

JOSÉ EDVALDO DE OLIVEIRA NUNES

**ANÁLISE DE PREÇOS DE *COMMODITIES* AGRÍCOLAS BRASILEIRAS
UTILIZANDO O MÉTODO GRAFO DE VISIBILIDADE HORIZONTAL**

**RECIFE
FEVEREIRO DE 2021**



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

**ANÁLISE DE PREÇOS DE *COMMODITIES* AGRÍCOLAS BRASILEIRAS UTILIZANDO
O MÉTODO GRAFO DE VISIBILIDADE HORIZONTAL**

Dissertação apresentada ao Programa de Pós-graduação em Biometria e Estatística Aplicada da Universidade Federal Rural de Pernambuco como requisito parcial para obtenção do título de Mestre em Biometria e Estatística Aplicada.

Área de concentração: Biometria e Estatística Aplicada

Orientador: Prof. Dr. Borko Stosic

Coorientadora: Profa. Dra. Tatijana Stosic

RECIFE
FEVEREIRO DE 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)

- N972a Nunes, José Edvaldo de Oliveira
Análise de preços de commodities agrícolas brasileiras utilizando o método grafo de visibilidade horizontal / José Edvaldo de Oliveira Nunes. - 2021.
47 f. : il.
- Orientador: Borko Stosic.
Coorientadora: Tatijana Stosic.
Inclui referências.
- Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Biometria e Estatística Aplicada, Recife, 2021.
1. Mercado agrícola . 2. Redes complexas . 3. Séries temporais. 4. Grafos de visibilidade . I. Stosic, Borko, orient. II. Stosic, Tatijana, 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

ANÁLISE DE PREÇOS DE *COMMODITIES* AGRÍCOLAS BRASILEIRAS
UTILIZANDO O MÉTODO GRAFO DE VISIBILIDADE HORIZONTAL

JOSÉ EDVALDO DE OLIVEIRA NUNES

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:

Prof. Dr. Borko Stosic
Departamento de Estatística e Informática / UFRPE

Banca Examinadora:

Profa. Dra. Tatijana Stosic
Departamento de Estatística e Informática / UFRPE

Prof. Dr. José Rodrigo Santos Silva
Departamento de Estatística e Ciências Atuariais / UFS

Dedico esse trabalho aos meus pais

Agradecimentos

Agradeço primeiramente a Deus.

Agradeço a minha família, especialmente ao meus pais, José Edvânio e Marilene e meus irmãos, Ednaldo e Edgar, por todo apoio, incentivo e cuidado.

Agradeço ao meu orientador Professor Dr. Borko Stosic e minha coorientadora Professora Dr.^a Tatijana Stosic, por todo conhecimento repassado, pelas orientações, incentivo, auxílio e revisões dos textos para artigo e dissertação. Agradeço por me inspirarem a ser cada dia melhor.

Agradeço a Joelma, doutoranda do PPGBEA, por toda ajuda, amizade e parceria durante este trabalho e por toda paciência ao esclarecer minhas dúvidas. Agradeço também a Dr.^a Lidiane Araújo por toda ajuda e parceria na escrita do primeiro artigo de minha pesquisa. Agradeço a minha amiga Marília Gabriela (minha irmã acadêmica), pela amizade, inspiração e parceria desde a graduação.

Agradeço aos amigos do Departamento de Estatística e Informática: Rubem, Caio, Alexandre, Diego, João Batista, Luciano Serafin, Denise, Fábio, Felipe Mendonça, Kerolly, Mickaelle, Leika, Camila, Katiane, André, Elielma e Domingos. Foi muito bom conviver com vocês e ter a oportunidade de trocar experiências significativas.

Agradeço a Henrique, João e Eduardo (grupo dos “véi”), pelos conselhos, amizade e por tornarem os dias mais divertidos. Agradeço aos meus amigos Bruno e Danielly, pelo incentivo, boas vibrações e boas conversas. Agradeço também a Vaniele, uma das amigas mais importantes que ganhei com o mestrado. Agradeço a minha amiga Raile, pelas boas conversas, respeito e incentivo.

Agradeço a Augusto César e a Gabriela Izabel pela amizade e pelas caronas no fim da tarde. Agradeço também a Lucas (Luquinhas), Natália e Marciele pela amizade e pela oportunidade de aprendizagem e de troca de experiências durante o período que dividimos apartamento.

Agradeço aos meus professores da graduação, Dr. Dâmocles Aurélio, Dr. Maurício, Ms. Elizângelo, Dr.^a Marilene Rosa, Dr. Robson e Ms. Felipe Barreto (Agora colega de turma) pelo incentivo e inspiração ao longo dos anos.

Agradeço aos meus professores do Departamento de Estatística e Informática, Dr. Frank Sinatra, Dr. Guilherme Rocha, Dr. Moacyr, Dr. Glauco Gonçalves, Dr. Victor Medeiros, Dr.

Antônio Samuel e Dr. Lucian Bejan, pelos ensinamentos. De modo geral, agradeço a toda equipe do DEINFO.

Agradeço a Universidade Federal Rural de Pernambuco (UFRPE), pela estrutura; à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela bolsa de pesquisa; ao Centro de Estudos Avançados em Economia Aplicada (CEPEA) da Esalq/USP pela disponibilidade dos dados. Agradeço também aos membros da banca examinadora pelas contribuições para este trabalho.

Por fim, agradeço a todos os meus amigos e familiares que de alguma forma contribuíram para realização deste trabalho.

“Não se apavore nem desamine, pois o Senhor, o seu Deus, estará com você por onde você andar”.

- BÍBLIA SAGRADA, JOSUÉ 1:9

“Pense grande, mire alto, trabalhe duro e nunca desista”

- ANTONIO CAMAROTTI

Resumo

As *commodities* agrícolas estão diretamente associadas ao agronegócio e exercem papel fundamental na economia brasileira. Essas mercadorias podem ser consideradas as mais importantes, pois seu preço tem efeito significativo sobre a vida da população. O objetivo deste trabalho foi analisar a variação temporal e comparar a dinâmica dos preços de 11 *commodities* agrícolas brasileiras e também do etanol, cuja variação de preços está diretamente relacionada aos preços do açúcar, e com isso contribuir para o desenvolvimento e validação de modelos teóricos e computacionais para previsão de preços desse mercado. Foram analisadas séries de preços diários como também as séries dos retornos e de volatilidade registradas no período de janeiro de 2010 a dezembro de 2019. Utilizamos o método Grafo de Visibilidade Horizontal (HVG), baseado na teoria de redes complexas, que converte séries temporais em grafos por meio de um critério de visibilidade geométrico que associa cada dado da série temporal a um nó no grafo de visibilidade. Para cada série foram calculados o Coeficiente de Agrupamento, o Coeficiente λ (inclinação da reta semilogarítmica da distribuição de probabilidade do grau dos nós da rede) e o Comprimento Médio do Menor Caminho, que são índices usados para descrever a topologia de redes. Os resultados mostraram que as séries de preços de frango e de suíno geraram redes menos conectadas e especificamente a série de preços do frango, gerou uma rede mais integrada e as séries de preços de algodão, frango e trigo são governadas por processos caóticos, indicando que seus preços são menos previsíveis no período analisado, enquanto as demais séries de preços (9 do total de 12), por processos estocásticos correlacionados. Tanto as séries de retorno, quando as de volatilidade, tiveram redes com nível de conexão parecido, exceto o frango (rede menos conectada). Quanto ao nível de integração, os retornos de preços de boi gordo e bezerro geraram redes mais integradas e a volatilidade dos preços de frango e café redes menos integradas. Além disso, observamos que as séries dos retornos dos preços da soja parecem exibir um comportamento de série não correlacionada. Constatou-se também que metade das séries dos retornos e de volatilidade dos preços são geradas por processos caóticos. Com isso, o HVG se mostrou eficiente para o estudo da estrutura e à classificação dos processos que governam as séries financeiras de *commodities* agrícolas brasileiras.

Palavras-chave: Mercado agrícola; Redes complexas; Séries temporais; Grafos de visibilidade.

Abstract

Agricultural commodities are directly associated with agribusiness and exert a fundamental role on the Brazilian economy. These goods can be considered to be among the most important, as their price has a significant effect on the population's life. The objective of this work was to analyze the temporal price variation, and to compare the price dynamics of 11 Brazilian agricultural commodities with that of ethanol, whose price variation is directly related to sugar prices, and thus contribute to the development and validation of theoretical and computational tools for forecasting prices of that market. The daily price series were analyzed, as well as the series of returns and volatility recorded from January 2010 to December 2019. We used the Horizontal Visibility Graph (HVG) method, based on the complex network theory, which maps time series into graphs through a geometric visibility criterion that associates each time series data point to a node in the visibility graph. For each series, the Clustering Coefficient, the λ Coefficient (slope of the semi-logarithmic line of the probability distribution of the degree of the network nodes), and the Average Length of the Shortest Path was calculated, representing indexes used to describe the network topology. The results demonstrate that the chicken and pork price series generated less connected networks, and specifically the chicken price series generated a more integrated network. The cotton, chicken and wheat price series are governed by chaotic processes, indicating that their prices are less predictable in the analyzed period, while the other price series (9 out of 12), represent correlated stochastic processes. Both the return series and the volatility series correspond to networks with similar connection levels, except for chicken (a less connected network). Regarding the level of integration, the returns for live cattle and calf prices correspond to more integrated networks, and the volatility of chicken and coffee prices to less integrated networks. In addition, we observed that the series of soybean price returns appear to exhibit an uncorrelated series behavior. It was also found that half of the series of returns and price volatility are generated by chaotic processes. Thereby, the HVG proved to be efficient in studying the structure and classification of the processes that govern the financial series of Brazilian agricultural commodities.

Keywords: Agricultural market; Complex networks; Time series; Visibility graphs.

Lista de Figuras e Tabelas

Figura 1: Representação de um grafo não direcionado (a) e direcionado (b).	22
Figura 2: Estrutura de rede <i>World Wide Web</i> (a) e da internet (b).	23
Figura 3: Exemplo ilustrativo de uma série temporal representada por barras verticais (parte superior) e seu correspondente grafo de visibilidade gerado pelo algoritmo VG (parte inferior).	25
Figura 4: Exemplo ilustrativo de uma série temporal representada por barras verticais (a) e seu correspondente grafo de visibilidade gerado pelo algoritmo HVG (b).	27
Figura 5: Séries temporais de preços de <i>commodities</i> agrícolas registradas diariamente para o período, 03 de janeiro de 2011 a 04 de dezembro de 2019.	31
Figura 6: Séries temporais de retornos dos preços de <i>commodities</i> agrícolas registradas diariamente para o período, 03 de janeiro de 2011 a 04 de dezembro de 2019.	32
Figura 7: Séries temporais de retornos dos preços de <i>commodities</i> agrícolas registradas diariamente para o período, 03 de janeiro de 2011 a 04 de dezembro de 2019.	33
Tabela 1: Produção e Exportações brasileiras no <i>Ranking</i> Mundial em 2019.	18
Tabela 2: <i>Commodities</i> agrícolas.	30
Tabela 3: Medidas topológicas das redes do HVG obtidas das séries de preços de <i>commodities</i> agrícolas brasileiras.	38
Tabela 4: Medidas topológicas das redes do HVG obtidas das séries de retorno R de preços das <i>commodities</i> agrícolas brasileiras.	39
Tabela 5: Medidas topológicas das redes do HVG obtidas das séries de volatilidade de preços das <i>commodities</i> agrícolas brasileiras.....	40

Lista de Siglas e Abreviações

ARCH	Heterocedasticidade Condicional Autorregressivo (<i>Autoregressive Conditional Heterosedastic</i>)
ARIMA	Modelo Autorregressivo Integrado de Médias Móveis (<i>Autoregressive Integrated Moving Average</i>)
B3	Bolsa de valores do Brasil (Brasil, Bolsa, Balcão)
BM&FBOVESPA	Bolsa de Valores, Mercadorias e Futuros
CEPEA	Centro de Estudos Avançados em Economia Aplicada
CNA	Confederação da Agricultura e Pecuária do Brasil
ESALQ	Escola de Agricultura Luiz de Queiroz
FAO	Organização das Nações Unidas para Agricultura e Alimentação (<i>Food and Agriculture Organization</i>)
HVG	Grafo de Visibilidade Horizontal (<i>Horizontal Visibility Graph</i>)
LACUNA	Laboratório de Modelagem Estatística e Computacional de fenômenos Naturais Complexos
pH	Potencial Hidrogeniônico
PPGBEA	Programa de Pós-graduação em Biometria e Estatística Aplicada
PR	Estado do Paraná
RS	Estado do Rio Grande do Sul
S&P500	<i>Standard & Poor's 500</i>
SARIMA	Modelo Autorregressivo Integrado de Médias Móveis Sazonal (<i>Seasonal Autoregressive Integrated Moving Average</i>)
SC	Estado de Santa Catarina
SENAR	Serviço Nacional de Aprendizagem Rural
SP	Estado de São Paulo
UFRPE	Universidade Federal Rural de Pernambuco
USP	Universidade de São Paulo
VBP	Valor Bruto de Produção
VG	Grafo de Visibilidade (<i>Visibility Graph</i>)

Sumário

1 INTRODUÇÃO	14
1.1 Objetivos.....	16
1.1.1 Objetivo geral	16
1.1.2 Objetivos específicos.....	16
1.2 Estrutura da dissertação	16
2 REVISÃO DE LITERATURA.....	17
2.1 Commodities agrícolas	17
2.2 Crise alimentar e efeitos no Brasil	19
2.3 Séries temporais.....	21
2.4 Redes complexas	22
2.5 Transformação das séries temporais em redes complexas	23
2.6 Grafos de visibilidade.....	25
2.6.1 Critério de visibilidade do Grafo de Visibilidade.....	25
2.7 Grafo de Visibilidade Horizontal.....	26
2.7.1 Critério de visibilidade Grafo de Visibilidade Horizontal.....	26
2.8 Índices topológicos do Grafo de Visibilidade Horizontal.....	28
2.8.1 Coeficiente da distribuição de grau de nó	28
2.8.2 Coeficiente de Agrupamento	28
2.8.3 Comprimento Médio do Menor Caminho	29
3 DADOS E METODOLOGIA.....	30
3.1 Descrição dos dados.....	30
3.1.1 Açúcar (Indicador do açúcar cristal CEPEA/ESALQ – São Paulo).....	33
3.1.2 Algodão (Indicador do algodão em pluma CEPEA/ESALQ - prazo de 8 dias).....	34
3.1.3 Boi gordo (Indicador do boi gordo CEPEA/B3)	34
3.1.4 Café (Indicador do café arábica CEPEA/ESALQ).....	34
3.1.5 Soja (Indicador da soja CEPEA/ESALQ - Paraná).....	34
3.1.6 Arroz (Indicador do arroz em casca ESALQ/SENAR-RS).....	35
3.1.7 Bezerro (Indicador do bezerro ESALQ/BM&FBOVESPA - Mato Grosso do Sul) ..	35
3.1.8 Etanol (Indicador diário do etanol hidratado ESALQ/ BM&FBOVESPA Posto Paulínia - SP).....	35
3.1.9 Frango (Preços do frango congelado CEPEA/ ESALQ - Estado de SP).....	35
3.1.10 Milho (Indicador do milho ESALQ/BM&FBOVESPA)	36
3.1.11 Suíno (Indicador do suíno vivo CEPEA/ESALQ)	36
3.1.12 Trigo (Preço médio do trigo CEPEA/ESALQ – Paraná)	36
3.2 Metodologia.....	37
4 RESULTADOS E DISCUSSÃO	38

5 CONCLUSÕES.....	42
REFERÊNCIAS	44

1 INTRODUÇÃO

As *commodities* agrícolas são artigos primários provenientes da lavoura e de origem animal que funcionam tanto como fonte de alimento como matéria prima para a indústria, e podem ser consideradas como uma das mercadorias mais importantes, pois seu preço tem o efeito significativo sobre vida da população. Na economia brasileira, as *commodities* agrícolas exercem um papel fundamental, devido, principalmente, ao seu relevante percentual de participação nas exportações mundiais, como também o alto consumo interno (CNA, 2020).

O mercado de *commodities* atraíram considerável atenção de diversos pesquisadores, resultado do aumento dos preços das *commodities* alimentares que atingiram altos níveis em 2007/2008 com a crise alimentar e, posterior aumento em 2010/2011, em consequência do aumento da demanda por alimentos e rações, choques climáticos nas principais regiões produtoras de alimentos, aumento na produção de biocombustível, desvalorização do dólar, especulações, aumento no custo de produção, além de políticas comerciais (HOCHMAN et al., 2014), provocando insegurança alimentar (IVANIC; MARTIN; ZAMAN, 2012) e levando ao aumento de conflitos sociais e políticos, principalmente nos países em desenvolvimento (BELLEMARE, 2015).

Os mercados agrícolas mostraram um alto nível de integração, por meio da transmissão de preços (ARAUJO et al., 2019), no entanto, ainda é um grande desafio compreender suas interações e comportamento complexo. Nesse sentido, os preços das *commodities* agrícolas foram estudados usando métodos fractais e multifractais (LIU, 2014; STOSIC; NEJAD; STOSIC, 2020), teoria da informação (KRISTOUFEK; VOSVRDA, 2014; ALBARRACÍN E. et al., 2019; ARAÚJO et al., 2020) e estrutura de redes (TABAK; SERRA; CAJUEIRO, 2010; SANTANA et al., 2020). Neste trabalho, contribuímos com a literatura existente ao analisar a variação dos preços das *commodities* agrícolas brasileiras utilizando análise de redes complexas de séries temporais.

A análise de redes complexas de séries temporais tem sido amplamente usada para resolver problemas desafiadores em diferentes campos de pesquisa (ZOU et al., 2019). Do mesmo modo que a descoberta de comportamentos complexos de séries temporais não lineares, constituem um problema fundamental de interesse contínuo, devido a sua importância em diversas áreas (GAO et al., 2016) que buscam cada vez mais compreender a dinâmica de processos estocásticos e caóticos (LUQUE et al., 2009). Assim, a combinação da abordagem de análise de séries temporais não lineares e a teoria de redes complexas, já sendo amplamente

aceitas no campo das ciências de sistemas complexos com fortes ligações com a dinâmica não linear e a física estatística, se tornou um campo importante da análise de séries temporais não lineares com uma variedade de aplicações em uma gama de disciplinas (ZOU et al., 2019).

Para tornar as séries temporais acessíveis a técnicas complexas, é necessário transformá-las em uma representação de rede por meio de um algoritmo que defina vértices e arestas. Com isso, existem pelo menos três métodos baseados em lógicas diferentes: similaridade estatística mútua, que gera redes de proximidades; convexidade de observações sucessivas, que se obtêm grafos de visibilidade e probabilidades de transição que gera redes de transição (ZOU et al., 2019). O Grafo de Visibilidade (*Visibility Graph* - VG) (LACASA et al., 2008) e sua extensão, o Grafo de Visibilidade Horizontal (*Horizontal Visibility Graph* - HVG) (LUQUE et al., 2009) são algoritmos que mapeiam uma série temporal numa rede complexa, mediante um critério de visibilidade, e foram estabelecidos como ferramentas eficientes para investigar a dinâmica de sistemas complexos reais a partir de séries temporais (GAO et al., 2016). Nos últimos anos, o HVG tornou-se um método conhecido devido à sua simplicidade e bons resultados quando aplicado a dados reais e gerados artificialmente (GONÇALVES et al., 2016; ZHU; LI; WEN, 2014; MADL, 2016; AHMADI; PECHENIZKIY, 2016; BRAGA et al., 2016; LANGE; SIPPEL; ROSSO, 2018; VAMVAKARIS; PANTELOUS; ZUEV, 2018; SILVA et al., 2020), no entanto, ainda têm sido pouco utilizados nos estudos de mercados de *commodities*.

Neste trabalho analisamos a variação temporal dos preços de um grupo de 11 *commodities* agrícolas brasileiras e do etanol durante o período de janeiro de 2011 a dezembro de 2019 (período pós-crise dos alimentos). Utilizamos o método o grafo de visibilidade horizontal (HVG), recentemente desenvolvido para análise se séries temporais com base na teoria de redes complexas.

1.1 Objetivos

1.1.1 Objetivo geral

Analisar a variação temporal dos preços das *commodities* agrícolas brasileiras através das redes complexas.

1.1.2 Objetivos específicos

- I. Aplicar o método Grafo de Visibilidade Horizontal (HVG) nas séries dos preços das *commodities* agrícolas brasileiras;
- II. Analisar e comparar a dinâmica dos preços das *commodities* utilizando os índices da topologia da rede gerada pelo HVG.

1.2 Estrutura da dissertação

Este trabalho está organizado da seguinte maneira: Nesse capítulo apresentamos o fenômeno estudado e os objetivos da pesquisa. O capítulo 2 destaca os principais estudos da literatura que estão relacionados com este trabalho. Discutimos sobre as *commodities* agrícolas, a crise alimentar e os efeitos no Brasil, redes complexas, métodos de transformação de séries temporais em redes complexas e grafos de visibilidade. O capítulo 3 descreve os dados e a metodologia utilizada na pesquisa. O capítulo 4 apresenta os resultados e as discussões de acordo com a implementação do algoritmo HVG para as séries de preços das *commodities* agrícolas. As conclusões e propostas para trabalhos futuros são apresentadas no Capítulo 5.

2 REVISÃO DE LITERATURA

2.1 *Commodities* agrícolas

Commodities agrícolas são artigos homogêneos e primários provenientes da lavoura, que funcionam como matéria prima, são produzidos em larga escala, podem ser estocados sem perda de qualidade e constituem a base do desenvolvimento da economia brasileira e mundial, tendo em vista que são mercadorias indispensáveis para a sobrevivência humana (ROCHA; PEREIRA; MARTIN, 2020).

A palavra *commodity*, em tradução livre do inglês, significa mercadoria. Para um produto ser considerado uma *commodity* ele precisa ser comercializado nas bolsas de valores e de mercadorias em todo o mundo, através da compra e venda de ações e, para que isso seja possível, deve ser um bem de alto valor comercial (ROCHA; PEREIRA; MARTIN, 2020). Destacam-se alguns exemplos como: o açúcar, café, boi gordo, milho, soja, arroz e o algodão.

Ao longo da história, a agricultura brasileira presenciou a ascensão e declínio de ciclos sucessivos de produção de *commodities* como a cana-de-açúcar, algodão, cacau, borracha e café, em resposta às oscilações no comportamento da demanda do comércio internacional (QUEIROZ, 2009). Durante o período colonial o Brasil já era considerado um grande exportador de *commodities* agrícolas, como a cana-de-açúcar, café e algodão. Ainda não conhecidos como *commodities*, estes produtos foram responsáveis por caracterizar o Brasil, nos mercados globais, pela sua grande produção e clima favorável para as plantações agrícolas (ROCHA; PEREIRA; MARTIN, 2020).

A soja, por exemplo, cultivada e vendida como grão, é um produto estrategicamente importante para o Brasil. O país é um dos maiores exportadores do produto, devido ao seu alto valor no mercado internacional. Já a batata, mesmo sendo um bem agrícola homogêneo e cultivada na terra, não é uma *commodity* (ROCHA; PEREIRA; MARTIN, 2020). De modo geral, a diferença entre uma *commodity* e um gênero alimentício é o alto valor que possui no mercado.

Algumas *commodities* agrícolas, como grãos, gado e laticínios, são insumos alimentícios para pessoas e animais em todo mundo. Além disso, alguns produtos também são utilizados na indústria, para produção de novos produtos. O café pode ser moído e usado não só para beber, mas também na preparação de sobremesas; o algodão se transforma principalmente em roupas e é usado na confecção de tecidos para uso geral; o trigo é transformado em farinha, que é usada

para a fabricação de pães, massas e outros diversos alimentos, além de ser um componente para a produção de cerveja; e a borracha, originada do látex extraído da árvore seringueira, é utilizado para a fabricação de pneus, luvas de borracha, brinquedos, utensílios de cozinha e preservativos (ROCHA; PEREIRA; MARTIN, 2020).

Segundo a Organização das Nações Unidas para Agricultura e Alimentação (FAO), o valor econômico do setor agrícola, em dólares constantes de 2010 foi superior a 3 trilhões. Com a expectativa de que a população mundial alcance 11,8 bilhões em 2100, é provável que as *commodities* agrícolas tenham um papel ainda maior nas próximas décadas (PINES, 2020)

No Brasil, as *commodities* têm mais relevância por estarem associadas ao agronegócio, segmento da economia brasileira que contempla diversas atividades produtivas associadas à agricultura e pecuária, com alta utilização de tecnologia a fim de aumentar a sua produtividade (ROCHA; PEREIRA; MARTIN, 2020).

O valor bruto da produção (VBP) agropecuária brasileira alcançou 651,5 bilhões de reais em 2019, dos quais 400,7 bilhões de reais na produção agrícola e 250,8 bilhões de reais no segmento pecuário. A soja em grãos é a principal responsável pelo faturamento brasileiro no setor agropecuário, seguido pela pecuária de corte. O terceiro maior VBP é do milho, seguido do leite, cana-de-açúcar, frango, café e algodão. Embora possuam desafios nos mercados doméstico e internacional, os destinos e a diversidade de produtos exportados pelo agronegócio brasileiro aumentaram de forma significativa (CNA, 2020) (ver tabela 1).

Tabela 1: Produção e exportações brasileiras no *ranking* mundial em 2019.

Principais Produtos	Produção	Exportação
Açúcar	2º	1º
Café	1º	1º
Suco de laranja	1º	1º
Soja em grãos	2º	1º
Carne de frango	2º	1º
Carne bovina	2º	1º
Milho	3º	3º
Carne suína	4º	4º

Fonte: CNA (2020).

As *commodities* agrícolas, nos últimos anos, vêm sendo estudadas por diversos autores a exemplo de Nazlioglu, Erdem e Soytaş (2013) que analisaram a transmissão de volatilidade entre o petróleo e os preços do trigo, milho, soja e o açúcar e mostraram que a dinâmica de transmissão da volatilidade muda significativamente após a crise dos preços dos alimentos.

Mais recentemente, Hong, Li e Xu (2019) investigaram se os preços dos estoques de alimentos caem com as elevações das temperaturas globais e dos riscos de seca e com isso mostraram que os mercados de ações são ineficientes no que diz respeito às informações sobre tendências de seca. Albarracín E. et al., (2019) mostraram que a eficiência do mercado do etanol e do açúcar aumenta após a crise dos alimentos e que o mercado de energia é menos regular (mais eficiente) do que o mercado agrícolas.

O mercado de *commodities* agrícolas e a relação com a crise alimentar foi estudado também por Bohl, Gross e Souza (2019) que examinaram o papel das economias emergentes no processo global de formação de preços de *commodities* e as evidências dos mercados de café brasileiro e norte-americano, e descobriram que os mercados brasileiros são importantes no processo de formação de preços globais e sua influência aumentou durante os picos de preços. Stosic, Nejad e Stosic (2020) estudaram as propriedades multifractais das *commodities* agrícolas brasileiras e constataram que após a crise alimentar de 2007/2008 a eficiência do mercado aumenta. Mostraram também que o café apresenta menor eficiência de mercado para preços em reais do que em dólares americanos, o que reflete a presença de restrições no mercado agrícola doméstico. Araújo et al. (2020) também analisaram os preços das *commodities* agrícolas brasileiras e a influência da crise alimentar, usando quantificadores da teoria da permutação-informação e verificaram que o mercado de café apresenta a menor previsibilidade (maior eficiência), enquanto o mercado de suínos apresenta a maior previsibilidade (menor eficiência).

2.2 Crise alimentar e efeitos no Brasil

A crise do *suprime*, desencadeada em meados de 2007, tornou-se uma crise financeira internacional que se originou no mercado hipotecário de alto risco norte-americano, alastrando-se pelo mundo rapidamente, com efeitos expressivos na economia mundial. A crise internacional atingiu a economia brasileira em um bom cenário. As empresas estavam em boa fase, produzindo e planejando novos investimentos e o mercado de trabalho passava por um período também favorável e com isso o crédito bancário era indispensável. Porém, com a explosão da crise, o primeiro efeito sentido pelo Brasil correspondeu à escassez de crédito internacional (LIMA; DEUS, 2013; SILVA; NETO, 2014).

Além do efeito sobre a oferta de crédito, o Brasil sentiu fortemente o efeito da crise sobre o preço da moeda nacional e sobre os fluxos de capitais transacionados no país. A partir

de agosto de 2008, com a queda do banco norte-americano Lehman Brothers, a crise financeira internacional aprofundou-se, aumentando intensamente a aversão ao risco que, desencadeou um generalizado movimento de fuga de capitais e forte desvalorização das moedas das economias periféricas (LIMA; DEUS, 2013).

Diante dos sinais de aprofundamento da crise financeira internacional, ocorreu um retrocesso nas atividades econômicas que estavam sendo estimuladas pelos preços das *commodities*. Nos meses que antecederam a eclosão da crise no mercado internacional, os preços das *commodities* em geral sofreram elevado aumento, conjecturando o temor de uma crise alimentar mundial e um movimento especulativo em direção aos produtos agrícolas (FACHINELLO; MEURER, 2017)

Alguns dos mais importantes produtores mundiais de cereais como a China, União Europeia, Índia e Estados Unidos da América, mudaram suas políticas agrícolas e com isso ocorreu uma queda significativa nos níveis de estoques. Os níveis baixos de estoque contribuíram para uma maior volatilidade dos preços nos mercados mundiais, devido, principalmente, a incertezas em relação a adequação dos suprimentos em tempos de escassez de produção (FAO, 2008).

O crescimento econômico e global, a expansão de biocombustíveis, as flutuações da taxa de câmbio e a inflação dos preços da energia, especulações, política comercial e fatores climáticos, foram refletidos na inflação dos preços dos alimentos, culminando na crise alimentar (HOCHMAN et al., 2014). A crise de 2008, como é conhecida, afetou diretamente na segurança alimentar (SOUSA et al., 2019) por causar efeitos nutricionais negativas, pois as famílias mais pobres reduziram a ingestão de calorias, comprometendo a diversidade alimentar (IVANIC; MARTIN; ZAMAN, 2012). Apesar das famílias rurais obterem ganhos com os preços mais altos dos alimentos, os impactos dos altos preços sobre a pobreza continuaram negativos, pois os consumidores líquidos também eram relativamente pobres (IVANIC; MARTIN, 2008) e dependiam da produção de alimentos para sua subsistência, pois grande parte da renda familiar era utilizada para alimentação (HEADEY; FAN, 2008).

De acordo com (MATIAS-PEREIRA, 2009), os relatórios e indicadores produzidos por diferentes instituições multilaterais e órgãos de pesquisa econômica e estatística durante a crise, indicaram um processo de forte desaceleração econômica, com efeitos perversos sobre o emprego e a renda das populações mundiais. A produção automobilística, por exemplo, apresentou uma queda na produção que foi refletido na indústria, e no desemprego. A retração das exportações, no período crítico da crise, deixou de injetar cerca de 52,5 bilhões de reais na

economia brasileira, o que contribuiu para a queda da produção e a eliminação de postos de trabalho (FACHINELLO; MEURER, 2017).

2.3 Séries temporais

Uma série temporal é uma sequência de observações registradas sequencialmente em um período de tempo (ADHIKARI; AGRAWAL, 2013). Os exemplos de séries temporais são abundantes em áreas como economia, engenharia, ciências naturais e ciências sociais, onde podem ser apresentados, como uma sequência mensal da quantificação de mercadorias enviadas de uma fábrica, uma série semanal do número de acidentes aéreos, quantidades diárias de chuva, observações horárias feitas sobre o rendimento de um processo químico, entre outros (BOX et al., 2015).

Os objetivos da análise de séries temporais consistem em investigar o mecanismo gerador da série temporal, fazer previsões de valores futuros, descrever o comportamento da série com a construção de gráficos e verificação da existência de tendências, ciclos e variações sazonais, ou procurar periodicidades relevantes (MORETTIN; TOLOI, 2006). Com isso, a previsão de séries temporais pode fornecer uma base importante para o planejamento econômico e comercial, planejamento de produção, controle de estoque e produção ou controle e otimizações de processos industriais (BOX et al., 2015).

Muitos modelos importantes foram propostos na literatura para melhorar a precisão e a eficácia da previsão de séries temporais (ADHIKARI; AGRAWAL, 2013). Um dos modelos mais conhecidos e frequentemente utilizados é o Modelo Autorregressivo Integrado de Médias Móveis (*Autoregressive Integrated Moving Average - ARIMA*) e o Modelo Autorregressivo Integrado de Médias Móveis Sazonal (*Seasonal Autoregressive Integrated Moving Average - SARIMA*).

Os modelos lineares têm chamado muita atenção devido à sua relativa simplicidade na compreensão e implementação. No entanto, em muitas situações, uma série temporal pode exibir comportamentos que mostram padrões não lineares (ADHIKARI; AGRAWAL, 2013), por exemplo, as leis dinâmicas da natureza bem como as atividades humanas raramente são lineares (ZOU et al., 2019). Com isso, na literatura há uma grande variedade de modelos não-lineares como, por exemplo, os Modelos de Heterocedasticidade Condicional Autorregressivo (*Autoregressive Conditional Heterosedastic - ARCH*).

Diferentes métodos de análise de séries temporais foram desenvolvidos para cumprir a tarefa de caracterizar processos dinâmicos em um sistema complexo, entre estes métodos, a análise do caos, análise fractal, gráfico de recorrência, medida de complexidade, *multiscale entropy*, entre outros. Porém, quando um sistema se torna mais complexo, os métodos tradicionais de análise de séries temporais têm dificuldade em lidar com os encargos específicos desse aumento da complexidade e fica difícil descrever o comportamento dinâmico das séries (GAO; SMALL; KURTHS, 2017).

2.4 Redes complexas


As redes complexas descrevem uma grande variedade de sistemas na natureza e na sociedade em diversas áreas. Historicamente, o estudo sobre redes complexas tem foco da teoria dos grafos (BOLLOBÁS, 2013). A teoria dos grafos, desde seu nascimento em 1736, quando o matemático suíço Leonhard Euler publicou a solução para o problema da ponte de Königsberg, presenciou importantes desenvolvimentos e forneceu respostas para uma série de perguntas práticas. Além das pesquisas na teoria matemática dos grafos, o estudo das redes teve conquistas importantes em outros ramos, como por exemplo as ciências sociais (BOCCALETTI et al., 2006).

Um grafo não direcionado ou direcionado (figura 1) é indicado por $G = (N, L)$, onde N e L são dois conjuntos de modo que $N \neq \emptyset$ e L é um conjunto de pares de elementos não ordenados ou ordenados de N . Os elementos de $N \equiv \{n_1, n_2, \dots, n_M\}$ são os nós (ou vértices) do grafo G , enquanto os elementos de $L \equiv \{l_1, l_2, \dots, l_K\}$ são os links (ou ligações ou arestas). O número de elementos de N e L são indicados por M e K respectivamente. Em um grafo não direcionado, cada uma das arestas é definida por alguns nós i e j , e é indicada como (i, j) ou l_{ij} e esses nós são referidos como adjacentes ou vizinhos. Em um grafo direcionado, a ordem dos dois nós é importante: l_{ij} representa uma aresta de i para j , e $l_{ij} \neq l_{ji}$ (BOCCALETTI et al., 2006). A maneira usual de imaginar um grafo é desenhando um ponto para cada nó e juntando dois pontos por uma linha.

Figura 1: Representação de um grafo não direcionado (a) e direcionado (b).

(a)


(b)



Fonte: (BOCCALETTI et al., 2006).

Diversos sistemas levaram a comunidade científica a investigar os mecanismos que determinam a topologia de redes complexas. Dentre esses sistemas destacam-se a *World Wide Web* (WWW) (figura 2(a)), que representa a maior rede para a qual informações topológicas estão disponíveis atualmente em que os nós da rede são os documentos (páginas da *web*) e as ligações/conexões são os *hiperlinks* (URLs); a internet (figura 2(b)); rede de colaboração de atores; rede de colaboração científica, em que os nós são os cientistas e dois nós estão conectados se dois cientistas escreveram um artigo juntos; redes ecológicas alimentares, em que os nós são as espécies e as ligações representam relações predador-presa (ALBERT; BARABÁSI, 2002).

Figura 2: Estrutura de rede *World Wide Web* (a) e da internet (b).



Fonte: (ALBERT; BARABÁSI, 2002).

2.5 Transformação das séries temporais em redes complexas

A literatura sobre análise de redes vem crescendo em um ritmo acelerado devido às suas amplas aplicações em diversos campos de pesquisa e novas metodologias estão sendo propostas para mapear uma série temporal numa rede complexa (GAO; SMALL; KURTHS, 2017).

Segundo (ZOU et al., 2019), as séries temporais precisam ser transformadas para que sejam acessíveis as técnicas complexas de análise de rede por meio de um algoritmo que defina vértices e arestas. Algumas classes de abordagens de redes complexas para análise de séries temporais são:

- (i) Similaridade estatística mútua ou proximidade métrica entre diferentes segmentos de uma série temporal;
- (ii) Convexidade de observações sucessivas;
- (iii) Probabilidade de transição entre estados discretos.

A primeira classe faz uso de semelhanças ou relações de proximidade entre diferentes partes da trajetória de um sistema dinâmico. Um exemplo importante de redes de proximidades são as redes de recorrência. A segunda classe são os grafos de visibilidade e conceitos relacionados e a terceira são as redes de transição, que fazem uso de ideias de dinâmicas simbólicas e processos estocásticos (ZOU et al., 2019).

Um mapeamento de séries temporais em redes complexas foi proposto por Zhang e Small (2006) que investigaram séries pseudoperiódicas, mostrando que os nós da rede correspondem diretamente a ciclos na série temporal, e a conectividade de rede é determinada pela força da correlação temporal entre os ciclos. Lacasa et al. (2008) apresentaram uma nova metodologia para caracterizar séries temporais em redes complexas: o Grafo de Visibilidade (*Visibility Graph* - VG). A ideia principal deste algoritmo é estudar até que ponto as técnicas da teoria dos grafos são úteis para estudar as séries temporais. Esse método tem recebido muita atenção, uma vez que abre a possibilidade de construir conexões importantes entre a análise de séries temporais, dinâmica não linear e teoria dos grafos (LACASA; TORAL, 2010). O grafo gerado herda várias propriedades das séries em sua estrutura, e o seu estudo revela informações não triviais sobre a série (LACASA et al., 2008). Essas descobertas sugerem que o grafo de visibilidade pode capturar as propriedades dinâmicas do processo que gerou a série (LUQUE et al., 2009).

Uma versão geometricamente mais simples e analiticamente solucionável do VG é o Grafo de Visibilidades Horizontal (*Horizontal Visibility Graph* - HVG) (LUQUE et al., 2009). O HVG vem sendo utilizado em diferentes áreas, como na medicina, para o estudo de estágios de sono (ZHU; LI; WEN, 2014), análise de rede de intervalos de pulsação (MADL, 2016) e para medir a sincronização entre sinais cerebrais (AHMADI; PECHENIZKIY, 2016); na hidrologia, para caracterização das flutuações do fluxo de rios (BRAGA et al., 2016) e para o

estudo da dinâmica não linear do escoamento (LANGE; SIPPEL; ROSSO, 2018) e em finanças, para o estudo do comportamento do preço das ações da S&P 500 (VAMVAKARIS; PANTELOUS; ZUEV, 2018). Mais recentemente o HVG foi utilizado para o estudo de séries temporais de focos de calor em biomas brasileiros (SILVA et al., 2020).

2.6 Grafos de visibilidade

Os grafos de visibilidade foram apresentados na literatura como um novo método para análise de séries temporais. O VG e o HVG mapeiam séries temporais em grafos, em que cada nó corresponde, na mesma ordem, aos dados da série, e dois nós são conectados de acordo com um critério geométrico de visibilidade.


2.6.1 Critério de visibilidade do Grafo de Visibilidade

Sejam y_a e y_b dois valores da série temporal observados em tempo t_a e t_b , com $t_a < t_b$. Eles terão visibilidade e, conseqüentemente, serão nós conectados do grafo, se todos outros dados y_c observados em tempo t_c com $t_a < t_c < t_b$, satisfazem a seguinte regra:

$$y_c < y_b + (y_a - y_b) \frac{t_a - t_c}{t_b - t_a}. \quad (1)$$

No grafo associado, cada nó “ver”, pelo menos, seus vizinhos mais próximos a direita e esquerda. O grafo também é não direcionado (não há direção definida das ligações) e invariante sob transformações afins dos dados da série, ou seja, o critério de visibilidade é invariante sob reescalonamento de ambos os eixos horizontal e vertical, e sob translações horizontal e vertical (LACASA et al., 2008). A figura 3 mostra um exemplo de uma série temporal (20 valores de dados) e o grafo associado derivado do algoritmo de visibilidade. No grafo, cada nó corresponde, na mesma ordem, aos dados da série. Os raios de visibilidade entre os dados definem ligações conectando nós no grafo.

Figura 3: Exemplo ilustrativo de uma série temporal representada por barras verticais (parte superior) e seu correspondente grafo de visibilidade gerado pelo algoritmo VG (parte inferior).



Fonte: (LACASA et al. 2008).

2.7 Grafo de Visibilidade Horizontal

Luque et al. (2009) apresentaram resultados sobre as propriedades dos grafos de visibilidade, e para obter estes resultados exatos, introduziram uma modificação do VG que é o Grafo de Visibilidade Horizontal (*Horizontal Visibility Graph - HVG*). Esse novo algoritmo é semelhante ao anterior, porém possui um critério de visibilidade geométrico mais simples.

2.7.1 Critério de visibilidade Grafo de Visibilidade Horizontal


Seja $\{x_i\}_{i=1,\dots,N}$ uma série temporal de N dados. O algoritmo associa cada dado da série temporal a um nó no grafo de visibilidade horizontal de acordo um critério geométrico de visibilidade. Dois nós i e j são conectados no grafo se for possível traçar uma linha horizontal na série temporal que una x_i e x_j que não intercepte nenhuma altura intermediária de dados (LUQUE et al., 2009). Logo, dois nós serão conectados se:

$$x_i, x_j > x_n \text{ para todos os } n \text{ tais que } i < n < j. \quad (2)$$

Dada uma série temporal, seu grafo de visibilidade horizontal é sempre um subgrafo do grafo de visibilidade associado. Um exemplo ilustrativo do algoritmo HVG é apresentado na Figura 4. Cada dado na série (Figura 4(a)) corresponde a um nó no grafo (Figura 4(b)), enumerado segundo a correspondência temporal do respectivo dado da série. Dois nós do grafo são conectados se suas alturas de dados correspondentes forem maiores do que todas as alturas

de dados entre eles. As linhas horizontais na série indicam as possíveis conexões do grafo, estabelecidas de acordo com o critério geométrico. A altura de cada barra vertical indica um dado da série temporal. Deve-se notar que, por exemplo, foi possível traçar linhas entre o dado x_5 e os dados x_3 , x_4 e x_6 sem que nenhuma barra vertical fosse interceptada. Qualquer outra conexão entre esse dado (x_5) e os demais violaria o critério de visibilidade descrito em (2). Assim, o nó $i = 5$ do grafo de visibilidade gerado está conectado apenas aos nós $j = 3$, $j = 4$ e $j = 6$.

Figura 4: Exemplo ilustrativo de uma série temporal representada por barras verticais (a) e seu correspondente grafo de visibilidade gerado pelo algoritmo HVG (b).



Fonte: Luque et al. (2009). Adaptado pelo autor.

O grafo gerado pelo HVG apresenta as seguintes propriedades (LUQUE et al., 2009):

- (i) Conectado: cada nó ver pelo menos seus vizinhos mais próximos, do lado esquerdo e lado direito;
- (ii) Invariante diante de transformações afins dos dados das séries temporais: o critério de visibilidade é invariante sob o redimensionamento dos eixos horizontais e verticais;
- (iii) Caracteres reversíveis e irreversíveis do mapeamento: algumas informações sobre as séries temporais são inevitavelmente perdidas no mapeamento, devido ao fato de que a estrutura da rede é completamente determinada na matriz de adjacência;
- (iv) Caracteres não direcionados ou direcionados: apesar desse algoritmo gerar grafos não direcionados, também é possível extrair um grafo direcionado de forma que, para um determinado nó, seja necessário distinguir os graus de entrada e saída;

- (v) Comparação entre critérios geométricos: o critério geométrico definido para o algoritmo de visibilidade horizontal é mais "restritivo à visibilidade" do que para o caso geral do algoritmo de visibilidade.

2.8 Índices topológicos do Grafo de Visibilidade Horizontal

Uma rede obtida do algoritmo VG ou HVG pode ser representada por sua matriz de adjacência $A = [a_{ij}]$ em que $a_{ij} = 1$ se os nós i e j são conectados e $a_{ij} = 0$, caso contrário. A matriz A pode ser usada para calcular as propriedades topológicas da rede (LACASA et al., 2008; LUQUE et al., 2009).

2.8.1 Coeficiente da distribuição de grau de nó

Em um grafo, nós diferentes podem ter um número diferente de conexões e a quantidade de conexões é chamada grau do nó. O grau é uma característica fundamental de uma rede, pois permite derivar muitas medidas importantes (SIVAKUMAR; WOLDEMESKEL, 2015).

A distribuição de graus dos nós é definida por uma função de distribuição $P(k)$ e fornece a probabilidade de um nó selecionado aleatoriamente ter exatamente k conexões. Por exemplo, em grafo puramente aleatório, uma vez que as conexões são colocadas aleatoriamente, a maioria dos nós tem aproximadamente o mesmo grau e se aproxima do grau médio \bar{k} da rede (ALBERT; BARABÁSI, 2002).

Lacasa e Toral (2010) mostraram que uma série mapeada em um grafo de visibilidade horizontal tem distribuição exponencial de graus da forma $P(k) \sim \exp(-\lambda k)$, em que λ é a inclinação da reta semilogarítmica da distribuição de probabilidade do grau do nó, que tende lentamente ao seu valor assintótico para correlações muito fracas, onde $\lambda < \ln(3/2)$ caracteriza um processo caótico, $\lambda > \ln(3/2)$ caracteriza um processo estocástico correlacionado e $\lambda = \ln(3/2)$ corresponde ao caso não correlacionado.

2.8.2 Coeficiente de Agrupamento

O coeficiente de agrupamento de uma rede mede a probabilidade de nós criarem grupos unidos com uma densidade relativamente alta de conexões (WATTS; STROGATZ, 1998). O coeficiente de agrupamento C é definido da seguinte forma. Suponha que um nó i tenha k_i

vizinhos; então, no máximo $k_i (k_i - 1) / 2$ arestas podem existir entre elas ou seja, isso ocorre quando todos os vizinhos de i estão conectados a todos os outros vizinhos. Com isso, a razão entre o número (E_i) de conexões que realmente existem entre esses nós k_i e o número total $k_i (k_i - 1) / 2$ fornece o coeficiente de agrupamento local, definido por:

$$C_i = \frac{2E_i}{k_i (k_i - 1)}. \quad (3)$$

Este procedimento é análogo para cada nó da rede. O valor médio do coeficiente de agrupamento C de todos os nós é chamado de coeficiente de agrupamento médio da rede, definido por:

$$C = \frac{1}{n} \sum_{i=1}^n C_i, \quad (4)$$

onde n é o número de nós na rede. Por definição $0 \leq C_i \leq 1$ e $0 \leq C \leq 1$.

2.8.3 Comprimento Médio do Menor Caminho

Uma importante medida de separação entre dois nós no grafo é dada pelo comprimento médio do caminho (BOCCALETTI et al., 2006). Esta medida indica o quão bem integrado é um grafo e a facilidade de transportar informações ou outras entidades na rede. O comprimento médio do menor caminho é definido como a média do caminho mais curto entre todos os pares possíveis de nós:

$$\langle d_{ij} \rangle = \frac{1}{N(N-1)} \sum_{ij} d_{ij}, \quad (5)$$

onde $d_{i,j}$ é a menor distância entre os nós i e j , ou seja, o número de arestas percorridas do menor caminho para ir de i até j (STAM; REIJNEVELD, 2007). Quanto menor for esse comprimento, mais integrada é a rede e mais eficiente será o transporte de informações dentro dela.

3 DADOS E METODOLOGIA

3.1 Descrição dos dados

Os dados utilizados nesta pesquisa são os preços diários de 12 *commodities* agrícolas brasileiras (tabela 2) registradas diariamente para o período de 03 de janeiro de 2011 a 04 de dezembro de 2019 (total de 2191 dados para cada série). Os dados foram obtidos no Centro de Estudos Avançados em Economia Aplicada / Escola de Agricultura Luiz de Queiroz / Universidade de São Paulo - CEPEA / ESALQ / USP (CEPEA, 2020).


Tabela 2: *Commodities* agrícolas.

Nome	Moeda/Unidade de medida
Açúcar	R\$/Saca de 50 kg
Algodão	R\$/Libra-peso de pluma 0,453597 kg
Arroz	R\$/Saca de 50 kg
Bezerro	Animal vivo (R\$/Cabeça)
Boi gordo	R\$/Arroba
Café	R\$/Saca de 60 kg
Etanol	R\$/m ³
Frango	R\$/kg
Milho	R\$/Saca de 60 kg
Soja	R\$/Saca de 60 kg
Suíno	R\$/kg
Trigo	R\$/Tonelada

Fonte: (CEPEA, 2020).


Para cada uma das *commodities* calculamos os retornos logarítmicos diários $R_t = \ln(P_t) - \ln(P_{t-1})$ onde P_t é o preço no dia t e a volatilidade: $|R_t|$. As séries originais de preços, as séries de retornos e volatilidade calculadas a partir dos preços em reais são mostradas na figura 5, figura 6 e figura 7 respectivamente.

Figura 5: Séries temporais de preços de *commodities* agrícolas registradas diariamente para o período, 03 de janeiro de 2011 a 04 de dezembro de 2019.




Fonte: Elaborados pelo autor a partir dos dados do CEPEA (2020).

Figura 6: Séries temporais de retornos dos preços de *commodities* agrícolas registradas diariamente para o período, 03 de janeiro de 2011 a 04 de dezembro de 2019.



Fonte: Autor.

Figura 7: Séries temporais de retornos dos preços de *commodities* agrícolas registradas diariamente para o período, 03 de janeiro de 2011 a 04 de dezembro de 2019.



Fonte: Autor.

Nas subseções seguintes são apresentadas as especificações sobre as *commodities* destacadas na tabela 2, de acordo com as metodologias do CEPEA.

3.1.1 Açúcar (Indicador do açúcar cristal CEPEA/ESALQ – São Paulo)

Descrição do produto: açúcar cristal com mínimo de polarização de 99,7 graus, máximo de 0,10% de umidade, máximo de 0,07% de cinzas, ensacado em sacas novas de polipropileno, destinado ao mercado interno. A região de referência é o estado de São Paulo, dividido nas regiões de Piracicaba, Ribeirão Preto, Jaú, Assis, Rio Preto e Araçatuba. Os valores coletados

se referem a negócios efetivados no dia do fechamento do indicador entre usinas e compradores (CEPEA, 2020).

3.1.2 Algodão (Indicador do algodão em pluma CEPEA/ESALQ - prazo de 8 dias)

Descrição do produto: algodão em pluma tipo 41, folha 4 - cor estritamente abaixo da média (strict low middling) – (antigo tipo 6, fibra 30/32 mm, sem característica). Os valores coletados se referem a negócios realizados no mercado físico, para pronta entrega (CEPEA, 2020).

3.1.3 Boi gordo (Indicador do boi gordo CEPEA/B3)

Este indicador é uma média diária ponderada de preços à vista do boi gordo no estado de São Paulo. O gado considerado para o indicador são bovinos machos, com 16 arrobas líquidas ou mais de carcaça e idade máxima de 42 meses. As regiões de referência são, Araçatuba, Presidente Prudente, Bauru, São José do Rio Preto e Vale do Paraíba (CEPEA, 2020).

3.1.4 Café (Indicador do café arábica CEPEA/ESALQ)

Descrição do produto: café arábica tipo 6, bebida dura para melhor, bem preparado, com até 86 defeitos por amostra de 300 gramas. As regiões de referência são o Cerrado e Sul de Minas Gerais, Mogiana (SP), Graça (SP) e noroeste do Paraná posto na cidade de São Paulo. O indicador se refere a negócios no mercado de lotes (CEPEA, 2020).

3.1.5 Soja (Indicador da soja CEPEA/ESALQ - Paraná)

Descrição do produto: soja em grão a granel, tipo exportação, conforme padrão Concex: até 14% de umidade, até 2% de impurezas, e limites máximos de 8% para grãos avariados (até 5% de ardidos) e 30% de grãos quebrados. A região de referência é o estado do Paraná, dividido

nas regiões Paranaguá, Ponta Grossa, Norte, Oeste e Sudoeste. O indicador se refere a negociações no mercado físico de lotes entre empresas (CEPEA, 2020).

3.1.6 Arroz (Indicador do arroz em casca ESALQ/SENAR-RS)

Arroz em casca, posto indústria, com rendimento do grão de 57% maior e 58% (menor, igual e maior) de grãos inteiros, com cerca de 10% de grãos quebrados por 100 gramas. As médias regionais são ponderadas pela respectiva participação do beneficiamento no total do estado no ano-safra anterior. O resultado, em reais, é o indicador do arroz em casca do Rio Grande do Sul ESALQ/SENAR-RS (CEPEA, 2020).

3.1.7 Bezerro (Indicador do bezerro ESALQ/BM&FBOVESPA - Mato Grosso do Sul)

Bezerro desmamado, macho, nelore, com idade entre 8 e 12 meses; valores coletados se referem a negócios realizados no mercado físico – preços ao produtor (a retirar na propriedade rural). A região de referência é o estado de Mato Grosso do Sul, dividido em cinco regiões: Três Lagoas, Campo Grande, Dourados, Pantanal e Cassilândia. O cálculo é feito pela média aritmética dos preços do bezerro nas principais regiões produtoras (CEPEA, 2020).

3.1.8 Etanol (Indicador diário do etanol hidratado ESALQ/ BM&FBOVESPA Posto Paulínia - SP)

Etanol hidratado combustível. Negociações realizadas nas usinas do Centro-Sul direcionadas às bases de armazenamento e distribuição de Paulínia e também enviadas às bases de regiões de ‘influência de Paulínia’, independente do estado de origem, sendo elas: Guarulhos, Barueri, Santo André, São Caetano do Sul, São José dos Campos, Cubatão, Ipiranga e São Paulo (CEPEA, 2020).

3.1.9 Frango (Preços do frango congelado CEPEA/ ESALQ - Estado de SP)

Frango inteiro abatido (congelado e resfriado). As regiões de referência são: estados do Rio Grande do Sul, Santa Catarina, Paraná, São Paulo e Minas Gerais. No total, são nove praças: Porto Alegre (RS), Erechim (RS), Chapecó (SC), Francisco Beltrão (PR), Toledo (PR), Pará de Minas (MG), Descalvado (SP), São José do Rio Preto (SP) e Grande São Paulo (CEPEA, 2020).

3.1.10 Milho (Indicador do milho ESALQ/BM&FBOVESPA)

Milho amarelo semi-duro, tipo 2, de odor e aspectos normais, em bom estado de conservação, livre de bagas de mamona e outras sementes prejudiciais e insetos vivos, duro ou semiduro, com umidade de até 14%, teor de impurezas máximo de 1% na peneira 3mm, máximo de 6% de grãos ardidos ou brotados e livre de grãos mofados e até 12% de grãos quebrados, partidos ou chochos. A região de referência é Campinas, no estado de São Paulo (CEPEA, 2020).

3.1.11 Suíno (Indicador do suíno vivo CEPEA/ESALQ)

Suíno vivo pronto para abate (animal terminado, macho ou fêmea, entre 80 e 120 quilos); preço ao produtor, são considerados apenas negócios realizados (não entram na amostra os valores nominais). As regiões de referência são os estados do Rio Grande do Sul, Santa Catarina, Paraná, São Paulo e Minas Gerais (CEPEA, 2020).

3.1.12 Trigo (Preço médio do trigo CEPEA/ESALQ – Paraná)

Trigo Tipo 1; pH 78; teor de matérias estranhas e impurezas, no máximo 1%; grãos danificados por insetos, no máximo 0,50%; grãos danificados pelo calor, mofados e ardidos, no máximo 0,50%; grãos chocos, triguilhos e quebrados, no máximo 1,5% e total de defeitos, no máximo 2%, de acordo com a Instrução Normativa 38/2010, do Ministério da Agricultura, Pecuária e Abastecimento. As regiões de referência são o estado do Paraná (CEPEA, 2020).

3.2 Metodologia

O estudo da dinâmica de preços das *commodities* brasileiras foi desenvolvido de acordo com o seguinte procedimento: com os dados de preços dessas *commodities*, são geradas as séries temporais originais e, a partir delas, são obtidas as séries de retorno e volatilidade. Aplica-se então o método Grafo de Visibilidade Horizontal (HVG) para transformá-las em redes complexas, das quais são extraídos alguns índices topológicos; isto é, o Coeficiente λ da distribuição de grau do nó, o Coeficiente de Agrupamento e o Comprimento Médio do Menor Caminho. Com essas medidas topológicas, obtêm-se informações úteis sobre a estrutura das redes geradas e se pode classificar o tipo de sistema que governa as séries temporais em estudo. Ou seja, o valor do Coeficiente de Agrupamento traz informações sobre a capacidade de agrupamento das redes, que indica seu nível de conectividade. O Comprimento Médio do Menor Caminho indica o quão bem integradas são as redes; quanto menor for esse comprimento, mais bem integrada é a rede e, portanto, mais eficiente será a transferência de informação dentro dela. E, de acordo com o valor obtido para o Coeficiente λ , é possível identificar se as séries temporais são governadas por processos caóticos ($\lambda < \ln(3/2)$), não correlacionados ($\lambda = \ln(3/2)$) ou estocásticos correlacionados ($\lambda > \ln(3/2)$). O algoritmo HVG foi implementado em software desenvolvido dentro de projeto LACUNA utilizando linguagem C de programação.

4 RESULTADOS E DISCUSSÃO

Aplicamos o método HVG as séries de preços diários (em moeda brasileira), de retorno e volatilidade das *commodities* agrícolas brasileiras. As séries temporais foram mapeadas em redes complexas através do critério de visibilidade do HVG e, a partir das redes obtidas, foram calculados o Coeficiente de Agrupamento, o Comprimento Médio do Menor Caminho e o Coeficiente λ da distribuição de graus dos nós.

Os resultados dos cálculos dos índices topológicos obtidos para as séries temporais de preços são mostrados na Tabela 3. Os Coeficientes de Agrupamento das redes obtidas pelo HVG apresentaram valores próximos para as *commodities* analisadas, exceto para a rede da série de preços da carne de frango e da série de preços do suíno (ambas com coeficiente de agrupamento pequeno o que indica que a rede possui menor aglomeração entre os nós), como também para a série de preços do café (com maior coeficiente de agrupamento entre os observados para as redes das séries de preços o que indica maior aglomeração entre os nós).

Tabela 3: Medidas topológicas das redes do HVG obtidas das séries de preços de *commodities* agrícolas brasileiras¹.

<i>Commodity</i>	Índices topológicos		
	Coeficiente de Agrupamento	Comprimento Médio do Menor Caminho	Coeficiente λ
Boi Gordo	0,5694	80,9373	0,4754
Bezerro	0,5224	62,7604	0,4417
Frango	0,2117	40,6443	0,1790*
Trigo	0,5932	75,8638	0,3565*
Açúcar	0,5622	98,7598	0,5653
Soja	0,5678	58,4614	0,6250
Arroz	0,5213	89,8086	0,5353
Suíno	0,2130	84,0650	0,7989
Etanol	0,5371	44,5027	0,4556
Algodão	0,5416	56,2605	0,2503*
Milho	0,5495	67,2644	0,5885
Café	0,6093	27,6186	0,5355

Fonte: Autor.

¹ Os valores do coeficiente $\lambda < \ln(3/2)$ estão sinalizados com (*).

O Comprimento Médio do Menor Caminho indicou que as redes obtidas das séries de preços de frango, de etanol e de café apresentaram características de redes mais integradas (a rede dos preços de café foi a mais integrada), no entanto, as redes das séries de preços de açúcar e de arroz foram menos integradas (maior distância entre os nós).

O valor do Coeficiente λ (inclinação da reta semilogarítmica da distribuição de probabilidade dos graus dos nós) mostrou que as séries de preços de algodão, de trigo e de carne de frango são geradas por processos caóticos ($\lambda < \ln(3/2)$), indicando menor previsibilidade do mercado dessas *commodities* (maior eficiência), enquanto as demais séries de preços (9 do total de 12) são geradas por processos estocásticos correlacionados ($\lambda > \ln(3/2)$), indicando maior previsibilidade do mercado dessas *commodities* (menor eficiência), sendo as séries de preços de soja e suíno as mais correlacionadas.

As medidas topológicas das redes geradas pelos retornos logarítmicos (Tabela 4) mostraram que os Coeficientes de Agrupamento apresentaram valores semelhantes para os retornos dos preços de todas as *commodities*, exceto para rede dos retornos de preços de carne de frango, que gerou uma rede menos conectada.

Tabela 4: Medidas topológicas das redes do HVG obtidas das séries de retorno R de preços das *commodities* agrícolas brasileiras².

<i>Commodity</i>	Índices topológicos		
	Coeficiente de Agrupamento	Comprimento Médio do Menor caminho	Coeficiente λ
Boi Gordo	0,6507	8,6995	0,3788*
Bezerro	0,6408	8,2979	0,3599*
Frango	0,5001	11,1134	0,4272
Trigo	0,6489	10,1645	0,4187
Açúcar	0,6457	10,6184	0,3857*
Soja	0,6435	9,3039	0,4023
Arroz	0,6454	9,6990	0,3909*
Suíno	0,6279	12,0294	0,4493
Etanol	0,6395	10,0746	0,4204
Algodão	0,6355	11,8886	0,4339
Milho	0,6445	10,3580	0,3883*
Café	0,6488	10,5978	0,3895*

Fonte: Autor.

O Comprimento Médio do Menor Caminho indicou que os retornos dos preços de boi gordo e de bezerro geraram redes mais integradas, com uma distância média de

² Os valores do coeficiente $\lambda < \ln(3/2)$ estão sinalizados com (*).

aproximadamente 8 passos necessários para ir de um nó até outro no Grafo de Visibilidade Horizontal. As redes dos retornos das séries de preços de frango, algodão e suíno, apresentaram características de redes menos integradas, pois apresentaram uma maior distância média entre os nós.

O valor do Coeficiente λ mostrou que as séries de retornos dos preços do frango, trigo, suíno, etanol e algodão exibem um comportamento de séries estocásticas correlacionadas (os retornos do suíno são os mais correlacionados) enquanto as séries de retorno de boi gordo, bezerro, açúcar, arroz, milho e café parecem exibir um comportamento caótico e, mais especificamente, possuem propriedades semelhantes com um processo caótico. O Coeficiente λ também indicou que a séries dos retornos dos preços da soja podem apresentar um comportamento de processos não correlacionados (λ mais próximo do resultado para séries não correlacionadas: $\ln(3/2) = 0,4055$), indicando maior eficiência do mercado.

Considerando os valores do Coeficiente λ obtidos das séries dos retornos, que são as menos afetadas por fatores como a inflação, notamos que nossos resultados estão corroborando com o que foi observado por Araújo et al. (2020) com relação a previsibilidade dos mercados do suíno, café e boi gordo, esses dois últimos que apresentaram menor previsibilidade (maior eficiência).

As redes das séries de volatilidade, que representam a medida de dispersão dos retornos, têm suas medidas dos índices topológicos apresentadas na Tabela 5. As redes mostraram valores próximos para o Coeficiente de Agrupamento, exceto a rede da carne de frango, cujo coeficiente indicou uma menor capacidade de agrupamento. O grafo gerado da série de volatilidade dos preços de carne frango e de café são menos integrados, de acordo com o Comprimento Médio do Menor Caminho. As demais redes apresentaram aproximadamente o mesmo Comprimento Médio do Menor Caminho sugerindo que possuem nível de integração parecido.

Tabela 5: Medidas topológicas das redes do HVG obtidas das séries de volatilidade de preços das *commodities* agrícolas brasileiras³.

<i>Commodity</i>	Índices topológicos		
	Coeficiente de Agrupamento	Comprimento Médio do Menor Caminho	Coeficiente λ
Boi Gordo	0,6282	9,0882	0,4122
Bezerro	0,6385	8,4486	0,3915*
Frango	0,3888	11,3365	0,3911*
Trigo	0,6398	10,4137	0,4371

³ Os valores do coeficiente $\lambda < \ln(3/2)$ estão sinalizados com (*).

Açúcar	0,6395	8,7665	0,3892*
Soja	0,6419	8,6447	0,3831*
Arroz	0,6235	9,4875	0,3886*
Suíno	0,5836	10,6327	0,4429
Etanol	0,6089	10,1496	0,3735*
Algodão	0,6334	10,0427	0,4233
Milho	0,6336	10,4507	0,4228
Café	0,6438	11,0626	0,4326

Fonte: Autor.

O valor do coeficiente λ da distribuição de nós $P(k)$ mostrou que, de acordo com as redes geradas pelo HVG, metade das séries analisadas (suíno, trigo, café, algodão, milho, boi gordo) apresentaram comportamento de séries correlacionas, enquanto as outras apresentaram comportamento caótico. Portanto, a variabilidade de volatilidade dos preços do etanol, arroz, soja, açúcar, frango e bezerro se mostraram menos previsíveis no período analisado.

Comparando os valores dos índices topológicos das redes das séries de preços (Tabela 3) e das séries dos retornos (Tabela 4) notaram-se que as redes das séries de preços são menos integradas (maior comprimento médio de caminho) e apresentam um coeficiente de agrupamento menor (menor capacidade de agrupamento). Isto também é observado quando comparamos a Tabela 3 com a Tabela 5. De maneira geral, as redes geradas das séries de preços são mais conectadas e a distribuição de graus dessas redes foram bem descritas por funções exponenciais, onde os expoentes característicos são quase sempre de séries estocásticas correlacionadas.

5 CONCLUSÕES

O presente trabalho apresentou o método Grafo de Visibilidade Horizontal, baseado no estudo de redes complexas de séries temporais, para analisar a dinâmica dos preços de *commodities* agrícolas brasileiras. De acordo com os índices topológicos calculados pelo HVG, os principais resultados mostraram:

- 1) Entre as séries dos preços, as séries de preços da carne de frango e do suíno geraram redes menos conectadas, enquanto a série de preços do café gerou uma rede mais conectada. Quanto ao nível de integração das redes, as séries de preço de carne de frango, de etanol e de café apresentaram redes mais integradas, enquanto as séries de preços de açúcar e de arroz mostraram redes menos integradas. Com relação aos valores do coeficiente característico da distribuição de graus dos nós das redes, constatou-se que as séries de preços do algodão, de trigo e de frango são geradas por processos caóticos (menor previsibilidade), enquanto as demais séries por processos estocásticos correlacionados (maior previsibilidade).
- 2) Os retornos logarítmicos dos preços geraram redes com um nível de conexão muito próximo, exceto os retornos dos preços de carne de frango que geraram redes menos conectadas. Constatou-se também que os retornos de preços de boi gordo e de bezerro geraram redes mais integradas, enquanto os retornos de preços de frango, de algodão e de suíno, geraram redes menos integradas. Observou-se que as séries de retorno dos preços do frango, trigo, suíno, etanol e algodão exibem comportamento de séries estocásticas correlacionadas (mais previsíveis) enquanto os retornos dos preços das demais *commodities* exibiram comportamento de séries caóticas. Para a série dos retornos dos preços de soja, o coeficiente λ apresentou um valor próximo do resultado para séries não correlacionadas, indicando que o mercado de soja é mais eficiente entre os mercados analisados.
- 3) A volatilidade dos preços, assim como os retornos, gerou redes com um nível de conectividade próximo, exceto a volatilidade dos preços de frango que gerou uma rede menos conectada. Além disso, a volatilidade dos preços de frango e dos preços de café geraram redes menos integradas de acordo com o Comprimento Médio do Menor Caminho, enquanto demais séries apresentaram os valores deste coeficiente bem próximo indicando que os grafos gerados tem o mesmo nível de integração dos nós. Constatou-se que metade das séries de volatilidade de preços são governadas

por processos caóticos, enquanto a outra metade por processos estocásticos correlacionados.

Os resultados deste trabalho podem ser úteis para desenvolvimento e validação de modelos teóricos e computacionais para previsão de preços das *commodities*. O método Grafo de Visibilidade Horizontal, até então não aplicado ao estudo da dinâmica de preços de produtos agrícolas, mostrou-se, portanto, eficiente quanto à captura de propriedades estruturais das redes geradas a partir de séries de preços diários de *commodities* agrícolas brasileiras e à classificação das séries em relação ao tipo de processo que as governa.

Como trabalhos futuros, outras medidas topológicas dos grafos de visibilidade podem ser exploradas e utilizadas para estudar o comportamento de outras *commodities* agrícolas brasileiras. Além disso pode-se aplicar variações do método Grafo de Visibilidade que estão sendo amplamente discutidas na literatura.

REFERÊNCIAS

ADHIKARI, R.; AGRAWAL, R. K. An introductory study on time series modeling and forecasting. **arXiv preprint arXiv:1302.6613**, 2013.

AHMADI, N.; PECHENIZKIY, M. Application of horizontal visibility graph as a robust measure of neurophysiological signals synchrony. In: **2016 IEEE 29th International Symposium on Computer-Based Medical Systems (CBMS)**. IEEE, 2016. p. 273-278.

GAMBOA, J. C. R.; MARQUES, E. C.; STOSIC, T. Complexity analysis of Brazilian agriculture and energy market. **Physica A: Statistical Mechanics and its Applications**, [s. l.], v. 523, p. 933–941, 2019.

ALBERT, R; BARABÁSI, A. L. Statistical mechanics of complex networks. **Reviews of modern physics**, v. 74, n. 1, p. 47, 2002.

ARAUJO, F. H. A. D.; BEJAN, L.; ROSSO, O. A.; STOSIC, T. Permutation entropy and statistical complexity analysis of Brazilian agricultural commodities. **Entropy**, v. 21, n. 12, p. 1220, 2019.

ARAUJO, F. H. A. D.; BEJAN, L.; STOSIC, B.; STOSIC, T. An analysis of Brazilian agricultural commodities using permutation–information theory quantifiers: The influence of food crisis. **Chaos, Solitons & Fractals**, v. 139, p. 110081, 2020.

BELLEMARE, M. F. Rising food prices, food price volatility, and social unrest. **american Journal of agricultural economics**, v. 97, n. 1, p. 1-21, 2015.

BOCCALETTI, S.; LATORA, V.; MORENO, Y.; CHAVEZ, M.; HWANG, D. U. Complex networks: Structure and dynamics. **Physics reports**, v. 424, n. 4-5, p. 175-308, 2006.

BOHL, M. T.; GROSS, C.; SOUZA, W. The role of emerging economies in the global price formation process of commodities: Evidence from Brazilian and US coffee markets. **International Review of Economics & Finance**, v. 60, p. 203-215, 2019.

BOLLOBÁS, B. **Modern graph theory**. Springer Science & Business Media, 2013.

BOX, G. E.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M **Time series analysis: forecasting and control**. John Wiley & Sons, 2015.

BRAGA, A. C.; ALVES, L. G. A.; COSTA, L. S.; RIBEIRO, A. A.; DE JESUS, M. M. A.;

TATEISHI, A. A.; RIBEIRO, H. V. Characterization of river flow fluctuations via horizontal visibility graphs. **Physica A: Statistical Mechanics and its Applications**, v. 444, p. 1003-1011, 2016.

Centro de Estudos Avançados em Economia Aplicada da Esalq/USP. 2020. Disponível em: <<https://www.cepea.esalq.usp.br/br/consultas-ao-banco-de-dados-do-site.aspx>>. Acesso em: 13 dez. 2019.

Confederação da Agricultura e Pecuária do Brasil. **Panorama do Agro**. 2020. Disponível em: <https://www.cnabrazil.org.br/cna/panorama-do-agro#_ftn2>. Acesso em: 13 jul. 2020.

FACHINELLO, A. L.; MEURER, R. Impactos da crise financeira internacional de 2008-09 no mercado de trabalho brasileiro. **Ensaio FEE**, v. 38, n. 1, p. 163-184, 2017.

Food and Agriculture Organization of the United Nations. **The State of Food Insecurity in the World 2008**. 2008. Disponível em: <<http://www.fao.org/3/a-i0291e.pdf>>. Acesso em: 20 abr. 2020.

GAO, Z. K.; CAI, Q.; YANG, Y. X.; DANG, W. D.; ZHANG, S. S. Multiscale limited penetrable horizontal visibility graph for analyzing nonlinear time series. **Scientific reports**, v. 6, p. 35622, 2016.

GAO, Z. K.; SMALL, M.; KURTHS, J. Complex network analysis of time series. **EPL (Europhysics Letters)**, v. 116, n. 5, p. 50001, 2017.

GONÇALVES, B. A.; CARPI, L.; ROSSO, O. A.; RAVETTI, M. G. Time series characterization via horizontal visibility graph and Information Theory. **Physica A: Statistical Mechanics and its Applications**, v. 464, p. 93-102, 2016.

HEADEY, D.; FAN, S. Anatomy of a crisis: the causes and consequences of surging food prices. **Agricultural economics**, v. 39, p. 375-391, 2008.

HOCHMAN, G.; RAJAGOPAL, D.; TIMILSINA, G.; ZILBERMAN, D. Quantifying the causes of the global food commodity price crisis. **Biomass and Bioenergy**, v. 68, p. 106-114, 2014.

HONG, H.; LI, F. W.; XU, J. Climate risks and market efficiency. **Journal of Econometrics**, v. 208, n. 1, p. 265-281, 2019.

IVANIC, M.; MARTIN, W. **Implications of higher global food prices for poverty in low-**

income countries. The World Bank, 2008.

IVANIC, M.; MARTIN, W.; ZAMAN, H. Estimating the short-run poverty impacts of the 2010–11 surge in food prices. **World Development**, v. 40, n. 11, p. 2302-2317, 2012.

KRISTOUFEK, L.; VOSVRDA, M. Commodity futures and market efficiency. **Energy Economics**, v. 42, p. 50-57, 2014.

LACASA, L.; LUQUE, B.; BALLESTEROS, F.; LUQUE, J.; NUNO, J. C. From time series to complex networks: The visibility graph. **Proceedings of the National Academy of Sciences**, v. 105, n. 13, p. 4972-4975, 2008.

LACASA, L.; TORAL, R. Description of stochastic and chaotic series using visibility graphs. **Physical Review E**, v. 82, n. 3, p. 036120, 2010.

LANGE, H.; SIPPEL, S.; ROSSO, O. A. Nonlinear dynamics of river runoff elucidated by horizontal visibility graphs. **Chaos: An Interdisciplinary Journal of Nonlinear Science**, v. 28, n. 7, p. 075520, 2018.

LIMA, T. D.; DEUS, L. N. A crise de 2008 e seus efeitos na economia brasileira. **Revista Cadernos de Economia**, v. 17, n. 32, p. 52-65, 2013.

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

LUQUE, B.; LACASA, L.; BALLESTEROS, F.; LUQUE, J. Horizontal visibility graphs: Exact results for random time series. **Physical Review E**, v. 80, n. 4, p. 046103, 2009.

MADL, T. Network analysis of heart beat intervals using horizontal visibility graphs. In: **2016 Computing in Cardiology Conference (CinC)**. IEEE, 2016. p. 733-736.

MATIAS-PEREIRA, J. Efeitos e custos da crise financeira e econômica global no Brasil. 2009. Disponível em: <<https://www.eumed.net/cursecon/ecolat/br/09/jmp.htm>>. Acesso em: 22 abr. 2020.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. Editora Blucher, 2006.

NAZLIOGLU, S.; ERDEM, C.; SOYTAS, U. Volatility spillover between oil and agricultural commodity markets. **Energy Economics**, v. 36, p. 658-665, 2013.

PINES, L. **Trader's Guide to Agricultural Commodities: Their Importance On The**

Stock Market Explained. 2020. Disponível em: <<https://commodity.com/soft-agricultural/>>. Acesso em: 6 abr. 2020.

QUEIROZ, F. A. D. Impactos da sojicultura de exportação sobre a biodiversidade do Cerrado. **Sociedade & Natureza**, v. 21, n. 2, p. 193-209, 2009.

ROCHA, H. R.; PEREIRA, B. L.; MARTIN, J. S. **Commodities agrícolas: o que são?** 2020. Disponível em: <<https://www.politize.com.br/commodities-agricolas/#toggle-id-1>. 2018 %3E>. Acesso em: 13 fev. 2020.

SANTANA, L. I. T. D.; SILVA, J. M. D.; ARAÚJO, L. D. S.; MOREIRA, G. R.; STOSIC, T. Análise de quantificação de recorrência de preços brasileiros do milho, da soja e da carne de frango. **Research, Society and Development**, v. 9, n. 10, p. e9979109461-e9979109461, 2020.

SILVA, J. M. D.; ARAÚJO, L. D. S.; STOSIC, T.; STOSIC, B. Análise de séries temporais de focos de calor em biomas brasileiros utilizando o Grafo de Visibilidade Horizontal. **Research, Society and Development**, v. 9, n. 9, p. e308996276-e308996276, 2020.

SIVAKUMAR, B.; WOLDEMESKEL, F. M. A network-based analysis of spatial rainfall connections. **Environmental Modelling & Software**, v. 69, p. 55-62, 2015.

SOUSA, L. R. M. D.; SEGALL-CORRÊA, A. M.; VILLE, A. S.; MELGAR-QUIÑONEZ, H. Food security status in times of financial and political crisis in Brazil. **Cadernos de saude publica**, v. 35, p. e00084118, 2019.

STAM, C. J.; REIJNEVELD, J. C. Graph theoretical analysis of complex networks in the brain. **Nonlinear biomedical physics**, v. 1, n. 1, p. 3, 2007.

STOSIC, T.; NEJAD, S. A.; STOSIC, B. Multifractal analysis of Brazilian agricultural market. **Fractals**, v. 28, n. 05, p. 2050076, 2020.

TABAK, B. M.; SERRA, T. R.; CAJUEIRO, D. O. Topological properties of commodities networks. **The European Physical Journal B**, v. 74, n. 2, p. 243-249, 2010.

VAMVAKARIS, M. D.; PANTELOUS, A. A.; ZUEV, K. M. Time series analysis of S&P 500 index: A horizontal visibility graph approach. **Physica A: Statistical Mechanics and Its Applications**, v. 497, p. 41-51, 2018.

WATTS, D. J.; STROGATZ, S. H. Collective dynamics of ‘small-world’ networks. **nature**, v. 393, n. 6684, p. 440-442, 1998.

ZHANG, J.; SMALL, M. Complex network from pseudoperiodic time series: Topology versus dynamics. **Physical review letters**, v. 96, n. 23, p. 238701, 2006.

ZHU, G.; LI, Y.; WEN, P. Analysis and classification of sleep stages based on difference visibility graphs from a single-channel EEG signal. **IEEE journal of biomedical and health informatics**, v. 18, n. 6, p. 1813-1821, 2014.

ZOU, Y.; DONNER, R. V.; MARWAN, N.; DONGES, J. F.; KURTHS, J. Complex network approaches to nonlinear time series analysis. **Physics Reports**, v. 787, p. 1-97, 2019.