sentido de causalidade entre preços agrícolas em diversos níveis de mercado (MAFIOLETTI, 2001; COLLE, 2014; TONIN, 2008; PINO e ROCHA, 2020; entre outros). Esse trabalho, tem como objetivo observar como se dão as transmissões de preços na comercialização da soja e seus derivados de primeiro processamento, no Estado de Goiás, especificamente para soja em grão, farelo de soja e óleo de soja, comparativamente aos mercados do Porto de Paranaguá e Bolsa de Chicago, no período de 2014 a 2023.

A hipótese básica desse trabalho é de que os preços são formados a partir dos preços da Bolsa de Chicago, por se conhecer a grandeza e a importância mundial desse mercado, principalmente no comércio de commodities. Sendo assim, é esperado que ela terá grande impacto sobre os preços do grão da soja no Estado de Goiás.

1.1 Cadeia Agroindustrial da Soja


Os produtos derivados da soja têm uma ampla gama de aplicações e usos. O farelo de soja, que é rico em proteínas, é principalmente utilizado na fabricação de rações para aves, suínos e bovinos de corte e de leite, sendo essa a principal forma de aproveitamento econômico da soja.

O farelo derivado dos grãos de soja é o mais utilizado na alimentação animal. Ele é abundante em proteína bruta e, além do alto teor proteico, possui um excelente equilíbrio de aminoácidos, sendo reconhecido como o suplemento proteico vegetal mais apropriado disponível. No ano de 2023 o Brasil passou a Argentina e assumiu a liderança de maior exportador mundial de farelo de soja, com o escoamento de 21,82 milhões de toneladas (CONAB, 2023).

Já o óleo de soja serve como matéria-prima para a indústria, sendo transformado em óleo refinado, gorduras hidrogenadas, margarinas, maionese, entre inúmeros outros produtos. Além disso, o óleo de soja tem sido empregado em itens industriais, como tintas, lubrificantes, solventes, plásticos e resinas. Ele também está presente em diversos produtos do cotidiano, como cosméticos, colchões e alimentos. Mais recentemente, tem sido a principal matéria-prima para produção de biodiesel no Brasil e nos EUA (FPA AGROPECUÁRIA, 2021).

Além de assegurar amplamente a segurança alimentar do país, o agronegócio da soja exporta para mercados consumidores relevantes, como China e Europa, e contribui para a entrada de divisas no Brasil. Cidades onde se produz soja tem melhor Índice de Desenvolvimento Humano (FPA AGROPECUÁRIA, 2021).

Figura 1 – Destinos e Uso da Soja Brasileira:



FONTE: Elaboração Aprosoja, FPA AGROPECUÁRIA, 2021

Acompanhar os preços da soja e seus derivados é muito importante para os produtores rurais que cultivam esse grão, para terem uma noção de como o mercado funciona, por quem e como os preços são influenciados; e assim, tomar a melhor decisão de quando efetuar a venda da sua soja.

Considerando o grão de soja, o farelo e o óleo de soja, a transmissão de choques entre os preços da Bolsa de Chicago, Porto de Paranaguá e do Estado de Goiás ocorrem por meio de uma série de canais econômicos que envolvem o comércio internacional, as cadeias de valor e as relações de oferta e demanda locais.

Chicago serve como a base de preços globais e qualquer choque (oferta ou demanda) afeta diretamente os preços globais. Paranaguá, como porto exportador, repassa os efeitos dos choques de preços de Chicago para os

mercados internacionais, influenciando o preço das exportações brasileiras. Já Goiás acompanha as flutuações de preços de Chicago e Paranaguá, mas com ajustes locais determinados pelos custos de transporte, políticas locais e a oferta interna.

As exportações do Brasil são direcionadas para diversas regiões dos mercados internacionais, caracterizando o Brasil como um global trade e, portanto, um mercado mais formador do que tomador de preços (GIEMBINSKY; HOLLAND, 2003).

A próxima seção traz o embasamento teórico acerca da formação dos preços e revisa os estudos anteriores na temática. Na sequência, tem-se o método e os dados utilizados para o estudo e a seção dos resultados e conclusões.

2 EMBASAMENTO TEÓRICO

O método estatístico utilizado para a realização desse trabalho foi a causalidade de Granger em Séries Temporais por ser uma ótima ferramenta para pesquisadores que procuram entender a dinâmica entre variáveis ao longo do tempo, com o objetivo de descobrir se a série temporal estudada pode ser prevista por outras.

E para isso, é importante compreender como os preços são formados em um mercado e como eles afetam a economia de forma geral, a Teoria dos Preços é um excelente estudo sobre esse assunto. Compreendê-la permite tomar decisões mais informadas sobre produção, consumo e regulação econômica, e isso é essencial para promover a eficiência econômica, a competitividade e o equilíbrio do mercado.

2.1 Transmissão de Preço

No que diz respeito à análise das interações entre variáveis econômicas, destaca-se a elasticidade de transmissão de preços. Este conceito é semelhante ao de outros tipos de elasticidade. Por exemplo, a clássica elasticidade-preço da demanda indica como mudanças nos preços de um produto afetam a quantidade demandada do mesmo. Já a elasticidade de transmissão de preços descreve como as variações de preço de um produto em um determinado mercado impactam os preços do mesmo produto dentro do mesmo mercado, mas em outro nível, ou como as alterações de preço em um mercado influenciam os preços do mesmo produto em outro mercado. No primeiro caso, temos a elasticidade de transmissão de preços vertical, e no segundo, a elasticidade de transmissão de preços horizontal - ou espacial - (MARGARIDO, 2012).

Nesse trabalho foram utilizados a transmissão vertical e horizontal de preços, já que as variáveis dessa pesquisa são produtos diferentes (soja em grão, farelo e óleo) no mesmo mercado e o mesmo produto em mercados diferentes (Praça Econômica de Rio Verde GO, Porto de Paranaguá e Bolsa de Chicago).

Estudos sobre a transmissão horizontal de preços são fundamentadas nos conceitos relacionados à formação competitiva dos preços, ou seja, têm como

base a Lei do Preço Único, que determina que em mercados competitivos, sem custos de transporte e sem restrições comerciais oficiais, produtos iguais negociados em diferentes regiões devem ser vendidos pelo mesmo preço. determinando assim, que os mercados são integrados. Sendo assim, variações de preços no mercado A são transmitidas proporcionalmente aos preços praticados no mercado B no longo prazo. Tal situação implica que a elasticidade de transmissão de preços deve ser igual a um (MARGARIDO, 2012).

Para compreender a transmissão espacial (horizontal) de preços ou o movimento conjunto dos preços da soja em diversos pontos de mercado, a condição de arbitragem espacial é um conceito teórico essencial a ser entendido. Este conceito afirma que as variações de preços do mesmo produto entre mercados distintos não podem exceder o custo de transação, caso contrário, a oportunidade de arbitragem seria prontamente aproveitada (MARTIGNONE, BEHRENDT, PAPARAS, 2022).

Oportunidade de arbitragem é uma situação no mercado em que é possível obter lucro sem risco, aproveitando as diferenças de preço de um mesmo bem ou ativo em diferentes mercados. A arbitragem ocorre quando uma pessoa ou entidade compra o bem ou ativo no mercado onde ele está mais barato e o vende em outro mercado onde o preço é mais alto. Esse processo de compra e venda simultânea garante um lucro, sem exposição ao risco, desde que os custos de transação (como frete, impostos ou taxas) não superem o lucro obtido com a diferença de preço.

Os conceitos de eficiência de mercado e integração de mercado são complementares à Lei do Preço Único (LOOP). O primeiro conceito, eficiência de mercado, refere-se à capacidade dos mercados de minimizar os custos quando a oferta e a demanda são equilibradas. Partindo da premissa de um mercado competitivo com informações perfeitas, o processo de arbitragem contribui para refletir todos os custos de transação. O conceito de integração de mercado foca na possibilidade de negociar bens entre mercados que estão espacialmente distantes (MARTIGNONE, BEHRENDT, PAPARAS, 2022).

2.2 Teoria dos Preços

O preço, originado do latim *pretium* é o valor pecuniário estimado de uma coisa ou valor monetário que vale algo; o equivalente de uma coisa. É a expressão monetária do valor. Todos os produtos e serviços disponíveis no mercado possuem um preço, que é a quantia que o comprador deve pagar para efetivar a transação (ROSA, 2017).

Em economia, contabilidade, finanças e negócios, preço é o valor monetário expresso numericamente relacionado a um bem, serviço ou ativo. O conceito de preço é fundamental na microeconomia, onde se destaca como uma das variáveis mais relevantes na teoria da alocação de recursos, também conhecida como teoria dos preços (ROSA, 2017).

O preço, em termos conceituais, representa o valor de um produto ou serviço em unidades monetárias. Fatores como as matérias-primas, o tempo de produção, o investimento em tecnologia e a concorrência no mercado são alguns dos elementos que influenciam a determinação do preço (ROSA, 2017).

É fundamental considerar que o preço também abrange valores intangíveis, como a marca. Uma bolsa feita com materiais idênticos pode ter preços significativamente distintos dependendo da marca, que agrega a ela um valor simbólico inquestionável.

A teoria do valor-trabalho reconhece que, em todas as sociedades, o processo de produção pode ser reduzido a uma série de esforços humanos. Para modificar o ambiente natural de maneira eficiente, os seres humanos geralmente se empenham em esforços voltados para a sobrevivência (ROSA, 2017).

O ponto de partida da teoria de Adam Smith considera o trabalho como o primeiro preço, o dinheiro da compra inicial pago por todas as coisas. Dessa forma, a condição essencial para que qualquer mercadoria tenha valor é o trabalho humano investido em sua produção. Esse valor do produto se manifesta pela combinação de três componentes: o salário, os lucros e os aluguéis (ROSA, 2017).

Como os lucros e os aluguéis foram somados aos salários para a determinação dos preços, a teoria dos preços de Adam Smith também é

conhecida como teoria da soma. Uma mera soma dos três componentes básicos para o preço (ROSA, 2017).

A formação do preço da soja depende de diversos fatores, o principal deles é a oferta e demanda. A Teoria dos preços faz esse estudo de como os preços são formados em uma economia de mercado, buscando explicar o seu comportamento com base na oferta e demanda, levando em consideração os custos de produção, poder de mercado, concorrência, e a interação entre os compradores e vendedores.

Essa Teoria faz uma distinção entre o preço de mercado e o preço natural. O preço de mercado é o valor real da mercadoria, que é influenciado pelas forças de oferta e demanda. Já o preço natural é aquele que cobre os custos de produção e permite gerar lucro, representando o preço de equilíbrio, embora também seja determinado pelas dinâmicas do mercado.

Sendo assim, quanto maior a demanda pelo grão de soja (muitas indústrias comprando), maior será o seu preço. E quando maior a oferta do grão (baixa produção rural e/ou poucas indústrias comprando), menor será o seu preço.

Não é possível afirmar se um produto ou serviço está caro ou barato sem uma referência para comparação. O preço de um item ou serviço será avaliado em relação a algo semelhante, permitindo assim determinar se o valor é adequado em comparação com o produto alternativo. Em outras palavras, os preços são relativos às alternativas disponíveis. Por isso que, nesse trabalho, foi comparado os preços de três produtos: soja em grão, farelo e óleo, em três diferentes lugares.

O produtor rural tem inúmeros custos para produzir a soja, como por exemplo: insumos (sementes, fertilizantes e defensivos agrícolas); maquinários; mão de obra; armazenagem; transporte; custos sobre a terra (arrendamento e/ou impostos); custo financeiro; licenciamentos e regulações; entre inúmeros outros, além de depender também do clima para ter uma boa produção. Sendo assim, é muito importante conseguir fazer uma boa venda, para que possa cobrir todo o seu custo produtivo e ainda gerar lucro.

2.3 Preço e Valor

Quando se busca adquirir algo para satisfazer uma necessidade, realiza-se diversos tipos de esforços, incluindo o investimento de tempo e dinheiro. A soma dos esforços despendidos para obter o que se deseja representa o preço pago, enquanto a soma dos benefícios recebidos ao alcançar o que se busca reflete o valor (ROSA, 2017).

Dois bens podem ser comercializados pelo mesmo preço, mas ter valores distintos, e, também podem ter o mesmo valor e ser vendidos por preços diferentes.

Portanto, em termos relativos, quanto menores forem os esforços (energia, tempo, dinheiro etc.) e maiores forem os benefícios percebidos na satisfação das necessidades, maior será o valor atribuído a um determinado bem, produto ou serviço. Afinal, o que realmente importa, ao se tratar de valor, é o valor percebido por quem adquire o produto ou serviço (ROSA, 2017).

Sendo assim, valor de mercado é a estimativa geral do valor de um bem com base na média das percepções de um determinado segmento de mercado, enquanto o preço de mercado é o valor médio pelo qual se espera vender esse produto ou serviço nesse mesmo segmento (ROSA, 2017).

As empresas mais bem-sucedidas e os melhores vendedores sempre oferecem mais valor do que a concorrência; por isso, conseguem manter preços mais altos e margens de lucro maiores. Os profissionais de vendas mais qualificados focam na percepção de valor dos seus clientes, não se prendendo apenas ao preço.

3 MÉTODOS E DADOS

O método básico utilizado foi da análise temporal da causalidade de Granger entre os preços de diferentes mercados de soja em grão, farelo e óleo, a saber: Rio Verde (Goiás), Paranaguá e Chicago.

O Teste de Causalidade de Granger é amplamente empregado em várias áreas do conhecimento. Na economia, pode ser utilizado para analisar a interação entre variáveis como taxa de juros e inflação. No campo financeiro, analistas podem aplicar o teste para prever flutuações nos preços de ativos com base em indicadores econômicos, entre outros meios de aplicação.

Para analisar os preços da soja em grão, farelo e óleo, para o produtor no Estado de Goiás, em comparação com o Porto de Paranaguá e a Bolsa de Chicago, e quais desses preços ajudam a prever os demais, foi usado o modelo de Série Temporal com a Causalidade de Granger, como uma maneira de verificar se uma série temporal (X) ajuda a prever a outra série (Y), ou vice-versa (MAIA, 2019).

Esse teste foi desenvolvido por Clive Granger (1969), economista que recebeu o Prêmio Nobel de Economia em 2003 por seu trabalho em causalidade de séries temporais.

O teste de causalidade de Granger serve para verificar se uma série temporal é útil em termos de previsão de outra série temporal, ou seja, o termo causalidade deve ser pensado como precedência temporal. Ele não verifica a causalidade de forma rigorosa entre duas variáveis, ou seja, não se trata de uma análise de inferência causal, mas sim uma relação preditiva (ANÁLISE MACRO, 2022).

Testes de causalidade considera que há existência de causalidade de uma variável X para uma variável Y se, e somente se, valores passados de X ajudam na previsão de Y. O aspecto de causalidade entre preços agrícolas tem sido relacionado à questão de estrutura de mercado e intervenção governamental (MAFIOLETTI, 2001).

Em uma série temporal, os acontecimentos do passado, podem ter efeitos no presente. Mas os acontecimentos do presente, não podem causar efeitos no

passado. Se X causa Y, então os valores passados de X_{t-j} contribuem para determinar Y_t , independente da contribuição dos valores passados de Y_{t-j} (MAIA, 2019).

Quando uma variável X, 'causa-Granger' uma variável Y, em sua média, o evento Y é verificado toda vez que o evento X ocorreu, em algum período anterior. A quantidade de Y que pode ser explicada, é influenciada tanto pelos seus próprios valores passados quanto pelos valores atuais e passados de X $\rightarrow Y_t = f(Y_{t-p}, X_t, X_{t-p})$ (BUENO, 2018).

O teste é realizado através da comparação de modelos de regressão linear, onde um modelo inclui as variáveis passadas de X e o outro não. A diferença na precisão dos modelos permite inferir a causalidade.

- Modelo restrito $\rightarrow y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_m y_{t-m} + erro_t$
- Modelo irrestrito $\rightarrow y_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_m y_{t-m} + \beta_1 x_{t-1} + \dots + \beta_m x_{t-m} + erro_t$ (ANÁLISE MACRO, 2022).

Especificando, o Modelo Irrestrito inclui todas as variáveis e defasagens (lags) que podem ser relevantes para explicar a variável dependente, ou seja, inclui as defasagens de Y e X, explicando Y com suas próprias defasagens e com as defasagens de X; H_0 : X 'causa-Granger' Y. Já o Modelo Restrito, é uma versão mais simples, onde as variáveis explicativas são limitadas, ou seja, algumas das defasagens de uma ou ambas as variáveis são omitidas, inclui as defasagens de Y e exclui as de X, explicando Y apenas com suas próprias defasagens; H_0 : X não 'causa-Granger' Y.

Para aplicar o Teste de Causalidade de Granger, é preciso seguir certos procedimentos. Primeiramente, as séries temporais precisam ser estacionárias, ou seja, suas propriedades estatísticas devem permanecer constantes ao longo do tempo. Esta é uma limitação desse estudo, pois as séries utilizadas não são estacionárias. Depois, é necessário determinar o número de defasagens a serem incorporadas no modelo.

Nesse trabalho com o teste de causalidade de Granger foram utilizados 119 valores passados das oito variáveis explicativas $\rightarrow$ preço da soja em grão, farelo e óleo no Porto de Paranaguá e na Bolsa de Chicago, e o preço do farelo

e do óleo no Estado de Goiás; e 119 valores passados da variável explicada, que é o preço do grão para o produtor no Estado de Goiás.

3.1 Teste F

A Causalidade de Granger utiliza a estatística de teste F, que testa a significância conjunta de parâmetros. Para se testar a hipótese de que não existe causalidade de Granger, verifica-se a probabilidade associada à estatística F do teste de hipótese (BUENO, 2018).

Ou seja, o teste F é uma ferramenta estatística usada para determinar se uma série temporal pode ser útil para prever outra série temporal. Avaliando se uma variável Y pode ser prevista com base nos valores passados de X, comparando os dois modelos — o restrito e o irrestrito. A ideia é ver se adicionar as defasagens de X é possível explicar Y.

Nesse teste, há duas hipóteses: $H_0 \rightarrow$ Hipótese Nula: a variável X não ajuda a prever Y, não há relação de causalidade de Granger. E a $H_1 \rightarrow$ Hipótese Alternativa: os valores passados de X ajudam a prever Y, há causalidade de Granger, ou seja, a variável X 'causa-Granger' Y.

Hipótese Nula (H_0): É a afirmação inicial de que não há efeito, diferença ou relação entre as variáveis. Ela geralmente representa a ideia de "não mudança" ou "não associação". O teste de hipótese tem como objetivo verificar se existem evidências suficientes para rejeitar a hipótese nula.

Hipótese Alternativa (H_1 ou H_A): É a afirmação que representa o oposto da hipótese nula. Ela sugere que existe um efeito, uma diferença ou uma relação entre as variáveis. O objetivo do teste de hipótese é determinar se os dados são suficientemente fortes para apoiar a hipótese alternativa, rejeitando assim a hipótese nula.

Afirmar que uma relação entre preços possui causalidade de Granger, significa dizer que variações em um preço no passado ajudam a prever as variações em outro preço no futuro, de forma estatística. Em outras palavras, se a série temporal de um preço A "Granger causa" o preço B, isso significa que as informações passadas de A contêm informações úteis para prever B, além das

informações passadas de B. Não implica causalidade no sentido comum, mas sim uma relação temporal, ou seja, um padrão de precedência nos dados

Se a probabilidade for superior à 0,10, a Hipótese Nula (H_0) será aceita com um nível de significância de 10%, ou seja, não há causalidade de Granger entre as variáveis. Por outro lado, se a probabilidade for inferior a 0,10, a hipótese de não-causalidade (H_0) será rejeitada, ou seja, a existência de causalidade entre as variáveis é confirmada.

Nessa pesquisa foi utilizado o período de fevereiro de 2014 a dezembro de 2023, a maior disponibilidade encontrada para o estudo. Para a execução desse TCC, os dados dos preços da soja em grão farelo e óleo na Bolsa de Chicago e no Porto de Paranaguá, foram extraídos do site da ABIOVE, todos em dólar e por tonelada.

A Bolsa de Chicago – Estados Unidos – foi escolhida por ser uma referência mundial, contribuindo para a estabilidade econômica ao gerenciar risco de preço e prevenir flutuações bruscas. Desempenha um importante papel na comercialização da soja, sendo um dos principais mercados financeiros para a negociação de commodities agrícolas do mundo. A CBOT é a referência para preços internacionais de soja, pois têm alta concentração de ofertantes e demandantes dos países produtores e importadores de soja (MANEJEBEM, 2020).

Os produtores de soja, comerciantes, indústrias de processamento e outros envolvidos no setor dependem da Bolsa para assegurar estabilidade, liquidez e transparência nas transações de soja, o que é essencial para o funcionamento eficiente do mercado global dessa commodity.

Já o Porto de Paranaguá – Paraná, Brasil – foi escolhido por estar em primeiro lugar no Brasil em movimentação de cargas para a exportação de soja em farelo, óleo e grão no ano de 2024; de acordo com uma publicação do site Portos do Paraná. 37,5% da exportação brasileira de soja saiu pelo Porto de Paranaguá em janeiro deste ano, segundo o sistema para consultas de dados do comércio exterior brasileiro Comex Stat (PORTOS DO PARANÁ, 2024).

Os preços da soja, em grão (por saca), farelo e óleo (ambos por toneladas) para o produtor, no Estado de Goiás, foram obtidos com o Itaú

Unibanco, Mesa Clientes Agro, referentes à Praça de Rio Verde – GO. Sendo feita uma média mensal dos preços diários que foram disponibilizados.

A Praça econômica de Rio Verde – GO é uma das mais relevantes do Brasil, principalmente no setor agrícola e pecuário. Com grande destaque nos mercados de soja, milho, algodão e carne, e contando com uma infraestrutura logística de alto nível, a cidade se estabeleceu como um centro de crescimento econômico, atraindo investimentos e fortalecendo o agronegócio no país.

Rio Verde possui alta influência no comércio de commodities agrícolas, tanto no mercado nacional quanto internacional, impactando diretamente a dinâmica do agronegócio brasileiro. Além de a cidade ser um ponto chave na logística de exportação para os Portos de Paranaguá (PR) e Santos (SP), entre outros portos brasileiros, facilitando o transporte por meio de rodovias e ferrovias.

Os preços internacionais, que estavam em dólar, foram convertidos para o real por meio do histórico das variações do dólar durante os anos que estão disponibilizados no site do Banco Central do Brasil. E os preços do grão em Goiás, que estavam por sacas, foram convertidos para a mesma unidade de medida dos demais → toneladas, usando a relação de que um saca de soja equivale à 60 kg → 1 tonelada = 1.000kg.

Para realizar esse trabalho, os dados foram rodados em série temporal com causalidade de Granger para se obter os resultados, utilizando o programa RStudio com programação em R.

O R é um software gratuito que trata de uma linguagem de programação dinâmica, com foco na manipulação, análise e visualização de dados. E o RStudio é um ambiente de desenvolvimento integrado para o R, incluindo recursos que permitem aumentar a produtividade e é executado em todas as principais plataformas.

A Tabela 1 apresenta as siglas utilizadas para representar as diferentes séries:

Tabela 1 – Significado das siglas:

PRODUTOS:	pg = preço do grão	pf = preço do farelo	po = preço do óleo
MERCADOS:	chi = Bolsa de Chicago	prn = Porto de Paranaguá	go = Praça de Rio Verde GO

Assim, serão realizados os testes de Granger em todos os cruzamentos possíveis para as nove séries estudadas. A seguir, tem-se os resultados do trabalho.

4 RESULTADOS E DISCUSSÃO

Nesta seção, os resultados são apresentados e discutidos, inicialmente para os dados básicos utilizados e na segunda parte, verificando os resultados dos testes de Granger e interpretando as relações encontradas.

4.1 Série Temporal


Os resultados apresentados a seguir são referentes aos testes econométricos propostos no item 3. Dessa forma, foram realizados os testes do período todo, a partir de fevereiro de 2014 até dezembro de 2023, comparando-os entre si.

Ao rodar os dados no modelo de série temporal, foi observado que todos os preços ao longo dos 10 anos observados (2014-2023) tiveram uma tendência de aumento, mas não foi possível observar a presença de sazonalidade.

Como já se sabe, na época da safra (colheita) da soja, que no Brasil é entre os meses de janeiro e abril, e nos EUA entre setembro e novembro, o seu preço tende a abaixar, em resposta do aumento de sua oferta no mercado, mas como esse assunto em específico não é o foco desse trabalho, ele não será abordado.

No Gráfico 1, no aumento dos preços da soja e seus derivados durante o período observado, é possível notar um grande pico a partir do ano 2020. A diferença temporal do preço do grão da soja no Estado de Goiás, por exemplo, é enorme, em 2014 seu preço médio era por volta dos R\$937,00/t, já em 2023 passou para a casa dos R\$2.093,00/t, uma diferença de R\$1.156,00/t, quase dobrou o seu preço. Assim como o seu valor na Bolsa de Chicago, que em 2014 sua média estava por volta dos R\$1.062,00/t e em 2023 passou para R\$2.594,00/t, uma diferença de R\$1.532,00, em apenas 10 anos.

Gráfico 1 – Tendência dos preços de soja em grão, farelo e óleo na Bolsa de Chicago, no Porto de Paranaguá e na Praça de Rio Verde GO, na década de 2014 a 2023:



FONTE: Elaboração própria com dados da pesquisa, utilizando o RStudio

Tabela 2 – Estatística Descritiva das correlações entre os preços, contando com valor mínimo, média e valor máximo:

PREÇO	MÍNIMO	MÉDIA	MAXIMO
pg_chi	R\$ 863,90	R\$ 1.731,40	R\$ 3.265,60
pg_prn	R\$ 1.040,00	R\$ 1.865,00	R\$ 3.368,00
pg_go	R\$ 845,50	R\$ 1.548,00	R\$ 3.004,40
pf_chi	R\$ 891,20	R\$ 1.633,90	R\$ 2.798,20
pf_prn	R\$ 949,40	R\$ 1.639,90	R\$ 2.943,10
pf_go	R\$ 809,70	R\$ 1.495,80	R\$ 2.763,70
po_chi	R\$ 1.671,00	R\$ 3.902,00	R\$ 8.885,00
po_prn	R\$ 1.040,00	R\$ 1.865,00	R\$ 3.368,00
po_go	R\$ 2.029,00	R\$ 4.157,00	R\$ 9.275,00

Fonte: Dados da pesquisa.

Essa grande diferença do preço do grão da soja em apenas 10 anos, se deve por muitas crises econômicas que o Brasil e o Mundo enfrentaram, sendo a maior delas a Pandemia do COVID-19 (2019-2023), Crise Econômica Global (2018–2020), Crise da Ucrânia (2022–presente), Crise de Energia Global (2021–2023); como também para o Brasil a Alta da Inflação (2021-2022), Incertezas Econômicas e Política (2022-2023), entre outros.

Como consequência, o efeito da crise da Covid-19 (2019-2023) provocou impactos profundos na pobreza e na desigualdade mundial. Pela primeira vez em uma geração, a pobreza global aumentou, e as perdas desproporcionais de renda entre as populações mais vulneráveis resultaram em um crescimento acentuado da desigualdade, tanto entre os países quanto dentro deles.

A Crise Econômica Global de 2018-2020 foi um evento marcante que evidenciou vulnerabilidades sistêmicas nas economias globais, especialmente aquelas relacionadas ao comércio, desigualdade social e preparação para choques globais, como a pandemia de COVID-19. Provocou recessão global e queda do PIB, aumento da pobreza e desigualdade, incerteza econômica, disparidades regionais, entre outros.

Consequências da Crise da Ucrânia (2022–presente): volatilidade dos preços internacionais dos alimentos, a interrupção do fluxo pelo Mar Negro, junto com as sanções à Rússia, impulsionou os preços globais dos alimentos. Estima-se que mais 47 milhões de pessoas no mundo sofreram de fome aguda em 2022 devido aos efeitos de propagação da guerra. Além dos alimentos, outro segmento afetado pela guerra além das fronteiras ucranianas e russas foi o de energia (LIRA, 2024).

O sistema energético global enfrentou um período de grande instabilidade e incerteza desde o início da pandemia de coronavírus, nos primeiros meses de 2020. O processo teve início com uma redução abrupta na demanda global e nos preços internacionais, causadas pela interrupção súbita e generalizada das atividades econômicas e pelo aumento imediato do desemprego. A economia mundial regrediu no ano de 2020, e a indústria energética sofreu um baque de rapidez e proporções desconhecidas. Em 2021, o cenário havia se invertido radicalmente, mas a oferta de energia não conseguiu responder à retomada econômica, por conta das próprias dificuldades técnicas de uma reversão tão rápida (FIORI, 2022).

Alta da Inflação (2021-2022): o Índice Nacional de Preços ao Consumidor Amplo (IPCA), que mede a inflação oficial, fechou 2022 com uma taxa de 5,79% acumulada no ano. O índice ficou abaixo dos 10,06% acumulados em 2021, segundo dados do Instituto Brasileiro de Geografia e Estatística (IBGE). A

inflação acumulada de 2022 foi puxada principalmente pelos alimentos e bebidas, que tiveram alta de preços de 11,64% no ano, acima dos 7,94% de 2021. Também tiveram impacto importante os gastos com saúde e cuidados pessoais, que ficaram 11,43% mais caros. O grupo de despesas vestuário, por sua vez, teve a maior variação no mês: 18,02% (ABDALA, 2023).

As incertezas econômicas e políticas de 2022-2023 no Brasil afetaram de forma significativa a recuperação econômica do país, provocando inflação alta, desaceleração do crescimento, volatilidade nos mercados financeiros e desafios fiscais. Além disso, a instabilidade política gerou um ambiente de desconfiança tanto doméstica quanto internacional, afetando negativamente o investimento e o emprego.

4.2 Causalidade de Granger, Teste F

Foram feitos testes entre as séries de preços do mercado da soja e seus derivados, ou seja, grão com grão, grão com farelo, grão com óleo, e farelo com óleo no período citado anteriormente. E esses preços foram comparados no mercado nacional e no mercado internacional.

Com a Causalidade de Granger, se observa as variações passadas dos preços que ajudam a prever outros preços futuros, com base nas informações históricas. Na seguinte tabela podemos analisar as correlações de cada preço de cada local:

Tabela 3 – Resultados do Teste de Causalidade de Granger nos preços, 2014-2023:

TESTE F E SUAS SIGNIFICÂNCIAS			TESTE F = testa a significância conjunta dos parâmetros							
		Graos			Farelo			Oleo		
		Chicago	Paranaguá	Goias	Chicago	Paranaguá	Goias	Chicago	Paranaguá	Goias
Graos	Chicago		0,4264NS	1,1876NS	0,6195NS	0,7775NS	1,7803.	6,9645***	2,5432**	1,7036.
	Paranaguá	1,5361NS		1,8184.	1,5931NS	1,8742*	2,1434*	6,2546***	3,0781**	2,2357*
	Goias	2,8394**	1,995*		2,2354*	2,1189*	0,548NS	3,5428***	3,3474***	1,8705.
Farelo	Chicago	0,9983NS	0,614NS	1,5864NS		0,4821NS	1,8088.	3,9584***	2,7009**	1,9993*
	Paranaguá	1,2093NS	0,7785NS	1,7084.	1,3917NS		1,6527.	2,8494**	1,7951.	2,7176**
	Goias	1,992*	0,8828NS	0,7506NS	1,8735*	1,444NS		1,9859*	2,5501**	2,1037*
Oleo	Chicago	1,587NS	1,1148NS	1,0317NS	1,7496.	2,5619**	2,1625*		4,1894***	0,9959NS
	Paranaguá	1,3574NS	1,224NS	1,2396NS	2,2963*	2,017*	1,6661.	7,4588***		1,8749*
	Goias	3,0318**	1,999*	1,6799.	1,7359.	1,5978NS	2,6239**	6,5001***	2,6105**	

FONTE: Elaboração própria com dados da pesquisa, utilizando o RStudio. 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1.

Quanto mais ***, ou quanto menor o número, mais próximo de 0, mais determinado preço causa-Granger o outro, ou seja, mais ele ajudou prever as variações em outro preço.

Os resultados que foram significativas com probabilidade igual ou menor que 10% num total de 72, foram 46, ou seja, aproximadamente 64% dos preços foram significativos, 64% apresentaram causalidade de Granger. Observando as tabelas 4 a 7, é possível notar que a maior parte dos preços que se transmitem aos outros, são os preços do óleo e do farelo de soja, principalmente nos mercados da Bolsa de Chicago e do Porto de Paranaguá.

Tabela 4 – Relações dos preços que foram significativos a 0,1%, com probabilidade entre 0 e 0,001:

Causa	Efeito	Relação
pg_chi	po_chi	O preço do grão de Chicago causa o preço do óleo de Chicago.
pg_prn	po_chi	O preço do grão de Paranaguá causa o preço do óleo de Chicago.
pg_go	po_chi	O preço do grão de Goiás causa o preço do óleo de Chicago.
pg_go	po_prn	O preço de grão de Goiás causa o preço do óleo de Paranaguá
pf_chi	po_chi	O preço do farelo de Chicago causa o preço do óleo de Chicago
po_chi	po_prn	O preço do óleo de Chicago causa o preço do óleo de Paranaguá.
po_prn	po_chi	O preço do óleo de Paranaguá causa o preço do óleo de Chicago.
po_go	po_chi	O preço do óleo de Goiás causa o preço do óleo de Chicago.

FONTE: Elaboração própria com dados da pesquisa, utilizando o RStudio

Tabela 5 – Relações dos preços que foram significativos a 1%, com probabilidade entre 0,001 e 0,01:

Causa	Efeito	Relação
pg_chi	po_prn	O preço do grão de Chicago causou o preço do óleo de Paranaguá.
pg_prn	po_prn	O preço do grão de Paranaguá causou o preço do óleo de Paranaguá.
pg_go	pg_chi	O preço do grão de Goiás causou o preço do grão de Chicago.
pf_chi	po_prn	O preço do farelo de Chicago causou o preço do óleo de Paranaguá.
pf_prn	po_chi	O preço do farelo de Paranaguá causou o preço do óleo de Chicago.
pf_prn	po_go	O preço do farelo de Paranaguá causou o preço do óleo de Goiás.
pf_go	po_prn	O preço do farelo de Goiás causou o preço do óleo de Paranaguá.
po_chi	pf_prn	O preço do óleo de Chicago causou o preço do farelo de Paranaguá.
po_go	pg_chi	O preço do óleo de Goiás causou o preço do grão de Chicago.
po_go	pf_go	O preço do óleo de Goiás causou o preço do farelo de Goiás.
po_go	po_prn	O preço do óleo de Goiás causou o preço do óleo de Paranaguá.

FONTE: Elaboração própria com dados da pesquisa, utilizando o RStudio

Tabela 6 – Relações dos preços que foram significativos a 5%, com probabilidade entre 0,01 e 0,05:

Causa	Efeito	Relação
pg_prn	pf_prn	O preço do grão de Paranaguá causou o preço do farelo de Paranaguá.
pg_prn	pf_go	O preço do grão de Paranaguá causou o preço do farelo de Goiás.
pg_prn	po_go	O preço do grão de Paranaguá causou o preço do óleo de Goiás.
pg_go	pg_prn	O preço do grão de Goiás causou o preço do grão de Paranaguá.
pg_go	pf_chi	O preço do grão de Goiás causou o preço do farelo de Chicago.
pg_go	pf_prn	O preço do grão de Goiás causou o preço do farelo de Paranaguá.
pf_chi	po_go	O preço do farelo de Chicago causou o preço do óleo de Goiás.
pf_go	pg_chi	O preço do farelo de Goiás causou o preço do grão de Chicago.
pf_go	pf_chi	O preço do farelo de Goiás causou o preço do farelo de Chicago.
pf_go	po_chi	O preço do farelo de Goiás causou o preço do óleo de Chicago.
pf_go	po_go	O preço do farelo de Goiás causou o preço do óleo de Goiás.
po_chi	pf_go	O preço do óleo de Chicago causou o preço do farelo de Goiás.
po_prn	pf_chi	O preço do óleo de Paranaguá causou o preço do farelo de Chicago.
po_prn	pf_prn	O preço do óleo de Paranaguá causou o preço do farelo de Paranaguá.
po_prn	po_go	O preço do óleo de Paranaguá causou o preço do óleo de Goiás.
po_go	pg_prn	O preço do óleo de Goiás causou o preço do grão de Paranaguá.

FONTE: Elaboração própria com dados da pesquisa, utilizando o RStudio

Tabela 7 – Relações dos preços que foram significativos a 10%, com probabilidade entre 0,05 e 0,1:

Causa	Efeito	Descrição
pg_chi	pf_go	O preço do grão de Chicago causou o preço do farelo de Goiás.
pg_chi	po_go	O preço do grão de Chicago causou o preço do óleo de Goiás.
pg_prn	pg_go	O preço do grão de Paranaguá causou o preço do grão de Goiás.
pg_go	po_go	O preço do grão de Goiás causou o preço do óleo de Goiás.
pf_chi	pf_go	O preço do farelo de Chicago causou o preço do farelo de Goiás.
pf_prn	pg_go	O preço do farelo de Paranaguá causou o preço do grão de Goiás.
pf_prn	po_prn	O preço do farelo de Paranaguá causou o preço do óleo de Paranaguá.
po_chi	pf_chi	O preço do óleo de Chicago causou o preço do farelo de Chicago.
po_prn	pf_go	O preço do óleo de Paranaguá causou o preço do farelo de Goiás.
po_go	pg_go	O preço do óleo de Goiás causou o preço do grão de Goiás.
po_go	pf_chi	O preço do óleo de Goiás causou o preço do farelo de Chicago.

FONTE: Elaboração própria com dados da pesquisa, utilizando o RStudio


Tabela 8 – Relações dos preços que não foram considerados significativos, ou seja, os preços que não se transmitem para o outro, com probabilidade entre 0,1 e 1:

Causa	Efeito	Relação
pg_chi	pg_prn	O preço do grão de Chicago não causou o preço do grão de Paranaguá.
pg_chi	pg_go	O preço do grão de Chicago não causou o preço do grão de Goiás.
pg_chi	pf_chi	O preço do grão de Chicago não causou o preço do farelo de Chicago.
pg_chi	pf_prn	O preço do grão de Chicago não causou o preço do farelo de Paranaguá.
pg_prn	pg_chi	O preço do grão de Paranaguá não causou o preço do grão de Chicago.
pg_prn	pf_chi	O preço do grão de Paranaguá não causou o preço do farelo de Chicago.
pg_go	pf_go	O preço do grão de Goiás não causou o preço do farelo de Goiás.
pf_chi	pg_chi	O preço do farelo de Chicago não causou o preço do grão de Chicago.
pf_chi	pg_prn	O preço do farelo de Chicago não causou o preço do grão de Paranaguá.
pf_chi	pg_go	O preço do farelo de Chicago não causou o preço do grão de Goiás.
pf_chi	pf_prn	O preço do farelo de Chicago não causou o preço do farelo de Paranaguá.
pf_prn	pg_chi	O preço do farelo de Paranaguá não causou o preço do grão de Chicago.
pf_prn	pg_prn	O preço do farelo de Paranaguá não causou o preço do grão de Paranaguá.
pf_prn	pf_chi	O preço do farelo de Paranaguá não causou o preço do farelo de Chicago.
pf_prn	pf_go	O preço do farelo de Paranaguá não causou o preço do farelo de Goiás.
pf_go	pg_prn	O preço do farelo de Goiás não causou o preço do grão de Paranaguá.
pf_go	pg_go	O preço do farelo de Goiás não causou o preço do grão de Goiás.
pf_go	pf_prn	O preço do farelo de Goiás não causou o preço do farelo de Paranaguá.
po_chi	pg_chi	O preço do óleo de Chicago não causou o preço do grão de Chicago.
po_chi	pg_prn	O preço do óleo de Chicago não causou o preço do grão de Paranaguá.
po_chi	pg_go	O preço do óleo de Chicago não causou o preço do grão de Goiás.
po_chi	po_go	O preço do óleo de Chicago não causou o preço do óleo de Goiás.
po_prn	pg_chi	O preço do óleo de Paranaguá não causa o preço do grão de Chicago
po_prn	pg_prn	O preço do óleo de Paranaguá não causa o preço do grão de Paranaguá
po_prn	pg_go	O preço do óleo de Paranaguá não causa o preço do grão de Goiás
po_go	pf_prn	O preço do óleo de Goiás não causou o preço do farelo de Paranaguá.

FONTE: Elaboração própria com dados da pesquisa, utilizando o RStudio

Para se ter uma melhor noção das causalidades, a figura abaixo representa os fluxos das relações de preços que tiveram significância de 10% ou menos:

Figura 2 – Fluxos do resultado do Teste de Causalidade de Granger das relações de preços com 10% de significância ou menos:



FONTE: Elaboração própria, com dados da pesquisa

Nessa figura 2, é possível observar que muitas setas vêm e saem de Goiás, sendo assim, a soja e seus derivados nesse Estado são muito influenciadas pelos demais. As variações dos preços do grão em Goiás são previstas principalmente pelos preços do grão e do farelo do Porto de Paranaguá e pelo preço do óleo do Estado de Goiás, ou seja, quando ocorre uma mudança nesses preços se observa uma mudança também nos preços de Goiás. Essa transmissão não é perfeita porque o Brasil exporta somente a quarta parte dos grãos, indo o restante para a indústria (PINO e ROCHA, 2020).

Chegam mais setas no óleo de Goiás, e este interfere no grão de Goiás. Os preços desse Estado estão mais atrelados aos de Chicago do que de Paranaguá, o que é normal, pois a CBOT é o mercado global mais influente e a soja de Goiás é exportada.

5 CONSIDERAÇÕES FINAIS

Na indústria de óleo de soja, por ser um mercado oligopolista, as grandes processadoras de soja têm capacidade para controlar o preço tanto do óleo quanto do farelo e do grão. Essas empresas podem ajustar suas políticas de preços para maximizar seus lucros, o que acaba influenciando os preços desses produtos. Para os produtores de soja, isso pode resultar em uma pressão para aceitar valores mais baixos por sua produção, enquanto os consumidores podem enfrentar aumentos nos preços devido ao poder dessas empresas para estabelecer os valores no mercado. Sendo as principais balizadoras na formação de preço do mercado da soja, rebatem o preço para os outros níveis, ou seja, para o farelo e para o grão (FREITAS, BARBOSA, FRANCA, 2000)

Em resumo, o oligopólio tem um papel decisivo na formação dos preços e na dinâmica do mercado da soja. Se o preço do óleo de soja subir, é bem provável que o preço do grão também subirá.

Para produzir o óleo, existem diversos custos envolvidos, como por exemplo: matéria-prima; energia; mão-de-obra; produtos químicos; embalagens; máquinas e equipamentos; salários, entre inúmeras outras despesas. Tudo isso será considerado na formação do preço final do seu produto, além do lucro desejado.

O mercado de grãos de soja é amplamente dominado por algumas grandes processadoras, como a Bunge Brasil, Cargill Agrícola, Louis Dreyfus, entre outras; o que acaba colocando os produtores em uma posição de fragilidade. Eles dependem dessas grandes empresas para vender sua soja e, muitas vezes, essas corporações têm o poder de reduzir o preço pago aos produtores, devido à escassez de concorrência entre os compradores.

Com relação as localidades, o produtor rural do Estado de Goiás, onde há muitos produtores pequenos que são tomadores de preço, deve ficar atento tanto aos preços do Porto de Paranaguá quanto da Bolsa de Chicago, pois ambos dominam Goiás. São locais de extrema importância, pois desempenham papéis fundamentais na formação dos preços da soja no mercado global, e sua

relevância está diretamente ligada às dinâmicas de produção, exportação e especulação.

Tanto o Porto de Paranaguá quanto a Bolsa de Chicago têm uma grande influência nos preços da soja, mas de formas complementares. O Porto de Paranaguá impacta diretamente o preço no mercado brasileiro e as exportações, enquanto a Bolsa de Chicago serve como um termômetro global, refletindo as expectativas e negociações sobre a oferta e demanda da soja mundial, sendo o mercado mais influente nos preços desse produto. A interação desses dois fatores é essencial para a determinação do preço da soja, tanto no Brasil quanto no mercado global.

Como o objetivo desse trabalho é voltado ao preço do grão da soja para o produtor no Estado de Goiás, então, se pode concluir que é muito importante a ele, ficar atento aos preços da indústria de óleo de soja, e acompanhar as variações de preços dessa cultura, principalmente na Bolsa de Chicago, e no Porto de Paranaguá.

A Hipótese formada no início desse estudo sobre a grande influência da Bolsa de Chicago no mercado da soja, foi confirmada com os resultados obtidos por meio da análise estatística desse trabalho. E um conhecimento a mais foi adquirido sobre a importância da indústria do óleo da soja na determinação dos preços dessa cultura.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDALA, Vitor. Inflação oficial fecha 2022 em 5,79%. Agência Brasil, 2023. Disponível em: <https://agenciabrasil.ebc.com.br/economia/noticia/2023-01/inflacao-oficial-fecha-2022-em-579#:~:text=A%20infla%C3%A7%C3%A3o%20acumulada%20de%202022,11%2C43%25%20mais%20caros.>

ABIOVE. Estatísticas da cadeia da soja. *ABIOVE*, 2024. Disponível em: <https://abiove.org.br/estatisticas-cadeia-da-soja/>.

ANÁLISE MACRO. O ovo ou a galinha: teste de causalidade de Granger na granja. *Análise Macro*, 2022. Disponível em: <https://analysemacro.com.br/data-science/o-ovo-ou-a-galinha-teste-de-causalidade-de-granger-na-granja/#:~:text=O%20que%20o%20teste%20%C3%A9,o%20valor%20presente%20de%20Y.>

BANCO CENTRAL DO BRASIL. Histórico de cotações. *Banco Central do Brasil*, 2024. Disponível em: <https://www.bcb.gov.br/estabilidadefinanceira/historicocotacoes.>

BRASIL. Companhia Nacional de Abastecimento. *Boletim Logístico: Brasil torna-se maior fornecedor mundial de farelo de soja*. 2023. Disponível em: <https://www.conab.gov.br/ultimas-noticias/5131-boletim-logistico-brasil-torna-se-maior-fornecedor-mundial-de-farelo-de-soja.>

BUENO, Rodrigo De Losso da Silveira. *Econometria de séries temporais*. 2. São Paulo: Cengage Learning, 2018. 1 recurso online. ISBN 9788522128259. Disponível em: <https://www.cengage.com.br/livro/ebook-econometria-de-series-temporais/>.

COLLE, Célio et al. Relações de Troca e Causalidade de Granger entre os preços pagos e recebidos pela soja e milho, insumos e máquinas no Rio Grande do Sul entre 1986 e 2013. 7º Encontro de Economia Gaúcha, 2014, Brasil., 2014. Disponível em: <https://repositorio.pucrs.br/dspace/handle/10923/10460.>

FREITAS, Silene Maria de; BARBOSA, Marisa Zeferino; FRANCA, Terezinha J.F. Cadeia de Produção de Soja no Brasil: o caso do óleo. *Informações Econômicas*, SP, v.30, n.12, 2000. Disponível em:

<http://www.iea.sp.gov.br/ftp/iea/ie/2000/TEC3-DEZ-2000.pdf>

FRIORI, José Luis Fiori. A crise energética de 2021: origem, impacto e transformações. INEEP, 2022. Disponível em: <https://ineep.org.br/a-crise-energetica-de-2021-origem-impacto-e-transformacoes/>.

FUNDO PARANÁ AGROPECUÁRIA. Importância da soja para o Brasil. *Fundo Paraná Agropecuária*, 18 out. 2021. Disponível em: <https://fpagropecuaria.org.br/2021/10/18/importancia-da-soja-para-o-brasil/#:~:text=Al%C3%A9m%20de%20garantir%2C%20com%20folga,melhor%20%C3%8Dndice%20de%20Desenvolvimento%20Humano.>

GIEMBINSKY, Renata; HOLLAND, Márcio. Comportamento do Preço no Complexo Soja: uma Análise de Cointegração e de Causalidade, *Anais do XXXI Encontro Nacional de Economia*, ANPEC - Associação Nacional dos Centros de Pós-Graduação em Economia (2003). Disponível em: <https://EconPapers.repec.org/RePEc:anp:en2003:e55>.

JARRAIS, Nome do autor. Ciência de Dados R: Conhecendo ao máximo as ferramentas do R. *R Pubs*, 2023. Disponível em: <https://rpubs.com/jarraais/Ciencia-Dados-R-Conhecendoao>.

LIRA, Roberto de. Guerra na Ucrânia faz 2 anos com crises e mais fome no mundo; o que mudou em 6 pontos. *InfoMoney*, 2024. Disponível em: <https://www.infomoney.com.br/mundo/dois-anos-de-guerra-na-ucrania-o-que-mudou-no-mundo/>

MAFIOLETTI, Robson Leandro. Formação de preços na cadeia agroindustrial da soja na década de 90. *Revista de Economia e Sociologia Rural*, v. 39, n. 4, p. 9-26, 2019. Disponível em: <https://revistasober.org/article/5d94e2b30e8825107f23f1dd>.

MAIA, Alexandre Gori. Econometria: conceitos e aplicações. Saint Paul Editora, São Paulo, 2019. Disponível em:

<https://editora.saintpaul.com.br/livros/econometria-conceitos-e-aplicacoes>.

MANEJE BEM. Preço da soja. *Maneje Bem*, 2020. Disponível

em: [https://www.manejebem.com.br/publicacao/novidades/preco-da-soja#:~:text=Bolsa%20de%20Chicago%20\(CBOT\)%20%C3%A9,futuro%20\(para%20esta%20bolsa\)](https://www.manejebem.com.br/publicacao/novidades/preco-da-soja#:~:text=Bolsa%20de%20Chicago%20(CBOT)%20%C3%A9,futuro%20(para%20esta%20bolsa)).

MARGARIDO, Mario Antônio. Análise da transmissão espacial de preços no mercado internacional de soja. *Revista de Economia e Administração* (Impresso), v. 11, p. 281-330, 2012. Disponível em:

<https://eesp.fgv.br/sites/eesp.fgv.br/files/file/4c99f41637b90.pdf>

MARTIGNONE Gustavo Barbosa; BEHRENDT, Carlos; PAPARAS, Dimitrios. Análise de transmissão de preços do mercado internacional de soja em um contexto de guerra comercial. *Economias*. 2022. Disponível em:

<https://doi.org/10.3390/economies10080203>

PINO, Francisco Alberto; ROCHA, Marina Brasil. Transmissão de preços de soja no Brasil. *Revista de Economia e Sociologia Rural*, v. 32, n. 4, p. 345-361, 2020. Disponível em:

<https://revistasober.org/article/5e9347f90e88256828dafd0a>.

PORTOS DO PARANÁ. Porto de Paranaguá é primeiro lugar nacional em movimentação para exportação de soja. *Portos do Paraná*, 3 mar. 2024.

Disponível em: <https://www.portosdoparana.pr.gov.br/Noticia/Porto-de-Paranagua-e-primeiro-lugar-nacional-em-movimentacao-para-exportacao-de-soja#:~:text=Portos%20do%20Paran%C3%A1-,Porto%20de%20Paranagu%C3%A1%20%C3%A9%20primeiro%20lugar%20nacional%20em%20movimenta%C3%A7%C3%A3o%20para,03%2F2024%20%2D%2011%3A44>.

PUC-SP. Enciclopédia Jurídica. *Preço*. 1. ed. 2019. Disponível

em: <https://enciclopediajuridica.pucsp.br/verbete/283/edicao->

[1/preco#:~:text=A%20Teoria%20dos%20Pre%C3%A7os%20estabelece,da%20oferta%20e%20da%20procura.](#)

ROSA, Íris Vânia Santos. Preço. Enciclopédia jurídica da PUC-SP. Tomo Direito Tributário. 1. ed. São Paulo: Pontifícia Universidade Católica de São Paulo, 2017. Disponível em: <https://enciclopediajuridica.pucsp.br/verbete/283/edicao-1/preco>

TONIN, Julyerme Matheus; BARCZSZ, Silvio Silvestre. TRANSMISSÃO DE PREÇOS DA SOJA ENTRE OS MERCADOS EXTERNO E INTERNO: UMA ABORDAGEM PARA A REGIÃO DE MARINGÁ. 2008. Disponível em: <https://ideas.repec.org/p/ags/sbrfsr/118707.html>.

VERTICE MT. Os 3 principais produtores de grãos do mundo. *Vertice MT*, 24 abr. 2024. Disponível em: <https://verticemt.com.br/2024/04/24/os-3-principais-produtores-de-graos-do-mundo/#:~:text=1.,produzida%20no%20mundo%20sendo%20brasileira>.

WORLD BANK. *World Development Report 2022: The economic impacts of the COVID-19 crisis*. 2022. Disponível em: <https://www.worldbank.org/pt/publication/wdr2022/brief/chapter-1-introduction-the-economic-impacts-of-the-covid-19-crisis#:~:text=A%20crise%20gerou%20impactos%20dram%C3%A1ticos,os%20pa%C3%ADses%20e%20dentro%20deles>.

APÊNDICE

Resultados do RStudio, Estatística Descritiva:

```
> summary (pg_chi)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
863.9  1188.4  1300.9  1731.4  2536.8  3265.6
> summary (pg_prn)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 1040   1265   1484   1865   2674   3368
> summary (pg_go)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
845.5  1010.8  1169.2  1548.0  2135.9  3004.4
> summary (pf_chi)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
891.2  1156.8  1347.1  1633.9  2198.4  2798.2
> summary (pf_prn)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
949.4  1108.7  1328.5  1639.9  2254.6  2943.1
> summary (pf_go)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
809.7  1019.1  1178.2  1495.8  2108.0  2763.7
> summary (po_chi)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
1671   2324   2572   3902   5925   8885
> summary (pg_prn)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 1040   1265   1484   1865   2674   3368
> summary (po_go)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
2029   2656   2899   4157   6055   9275
```

Causalidade de Granger, Teste F das correlações entre os preços:

```
> # chicago grao com graos ----
> gpg_chi.pg_prn=grangertest(pg_chi,pg_prn,order = 12) # pg_chi não Granger cau
sa pg_prn
> gpg_chi.pg_prn # Pr(>F) = 0.8617 => maior que 0.10 aceita H0: grao de chicago
nao causou grao de paranagua
Granger causality test

Model 1: pg_prn ~ Lags(pg_prn, 1:12) + Lags(pg_chi, 1:12)
Model 2: pg_prn ~ Lags(pg_prn, 1:12)
  Res.Df Df    F Pr(>F)
1      82
2      94 -12 0.4264 0.9487
> gpg_chi.pg_go=grangertest(pg_chi,pg_go,order = 12) # pg_chi não Granger causa
pg_go
> gpg_chi.pg_go
Granger causality test

Model 1: pg_go ~ Lags(pg_go, 1:12) + Lags(pg_chi, 1:12)
Model 2: pg_go ~ Lags(pg_go, 1:12)
  Res.Df Df    F Pr(>F)
1      82
2      94 -12 1.1876 0.3059
> # chicago grao com farelos ----
> gpg_chi.pf_chi=grangertest(pg_chi,pf_chi,order = 12) # pg_chi não Granger cau
sa pf_chi
> gpg_chi.pf_chi
Granger causality test

Model 1: pf_chi ~ Lags(pf_chi, 1:12) + Lags(pg_chi, 1:12)
Model 2: pf_chi ~ Lags(pf_chi, 1:12)
  Res.Df Df    F Pr(>F)
1      82
2      94 -12 0.6195 0.8199
> gpg_chi.pf_prn=grangertest(pg_chi,pf_prn,order = 12) # pg_chi não Granger caus
a pf_prn
> gpg_chi.pf_prn
Granger causality test

Model 1: pf_prn ~ Lags(pf_prn, 1:12) + Lags(pg_chi, 1:12)
Model 2: pf_prn ~ Lags(pf_prn, 1:12)
```

```

      Res.Df Df      F Pr(>F)
1         82
2         94 -12 0.7775 0.6716
pf_go > gpg_chi.pf_go=grangertest(pg_chi,pf_go,order = 12) # pg_chi não Granger causa
> gpg_chi.pf_go
Granger causality test

Model 1: pf_go ~ Lags(pf_go, 1:12) + Lags(pg_chi, 1:12)
Model 2: pf_go ~ Lags(pf_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 1.7803 0.06512 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # chicago grao com oleos ----
sa po_chi > gpg_chi.po_chi=grangertest(pg_chi,po_chi,order = 12) # pg_chi não Granger cau
> gpg_chi.po_chi
Granger causality test

Model 1: po_chi ~ Lags(po_chi, 1:12) + Lags(pg_chi, 1:12)
Model 2: po_chi ~ Lags(po_chi, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 6.9645 1.558e-08 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
a po_prn > gpg_chi.po_prn=grangertest(pg_chi,po_prn,order = 12) # pg_chi não Granger caus
> gpg_chi.po_prn
Granger causality test

Model 1: po_prn ~ Lags(po_prn, 1:12) + Lags(pg_chi, 1:12)
Model 2: po_prn ~ Lags(po_prn, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 2.5432 0.006622 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
po_go > gpg_chi.po_go=grangertest(pg_chi,po_go,order = 12) # pg_chi não Granger causa
> gpg_chi.po_go
Granger causality test

Model 1: po_go ~ Lags(po_go, 1:12) + Lags(pg_chi, 1:12)
Model 2: po_go ~ Lags(po_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 1.7036 0.08087 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
sa pg_chi > # paranagua grao com graos ----
> gpg_prn.pg_chi=grangertest(pg_prn,pg_chi,order = 12) # pg_prn não Granger cau
sou grao de chicago > gpg_prn.pg_chi # Pr(>F)=> maior que 0.10 aceita H0: grao de paranagua nao cau
Granger causality test

Model 1: pg_chi ~ Lags(pg_chi, 1:12) + Lags(pg_prn, 1:12)
Model 2: pg_chi ~ Lags(pg_chi, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 1.5361 0.1281
pg_go > gpg_prn.pg_go=grangertest(pg_prn,pg_go,order = 12) # pg_prn não Granger causa
> gpg_prn.pg_go
Granger causality test

Model 1: pg_go ~ Lags(pg_go, 1:12) + Lags(pg_prn, 1:12)
Model 2: pg_go ~ Lags(pg_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 1.8184 0.05839 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
sa pf_chi > # paranagua grao com farelos ----
> gpg_prn.pf_chi=grangertest(pg_prn,pf_chi,order = 12) # pg_prn não Granger cau
> gpg_prn.pf_chi
Granger causality test

Model 1: pf_chi ~ Lags(pf_chi, 1:12) + Lags(pg_prn, 1:12)
Model 2: pf_chi ~ Lags(pf_chi, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 1.5931 0.1098

```

```

a pf_prn > gpg_prn.pf_prn=grangertest(pg_prn,pf_prn,order = 12) # pg_prn não Granger caus
a pf_prn > gpg_prn.pf_prn
Granger causality test

Model 1: pf_prn ~ Lags(pf_prn, 1:12) + Lags(pg_prn, 1:12)
Model 2: pf_prn ~ Lags(pf_prn, 1:12)
      Res.Df Df       F       Pr(>F)
1         82
2         94 -12  1.8742  0.04971 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
pf_go > gpg_prn.pf_go=grangertest(pg_prn,pf_go,order = 12) # pg_prn não Granger causa
pf_go > gpg_prn.pf_go
Granger causality test

Model 1: pf_go ~ Lags(pf_go, 1:12) + Lags(pg_prn, 1:12)
Model 2: pf_go ~ Lags(pf_go, 1:12)
      Res.Df Df       F       Pr(>F)
1         82
2         94 -12  2.1434  0.02243 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
# paranagua grao com oleos ----
po_chi > gpg_prn.po_chi=grangertest(pg_prn,po_chi,order = 12) # pg_prn não Granger causa
po_chi > gpg_prn.po_chi
Granger causality test

Model 1: po_chi ~ Lags(po_chi, 1:12) + Lags(pg_prn, 1:12)
Model 2: po_chi ~ Lags(po_chi, 1:12)
      Res.Df Df       F       Pr(>F)
1         82
2         94 -12  6.2546  1.048e-07 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
po_prn > gpg_prn.po_prn=grangertest(pg_prn,po_prn,order = 12) # pg_prn não Granger causa
po_prn > gpg_prn.po_prn
Granger causality test

Model 1: po_prn ~ Lags(po_prn, 1:12) + Lags(pg_prn, 1:12)
Model 2: po_prn ~ Lags(po_prn, 1:12)
      Res.Df Df       F       Pr(>F)
1         82
2         94 -12  3.0781  0.001257 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
o_go > gpg_prn.po_go=grangertest(pg_prn,po_go,order = 12) # pg_prn não Granger causa p
o_go > gpg_prn.po_go
Granger causality test

Model 1: po_go ~ Lags(po_go, 1:12) + Lags(pg_prn, 1:12)
Model 2: po_go ~ Lags(po_go, 1:12)
      Res.Df Df       F       Pr(>F)
1         82
2         94 -12  2.2357  0.01698 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
# goias grao com graos ----
pg_chi > gpg_go.pg_chi=grangertest(pg_go,pg_chi,order = 12) # pg_go não Granger causa
pg_chi > gpg_go.pg_chi # Pr(>F)=> maior que 0.10 aceita H0: grao de goias nao causou g
rao de chicago
rao de chicago > gpg_go.pg_chi
Granger causality test

Model 1: pg_chi ~ Lags(pg_chi, 1:12) + Lags(pg_go, 1:12)
Model 2: pg_chi ~ Lags(pg_chi, 1:12)
      Res.Df Df       F       Pr(>F)
1         82
2         94 -12  2.8394  0.002643 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
pg_prn > gpg_go.pg_prn=grangertest(pg_go,pg_prn,order = 12) # pg_go não Granger causa
pg_prn > gpg_go.pg_prn
Granger causality test

Model 1: pg_prn ~ Lags(pg_prn, 1:12) + Lags(pg_go, 1:12)
Model 2: pg_prn ~ Lags(pg_prn, 1:12)
      Res.Df Df       F       Pr(>F)
1         82
2         94 -12  1.995  0.03491 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

```

> # goias grao com farelos ----
pf_chi > gpg_go.pf_chi=grangertest(pg_go,pf_chi,order = 12) # pg_go não Granger causa
> gpg_go.pf_chi
Granger causality test

Model 1: pf_chi ~ Lags(pf_chi, 1:12) + Lags(pg_go, 1:12)
Model 2: pf_chi ~ Lags(pf_chi, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 2.2354 0.01699 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
f_prn > gpg_go.pf_prn=grangertest(pg_go,pf_prn,order = 12) # pg_go não Granger causa p
> gpg_go.pf_prn
Granger causality test

Model 1: pf_prn ~ Lags(pf_prn, 1:12) + Lags(pg_go, 1:12)
Model 2: pf_prn ~ Lags(pf_prn, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 2.1189 0.02414 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
go > gpg_go.pf_go=grangertest(pg_go,pf_go,order = 12) # pg_go não Granger causa pf_
> gpg_go.pf_go
Granger causality test

Model 1: pf_go ~ Lags(pf_go, 1:12) + Lags(pg_go, 1:12)
Model 2: pf_go ~ Lags(pf_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 0.548 0.8765
> # goias grao com oleos ----
_chi > gpg_go.po_chi=grangertest(pg_go,po_chi,order = 12) # pg_go não Granger causa po
> gpg_go.po_chi
Granger causality test

Model 1: po_chi ~ Lags(po_chi, 1:12) + Lags(pg_go, 1:12)
Model 2: po_chi ~ Lags(po_chi, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 3.5428 0.0002966 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
_prn > gpg_go.po_prn=grangertest(pg_go,po_prn,order = 12) # pg_go não Granger causa po
> gpg_go.po_prn
Granger causality test

Model 1: po_prn ~ Lags(po_prn, 1:12) + Lags(pg_go, 1:12)
Model 2: po_prn ~ Lags(po_prn, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 3.3474 0.0005436 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
o > gpg_go.po_go=grangertest(pg_go,po_go,order = 12) # pg_go não Granger causa po_g
> gpg_go.po_go
Granger causality test

Model 1: po_go ~ Lags(po_go, 1:12) + Lags(pg_go, 1:12)
Model 2: po_go ~ Lags(po_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 1.8705 0.05024 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
sa pg_chi > # chicago farelo com graos ----
> gpf_chi.pg_chi=grangertest(pf_chi,pg_chi,order = 12) # pf_chi não Granger cau
> gpf_chi.pg_chi
Granger causality test

Model 1: pg_chi ~ Lags(pg_chi, 1:12) + Lags(pf_chi, 1:12)
Model 2: pg_chi ~ Lags(pg_chi, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 0.9983 0.4581
> gpf_chi.pg_prn=grangertest(pf_chi,pg_prn,order = 12) # pf_chi não Granger caus
a pg_prn > gpf_chi.pg_prn
Granger causality test

```

```

Model 1: pg_prn ~ Lags(pg_prn, 1:12) + Lags(pf_chi, 1:12)
Model 2: pg_prn ~ Lags(pg_prn, 1:12)
  Res.Df Df    F Pr(>F)
1      82
2      94 -12 0.614 0.8246
pg_go > gpf_chi.pg_go=grangertest(pf_chi,pg_go,order = 12) # pf_chi não Granger causa
> gpf_chi.pg_go
Granger causality test

Model 1: pg_go ~ Lags(pg_go, 1:12) + Lags(pf_chi, 1:12)
Model 2: pg_go ~ Lags(pg_go, 1:12)
  Res.Df Df    F Pr(>F)
1      82
2      94 -12 1.5864 0.1118
> # chicago farelo com farelos ----
> gpf_chi.pf_prn=grangertest(pf_chi,pf_prn,order = 12) # pf_chi não Granger caus
a pf_prn
> gpf_chi.pf_prn # Pr(>F)=> maior que 0.10 aceita H0: farelo de chicago nao cau
sou farelo de paranagua
Granger causality test

Model 1: pf_prn ~ Lags(pf_prn, 1:12) + Lags(pf_chi, 1:12)
Model 2: pf_prn ~ Lags(pf_prn, 1:12)
  Res.Df Df    F Pr(>F)
1      82
2      94 -12 0.4821 0.9198
pf_go > gpf_chi.pf_go=grangertest(pf_chi,pf_go,order = 12) # pf_chi não Granger causa
> gpf_chi.pf_go
Granger causality test

Model 1: pf_go ~ Lags(pf_go, 1:12) + Lags(pf_chi, 1:12)
Model 2: pf_go ~ Lags(pf_go, 1:12)
  Res.Df Df    F Pr(>F)
1      82
2      94 -12 1.8088 0.06002 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # chicago farelo com oleos ----
> gpf_chi.po_chi=grangertest(pf_chi,po_chi,order = 12) # pf_chi não Granger causa
po_chi > gpf_chi.po_chi
Granger causality test

Model 1: po_chi ~ Lags(po_chi, 1:12) + Lags(pf_chi, 1:12)
Model 2: po_chi ~ Lags(po_chi, 1:12)
  Res.Df Df    F Pr(>F)
1      82
2      94 -12 3.9584 8.255e-05 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpf_chi.po_prn=grangertest(pf_chi,po_prn,order = 12) # pf_chi não Granger causa
po_prn > gpf_chi.po_prn
Granger causality test

Model 1: po_prn ~ Lags(po_prn, 1:12) + Lags(pf_chi, 1:12)
Model 2: po_prn ~ Lags(po_prn, 1:12)
  Res.Df Df    F Pr(>F)
1      82
2      94 -12 2.7009 0.004064 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpf_chi.po_go=grangertest(pf_chi,po_go,order = 12) # pf_chi não Granger causa p
o_go > gpf_chi.po_go
Granger causality test

Model 1: po_go ~ Lags(po_go, 1:12) + Lags(pf_chi, 1:12)
Model 2: po_go ~ Lags(po_go, 1:12)
  Res.Df Df    F Pr(>F)
1      82
2      94 -12 1.9993 0.03447 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # paranagua farelo com graos ----
> gpf_prn.pg_chi=grangertest(pf_prn,pg_chi,order = 12) # pf_prn não Granger cau
sa pg_chi
> gpf_prn.pg_chi
Granger causality test

Model 1: pg_chi ~ Lags(pg_chi, 1:12) + Lags(pf_prn, 1:12)
Model 2: pg_chi ~ Lags(pg_chi, 1:12)
  Res.Df Df    F Pr(>F)
1      82

```

```

2      94 -12 1.2093 0.291
> gpf_prn.pg_prn=grangertest(pf_prn,pg_prn,order = 12) # pf_prn não Granger caus
a pg_prn
> gpf_prn.pg_prn
Granger causality test

Model 1: pg_prn ~ Lags(pg_prn, 1:12) + Lags(pf_prn, 1:12)
Model 2: pg_prn ~ Lags(pg_prn, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 0.7785 0.6707
> gpf_prn.pg_go=grangertest(pf_prn,pg_go,order = 12) # pf_prn não Granger causa
pg_go
> gpf_prn.pg_go
Granger causality test

Model 1: pg_go ~ Lags(pg_go, 1:12) + Lags(pf_prn, 1:12)
Model 2: pg_go ~ Lags(pg_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 1.7084 0.07979 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # paranagua farelo com farelos ----
> gpf_prn.pf_chi=grangertest(pf_prn,pf_chi,order = 12) # pf_prn não Granger cau
sa pf_chi
> gpf_prn.pf_chi # Pr(>F)=> maior que 0.10 aceita H0: farelo de paranagua nao
causou farelo de chicago
Granger causality test

Model 1: pf_chi ~ Lags(pf_chi, 1:12) + Lags(pf_prn, 1:12)
Model 2: pf_chi ~ Lags(pf_chi, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 1.3917 0.1867
> gpf_prn.pf_go=grangertest(pf_prn,pf_go,order = 12) # pf_prn não Granger causa
pf_go
> gpf_prn.pf_go
Granger causality test

Model 1: pf_go ~ Lags(pf_go, 1:12) + Lags(pf_prn, 1:12)
Model 2: pf_go ~ Lags(pf_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 1.6527 0.09318 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # paranagua farelo com oleos ----
> gpf_prn.po_chi=grangertest(pf_prn,po_chi,order = 12) # pf_prn não Granger causa
po_chi
> gpf_prn.po_chi
Granger causality test

Model 1: po_chi ~ Lags(po_chi, 1:12) + Lags(pf_prn, 1:12)
Model 2: po_chi ~ Lags(po_chi, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 2.8494 0.002562 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpf_prn.po_prn=grangertest(pf_prn,po_prn,order = 12) # pf_prn não Granger causa
po_prn
> gpf_prn.po_prn
Granger causality test

Model 1: po_prn ~ Lags(po_prn, 1:12) + Lags(pf_prn, 1:12)
Model 2: po_prn ~ Lags(po_prn, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 1.7951 0.06243 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpf_prn.po_go=grangertest(pf_prn,po_go,order = 12) # pf_prn não Granger causa p
o_go
> gpf_prn.po_go
Granger causality test

Model 1: po_go ~ Lags(po_go, 1:12) + Lags(pf_prn, 1:12)
Model 2: po_go ~ Lags(po_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12 2.7176 0.003859 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # goias farelo com graos ----
> gpf_go.pg_chi=grangertest(pf_go,pg_chi,order = 12) # pf_go não Granger causa
pg_chi

```

```

> gpf_go.pg_chi
Granger causality test

Model 1: pg_chi ~ Lags(pg_chi, 1:12) + Lags(pf_go, 1:12)
Model 2: pg_chi ~ Lags(pg_chi, 1:12)
  Res.Df  Df      F Pr(>F)
1      82
2      94 -12  1.992 0.03522 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpf_go.pg_prn=grangertest(pf_go,pg_prn,order = 12) # pf_go não Granger causa p
g_prn
> gpf_go.pg_prn
Granger causality test

Model 1: pg_prn ~ Lags(pg_prn, 1:12) + Lags(pf_go, 1:12)
Model 2: pg_prn ~ Lags(pg_prn, 1:12)
  Res.Df  Df      F Pr(>F)
1      82
2      94 -12  0.8828 0.5673
> gpf_go.pg_go=grangertest(pf_go,pg_go,order = 12) # pf_go não Granger causa pg_
go
> gpf_go.pg_go
Granger causality test

Model 1: pg_go ~ Lags(pg_go, 1:12) + Lags(pf_go, 1:12)
Model 2: pg_go ~ Lags(pg_go, 1:12)
  Res.Df  Df      F Pr(>F)
1      82
2      94 -12  0.7506 0.6982
> # goias farelo com farelos ----
> gpf_go.pf_chi=grangertest(pf_go,pf_chi,order = 12) # pf_go não Granger causa
pf_chi
> gpf_go.pf_chi # Pr(>F)=> maior que 0.10 aceita H0: farelo de goias nao causo
u farelo de chicago
Granger causality test

Model 1: pf_chi ~ Lags(pf_chi, 1:12) + Lags(pf_go, 1:12)
Model 2: pf_chi ~ Lags(pf_chi, 1:12)
  Res.Df  Df      F Pr(>F)
1      82
2      94 -12  1.8735 0.04981 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpf_go.pf_prn=grangertest(pf_go,pf_prn,order = 12) # pf_go não Granger causa p
f_prn
> gpf_go.pf_prn
Granger causality test

Model 1: pf_prn ~ Lags(pf_prn, 1:12) + Lags(pf_go, 1:12)
Model 2: pf_prn ~ Lags(pf_prn, 1:12)
  Res.Df  Df      F Pr(>F)
1      82
2      94 -12  1.444 0.1632
> # goias farelo com oleos ----
> gpf_go.po_chi=grangertest(pf_go,po_chi,order = 12) # pf_go não Granger causa po
_chi
> gpf_go.po_chi
Granger causality test

Model 1: po_chi ~ Lags(po_chi, 1:12) + Lags(pf_go, 1:12)
Model 2: po_chi ~ Lags(po_chi, 1:12)
  Res.Df  Df      F Pr(>F)
1      82
2      94 -12  1.9859 0.03585 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpf_go.po_prn=grangertest(pf_go,po_prn,order = 12) # pf_go não Granger causa po
_prn
> gpf_go.po_prn
Granger causality test

Model 1: po_prn ~ Lags(po_prn, 1:12) + Lags(pf_go, 1:12)
Model 2: po_prn ~ Lags(po_prn, 1:12)
  Res.Df  Df      F Pr(>F)
1      82
2      94 -12  2.5501 0.006482 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpf_go.po_go=grangertest(pf_go,po_go,order = 12) # pf_go não Granger causa po_
o
> gpf_go.po_go
Granger causality test

Model 1: po_go ~ Lags(po_go, 1:12) + Lags(pf_go, 1:12)
Model 2: po_go ~ Lags(po_go, 1:12)
  Res.Df  Df      F Pr(>F)

```

```

1      82
2      94 -12 2.1037 0.02527 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # chicago oleo com graos ----
> gpo_chi.pg_chi=grangertest(po_chi,pg_chi,order = 12) # po_chi não Granger cau
sa pg_chi
> gpo_chi.pg_chi
Granger causality test

Model 1: pg_chi ~ Lags(pg_chi, 1:12) + Lags(po_chi, 1:12)
Model 2: pg_chi ~ Lags(pg_chi, 1:12)
Res.Df Df      F Pr(>F)
1      82
2      94 -12 1.587 0.1116
> gpo_chi.pg_prn=grangertest(po_chi,pg_prn,order = 12) # po_chi não Granger caus
a pg_prn
> gpo_chi.pg_prn
Granger causality test

Model 1: pg_prn ~ Lags(pg_prn, 1:12) + Lags(po_chi, 1:12)
Model 2: pg_prn ~ Lags(pg_prn, 1:12)
Res.Df Df      F Pr(>F)
1      82
2      94 -12 1.1148 0.3598
> gpo_chi.pg_go=grangertest(po_chi,pg_go,order = 12) # po_chi não Granger causa
pg_go
> gpo_chi.pg_go
Granger causality test

Model 1: pg_go ~ Lags(pg_go, 1:12) + Lags(po_chi, 1:12)
Model 2: pg_go ~ Lags(pg_go, 1:12)
Res.Df Df      F Pr(>F)
1      82
2      94 -12 1.0317 0.4285
> # chicago oleo com farelos ----
> gpo_chi.pf_chi=grangertest(po_chi,pf_chi,order = 12) # po_chi não Granger cau
sa pf_chi
> gpo_chi.pf_chi
Granger causality test

Model 1: pf_chi ~ Lags(pf_chi, 1:12) + Lags(po_chi, 1:12)
Model 2: pf_chi ~ Lags(pf_chi, 1:12)
Res.Df Df      F Pr(>F)
1      82
2      94 -12 1.7496 0.07105 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpo_chi.pf_prn=grangertest(po_chi,pf_prn,order = 12) # po_chi não Granger caus
a pf_prn
> gpo_chi.pf_prn
Granger causality test

Model 1: pf_prn ~ Lags(pf_prn, 1:12) + Lags(po_chi, 1:12)
Model 2: pf_prn ~ Lags(pf_prn, 1:12)
Res.Df Df      F Pr(>F)
1      82
2      94 -12 2.5619 0.006251 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpo_chi.pf_go=grangertest(po_chi,pf_go,order = 12) # po_chi não Granger causa
pf_go
> gpo_chi.pf_go
Granger causality test

Model 1: pf_go ~ Lags(pf_go, 1:12) + Lags(po_chi, 1:12)
Model 2: pf_go ~ Lags(pf_go, 1:12)
Res.Df Df      F Pr(>F)
1      82
2      94 -12 2.1625 0.02118 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # chicago oleo com oleos ----
> gpo_chi.po_prn=grangertest(po_chi,po_prn,order = 12) # po_chi não Granger caus
a po_prn
> gpo_chi.po_prn # Pr(>F)=> maior que 0.10 aceita H0: oleo de chicago nao cau
sou oleo de paranagua
Granger causality test

Model 1: po_prn ~ Lags(po_prn, 1:12) + Lags(po_chi, 1:12)
Model 2: po_prn ~ Lags(po_prn, 1:12)
Res.Df Df      F Pr(>F)
1      82
2      94 -12 4.1894 4.085e-05 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

```

po_go > gpo_chi.po_go=grangertest(po_chi,po_go,order = 12) # po_chi não Granger causa
po_go > gpo_chi.po_go
Granger causality test

Model 1: po_go ~ Lags(po_go, 1:12) + Lags(po_chi, 1:12)
Model 2: po_go ~ Lags(po_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12  0.9959 0.4602
> # paranagua oleo com graos ----
sa pg_chi > gpo_prn.pg_chi=grangertest(po_prn,pg_chi,order = 12) # po_prn não Granger cau
sa pg_chi > gpo_prn.pg_chi
Granger causality test

Model 1: pg_chi ~ Lags(pg_chi, 1:12) + Lags(po_prn, 1:12)
Model 2: pg_chi ~ Lags(pg_chi, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12  1.3574 0.2035
> gpo_prn.pg_prn=grangertest(po_prn,pg_prn,order = 12) # po_prn não Granger caus
a pg_prn > gpo_prn.pg_prn
Granger causality test

Model 1: pg_prn ~ Lags(pg_prn, 1:12) + Lags(po_prn, 1:12)
Model 2: pg_prn ~ Lags(pg_prn, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12  1.224 0.2812
pg_go > gpo_prn.pg_go=grangertest(po_prn,pg_go,order = 12) # po_prn não Granger causa
pg_go > gpo_prn.pg_go
Granger causality test

Model 1: pg_go ~ Lags(pg_go, 1:12) + Lags(po_prn, 1:12)
Model 2: pg_go ~ Lags(pg_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12  1.2396 0.2711
> # paranagua oleo com farelos ----
sa pf_chi > gpo_prn.pf_chi=grangertest(po_prn,pf_chi,order = 12) # po_prn não Granger cau
sa pf_chi > gpo_prn.pf_chi
Granger causality test

Model 1: pf_chi ~ Lags(pf_chi, 1:12) + Lags(po_prn, 1:12)
Model 2: pf_chi ~ Lags(pf_chi, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12  2.2963 0.01412 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
a pf_prn > gpo_prn.pf_prn=grangertest(po_prn,pf_prn,order = 12) # po_prn não Granger caus
a pf_prn > gpo_prn.pf_prn
Granger causality test

Model 1: pf_prn ~ Lags(pf_prn, 1:12) + Lags(po_prn, 1:12)
Model 2: pf_prn ~ Lags(pf_prn, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12  2.017 0.03271 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
pf_go > gpo_prn.pf_go=grangertest(po_prn,pf_go,order = 12) # po_prn não Granger causa
pf_go > gpo_prn.pf_go
Granger causality test

Model 1: pf_go ~ Lags(pf_go, 1:12) + Lags(po_prn, 1:12)
Model 2: pf_go ~ Lags(pf_go, 1:12)
      Res.Df Df      F Pr(>F)
1         82
2         94 -12  1.6661 0.08979 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # paranagua oleo com oleos ----
po_chi > gpo_prn.po_chi=grangertest(po_prn,po_chi,order = 12) # po_prn não Granger causa
po_chi > gpo_prn.po_chi # Pr(>F)=> maior que 0.10 aceita H0: oleo de paranagua nao c
ausou oleo de chicago
Granger causality test

Model 1: po_chi ~ Lags(po_chi, 1:12) + Lags(po_prn, 1:12)
Model 2: po_chi ~ Lags(po_chi, 1:12)

```

```

      Res.Df Df      F      Pr(>F)
1         82
2         94 -12 7.4588 4.311e-09 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpo_prn.po_go=grangertest(po_prn,po_go,order = 12) # po_prn não Granger causa p
o_go
> gpo_prn.po_go
Granger causality test

Model 1: po_go ~ Lags(po_go, 1:12) + Lags(po_prn, 1:12)
Model 2: po_go ~ Lags(po_go, 1:12)
      Res.Df Df      F      Pr(>F)
1         82
2         94 -12 1.8749 0.04961 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # goias oleo.com graos ----
pg_chi > gpo_go.pg_chi=grangertest(po_go,pg_chi,order = 12) # po_go não Granger causa
pg_chi
> gpo_go.pg_chi
Granger causality test

Model 1: pg_chi ~ Lags(pg_chi, 1:12) + Lags(po_go, 1:12)
Model 2: pg_chi ~ Lags(pg_chi, 1:12)
      Res.Df Df      F      Pr(>F)
1         82
2         94 -12 3.0318 0.001452 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpo_go.pg_prn=grangertest(po_go,pg_prn,order = 12) # po_go não Granger causa p
g_prn
> gpo_go.pg_prn
Granger causality test

Model 1: pg_prn ~ Lags(pg_prn, 1:12) + Lags(po_go, 1:12)
Model 2: pg_prn ~ Lags(pg_prn, 1:12)
      Res.Df Df      F      Pr(>F)
1         82
2         94 -12 1.999 0.0345 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpo_go.pg_go=grangertest(po_go,pg_go,order = 12) # po_go não Granger causa pg_
go
> gpo_go.pg_go
Granger causality test

Model 1: pg_go ~ Lags(pg_go, 1:12) + Lags(po_go, 1:12)
Model 2: pg_go ~ Lags(pg_go, 1:12)
      Res.Df Df      F      Pr(>F)
1         82
2         94 -12 1.6799 0.08642 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # goias oleo.com farelos ----
pf_chi > gpo_go.pf_chi=grangertest(po_go,pf_chi,order = 12) # po_go não Granger causa
pf_chi
> gpo_go.pf_chi
Granger causality test

Model 1: pf_chi ~ Lags(pf_chi, 1:12) + Lags(po_go, 1:12)
Model 2: pf_chi ~ Lags(pf_chi, 1:12)
      Res.Df Df      F      Pr(>F)
1         82
2         94 -12 1.7359 0.07385 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> gpo_go.pf_prn=grangertest(po_go,pf_prn,order = 12) # po_go não Granger causa p
f_prn
> gpo_go.pf_prn
Granger causality test

Model 1: pf_prn ~ Lags(pf_prn, 1:12) + Lags(po_go, 1:12)
Model 2: pf_prn ~ Lags(pf_prn, 1:12)
      Res.Df Df      F      Pr(>F)
1         82
2         94 -12 1.5978 0.1084
> gpo_go.pf_go=grangertest(po_go,pf_go,order = 12) # po_go não Granger causa pf_
go
> gpo_go.pf_go
Granger causality test

Model 1: pf_go ~ Lags(pf_go, 1:12) + Lags(po_go, 1:12)
Model 2: pf_go ~ Lags(pf_go, 1:12)
      Res.Df Df      F      Pr(>F)
1         82
2         94 -12 2.6239 0.00516 **

```

```

---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
> # goias oleo.com oleos ----
_chi > gpo_go.po_chi=grangertest(po_go,po_chi,order = 12) # po_go não Granger causa po
oleo de chicago
> gpo_go.po_chi      # Pr(>F)=> maior que 0.10 aceita H0: oleo de goias nao causou
Granger causality test

Model 1: po_chi ~ Lags(po_chi, 1:12) + Lags(po_go, 1:12)
Model 2: po_chi ~ Lags(po_chi, 1:12)
  Res.Df  Df    F    Pr(>F)
1      82
2      94 -12  6.5001 5.375e-08 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
_prn > gpo_go.po_prn=grangertest(po_go,po_prn,order = 12) # po_go não Granger causa po
> gpo_go.po_prn
Granger causality test

Model 1: po_prn ~ Lags(po_prn, 1:12) + Lags(po_go, 1:12)
Model 2: po_prn ~ Lags(po_prn, 1:12)
  Res.Df  Df    F    Pr(>F)
1      82
2      94 -12  2.6105 0.005379 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```