

**RUBEN VIVALDI SILVA PESSOA**

**CORRELAÇÕES EM SÉRIES TEMPORAIS DE PREÇOS DE  
FRANGO, SOJA E MILHO**

**Recife – PE  
Fevereiro/2021**



**UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO**  
**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM BIOMETRIA E ESTATÍSTICA**  
**APLICADA**

**CORRELAÇÕES EM SÉRIES TEMPORAIS DE PREÇOS DE**  
**FRANGO, SOJA E MILHO**

Dissertação apresentada ao Programa de Pós-Graduação em Biometria e Estatística Aplicada como exigência parcial à obtenção do título de Mestre em Biometria e Estatística Aplicada.

**Área de Concentração: Biometria e Estatística Aplicada**

**Orientador: Prof. Dr. Borko Stosic**

**Co-Orientadores: Profa. Dra. Tatijana Stosic;  
Dr. Ikaró Barreto**

**Recife – PE**  
**Fevereiro/2021**

Dados Internacionais de Catalogação na Publicação  
Universidade Federal Rural de Pernambuco  
Sistema Integrado de Bibliotecas  
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

---

P475c Pessoa, Ruben Vivaldi Silva  
CORRELAÇÕES EM SÉRIES TEMPORAIS DE PREÇOS DE FRANGO, SOJA E MILHO / Ruben  
Vivaldi Silva Pessoa. - 2021.  
45 f. : il.

Orientador: Borko Stosic.  
Coorientador: Ikaró Barreto.  
Inclui referências.

Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em  
Biometria e Estatística Aplicada, Recife, 2021.

1. Frango. 2. Soja. 3. Milho. 4. Commodities. 5. Crise alimentar. I. Stosic, Borko, orient. II. Barreto, Ikaró,  
coorient. III. Título

---

CDD 519.5

**UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO**  
**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM BIOMETRIA E ESTATÍSTICA**  
**APLICADA**

**CORRELAÇÕES EM SÉRIES TEMPORAIS DE PREÇOS DE**  
**FRANGO, SOJA E MILHO**

**RUBEN VIVALDI SILVA PESSOA**

Manuscrito da Dissertação julgada adequada para obtenção do título de Mestre em Biometria e Estatística Aplicada, defendida e aprovada por unanimidade em 19/02/2021 pela Banca Examinadora.

Orientador(a):

---

Prof. Dr. Borko Stosic  
Universidade Federal Rural de Pernambuco

Banca Examinadora:

---

Prof. Dra. Tatijana Stosic  
Universidade Federal Rural de Pernambuco

---

Prof. José Rodrigo Santos Silva  
Universidade Federal de Sergipe

A minha avó Irene.

## Agradecimentos

Agradeço a Deus, pois Ele se faz presente em todas as fases da minha vida e me concede a graça de concluir essa dissertação.

Aos meus pais que me educaram e junto a meus irmãos, tia e avó, me deram todo suporte em minha vida para que eu chegasse até aqui, obrigado por acreditarem em mim.

Agradeço aos meus professores desde a Educação Infantil, pois sem eles, eu jamais teria chegado aqui. Em particular, aos docentes que pude conhecer e aprender no Programa de Pós-Graduação em Biometria e Estatística Aplicada. Especialmente, ao meu orientador Borko Stosic e aos meus co-orientadores Tatijana Stosic e Ikaró Barreto. A vocês, a minha enorme gratidão por terem aceitado me orientar, pelo apoio, paciência e vasto conhecimento transmitidos que foram muito importantes nesta jornada, além da preocupação em transmitir confiança e tranquilidade de forma leve para os momentos difíceis dessa jornada. Tudo isso contribuiu e seguirá contribuindo para minha vida acadêmica.

A minha grande família da igreja, por todo apoio nos momentos difíceis, pelas boas conversas que suavizaram essa caminhada, conselhos importantes para minha vida e pelas orações que fizeram toda a diferença para o sucesso nesse curso.

A minha namorada que além de deixar meus dias mais leves e felizes, sempre me incentiva e acredita no meu potencial para obter sucesso no que faço.

Aos colegas da graduação, que mesmo após anos do fim do curso, mantem o elo e estão sempre na torcida pelo sucesso e felicidade do outro. Aos colegas do Programa. Foi ótimo compartilhar esses 24 meses com vocês, sou grato pelo apoio de cada um, por cada conversa, presencial ou virtual que me fizeram sentir satisfação em fazer parte desse grupo.

Agradeço a Marco Santos, secretário do Programa, pela disponibilidade e ajuda do início ao fim do curso. Aos técnicos e terceirizados da UFRPE que da sua forma ajudam a todos. Ao DEINFO e UFRPE pela estrutura ofertada para o desenvolvimento do projeto. A CAPES/CNPq pelo incentivo à pesquisa no país.

"Não vos inquieteis, pois, pelo dia de amanhã; porque o dia de amanhã trará suas próprias preocupações. Basta a cada dia o seu problema".  
Mateus 6:34. Bíblia Sagrada.

## Resumo

Com a evolução do mercado agrícola, o processo de produção, exportação e consumo de commodities alimentares foi alterado. Diante desse cenário, os preços de alimentos podem ser afetados por diversos fatores, como por exemplo pelo mercado energético por meio de estratégias que chegam a desviar as culturas alimentares para a produção de biocombustíveis, provocando o interesse por uma melhor compreensão destas relações. Nos últimos anos, desenvolveram-se muitos estudos acerca da relação entre o mercado de alimentos e outros mercados, buscando explicar a ligação entre os preços de diferentes commodities com os preços das *commodities* (matérias-primas) agrícolas. Aqui, o objetivo foi investigar correlações intrínsecas de longo prazo entre os mercados brasileiros de alimentos, utilizando as técnicas da Econofísica. Foram analisadas as séries diárias de preços e retornos de frango, soja e milho para o período de 02/08/2004 a 16/06/2017, obtidas pelo Centro de Estudos Avançados em Economia Aplicada/ Escola Superior de Agricultura Luiz de Queiroz/ Universidade de São Paulo - CEPEA / ESALQ / USP. Os preço de frango depende, principalmente, do custo da ração, que inclui o milho e a soja como fonte de energia e proteína, respectivamente. As correlações foram analisadas utilizando os métodos *Detrended Cross Correlation Analysis* (DCCA) e o coeficiente de correlação a ela associada e da recentemente proposta *Detrended Partial Cross Correlation Analysis* (DPCCA) útil para quantificar as correlações cruzadas intrínsecas entre duas séries temporais não estacionárias. Os resultados obtidos apontam para ausência de correlações cruzadas nas escalas de até 30 dias. As correlações intrínsecas apresentadas pela DPCCA entre frango e milho são mais fortes do que as correlações entre frango e soja, especialmente a partir de escalas de 250 dias, sinalizando que as interações entre os mercados dessas commodities são maiores a longo prazo. Ainda, pôde se observar que após a crise de 2008, as correlações diminuíram para escalas de até 200 dias.

**Palavras-chave:** Frango, Soja, Milho, *Commodities*, Crise alimentar.



## Abstract

With the evolution of the agricultural market, the process of production, export and consumption of food commodities has changed. Given this scenario, food prices can be affected by several factors, such as the energy market through strategies that even divert food cultures for the production of biofuels, causing interest in a better understanding of these relationships. In recent years, many studies were developed on the relationship between the food market and other markets, seeking to explain the link between the prices of different commodities with the prices of agricultural commodities (raw materials). However, Brazil still needs more attention in its food market. Here, the objective was to investigate intrinsic long-term correlations between Brazilian food markets, using Econophysics techniques. The daily series of price returns for chicken, soybeans and corn were analysed for the period from 02/02/2004 to 06/16/2017, obtained by the Center for Advanced Studies in Applied Economics / Escola Superior de Agricultura Luiz de Queiroz / Universidade of São Paulo - CEPEA / ESALQ / USP. Chicken prices depend mainly on the cost of the feed, which includes corn and soy as a source of energy and protein, respectively. The correlations were analysed using methods the Detrended Cross Correlation Analysis (DCCA) and the correlation coefficient associated with it and the recently proposed Detrended Partial Cross Correlation Analysis (DPCCA) useful to quantify the intrinsic cross correlations between two non-stationary time series. The results point to the absence of cross correlations for temporal scales up to 30 days. The intrinsic correlations presented by the DPCCA between chicken and corn price returns are stronger than the correlations between chicken and soybeans, especially from 250-day scales, signalling that the interactions between the markets for these commodities are greater in the long run. Furthermore, it was observed that after the 2008 crisis, the correlations decreased for temporal scales up to 200 days.

**Keywords:** Chicken, Soy, Corn, Commodities, Food crisis.

## Lista de Figuras

Figura 1a	Evolução temporal dos Preços de Soja de Agosto de 2004 a junho de 2017 .....	21
Figura 1b	Evolução temporal dos retornos de preços de Soja de Agosto de 2004 a Junho de 2017.....	21
Figura 2a	Evolução temporal dos Preços de Frango de Agosto de 2004 a Junho de 2017.....	22
Figura 2b	Evolução temporal dos retornos de preços de Frango de Agosto de 2004 a Junho de 2017.....	22
Figura 3a	Evolução temporal dos Preços de Milho de Agosto de 2004 a Junho de 2017 .....	23
Figura 3b	Evolução temporal dos retornos de preços de Milho de Agosto de 2004 a Junho de 2017.....	23
Figura 4	Coeficiente DCCA e DPCCA das séries de retorno de preço do Frango e do Milho no período de Agosto de 2004 a Junho de 2017 ...	31
Figura 5	Coeficiente DCCA e DPCCA das séries de retorno de preço do Frango e da Soja no período de Agosto de 2004 a Junho de 2017.....	32
Figura 6	Coeficiente $\Delta\rho$ DCCA das séries de retorno do preço do Frango e do Milho no período de Agosto de 2004 a Junho de 2017.....	33
Figura 7	Coeficiente $\Delta\rho$ DCCA das séries de retorno do preço do Frango e da Soja no período de Agosto de 2004 a Junho de 2017 .....	34
Figura 8	Coeficiente $\Delta\rho$ DPCCA das séries de retorno do preço do Frango e do Milho no período de Agosto de 2004 a Junho de 2017.....	35
Figura 9	Coeficiente $\Delta\rho$ DPCCA das séries de retorno do preço do Frango e da Soja no período de Agosto de 2004 a Junho de 2017.....	36

## Lista de Tabelas

Tabela 1	Análise descritiva dos retornos dos preços das commodities Frango, Soja e Milho para: (i) séries temporais completas, (ii) antes da crise de 2008, e (iii) após a crise de 2008 .....	29
----------	---	----

## SUMÁRIO

1. INTRODUÇÃO .....	13
2. MERCADO BRASILEIRO DE ALIMENTOS .....	16
2.1. <i>Commodities</i> Agrícolas .....	17
2.2. <i>Commodities</i> Frango, Soja e Milho .....	18
3. DADOS E METODOLOGIA .....	20
3.1. Dados .....	20
3.2. <i>Detrended Fluctuation Analysis</i> (DFA) .....	24
3.3. <i>Detrended Cross-Correlation Analysis</i> (DCCA) .....	25
3.4. <i>Detrended Cross-Correlation Coefficient</i> ( $\rho$ _(DCCA)) .....	26
3.5. <i>Detrended Partial Cross-Correlation Analysis</i> (DPCCA) .....	27
4. RESULTADOS E DISCUSSÃO .....	29
5. CONCLUSÃO .....	37
6. REFERÊNCIAS BIBLIOGRÁFICAS .....	39

## 1 Introdução

Ao longo das últimas décadas, especialmente após o advento do Plano Real (1994) no Brasil, o consumo de carne de frango aumentou devido à estabilidade econômica e à melhoria das condições de renda da população. Em 2018, o consumo brasileiro de carne per capita de aves foi de 42 kg, superando o consumo de outras fontes de proteínas, como carne bovina e suína (EMBRAPA, 2020).

A produção, exportação e consumo doméstico de carne de frango no Brasil se encontram em constante crescimento desde o fim do século XX. Em 2018, a produção de aves do país foi de 13.355 mil toneladas, representando a segunda maior produção do mundo (atrás apenas dos EUA) e 14% do total da produção mundial.

Também em 2018, o Brasil também foi o maior exportador mundial, com 3687 mil toneladas, representando 33% da exportação mundial total e 28% da produção avícola brasileira (EMBRAPA, 2020).

As variações de preço da carne de frango podem ter um impacto negativo na receita da grande maioria das famílias brasileiras. O valor da carne de frango depende muito do custo da alimentação, que representa cerca de 70% do custo total de produção. Considerando que tal alimentação se baseia nas rações formadas por milho e farelo de soja, e estes passam por variações nos preços durante o ano devido a sazonalidade de produção, o preço da carne de frango também sofrerá com a variabilidade (ARAÚJO, 2019).

Assim, espera-se que tais mercados se influenciem através de interações complexas que incluem fatores exógenos como preços do petróleo, condições do clima, produção de biocombustíveis e taxa de câmbio, dificultando a escolha de uma abordagem quantitativa apropriada. Embora métodos estatísticos ainda sejam a ferramenta básica para estudar correlações e transmissões de preços entre mercados agrícolas (BECKMANN; CZUDAJ, 2014; DE NICOLA; DE PACE; HERNANDEZ, 2016), o campo da econofísica (através dos métodos e modelos baseados na mecânica estatística) gera novos conhecimentos para melhor

compreensão das variações e relações dos preços das commodities agrícolas dentro deste mercado e com outros mercados (LIU, 2018; PAL; MITRA, 2018; LIMA et. al. 2019).

Embora os preços das commodities agrícolas e suas relações com outros mercados, como o de petróleo, biocombustível, taxas de câmbio e índices de ações tenham sido estudados extensivamente tanto na economia quanto na econofísica (LIU, 2018; PAL; MITRA, 2018; LIMA et. al. 2019; SU et. al. 2019), pouco se sabe sobre as relações de preços entre as mercadorias na cadeia de suprimentos vertical. Frascaroli e Carvalho (2016) estudaram a transmissão de preços no mercado de Bioetanol entre os estados de Alagoas e Pernambuco, usando testes estatísticos de raízes unitárias, testes de cointegração, teste de Hansen e Seo. Eles descobriram que possíveis custos de transação têm efeitos reduzidos sobre a dinâmica de transmissão de preços entre esses mercados.

Cinar e Keskin (2018) estudaram o efeito de transbordamento de insumos importados (biocombustível e soja) nos preços de frango na Turquia. Usando o *Vector Error Correction Model* (VECM), eles observaram que os insumos importados não têm efeitos de curto prazo nos preços da carne de frango na Turquia, a energia afetou os preços da soja a curto e longo prazo, e os preços do frango apenas a longo prazo. Zhen, Rude e Qiu (2017) estudaram transbordamentos de volatilidade entre preços de cevada para alimentação de Alberta, preços de gado alimentador e preços de gado alimentado usando extensão assimétrica bivariada para um modelo BEKK-GARCH. Eles acharam que as repercussões da volatilidade fluem do retorno do gado alimentador ao retorno do gado alimentado e do retorno da cevada ao retorno do bezerro alimentador.

Tendo em vista esses relatos, contribuimos com a literatura existente, utilizando a abordagem econofísica a fim de estudar a interdependência de preços na cadeia produtiva brasileira de aves: preços da carne de frango e seus materiais de linha de alimentação soja e milho. Para cada mercadoria, analisamos primeiro as correlações de longo prazo nas séries de retorno usando o *Detrended fluctuation method* (DFA) (PENG et. al. 1994), que fornece expoentes de escala que quantificam a natureza do processo estocástico contido (persistente, antipersistente ou aleatório). Em seguida, analisamos correlações

cruzadas de longo prazo entre cada par de mercadorias usando a *Detrended cross correlation analysis* (DCCA) (Podobnik; Stanley, 2008) e calculamos o *Detrended cross correlation coefficient* ( $\rho_{\text{DCCA}}$ ) que quantifica correlações cruzadas em diferentes escalas temporais (ZEBENDE, 2011). Finalmente, comparamos resultados do DCCA com os resultados do método introduzido recentemente *Detrended partial cross correlation analysis* (DPCCA) (Qian et. al. 2015; Yuan et. al. 2015), que avalia as correlações cruzadas intrínsecas entre duas séries temporais que são influenciadas pela terceira série comum.

Com isso, esse estudo tem como objetivo analisar as correlações inerentes a longo prazo entre mercados brasileiros de alimentos, a partir de técnicas da Econofísica: *Detrended Fluctuation Analysis* (DFA) (PENG et. al.1994), *Detrended Cross Correlation Analysis* (DCCA) (Podobnik; Stanley, 2008) e a *Detrended Partial Cross Correlation Analysis* (DPCCA) (Qian et. al. 2015; Yuan et. al. 2015). O DCCA é útil na mensuração de correlações cruzadas de longo prazo em séries temporais que não são estacionárias, analisando a dependência de escala da covariância, enquanto elimina a tendência. Porém, quando uma nova série exerce influência sobre duas já existentes, o estudo do DCCA já não indica a sua verdadeira relação. A fim de remover correlações cruzadas inerentes de longo alcance entre duas séries não estacionárias, sob influências de outras séries retiradas, o método DPCCA foi independentemente proposto por Qian et. al. 2015 e Yuan et. al. 2015, como a união da técnica de correlação parcial e DCCA.

Esta dissertação se divide em cinco partes. No Capítulo 2, demonstramos as características do objeto de estudo, o mercado brasileiro de alimentos. No Capítulo 3, exibimos os dados utilizados neste trabalho, bem como as metodologias usadas nas análises. No Capítulo 4, apresentamos os resultados e discussão. As conclusões e a proposta dos futuros trabalhos se encontram no Capítulo 5.

## 2 Mercado Brasileiro de Alimentos

Recentemente, a discussão sobre o uso de biocombustíveis ganhou força. Os biocombustíveis foram acusados de atenuar a insegurança alimentar, a longo prazo, de muitos países, principalmente aqueles mais pobres da África, além de contribuir para o aquecimento global, pois são uma fonte de energia renovável derivada de matéria orgânica. Segundo o Estudo do International Food Policy Research Institute (IFPRI, 2016), no ano de 2009, ao menos 1 bilhão de pessoas sofria de desnutrição na Terra. Ainda, segundo o “Global Hunger Index 2016”, cerca de 795 milhões de pessoas ainda possuíam o problema, o que equivalia a 13,1% da população mundial (IFPRI, 2016).

O Brasil é considerado pelos pesquisadores do IFPRI como um país com êxito no combate à fome. O relatório menciona programas de proteção social aplicados nos últimos anos que são modelos para outros países. Ainda assim, biocombustíveis são apontados como uma das razões da alta crescente nos preços das commodities agrícolas, porque as plantas utilizadas na sua fabricação estão na disputa por terras agrícolas e água, que poderiam ser utilizadas na produção de alimentos (IFPRI, 2016).

Sabe-se que a produção de alimentos é um dos pilares da economia brasileira, devido a sua abrangência e por se tratar de algo tão essencial para a população, além de estar ligado a uma grande rede de setores de forma direta e indireta. Diante disso, se faz importante estudar o mercado brasileiro de alimentos e seu reflexo na economia brasileira (PINHEIRO, 2020).

Dados do Instituto Brasileiro de Geografia e Estatística (IBGE) apontaram que a produção de alimentos em 2017 avançou entre 0,6% e 1,2% em relação ao ano de 2016 e que as exportações de alimentos variaram entre US\$ 37 e 40 bilhões para o mesmo ano. Ainda segundo o IBGE, O aumento da população e o crescimento da economia são considerados fatores determinantes para a demanda de produtos alimentícios (IBGE, 2017).



## 2.1 Commodities agrícolas

Commodity, é uma expressão originária do inglês que significa mercadoria e se propagou no ramo da economia por ser um termo utilizado para se referir a produtos ou bens que tenham origem primária, em estado bruto ou que possuam um nível baixo de transformação (matéria-prima) e que também sejam produzidos em escala, podendo ser armazenados sem se perder a qualidade. Ainda, é tido como um produto cujo mercado apresenta sua competitividade ligada a escala de produção, baixos custos de produção, baixo valor agregado. (ARAÚJO, 2017). As commodities podem ser classificadas de diversas formas: agrícolas, minerais, financeiras, ambientais, dentre outras (FERREIRA, 2016).

Algumas commodities são classificadas como agrícolas por serem cultivadas por meio do agronegócio. Tais commodities têm suas próprias cotações de preço, que são calculadas considerando a saca, quilo ou até mesmo tonelada. Essas cotações podem ser afetadas tanto positiva como negativamente por algumas variáveis, como estoques, clima e previsão, o que pode levar as cotações a apresentarem certa variação ao longo do dia. É interessante dizer que no mercado das commodities agrícolas, é comum que a partir do resultado final da safra, o comprador e o vendedor possam perder dinheiro, considerando que as commodities são negociadas no mercado futuro, o que viabiliza a compra e venda de safras antes mesmo da colheita. Como Exemplos de commodities agrícolas temos soja, milho, café, trigo e açúcar.

Algumas das commodities agrícolas mais comuns como açúcar e soja são produzidas em larga escala no solo brasileiro, onde a negociação é realizada pela Bolsa de Valores, Mercadorias e Futuros, fundada no ano de 2008 numa integração realizada entre Bolsa de Mercadorias & Futuros e a Bolsa de Valores de São Paulo (BOVESPA). Essas companhias fazem parte das três maiores bolsas do planeta em valor de mercado, estando entre as duas maiores das Américas e sendo a maior na América Latina (BM&FBOVESPA, 2020).

Essas apresentam a seguinte dinâmica de funcionamento: O mercado mundial estabelece o preço da commodity a partir da respectiva oferta e procura, que são negociadas em bolsas de valores do mundo inteiro, ou seja, o

comprador e o produtor estabelecem um contrato contendo o preço fixado no presente para a entrega e pagamento do produto numa futura data, acordada com antecedência. (VIEIRA, 2020)

As transformações econômicas no agronegócio conduziram as maneiras de investimentos e de comercialização de commodities agrícolas nos mercados globais a mudanças significativas. Ainda, o comportamento do comércio de produtos ligados a agricultura nos mercados futuros foi crucial para a política de preços, conforme a sua influência no sistema financeiro ocasionou especulação, que aumentou os preços das commodities negociadas, utilizadas na produção de biocombustíveis e no consumo de alimentos (PEREIRA; DOS SANTOS; FERREIRA, 2019).

## **2.2 Commodities frango, soja, milho**

Dentre os principais commodities agrícolas, se encontram o frango, soja e o milho. Na lista dos maiores produtores mundiais dessas commodities, tem-se além do Brasil, países como Estados Unidos, China e Argentina. Quando se traça um comparativo para produção mundial de soja, pode-se notar uma grande concentração numa quantidade mais restrita de países do que para as produções de milho e frango. (Freitas; Santos, 2017).

No caso do milho, a produção mundial é liderada por Estados Unidos e China, além de haver um conjunto de produtores que também concorrem junto da produção brasileira. É possível constatar uma situação similar na produção de frangos, em que China e Estados Unidos também disputam de forma direta com a produção do Brasil, além de países como Indonésia e Rússia apresentarem uma produção significativa (Freitas; Santos, 2017).

Diferentemente de outras commodities agrícolas, a rede de produção do frango no Brasil apresenta uma grande complexidade. Uma das maiores razões para isso é o fato de ter passado por fortes mudanças ao longo da história, em especial nas regiões Sudeste e Sul do Brasil. Durante esse período, ocorreu um grande desenvolvimento em muitas atividades ligadas a produção como no

controle das doenças, na seleção genética das aves, nas rações, no processamento, na distribuição e comercialização (Schmidt; Silva, 2018).

Como dito anteriormente, o Brasil encontra-se entre os maiores produtores mundiais de soja. Apesar disso, devido ao clima seco e quente do verão do país, a produtividade passa por períodos de baixa, apresentando forte tendência de queda ao longo da colheita (CONTESSA, 2020). Historicamente, a seca ocorrida no período de produção da soja na entressafra de 1976/1977 e 2013/2014 gerou perdas financeiras no país que totalizaram um valor superior a 79 bilhões de dólares (FERREIRA, 2016).

A cultura de produção do milho é um dos ramos econômicos mais importantes do agronegócio em solo brasileiro, e de acordo com o estudo da Companhia Nacional de Abastecimento (CONAB, 2019), a produção primária de milho equivale a quase 40% do total da produção de grãos no Brasil para o ano de 2019. Nas últimas décadas, a produção brasileira de milho cresceu muito, tendo passado de 35.715,6 mil toneladas, no fim do século XIX, para 73.177,7 mil toneladas, na safra de 2016, gerando um aumento de mais de 100% (CONAB, 2019).


### 3 Dados e metodologia

#### 3.1 Dados

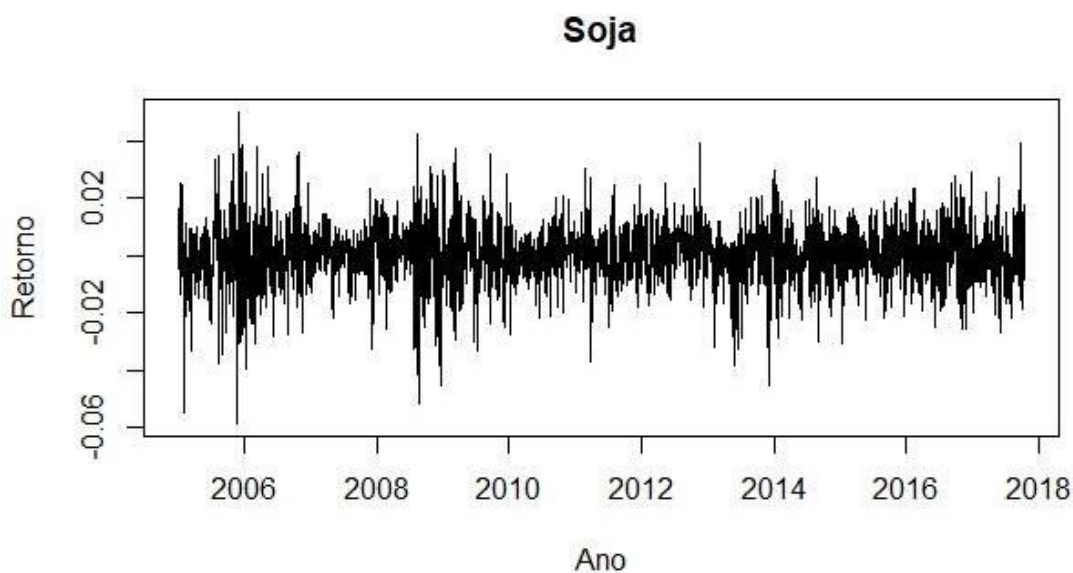
Os dados utilizados foram preços diários expressos em reais (R\$) de milho (saco de 60kg), soja (saco de 60 kg) e frango (kg) registrados no período de 02 de agosto de 2004 a 16 de junho de 2017. As séries de dados foram obtidas no Centro de Estudos Avançados em Economia Aplicada/ Escola Superior de Agricultura Luiz de Queiroz/ Universidade de São Paulo - CEPEA / ESALQ / USP. Para tais dados, foram analisadas as séries diárias de retornos diários  $R_t$ , em que  $R_t = \ln(P_t) - \ln(P_{t-1})$ , em que  $P_t$  é o preço de uma *commodity* no dia  $t$ .

As Figuras 1a e 1b apresentam, respectivamente, o comportamento das séries originais dos preços diários das séries dos retornos da soja, para o período analisado. Na Figura 1a, observa-se a diminuição do preço da soja no início do período até o mês de Abril de 2006, subindo após esse período, mas apresentando uma nova queda em 2009, depois da crise financeira global. Após esse período sob os efeitos da crise, o preço volta a subir em 2010 e alcança valores maiores em 2012 e, depois disso, apresenta oscilações entre os valores mais altos. Na análise dos retornos, é possível observar períodos, como o da crise, em que os retornos são maiores (Figura 1b).

**Figura 1a – Evolução temporal dos preços de Soja de Agosto de 2004 a Junho de 2017.**



**Figura 1b – Evolução temporal dos retornos de preços de Soja de Agosto de 2004 a Junho de 2017.**



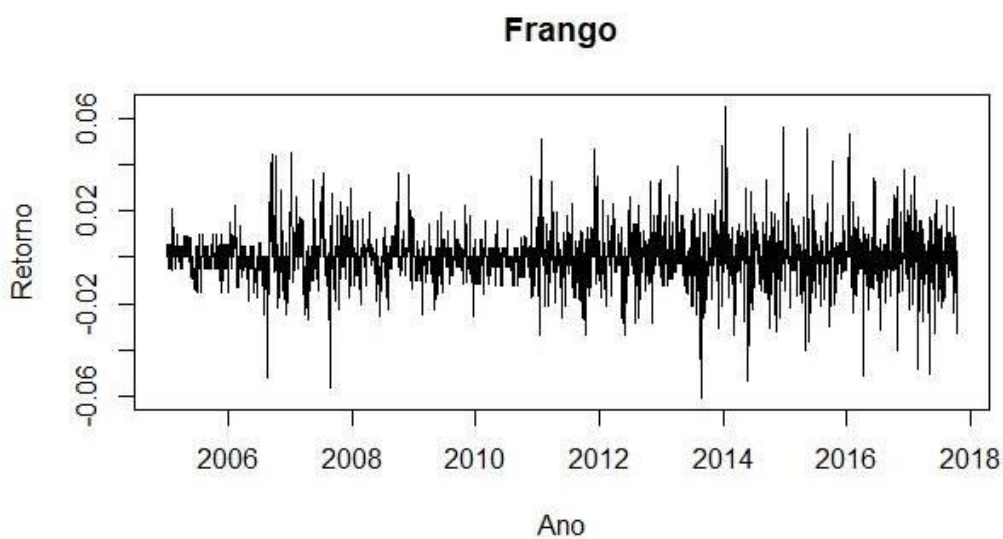
As figuras 2a e 2b apresentam, respectivamente, o comportamento das séries originais dos preços diários e das séries dos retornos do frango, para o período analisado. Percebe-se que o preço do frango apresenta uma queda até Março de 2006, subindo após isso seus valores sob oscilação, mas no período

da crise financeira, o preço volta a cair de forma mais constante e após a crise, o preço tende a subir novamente (Figura 2a). Interessante dizer que este período coincide com o período de aumento do preço da soja (Figura 1a). Ainda, percebe-se que os maiores retornos foram registrados em períodos de diminuição dos preços como em 2006, 2008 e 2012 (Figura 2b).

**Figura 2a – Evolução temporal dos preços de Frango de Agosto de 2004 a Junho de 2017.**




**Figura 2b – Evolução temporal dos retornos de preços de Frango de Agosto de 2004 a Junho de 2017.**




As Figuras 3a e 3b apresentam, respectivamente, o comportamento das séries originais dos preços diários e das séries dos retornos do milho, para o período analisado. Na Figura 3a observa-se o aumento de preço do milho de Abril a Dezembro de 2006 mas desde o início da crise financeira global de 2008, os preços voltaram a cair, so apresentando recuperação no segundo semestre de 2010. Percebe-se ainda uma variação dos preços, refletida pelos maiores retornos, observados em anos como o de 2009 (crise), ilustrados na Figura 3b.

**Figura 3a – Evolução temporal dos preços de Milho de Agosto de 2004 a Junho de 2017.**



**Figura 3b – Evolução temporal dos retornos de preços de Milho de Agosto de 2004 a Junho de 2017.**



### 3.2 Detrended fluctuation analysis (DFA)

A *Detrended fluctuation analysis* (DFA) foi introduzida (PENG et. al., 1994) como uma análise da raiz quadrada média modificada de um passeio aleatório e serve para detectar correlações de longo alcance em séries temporais que não apresentem a estacionariedade (KANTELHARDT et. al. 2001). Esse método DFA foi aplicado com sucesso em fisiologia (GOLDBERGER et. al. 2002), geofísica (ZHENG et. al. 2012), ecologia (STOSIC et. al. 2016) e climatologia (JIANG; ZHAO; WANG, 2016).

A implementação do algoritmo DFA é descrita da seguinte forma:

Primeiro, a série temporal original  $x(i), i = 1, \dots, N$  é integrada para produzir:

$$X(k) = \sum_{i=1}^k [x(i) - \langle x \rangle], \quad k = 1, \dots, N \quad (3.1)$$

em que  $\langle x \rangle = \frac{1}{N} \sum_{i=1}^N x(i)$  é a média aritmética da série.

Em seguida, a série integrada  $X(k)$  é dividida em  $N_n = \text{int}(N/n)$  segmentos de comprimento  $n$  não sobrepostos e, para cada segmento  $s = 1, \dots, N_n$ , a tendência local  $X_{n,s}(k)$  é estimada como um polinômio linear ou ordem superior, com ajuste quadrado mínimo e subtraído de  $X(k)$ .

A variância sem tendência é então calculada como:

$$F_{DFA}^2(n) = \frac{1}{nN_n} \sum_{(s=1)}^{N_n} \sum_{(s-1)n+1}^{sn} [X(k) - X_{(n,s)}(k)]^2 \quad (3.2)$$

Repetir esse cálculo para diferentes tamanhos de janela fornece a relação entre a função de flutuação  $F(n)$  e o tamanho da janela  $n$ . Se houver correlações de longo prazo na série original,  $F(n)$  aumenta com  $n$  de acordo com uma lei de potência  $F(n) \sim n^\alpha$ .



O expoente escalar  $\alpha$  é obtido como a inclinação da regressão linear de  $\log F(n)$  versus  $\log n$ . Para  $0 < \alpha < 1$ , o expoente DFA é igual ao expoente Hurst  $H$  e descreve autocorrelações nas séries originais: o valor  $\alpha = 0,5$  indica a ausência de correlações (ruído branco),  $\alpha > 0,5$  indica correlações persistentes a longo prazo, o que significa que valores grandes (pequenos) têm mais probabilidade de serem seguidos por grandes valores (pequenos),  $\alpha < 0,5$  indica correlações anti-persistentes a longo prazo, o que significa que valores grandes têm mais probabilidade de serem seguidos por valores pequenos e vice-versa. O valor  $1 < \alpha < 2$  indica movimento browniano fracionário com incrementos descritos pelo expoente Hurst  $H = \alpha - 1$ . Os valores  $\alpha = 1$  e  $\alpha = 1,5$  correspondem ao ruído  $1/f$  e ao ruído browniano (integração do ruído branco), respectivamente (LØVSLETTEN, 2017).

### 3.3 Detrended cross-correlation analysis (DCCA)

O método *Detrended cross-correlation analysis* (DCCA) foi introduzido por Podobnik e Stanley (PODOBNIK, 2008), como uma generalização do método *Detrended fluctuation analysis* (DFA) (PENG, 1994), e é útil para mensurar as correlações entre duas séries temporais simultâneas. Assim como no DFA, esta técnica é aplicada para detectar e mensurar correlações existentes entre duas séries não estacionárias e já foi diversamente utilizada em áreas como fisiologia (JUN; DA-QING, 2012), engenharia (XU; SHANG; KAMAE, 2010), climatologia (DOS ANJOS et. al. 2015), hidrologia (DEY; MUJUMDAR, 2018) e finanças (PODOBNIK et. al., 2009). A implementação de algoritmo DCCA é descrita da seguinte forma (PODOBNIK E STANLEY, 2008):

Inicialmente as duas séries temporais simultâneas  $x(i)$  e  $y(i)$ ,  $i = 1, \dots, N$  são integradas para produzir

$$X(k) = \sum_{i=1}^k [x(i) - \langle x \rangle] \text{ e } Y(k) = \sum_{i=1}^k [y(i) - \langle y \rangle] , \quad k = 1, \dots, N, \quad (3.3)$$

em que  $\langle x \rangle = \frac{1}{N} \sum_{i=1}^N x(i)$  e  $\langle y \rangle = \frac{1}{N} \sum_{i=1}^N y(i)$  representam as médias aritméticas das séries  $x(i)$  e  $y(i)$  respectivamente.

Na sequência, as séries integradas  $X(k)$  e  $Y(k)$  são divididas em  $N_n$  intervalos (segmentos) não sobrepostos de tamanho  $n$  e para cada segmento  $s = 1, \dots, N_s$ , as tendências locais  $X_{n,s}(k)$  e  $Y_{n,s}(k)$  (feita com ajuste linear ou polinomial) são estimadas e subtraídas das séries  $X(k)$  e  $Y(k)$ , respectivamente. Calcula-se então, a covariância sem tendências:

$$F_{DCCA}^2(n) = \frac{1}{nN_n} \sum_{s=0}^{N_n-1} \sum_{k=ns+1}^{n(s+1)} [X(k) - X_{n,s+1}(k)] [Y(k) - Y_{n,s+1}(k)] \quad (3.4)$$

Este cálculo se repete para diferentes tamanhos dos segmentos, dando a relação entre a função de flutuação  $F_{DCCA}(n)$  e o tamanho do segmento  $n$ . Se entre as duas séries originais  $x(i)$  e  $y(i)$  existem correlações de longo alcance,  $F_{DCCA}(n)$  segue uma lei de potências  $F_{DCCA}(n) \sim n^{-\lambda}$ . O expoente da escala  $\lambda$  pode ser obtido como o coeficiente angular da reta entre  $\log F_{DCCA}(n)$  e  $\log n$ . A interpretação de  $\lambda$  se faz similar a do expoente  $\alpha$  de DFA. A presença das correlações cruzadas de longo prazo entre duas séries simultâneas implica que cada série tem uma longa memória dos seus valores anteriores, bem como uma longa memória de valores anteriores da outra série (PODOBNIK E STANLEY, 2008). No caso de apenas uma série ser analisada, os métodos DCCA e DFA são equivalentes

### 3.4 Detrended cross correlation coefficient ( $\rho_{DCCA}$ )

Zebende, da Silva e Machado Filho (2013) mostraram que a relação entre os expoentes DFA das series individuais ( $\alpha_1$  e  $\alpha_2$ ) e expoente DCCA ( $\lambda$ ) correspondente, pode ser estabelecida através de coeficiente  $\rho_{DCCA}$ .

$$\rho_{DCCA}(n) = \frac{\hat{F}_{DCCA}^2(n)}{F_{DFA_1}(n)F_{DFA_2}(n)} \quad (3.5)$$

Em que  $F_{DCCA}^2(n)$  é a covariância sem tendência obtida pelo DCCA e  $F_{DFA_1}(n)$  e  $F_{DFA_2}(n)$  representam as funções de flutuação obtidas através do DFA. O coeficiente de correlação cruzada DCCA já foi utilizado em análise dos

processos fisiológicos (CHEN et.al., 2018), séries climáticas (VASSOLER; ZEBENDE, 2012) e dados financeiros (FERREIRA et. al.,2019).

Esse coeficiente, introduzido por Zebende (2011), se baseia na *Detrended fluctuation analysis* (VASSOLER; ZEBENDE, 2012) e *Detrended cross correlation analysis* (FERREIRA et. al., 2019) e pode ser visto como um análogo do coeficiente de Pearson, tendo valor mínimo  $-1$  para correlação cruzada negativa perfeita e valor máximo  $1$  para correlação cruzada positiva perfeita.

Se as duas series não apresentarem correlação cruzada,  $\rho_{DCCA}(n)$  oscila em torno de zero enquanto para séries anti-correlacionadas,  $\rho_{DCCA}(n)$  é estritamente negativo e para séries correlacionadas positivamente,  $\rho_{DCCA}(n)$  é positivo. Nos casos em que há correlações de longo alcance entre as séries analisadas, o coeficiente segue uma lei de potencias tal que  $\rho_{DCCA}(n) \sim n^\omega$ , em que  $\omega = 2\lambda - \alpha_1 - \alpha_2$  (ZEBENDE et al., 2013).

### **3.5 Detrended partial cross correlation analysis (DPCCA).**

Recentemente, foi introduzida a *Detrended partial cross correlation analysis* (DPCCA) (QIAN et. al. 2015) para mensurar correlações cruzadas de longo alcance entre séries temporais ligadas por uma terceira série temporal em comum. Esta técnica agrega a correlação cruzada parcial da Estatística clássica na *Detrended cross-correlation analysis* (DCCA) e, dessa forma, busca retirar a influência de outros sinais ao avaliar correlações cruzadas entre as séries em questão. Essa técnica, ainda possui poucas aplicações, tendo essas aplicações concentradas na área de climatologia (Shen,Cao-ling, 2016; Piao et. al. , 2016). Neste trabalho, aplicamos o método de inversão matricial a seguir (YUAN et. al. 2015) para calcular coeficientes parciais de correlação cruzada em diferentes escalas temporais. A implementação do DPCCA para  $m$  séries temporais de dimensão  $N_{x_i}(k)$ ,  $i = 1, \dots, m$ ;  $k = 1, \dots, N$ , consiste em inverter uma matriz de coeficientes de correlação cruzada DCCA calculados na escala  $n$ .

$$\rho(n) = \mathbf{I} \begin{pmatrix} \rho_{1,1}(n) & \rho_{1,2}(n) & \cdots & \rho_{1,m}(n) \\ \rho_{2,1}(n) & \rho_{2,2}(n) & \cdots & \rho_{2,m}(n) \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{m,1}(n) & \rho_{m,2}(n) & \cdots & \rho_{m,m}(n) \end{pmatrix} \quad (3.6)$$

em que  $\rho_{i,j}(n) = F^{2i,j}(n) / [F_i(n) F_j(n)]$ , para  $i, j = 1, \dots, m$ , é o coeficiente do DCCA  $F^{2i,j}(n)$  é a *detrended covariance* entre duas séries obtidas pelo DCCA e  $F_i(n)$  e  $F_j(n)$  são funções de flutuação das séries individuais obtidas por meio do DFA. Dessa forma, a matriz inversa se apresenta como:

$$C(n) = \rho^{-1}(n) = \mathbf{I} \begin{pmatrix} C_{1,1}(n) & C_{1,2}(n) & \cdots & C_{1,m}(n) \\ C_{2,1}(n) & C_{2,2}(n) & \cdots & C_{2,m}(n) \\ \vdots & \vdots & \ddots & \vdots \\ C_{m,1}(n) & C_{m,2}(n) & \cdots & C_{m,m}(n) \end{pmatrix} \quad (3.7)$$

e tem como propósito o cálculo dos coeficientes de correlação cruzada parcial DPCCA que se relacionam através da expressão seguinte:

$$\rho_{DPCCA}(i, j; n) = \frac{-C_{i,j}(n)}{\sqrt{C_{i,i}(n) \cdot C_{j,j}(n)}}, \quad i, j = 1, \dots, m \quad (3.8)$$

em que o cálculo dos coeficientes  $\rho_{DPCCA}$  contribuem para a avaliação das correlações cruzadas entre as séries  $i$  e  $j$  que estão em análise, para cada escala  $n$ , quando a influência das outras séries é eliminada. Para fins de interpretação, a do coeficiente  $\rho_{DPCCA}$  é análoga a do coeficiente  $\rho_{DCCA}$ , de forma que quando as séries são anticorrelacionadas,  $\rho_{DPCCA}$  é negativo, quando são correlacionadas,  $\rho_{DPCCA}$  é positivo e se as séries não apresentam correlação,  $\rho_{DPCCA}$  é nulo (YUAN et. al. 2015).

#### 4 Resultados e discussão

Nesta seção serão apresentados os resultados obtidos a partir das análises das séries temporais diárias de preços de frango, soja e milho disponibilizadas através do Centro de Estudos Avançados CEPEA / ESALQ / USP para o período de 2 de agosto de 2004 a 16 de junho de 2017.

A Tabela 1 demonstra a estatística descritiva dos retornos do preço de Frango, Soja e Milho para a série histórica, antes (02/08/2004 - 15/09/2008) e depois (01/07/2009 - 16/06/2017) da crise de 2008. A análise descritiva para a série temporal apresenta médias baixas para os retornos das três commodities em questão, uma assimetria positiva para elas, exceto para Soja que possui um valor negativo. Para o Frango, a assimetria foi positiva para todo e após a crise, mas antes da crise, a assimetria foi negativa com valor próximo a zero. Aqui, os valores de Curtose são altos, denotando retornos com comportamentos mais agudos que a distribuição normal.

**Tabela 1: Análise descritiva dos retornos dos preços das commodities Frango, Soja e Milho para: séries temporais completas, antes e após a crise de 2008.**

Medidas/Período	Completa	Antes	Depois
<b>Frango</b>			
<b>Média</b>	0,0002	0,0007	0,0002
<b>Máximo</b>	0,3489	0,0556	0,3489
<b>Mínimo</b>	-0,1152	-0,0637	-0,1152
<b>Desvio Padrão</b>	0,0119	0,0130	0,0133
<b>Assimetria</b>	6,3376	-0,1129	7,0082
<b>Curtose</b>	190,76	1,6419	189,188
<b>N (Obs.)</b>	3953	1183	2574
<b>Soja</b>			
<b>Média</b>	0,0001	-0,00002	0,0002
<b>Maximo</b>	0,0499	0,0499	0,0394
<b>Mínimo</b>	-0,0633	-0,0633	-0,0453
<b>Desvio Padrão</b>	0,0100	0,0124	0,0087
<b>Assimetria</b>	-0,2914	-0,4318	-0,0993
<b>Curtose</b>	2,8015	2,6303	1,4554


<b>N (Obs.)</b>	3953	1183	2574
<b>Milho</b>			
<b>Média</b>	0,00019	0,07001	0,00025
<b>Máximo</b>	0,07508	0,06272	0,07508
<b>Mínimo</b>	-0,05358	-0,05358	-0,04873
<b>Desvio Padrão</b>	0,00957	0,00943	0,00971
<b>Assimetria</b>	0,54671	0,45836	0,47040
<b>Curtose</b>	4,72440	4,57678	4,04936
<b>N (Obs.)</b>	3953	1183	2574

Fonte: Autoria própria

Tendo realizado uma análise descritiva da série, foi aplicado o  $\rho_{DCCA}$  e o  $\rho_{DPCCA}$ . Os resultados são encontrados nas Figuras 4 e 5.

Na Figura 4, é possível observar os coeficientes de correlação DCCA e DPCCA (usando o polinômio de ordem  $m=2$  para retirar tendência local) das séries de retornos dos preços de frango e milho, em que as correlações entre frango e milho são fracas e negativas ( $\rho_{DCCA} < 0$ ,  $\rho_{DPCCA} < 0$ ), mas crescem a partir do aumento da escala temporal. Esse crescimento faz com que para escalas a partir de 30 dias ( $\log n \sim 1.5$ ), as correlações passem a ser positivas. Nas escalas maiores de aproximadamente 250 dias ( $\log n \sim 2.4$ ), pode-se observar a influência dos preços da soja ( $\rho_{DPCCA} < \rho_{DCCA}$ ), refletindo diretamente na variação de preços das commodities: a variação de preços da soja afeta diretamente as correlações existentes entre os preços do frango e do milho. Os preços são diretamente influenciados pelo preço da soja e quando essa influência é excluída (com DPCCA), as correlações entre frango e milho se tornam mais fracas ( $\rho_{DPCCA} < \rho_{DCCA}$ ), indicando que as correlações intrínsecas entre as commodities relacionadas são mais fracas do que quando as interações com fator externo são consideradas para escalas maiores que 250 dias.

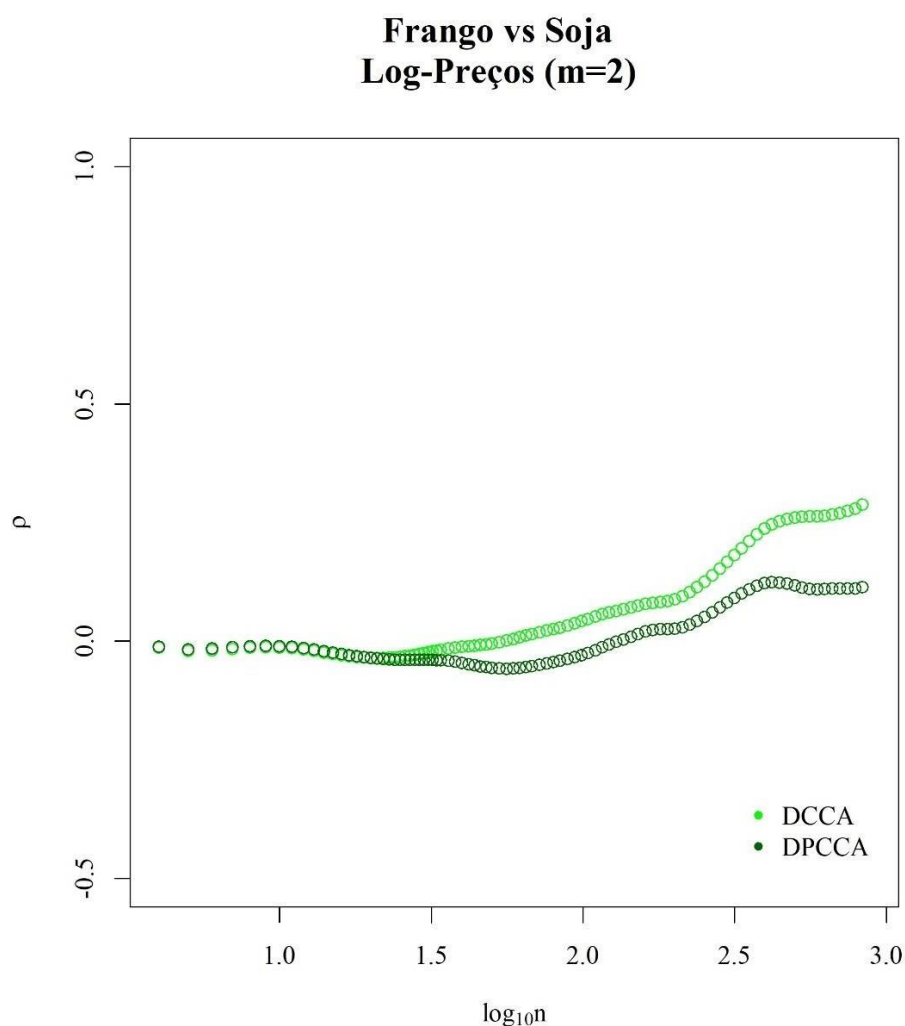
**Figura 4: Coeficiente DCCA e DPCCA das séries de retorno do preço do Frango e do Milho no período de Agosto de 2004 a Junho de 2017.**



Na Figura 5, pode-se observar os coeficientes DCCA e DPCCA (usando o polinômio de ordem  $m=2$  para retirar tendência local) das séries de retornos dos preços de frango e soja. Até a escala temporal de 30 dias ( $\log n \sim 1.5$ ) os retornos não são correlacionados ( $\rho_{DCCA} \sim 0$ ,  $\rho_{DPCCA} \sim 0$ ). A partir desta escala, as correlações intrínsecas entre frango e soja também se apresentam como negativas ( $\rho_{DPCCA} < 0$ ), até a escala de 180 dias ( $\log n \sim 2.25$ ) quando a correlação passa a ser positiva ( $\rho_{DPCCA} > 0$ ). Ainda com o aumento das escalas temporais, a partir de 30 dias é possível observar a influência dos preços do milho ( $\rho_{DPCCA} <$

$\rho_{DCCA}$ ), o que reflete diretamente na variação dos preços das commodities: a variação do preço do milho impacta as correlações entre preços de frango e soja. Ao se retirar a influência do milho (usando o DPCCA), correlações entre frango e soja se tornam mais fracas ( $\rho_{DPCCA} < \rho_{DCCA}$ ). O comportamento das correlações entre frango e soja é similar ao comportamento das correlações entre frango e milho, refletindo a interação entre as commodities agrícolas. Contudo, a correlação intrínseca entre frango e milho (Figura 4) é mais forte do que entre frango e soja (Figura 5), indicando que as variações nos custos do frango afetam mais os preços do milho do que variações de preços da soja, principalmente para escalas superiores a 250 dias.

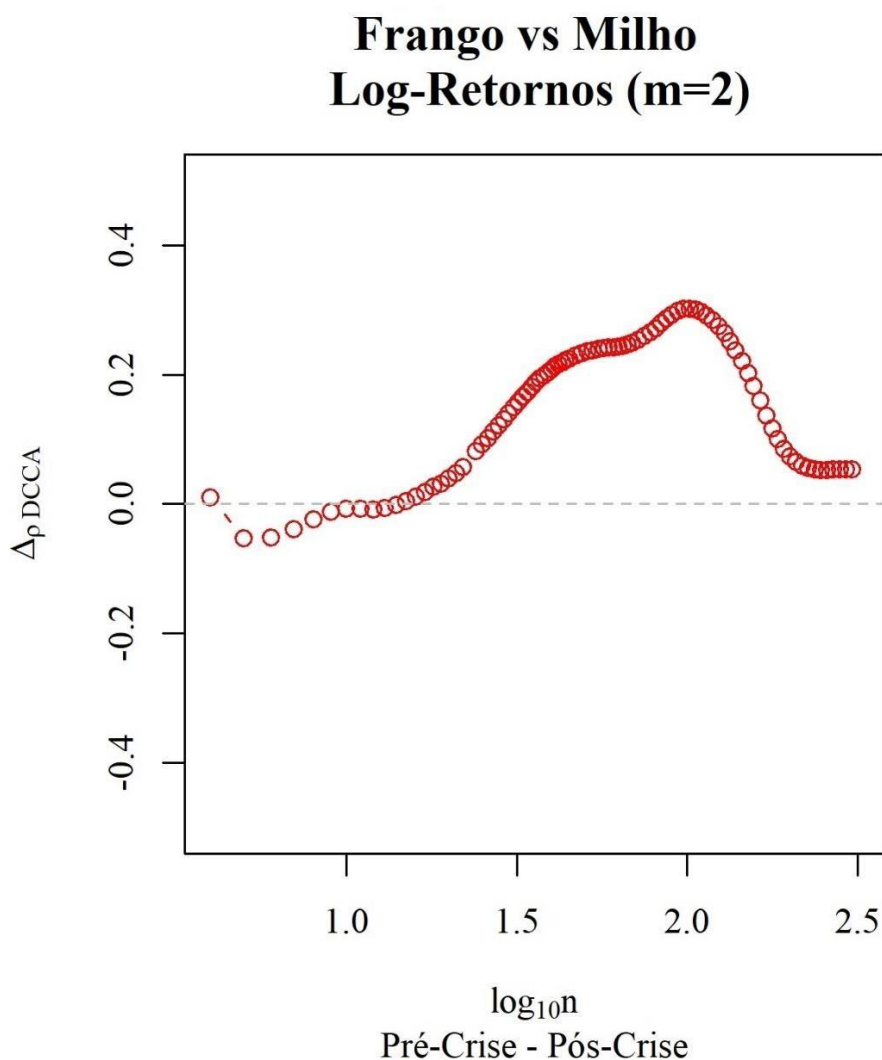
**Figura 5: Coeficiente DCCA e DPCCA das séries de retorno do preço do Frango e da Soja no período de Agosto de 2004 a Junho de 2017.**





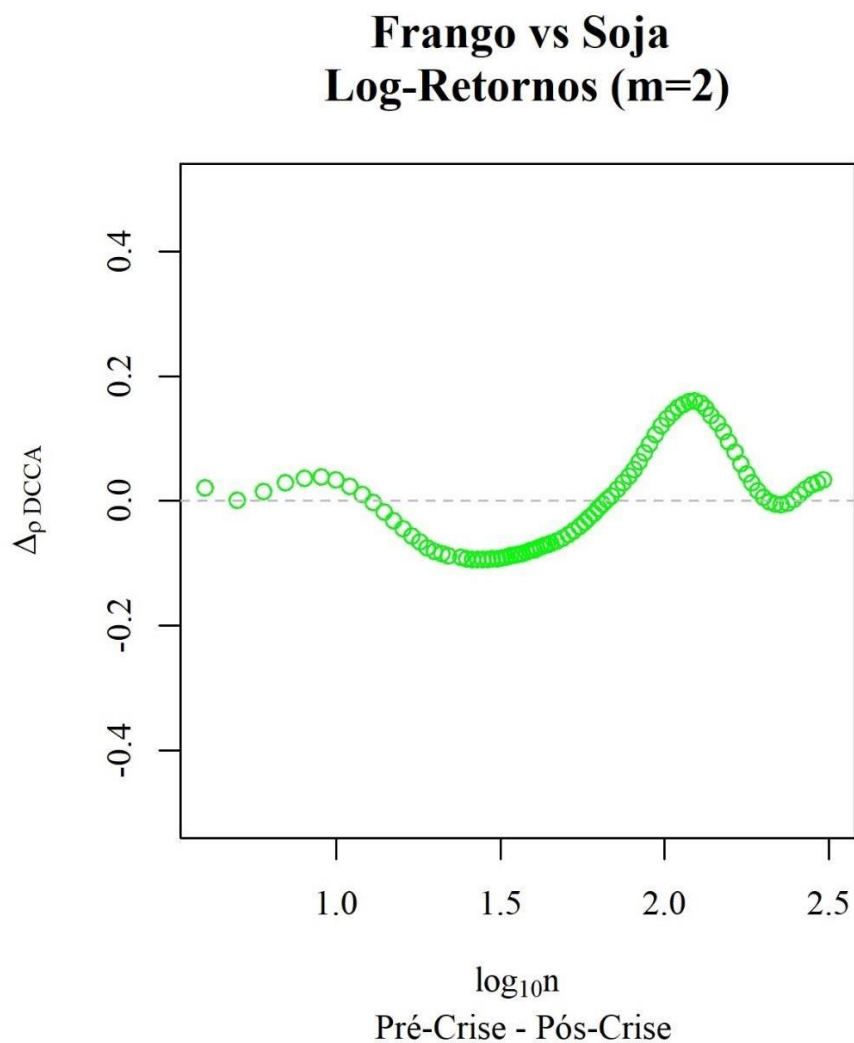
As figuras 6 e 7 apresentam a diferença entre os coeficientes DCCA para períodos antes (02/08/2004 - 15/09/2008) e depois (01/07/2009 - 16/06/2017) da crise de 2008:  $\Delta\rho_{DCCA} = \rho_{DCCA}(\text{antes}) - \rho_{DCCA}(\text{depois})$ , entre as séries de retornos de frango e milho (Figura 6) e frango e soja (Figura 7). Na Figura 6, pode se observar que a partir da escala de 30 dias ( $\log n \sim 1.5$ ),  $\Delta\rho_{DCCA}$  se torna positivo significando que as correlações diminuíram depois da crise de 2008. Mais especificamente,  $\Delta\rho_{DCCA}$  aumenta até a escala de 100 dias ( $\log n \sim 2$ ) e depois diminui. A partir da escala de 200 dias ( $\log n \sim 2.3$ ), não tem mais a diferença entre as correlações dos dois períodos ( $\Delta\rho_{DCCA} \sim 0$ ).

**Figura 6:  $\Delta\rho_{DCCA}$  das séries de retorno do preço do Frango e do Milho**



Na Figura 7, pode-se notar que  $\Delta\rho_{DCCA}$  oscila em torno de zero até a escala de 15 dias ( $\log n \sim 1.2$ ) e depois se torna negativo até a escala de 60 dias ( $\log n \sim 1.8$ ), significando que neste intervalo da escala, as correlações foram mais forte depois da crise de 2008. A partir desta escala até a escala de 200 dias ( $\log n \sim 2.3$ )  $\Delta\rho_{DCCA}$  se torna positivo, significando que as correlações diminuíram depois da crise.

**Figura 7:  $\Delta\rho_{DCCA}$  das séries de retorno do preço do Frango e da Soja**



As figuras 8 e 9 apresentam  $\Delta\rho_{DPCCA}$ , que representa a diferença entre os coeficientes DPCCA para séries de retorno de frango e milho (Figura 8) e frango e soja (Figura 9) para períodos antes (08/12/2003 - 16/09/2008) e depois (01/07/2009 - 17/06/2017) da crise de 2008. Observa-se na Figura 8 que no caso de frango e milho, para escalas entre 15 dias ( $\log n \sim 1.2$ ) e 200 dias ( $\log n \sim 2.3$ ),  $\Delta\rho_{DPCCA} > 0$ , significando que as correlações intrínsecas diminuíram depois da crise de 2008. Para outras escalas, não houve a alteração em correlações intrínsecas ( $\Delta\rho_{DPCCA} \sim 0$ ). No caso de frango e soja (Figura 9), as correlações intrínsecas aumentaram depois da crise 2008 ( $\Delta\rho_{DPCCA} < 0$ ), para intervalo de escala entre 15 dias ( $\log n \sim 1.2$ ) e 100 dias ( $\log n \sim 2$ ) e a partir de escala de 160 dias ( $\log n \sim 2.2$ ). Nas escalas entre 100 e 160 dias, as correlações intrínsecas foram mais fortes antes da crise ( $\Delta\rho_{DPCCA} > 0$ ).

**Figura 8:  $\Delta\rho_{DPCCA}$  das séries de retorno do preço do Frango e do Milho.**

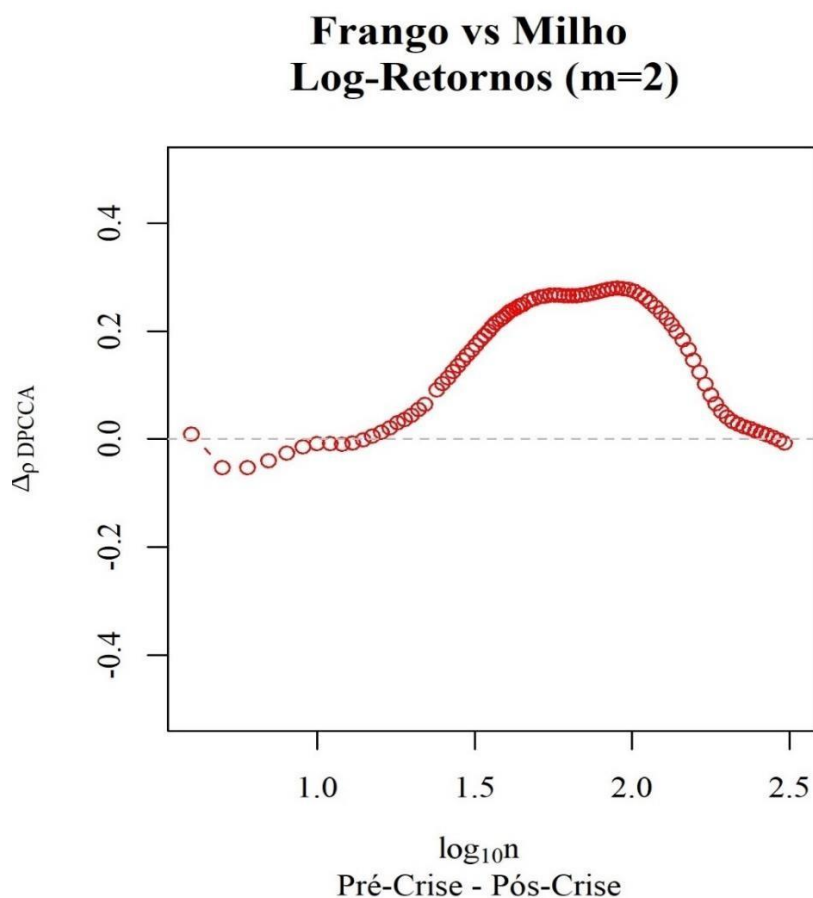



Figura 9:  $\Delta_p$ DPCCA das séries de retorno do preço do Frango e da Soja.

## 5 Conclusão

A relação entre as commodities alimentares no Brasil é profunda e ainda inexplorada em sua plenitude. Os mercados dessas commodities são altamente interligados e competitivos, sendo influenciados por fatores globais (taxa de câmbio) e por características locais específicas do desenvolvimento comercial brasileiro.

As commodities alimentares tem seus preços altamente correlacionados, contudo tais correlações não são devidamente trabalhadas ao se optar pelos métodos convencionais, ainda mais porque os preços da soja e do milho são afetados pelos preços do frango. Esse fato acaba por comprometer a real análise das correlações intrínsecas que tendem a ser diferentes para cada escala temporal. A técnica da DPCCA foi desenvolvida com o intuito de quantificar as correlações cruzadas de longo alcance entre series temporais que não sejam estacionárias, retirando a interferência de sinais externos. Esta técnica foi utilizada aqui para as series temporais dos preços de frango, soja e milho, a fim de estudar as correlações intrínsecas do mercado dessas commodities no Brasil. Os principais resultados foram:

- a) A ausência das correlações cruzadas significativas entre os pares das séries analisadas para escalas temporais inferiores a 30 dias.
- b) As correlações intrínsecas entre séries de retorno dos preços frango-milho são mais fortes quando há interação com fator externo para escalas superiores a 250 dias e para escalas de 30 a 180 dias, as correlações intrínsecas entre frango e soja são negativas, sendo positivas após esse período.
- c) As correlações intrínsecas entre as séries de retorno dos preços frango-milho são mais fortes do que entre as de retorno dos preços frango-soja, principalmente para escalas superiores a 250 dias.
- d) As correlações entre os preços de Frango e Milho diminuíram depois da crise de 2008. E a partir da escala de 200 dias, não há mais a diferença entre correlações dessas commodities nos períodos antes e após a crise.

- e) No intervalo de 15 a 60 dias, as correlações entre Frango e Soja foram mais fortes e de 60 a 200 dias, essas correlações diminuíram, depois da crise de 2008.
- f) As correlações intrínsecas dos preços de frango e milho diminuíram depois da crise de 2008. No caso de frango e soja, as correlações intrínsecas aumentaram depois da crise de 2008 e nas escalas entre 100 e 160 dias, as correlações intrínsecas foram mais fortes antes da crise.

Com isso, espera-se que os resultados obtidos venham corroborar para uma melhor compreensão da essência da relação dos mercados de alimentos e dessa forma acrescentar ao conjunto dos resultados já obtidos na área, necessários para o desenvolvimento dos modelos de previsão dos preços das *commodities* agrícolas. Os modelos dão um suporte para que o governo consiga ter um controle dos preços de alimentos nos períodos de crise e com isso, proteger a população mais vulnerável, que tem grande parte da sua renda comprometida com a compra de alimentos.

Para trabalhos futuros, é possível investigar de maneira mais profunda a correlação intrínseca entre os preços dessas commodities, fazendo uso da correlação parcial associado a outros métodos de análise fractal, como o *Multifractal Detrended Cross-Correlation Analysis* (MF-DCCA). Esta análise pode apresentar a natureza das correlações intrínsecas para subconjuntos das séries analisadas que possuem diferentes tamanhos de flutuações.

## 6 Referências

ARAÚJO, Caroliny Costa. Utilização do arroz, quirera e farelo de arroz integral na alimentação de frangos de crescimento lento. 2019.

ARAÚJO, Heliene Macedo de. O perfil do consumidor e a percepção das estratégias de marketing em três mercados de proximidades agroecológicos no estado de Minas Gerais. 2017.

BECKMANN, Joscha; CZUDAJ, Robert. Volatility transmission in agricultural futures markets. **Economic Modelling**, v. 36, p. 541-546, 2014.

BM&FBOVESPA - Bolsa de Valores, Mercadorias e Futuros. - Disponível em: <<http://www.portalbrasil.net/bovespa.html>>. Acesso em: 22 jan. 2020.

Centro de Estudos Avançados em Economia Aplicada – CEPEA. Disponível em: <<https://www.cepea.esalq.usp.br/br>>. Acesso em: 09 abr. 2020

CHEN, Yingyuan et al. DCCA cross-correlation coefficients reveals the change of both synchronization and oscillation in EEG of Alzheimer disease patients. **Physica A: Statistical Mechanics and its Applications**, v. 490, p. 171-184, 2018.

CONAB - Companhia Nacional de Abastecimento. Séries históricas de área plantada, produtividade e produção. 2019. Disponível em: <<https://www.conab.gov.br/info-agro/safras/serie-historica-das-safras>>. Acesso em: 20 de julho de 2020.

CONTESSA, Margareth Anne Camargo et al. A expansão do complexo de soja no Brasil. 2020.

DA SILVA, Marcus Fernandes et al. Quantifying the contagion effect of the 2008 financial crisis between the G7 countries (by GDP nominal). **Physica A: Statistical Mechanics and its Applications**, v. 453, p. 1-8, 2016.

DE NICOLA, Francesca; DE PACE, Pierangelo; HERNANDEZ, Manuel A. Co-movement of major energy, agricultural, and food commodity price returns: A time-series assessment. **Energy Economics**, v. 57, p. 28-41, 2016.

DEY, Pankaj; MUJUMDAR, P. P. Multiscale evolution of persistence of rainfall and streamflow. **Advances in water resources**, v. 121, p. 285-303, 2018.

DOS ANJOS, Priscilla Sales et al. Long-term correlations and cross-correlations in wind speed and solar radiation temporal series from Fernando de Noronha Island, Brazil. **Physica A: Statistical Mechanics and its Applications**, v. 424, p. 90-96, 2015.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. Disponível em: <https://www.embrapa.br/suinos-e-aves/cias/estatisticas/frangos/mundo>. Acesso em: 20 jul. 2020.

FERREIRA, Inês Sofia Morais. **Opções sobre Commodities**. 2016. Tese de Doutorado.



FERREIRA, Paulo et al. Detrended correlation coefficients between oil and stock markets: The effect of the 2008 crisis. **Physica A: Statistical Mechanics and its Applications**, v. 517, p. 86-96, 2019.

FERREIRA, R. C. **Quantificação Das Perdas Por Seca Na Cultura Da Soja O Brasil**. 2016. Tese de Doutorado. Universidade Estadual de Londrina.

FRASCAROLI, Bruno Ferreira; DE ARAÚJO CARVALHO, Patrícia Soares. Transmissão De Preços No Mercado De Bioetanol Entre Alagoas E Pernambuco: Uma Análise De Cointegração. **Revista de Economia e Agronegócio**, v. 14, n. 1, 2, 3, 2016.

FREITAS, Rogério Edivaldo; SANTOS, Gesmar Rosa dos. Exportações do complexo soja-milho-aves: concorrentes do Brasil e potenciais acordos bilaterais. 2017.

GOLDBERGER, Ary L. et al. Fractal dynamics in physiology: alterations with disease and aging. **Proceedings of the national academy of sciences**, v. 99, n. suppl 1, p. 2466-2472, 2002.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE/ SIDRA, Índice Nacional de Preços ao Consumidor Amplo 15 - Sistema IBGE de Recuperação de Dados Automática. Disponível em: <<http://www.sidra.ibge.gov.br/bda/default.asp>>. Acesso em 24 de Abril de 2020.

IFPRI - International Food Policy Research Institute. Global hunger In: Getting to zero hunger. 2016 Disponível em: <<https://www.ifpri.org/publication/2016-global-hunger-index-getting-zero-hunger>>. Acesso em: 20 de junho de 2020.

JIANG, Lei; ZHAO, Xia; WANG, Lu. Long-range correlations of global sea surface temperature. **PloS one**, v. 11, n. 4, p. e0153774, 2016.

JUN, Wang; DA-QING, Zhao. Detrended cross-correlation analysis of electroencephalogram. **Chinese Physics B**, v. 21, n. 2, p. 028703, 2012.

KANTELHARDT, Jan W. et al. Detecting long-range correlations with detrended fluctuation analysis. **Physica A: Statistical Mechanics and its Applications**, v. 295, n. 3-4, p. 441-454, 2001.

KESKIN, Berkay; CINAR, Gokhan. The spillover effect of imported inputs on broiler prices in Turkey. **New Medit: Mediterranean Journal of Economics, Agriculture and Environment= Revue Méditerranéenne d'Economie Agriculture et Environment**, v. 17, n. 1, 2018.

LIMA, Cristiane Rocha Albuquerque et al. Cross-correlations between Brazilian biofuel and food market: Ethanol versus sugar. **Physica A: Statistical Mechanics and its Applications**, v. 513, p. 687-693, 2019.

LIU, Li. Cross-correlations between crude oil and agricultural commodity markets. **Physica A: Statistical Mechanics and its Applications**, v. 395, p. 293-302, 2014.

LØVSLETTEN, Ola. Consistency of detrended fluctuation analysis. **Physical Review E**, v. 96, n. 1, p. 012141, 2017.

PAL, Debdatta; MITRA, Subrata K. Interdependence between crude oil and world food prices: A detrended cross correlation analysis. **Physica A: Statistical Mechanics and its Applications**, v. 492, p. 1032-1044, 2018.

PEREIRA, Luiz Andrei Gonçalves; DOS SANTOS, Igor José Ferreira; FERREIRA, William Rodrigues. Geografia do comércio de commodities, dinâmicas espaciais da logística de transportes e dos fluxos de exportações do setor de soja no Brasil. **Geografia Ensino & Pesquisa**, v. 23, p. 3, 2019.

PENG, C.-K. et al. Mosaic organization of DNA nucleotides. **Physical review e**, v. 49, n. 2, p. 1685, 1994.

PIAO, Lin; FU, Zuntao; YUAN, Naiming. "Intrinsic" correlations and their temporal evolutions between winter-time PNA/EPW and winter drought in the west United States. **Scientific reports**, v. 6, n. 1, p. 1-10, 2016.

PINHEIRO, Williane Silva et al. Panorama atual do mercado brasileiro de alimentos e bebidas. **Brazilian Journal of Development**, v. 6, n. 8, p. 60482-60487, 2020.

PODOBNIK, Boris et al. Cross-correlations between volume change and price change. **Proceedings of the National Academy of Sciences**, v. 106, n. 52, p. 22079-22084, 2009.

PODOBNIK, Boris; STANLEY, H. Eugene. Detrended cross-correlation analysis: a new method for analyzing two nonstationary time series. **Physical review letters**, v. 100, n. 8, p. 084102, 2008.

QIAN, Xi-Yuan et al. Detrended partial cross-correlation analysis of two nonstationary time series influenced by common external forces. **Physical Review E**, v. 91, n. 6, p. 062816, 2015.

SCHMIDT, N. S.; DA SILVA, C. L. Pesquisa e desenvolvimento na cadeia produtiva de frangos de corte no Brasil. **Revista de Economia e Sociologia Rural**, v. 56, n. 3, p. 467-482, 2018.

SHEN, Chen-hua; LI, Cao-ling. An analysis of the intrinsic cross-correlations between API and meteorological elements using DPCCA. **Physica A: Statistical Mechanics and its Applications**, v. 446, p. 100-109, 2016.

STOSIC, Tatijana et al. Identifying drought-induced correlations in the satellite time series of hot pixels recorded in the Brazilian Amazon by means of the detrended fluctuation analysis. **Physica A: Statistical Mechanics and its Applications**, v. 444, p. 660-666, 2016.

SU, Chi Wei et al. Do oil prices drive agricultural commodity prices? Further evidence in a global bio-energy context. **Energy**, v. 172, p. 691-701, 2019.

VASSOLER, R. T.; ZEBENDE, G. F. DCCA cross-correlation coefficient apply in time series of air temperature and air relative humidity. **Physica A: Statistical Mechanics and its Applications**, v. 391, n. 7, p. 2438-2443, 2012.

VIEIRA, Lucca Benchimol et al. Efetividade e razão ótima de hedge para barril de petróleo. 2020.

XU, Na; SHANG, Pengjian; KAMAE, Santi. Modeling traffic flow correlation using DFA and DCCA. **Nonlinear Dynamics**, v. 61, n. 1, p. 207-216, 2010.

YUAN, Naiming et al. Detrended partial-cross-correlation analysis: a new method for analyzing correlations in complex system. **Scientific reports**, v. 5, n. 1, p. 1-7, 2015.

ZEBENDE, Gillney Figueira. DCCA cross-correlation coefficient: Quantifying level of cross-correlation. **Physica A: Statistical Mechanics and its Applications**, v. 390, n. 4, p. 614-618, 2011.

ZEBENDE, G. F.; DA SILVA, M. F.; MACHADO FILHO, A. DCCA cross-correlation coefficient differentiation: Theoretical and practical approaches. **Physica A: Statistical Mechanics and its Applications**, v. 392, n. 8, p. 1756-1761, 2013.

ZHEN, Miao; RUDE, James; QIU, Feng. Price volatility spillovers in the western Canadian feed barley, US corn, and Alberta cattle markets. **Canadian Journal of Agricultural Economics/Revue canadienne d'agroeconomie**, v. 66, n. 2, p. 209-229, 2018.

ZHENG, Zeyu et al. Scaling of seismic memory with earthquake size. **Physical Review E**, v. 86, n. 1, p. 011107, 2012.