

FERNANDO HENRIQUE ANTUNES DE ARAUJO

**ANÁLISE DOS PREÇOS DAS COMMODITIES AGRÍCOLAS USANDO
MÉTODOS DE TEORIA DA INFORMAÇÃO**

RECIFE – JANEIRO/2022.



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

**ANÁLISE DOS PREÇOS DAS COMMODITIES AGRÍCOLAS USANDO
MÉTODOS DE TEORIA DA INFORMAÇÃO**

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

Área de Concentração: Estatística aplicada e experimental.

Orientadora: Prof^ª. Dr^ª. Tatijana Stosic
Coorientador: Prof. Dr. Lucian Bejan

RECIFE – JANEIRO/2022.

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)

A663a

Araujo, Fernando Henrique Antunes de

Análise Dos Preços Das Commodities Agrícolas Usando Métodos De Teoria
Da Informação / Fernando Henrique Antunes de Araujo. - 2022.
72 f. : il.

Orientadora: Tatijana Stosic.

Coorientador: Lucian Bejan.

Inclui referências e anexo(s).

Tese (Doutorado) - Universidade Federal Rural de Pernambuco, Programa de
Pós-Graduação em Biometria e Estatística Aplicada, Recife, 2022.

1. Entropia de Permutação. 2. Informação de Fisher. 3. Complexidade
Estatística. 4. Commodities. I. Stosic, Tatijana, orient. II. Bejan, Lucian, 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

**ANALISE DOS PREÇOS DAS COMMODITIES AGRÍCOLAS USANDO
MÉTODOS DE TEORIA DA INFORMAÇÃO**

FERNANDO HENRIQUE ANTUNES DE ARAUJO

Tese julgada adequada para obtenção do título
de Doutor em Biometria e Estatística Aplicada,
defendida e aprovada por unanimidade em
01/2022 pela Banca Examinadora.

Orientadora:

Prof^a. Dr^a. Tatijana Stosic
Universidade Federal Rural de Pernambuco

Banca Examinadora:

Prof. Dr. Jader da Silva Jale
Universidade Federal Rural de Pernambuco

Prof. Dr. Lucian Bogdan Bejan
Universidade Federal Rural de Pernambuco

Prof. Dr. Jose Rodrigo Santos Silva
Universidade Federal de Sergipe

Prof. Dr. Sílvio Fernando Alves Xavier Júnior
Universidade Estadual da Paraíba



***À DOCE E HUMILDE
SEMPRE VIRGEM
MARIA.***

AGRADECIMENTOS

Agradeço ao Sacratíssimo Coração de Jesus e ao Imaculado Coração de Maria.

*“Lembre-se de que você tem no Céu não
somente um Pai, mas também uma doce
Mãe.”*

São Pe. Pio

RESUMO

As commodities agrícolas são consideradas, talvez, as commodities mais importantes, já que qualquer aumento abrupto no preço dos alimentos tem sérias consequências na segurança alimentar e no bem-estar, especialmente nos países em desenvolvimento. Neste trabalho analisamos a previsibilidade dos preços das commodities agrícolas brasileiras durante o período após a crise alimentar de 2007/2008 e também analisamos esses preços em janelas móveis deslizantes em cinco dessas commodities (algodão, açúcar, soja, café e boi gordo), observando a evolução desses preços ao longo do período antes, durante e após crise alimentar de 2007/2011. Utilizamos o método baseado na teoria da informação Plano de causalidade de Complexidade / Entropia (CECP) que demonstrou ser bem sucedido na análise da eficiência e previsibilidade do mercado e o Plano de entropia-informação de Fisher (FI). Ao estimar os quantificadores de informação, a entropia de permutação e a complexidade estatística, associamos a cada mercadoria a posição no CECP e no FI e comparamos sua eficiência (previsibilidade) usando o desvio de um processo aleatório. O mercado de café apresentou maior eficiência (menor previsibilidade) enquanto o mercado de carne suína apresentou menor eficiência (maior previsibilidade). Quando analisamos 5 commodities entre o período (1996-2018), observamos a evolução temporal do índice de eficiência derivado da entropia de Shannon e da medida de informação de Fisher, vimos que as séries de preços do café e da soja apresentam alta e estável eficiência informacional para todo o período analisado, a eficiência do mercado açucareiro apresenta aumento constante, enquanto a eficiência do boi gordo e do algodão, o mercado diminui primeiro (até a crise) e depois aumenta no período pós-crise. No caso do açúcar, boi gordo e algodão é possível observar o período da crise alimentar (2007-2011), enquanto que para o café e soja essas medidas não foram capazes de captar diferença de previsibilidade e desordem nas mesmas, o que classificamos como commodities que não sofreram distorções nesse período em suas séries de preços.

Palavras-chave: Commodities, Entropia, CECP, Informação de Fisher.

ABSTRACT

Agricultural commodities are considered perhaps the most important commodities, as any sharp rise in food prices has serious consequences for food security and well-being, especially in developing countries. In this paper we analyze the predictability of Brazilian agricultural commodity prices during the period after the 2007/2008 food crisis and we also analyze these prices in sliding windows in five of these commodities, observing the evolution of these prices over the period before, during and after 2007/2011 food crisis. We use the method based on the information theory Complexity / Entropy Causality Plane (CECP) which is shown successful in analyzing the efficiency and predictability of financial markets and Entropy-Fisher's Information plane (FI). By estimating information quantifiers, a permutation entropy, statistical complexity and Fisher information we associate each commodity with its CECP and FI position and compare its efficiency (predictability) using the deviation of a random process. The coffee market showed greater efficiency (less predictability) while the pork market showed less efficiency (greater predictability). When we analyzed 5 commodities between the periods (1996-2018), we observed a temporal evolution of the efficiency index derived from Shannon's entropy and Fisher's information measure, we saw that the coffee and soybean price series present high and stable efficiency. For the entire period analyzed, the efficiency of the sugar market shows a constant increase, while the efficiency of cattle and cotton, first decreases (until the crisis) and then increases in the post-crisis period. In the case of sugar, live cattle and cotton, it is possible to observe the period of the food crisis (2007-2011), while for coffee and soy these measures were not able to capture differences in predictability and disorder in them, which we classify as commodities which did not suffer distortions in their price series during this period.

Keywords: Commodities, Entropy, CECP, Fisher Information.

LISTA DE FIGURAS

Figura 1 - Séries temporais de preços de commodities agrícolas registradas diariamente durante o período de 04 de janeiro de 2010 a 03 de julho de 2018.	30
Figura 2 - Séries temporais de preços de commodities agrícolas registradas diariamente durante o período 1996 a 2018.	31
Figura 3 – Figura das seis permutações ordinais possíveis para $d = 3$ (OLIVIER, et al., 2019).	36
Figura 4 - Posição no plano complexidade - entropia das séries de mercadorias originais (A) e (B) randomizadas para dimensão de incorporação $d = 4$	40
Figura 5 - Posição no plano complexidade - entropia das séries de mercadorias originais (A) e (B) randomizadas para dimensão de incorporação $d = 5$	40
Figura 6 - Evolução temporal da medida de ineficiência (distância do ponto CECP $HS = 1$, $C = 0$) para séries de mercadorias para dimensão de incorporação $d = 5$	42
Figura 7 - Posição no plano de entropia-complexidade (CECP) e plano de entropia-informação de Fisher (FI) da série de commodities original e aleatória para a dimensão de incorporação $d = 6$	44
Figura 8 - Trajetória no plano de entropia-complexidade (CECP) de séries temporais de commodities agrícolas para a dimensão de incorporação $d = 4$, tamanho da janela $w = 500$ e passo deslizando $\Delta = 20$	45
Figura 9 - Trajetória no plano de informação de entropia-Fisher (HF) de séries temporais de commodities agrícolas para a dimensão de incorporação $d = 4$, tamanho da janela $w = 500$ e passo deslizando $\Delta = 20$	46
Figura 10 - Evolução temporal do índice de eficiência $E=H-FI$ de séries temporais de commodities agrícolas para dimensão de embutimento $d=4$, tamanho de janela $w=500$ e passo deslizando $\Delta=20$	47

LISTA DE TABELAS

Tabela 1. Commodities agrícolas	29
Tabela 2 - Commodities utilizadas no estudo e suas descrições	31
Tabela 3 Classificação de commodities agrícolas por eficiência decrescente. Valores de entropia de permutação Hs e complexidade estatística C e distância do vértice $(1, 0)$ são calculados para $d = 4$ e $d = 5$	39
Tabela 4. Valores médios e desvio padrão do índice de eficiência $E = H[P] - F[P]$ para commodities agrícolas calculados para janelas deslizantes para os períodos antes (1996-2006), durante (2007-2011) e após (2012-2018) alimentos crise.	48

SUMÁRIO

1	INTRODUÇÃO.....	13
2	REVISÃO DE LITERATURA	16
2.1	<i>Commodities</i>	16
2.2	<i>Comodities</i> agrícolas	17
2.3	A Crise <i>subprime</i>	18
2.4	Consequências da crise no Brasil	19
2.5	Crise alimentar.....	19
2.6	Consequências da crise alimentar no Brasil	21
2.7	Complexidade das séries temporais.....	22
2.7.1	Medidas de Entropia.....	23
2.7.1.1	Entropia de Shannon	23
2.7.1.2	Entropia conjunta e Entropia condicional	24
2.7.1.3	Entropia Relativa e Informação Mútua	24
2.7.1.4	Entropia de Rényi e Entropia de Tsallis.....	25
2.7.1.5	Entropia amostral (Sample Entropy).....	26
2.7.1.6	Entropia de Permutação	27
3	DADOS E METODOLOGIA	29
3.1	Dados	29
3.2	Plano Complexidade - Entropia (<i>Complexity entropy causality plane</i> – CECP)	33
3.3	Informação de Fisher	34
3.4	Implementação do algoritmo de Entropia de Permutação, Complexidade Estatística e Informação de Fisher	35
3.5	Evolução temporal, janelas deslizantes	37
4	RESULTADOS E DISCUSSÃO	38
4.1	Análise de previsibilidade das commodities agrícolas brasileiras utilizando CECP.....	38
4.2	Análise de previsibilidade das commodities agrícolas brasileiras utilizando CECP: a influência da crise financeira.....	43
5	CONCLUSÃO.....	49
6	REFERÊNCIAS BIBLIOGRÁFICAS	52
7	ANEXO – Artigos publicados.....	72

1 INTRODUÇÃO

Nos últimos anos, os mercados de commodities agrícolas atraíram considerável atenção de pesquisadores tanto da economia agrícola (ROBERT e SCHLENKER, 2013; NAZLIOGLU e SOYTAS, 2012; ADÄMMER e BOHL, 2015; BECKMANN e CZUDAJ, 2014) quanto de áreas relacionadas, como a econofísica (HE e CHEN, 2010; HE e CHEN (b), 2011; LIU, 2014; SIQUEIRA et al., 2010; KRISTOUFEK e VOSVRDA, 2014; ZUNINO et al. 2011; TABAK et al., 2010). A razão para tal expansão são as preocupações relacionadas ao aumento dos preços das commodities alimentares na última década: o início do crescimento dos preços em 2001, o forte aumento durante a crise alimentar de 2007/2008, seguido de novo aumento em 2010/2011 (HOCHMAN, et al., 2014). Os fatores mais importantes que afetam os aumentos dos preços de commodities alimentares na última década são o aumento na produção de biocombustível, que contribuiu para o aumento do preço das commodities em 2007/2008, a desvalorização do dólar em relação às principais moedas mundiais, especulações, aumento no custo de produção devido aos altos preços de energia e estagnação no crescimento da produtividade devido a menos investimento em tecnologia e infraestrutura. Finalmente, políticas comerciais como a proibição de exportação de grãos por alguns países asiáticos e as tarifas de importação de biocombustíveis, como as tarifas dos EUA sobre o etanol de cana-de-açúcar do Brasil, também contribuíram para a alta dos preços de commodities de 2007/2008 e 2010/2011 (HOCHMAN, et al., 2014).

As graves consequências dos aumentos de preços na segurança alimentar, especialmente nos países em desenvolvimento onde milhões de pessoas foram empurradas para a fome e a pobreza (IVANIC, 2012), muitas vezes seguidas de inquietação social, instabilidade política e conflitos sociopolíticos (BELLEMARE, 2015), são as principais preocupações dos governos e organizações internacionais (ROSEGRANT e CLINE, 2003). Nesse sentido, toda nova evidência empírica sobre o comportamento de commodities agrícolas em escala global e/ou local fornece contribuição valiosa para os esforços mundiais no estabelecimento de base científica confiável, para servir como uma ajuda para desenvolver e testar novos modelos de previsão que incluirão vários aspectos deste fenômeno complexo. Este trabalho é concebido como uma contribuição nesse sentido.

O Brasil é o terceiro maior exportador mundial (depois da União Europeia e Estados Unidos) de commodities agrícolas (FAO, 2018), e é um dos maiores produtores de produtos agrícolas, incluindo açúcar, suco de laranja, soja, café, frango, carne bovina, suína, milho e

algodão (MUELLER, B e MUELLER, C, 2016). Os mercados agrícolas mostram alto nível de integração, através da correlação entre preços e transmissão de volatilidade, e os preços das commodities agrícolas brasileiras foram estudados dentro desse contexto. Ceballos et al., (2016) analisaram a transmissão da volatilidade do preço dos alimentos (milho, arroz, sorgo e trigo) do mercado internacional para mercados de países em desenvolvimento e descobriram que a volatilidade internacional dos preços é mais provável de ser transmitida aos mercados da América do Sul. Balcombe et al. (2007) verificaram a transmissão de preços de trigo, milho e soja entre os EUA, Argentina e Brasil durante o final dos anos 80 e início dos anos 90, geralmente com causalidade fluindo dos EUA e Argentina para o Brasil. As culturas agrícolas também foram utilizadas para a produção de biocombustíveis. O impacto dos programas de biocombustíveis que foram introduzidos nos Estados Unidos, no Brasil, na União Europeia e em outros países, e a relação entre os mercados de alimentos e energia tornaram-se grandes tópicos de pesquisa econômica (HERTEL et al., 2010).

Nos últimos anos foi dada especial atenção à relação entre biocombustíveis e sua matéria-prima, como o etanol e milho nos Estados Unidos, etanol e açúcar no Brasil e biodiesel e de colza na União Europeia (KRISTOUFEK, et al., 2016; CABRERA e SCHULZ, 2016). Os mercados agrícolas também atraíram a atenção de pesquisadores de áreas afins, como a econofísica, oferecendo uma nova compreensão dos processos estocásticos que regem a dinâmica de preços, como propriedades multifractais (HE e CHEN (a), 2011; HE e CHEN (b), 2011; LIU, 2014; HE e CHEN, 2010), conteúdo informacional (KRISTOUFEK e VOSVRDA, 2014; ZUNINO et al., 2011) e estrutura da rede (TABAK et al. 2010; KRISTOUFEK et al., 2012; KRISTOUFEK et al., 2013). Estudos anteriores sobre commodities agrícolas brasileiras baseadas em métodos econofísicos incluem autocorrelações de longo prazo (SIQUEIRA et al., 2010), propriedades multifractais (STOSIC et al, 2020), correlações cruzadas de longo prazo e complexidade das series de preços de etanol e açúcar (LIMA et al., 2019; GAMBOA et al., 2019)

Neste trabalho, analisaremos diferentes commodities brasileiras quanto a sua eficiência (ineficiência) utilizando os métodos da teoria de informação, entropia de permutação, complexidade estatística e informação de Fisher, obtendo assim um ranking entre elas quanto a instabilidade das flutuações dos preços das mesmas no mercado. O método da entropia de permutação/complexidade estatística com o seu espaço de representação chamado Plano Complexidade - Entropia (*Complexity entropy causality plane* – CECP) demonstrou ser bem sucedido na análise da eficiência e previsibilidade dos mercados financeiros (ZUNINO et al.,

2011; ZUNINO et al., 2010; ZUNINO et al., 2012; BARIVIERA et al., 2018; BARIVIERA et al., 2013).

O objetivo deste estudo foi fornecer informações sobre a eficiência do mercado agrícola brasileiro. Analisamos a previsibilidade dos preços das commodities agrícolas durante o período após a crise alimentar de 2007/2008 para um grupo de 11 commodities e o etanol, e construímos um ranking de eficiência de mercado entre essas commodities a partir de localização das series em CECp. Além disso identificamos cinco commodities com séries de preços mais longas (algodão, açúcar, café, boi gordo e soja) durante o período 1996-2018, abrangendo a crise alimentar 2007/2011 e, utilizando janelas móveis deslizantes, analisamos a trajetória correspondente no CECp e no plano de Entropia - Informação de Fisher. Essa abordagem permite avaliar a previsibilidade dos preços das commodities e a eficiência do mercado em função do tempo e identificar a possível influência da crise financeira.

Esta tese está dividida em seis capítulos: o primeiro é a introdução onde se mostra o que é estudado e porque esse estudo merece importância.

No segundo capítulo faz-se uma revisão de literatura, trata-se do tema commodities agrícolas. Fala-se da crise *subprime* e crise alimentar e suas consequências no Brasil. Além disso mostram-se os conceitos básicos da teoria de informação sobre os quais foram construídas as metodologias utilizadas neste trabalho; fez-se uma revisão de literatura com ênfase em aplicações destes métodos em dados financeiros.

No capítulo três tem-se a descrição dos dados, a metodologia Plano Complexidade - Entropia (CECP), evolução temporal do CECp e o Plano Entropia - Informação de Fisher.

No quarto capítulo são mostrados todos os resultados obtidos e é feita também uma discussão sobre os mesmos. Este capítulo está publicado em periódicos internacionais nos artigos: *Permutation entropy and statistical complexity analysis of Brazilian agricultural commodities* (De Araujo et. al, 2019); *An analysis of Brazilian agricultural commodities using permutation-information theory quantifiers: The influence of food crisis* (De Araujo et. al, 2020).

No quinto e último capítulo são mostradas as referências bibliográficas utilizadas neste trabalho e os artigos (13) publicados durante o período do doutorado que não fazem parte desta tese, mas foram elaborados com o conhecimento adquirido na mesma.

2 REVISÃO DE LITERATURA

2.1 *Commodities*

É um termo utilizado para produtos em estado bruto, ou seja, produtos de base (matérias-primas) ou com baixo grau de industrialização, de qualidade aproximadamente uniforme, produzidos em larga escala e por diferentes produtores. Sem perda expressiva de qualidade, estes produtos *in natura*, cultivados ou de extração mineral, podem ser armazenados por determinado tempo com seu padrão de qualidade preservado. Utilizando bolsas de mercadorias, têm cotação e negociabilidade globais. Commodity é um termo de língua inglesa (plural commodities), cujo significado é mercadoria. É usado nas transações comerciais de produtos de origem primária nas bolsas de mercadorias (MEICES, 2018).

O que faz com que as commodities sejam muito importantes na economia é a ocorrência de que, muito embora sejam mercadorias primárias, ou de baixa industrialização, possuem negociabilidade global. Seus preços são definidos em nível global, isto por acontecer em bolsas de mercadorias. Nesse sentido são influenciadas por oscilações nas cotações de mercado, em virtude de ganhos e perdas nos fluxos financeiros mundiais (AGRÍCOLAS, 2010).

O Brasil é um dos grandes produtores e exportadores de commodities. As principais commodities produzidas no país são: café, petróleo, minério de ferro, suco de laranja, alumínio e soja. O fato de atuar como importante produtor e exportador de commodities é um fator positivo ao país, porém cria-se uma dependência ante aos preços praticados internacionalmente. Em períodos de crescimento econômico, isto implica em demanda firme, os preços sobem e as empresas/produtores obtêm lucro expressivo. Por outro lado, em cenário oposto, a economia do país sofre problemas graves. Os principais tipos de commodities são (AGRÍCOLAS, 2010):

- (a) Agrícolas: café, trigo, soja, milho, açúcar, arroz;
- (b) Minerais: ouro, petróleo, ferro, alumínio;
- (c) Financeiras: dólar, euro, real, índices futuros;
- (d) Ambientais: créditos de carbono, condições climáticas médias em regiões do planeta;
- (e) Recursos energéticos: energia elétrica;
- (f) Químicas: ácido sulfúrico, sulfato de sódio, fertilizantes.

2.2 *Comodities* agrícolas

Commodities agrícolas são artigos homogêneos e primários vindos das lavouras. Porém, não são denominados *commodities* todos os produtos advindos do campo. A batata, por exemplo, não é uma *commoditie*, mesmo ela sendo um bem agrícola homogêneo e cultivada na terra (ROCHA, et al. 2018).

Para ser considerado uma *commoditie* um produto agrícola tem de ser comercializado nas bolsas de valores e de mercadoria no mundo inteiro, pela via da compra e venda de ações e, para que isso aconteça, deve ser um bem estratégico e de alto valor comercial. Como exemplo, a soja: vendida e cultivada como grão, neste caso, um produto homogêneo, produto muito importante estrategicamente para o Brasil e que possui alto valor no mercado internacional. Além disso, é um dos principais produtos exportados pelo país, portanto um dos principais responsáveis por alavancar a economia brasileira (ROCHA et al., 2018).

A contar do período colonial, o Brasil tem características de grande exportador de *commodities* agrícolas, por exemplo, algodão, café e cana de açúcar, que, nestes tempos, ainda não eram ditas como *commodities*, porém fizeram com que o Brasil ficasse marcado pelo seu clima favorável para plantação agrícola, com uma grande produção (ROCHA et al. 2018). Dessa forma, o Brasil foi conhecido por sua produção de bens agrícolas e por ser uma das colônias exportadoras mais lucrativas da época, sendo a mais lucrativa para o reino português (ROCHA et. al, 2018).

Nos últimos anos, a exportação de soja ganhou destaque, ultrapassando a de café e tornando o Brasil o maior exportador de soja a nível mundial e o terceiro país em maior produção, ficando atrás apenas dos Estados Unidos e da União Europeia. Assim como a soja, outras *commodities* agrícolas têm sido relevantes para o comércio brasileiro com outros países (ROCHA et al. 2018).

Quase todas as *commodities* agrícolas são exportadas para a produção de novos produtos: a soja vira leite, óleo em molho; o café pode ser moído e usado não só para beber, mas também na preparação de sobremesas; o algodão se transforma majoritariamente em roupas e é usado na confecção de tecidos para uso geral (cama, mesa e banho); o trigo é modificado em farinha (que é usada para a fabricação de pães, massas e outras diversos alimentos que consumimos no dia-a-dia), além de ser um componente para a produção de cerveja; e a borracha, originada do látex extraído da árvore seringueira, é utilizada para a fabricação de pneus, luvas de borracha, brinquedos, utensílios de cozinha e preservativos (ROCHA et. a., 2018).

No nosso país, 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 et al., 2018).

2.3 A Crise *subprime*

O mercado *subprime* adentrou na economia após a crise das empresas “ponto com” nos Estados Unidos da América. O Federal Reserve (Fed), uma espécie de banco central americano, baixou a taxa de juros para aceleração da economia. Neste contexto, o setor imobiliário aproveitou o clima de crédito favorável (os juros chegaram a 1% ao ano), tornou-se viável e acessível para a maioria das pessoas realizar a compra da casa própria. Desse modo, muitas pessoas compraram casas financiadas e, quem já possuía imóveis, hipotecava usando o dinheiro para quitar dívidas ou elevar seus gastos. A compra de imóveis se transformou em um bom investimento, pois a valorização era o esperado para tal empreendimento. Os *subprime* foram transformados em papéis e vendidos para outras instituições financeiras, que por sua vez, emprestavam novas quantias antes mesmo de receber pelos papéis comprados. Isso tudo se tornou em um ciclo de dívidas (GALLE, et al., 2009).

Após um tempo, com o aumento das taxas de juros, encareceu o crédito e os negócios imobiliários desaqueceram, aconteceu uma desvalorização nos preços dos imóveis, porque, com juros altos, já não era mais interessante comprar imóveis. Em consequência disto, quem comprou casas não conseguiu revendê-las (GALLE, et al., 2009). Em 2006, começou um rápido processo de execução de hipotecas nos EUA, o que acabaria resultando em uma crise de proporções globais (GALLE, et al., 2009).

Em 2008, por volta do último trimestre, a crise financeira mundial originada no mercado de hipotecas de alto risco (*subprime*) dos Estados Unidos foi agravada. Esta é considerada a maior crise do capitalismo moderno desde 1929 (quando a bolsa de Nova York quebrou) (GALLE, et al., 2009; VIZI, 2011; BORGES, et al., 2011). A crise tornou-se global, todas as classes de títulos financeiros foram atingidas, logo o desempenho do comércio internacional e das economias emergentes e avançadas foram comprometidas (EICHENGREEN, et al., 2010). Apenas no seu início, a crise originou uma perda acumulada de 2.2 trilhões de dólares (CARNEIRO, 2009).

2.4 Consequências da crise no Brasil

Difícilmente seria prevista uma valorização do real frente ao dólar americano, devido a política monetária adotada com rigor pelo governo brasileiro até setembro de 2008. Muitas empresas confiaram que o dólar continuaria caindo até o final do ano de 2008. Quando o dólar começou a subir, houve a necessidade de cobrir os prejuízos que passaram da soma de 5 bilhões de reais. Em setembro de 2008, com a queda do banco norte-americano Lehman Brothers, acontece uma grande redução do crédito internacional e o dólar dispara no Brasil (VASQUEZ, 2008).

Pequenos e médio bancos brasileiros foram afetados pela crise internacional de confiança e a falta de crédito externo. Os depósitos compulsórios tiveram mudanças em seu recolhimento feitas pelo Banco Central brasileiro, beneficiando bancos menores e instituições que trabalhavam com leasing (FERNANDES e PEDRO, 2011).

2.5 Crise alimentar

O aumento nos preços internacionais de cereais em 2007 e 2008 foi realmente uma crise. Praticamente dobraram os preços internacionais do milho e do trigo de 2003 ao seu pico em meados de 2008, enquanto os preços do arroz triplicaram em questão de meses. Não se sabe ao certo quantas pessoas foram levadas a fome e à pobreza devido à crise alimentar, mas o Banco Mundial coloca a soma em mais de 130 milhões de pessoas, enquanto a FAO prevê que 75 milhões de pessoas ficaram desnutridas (OCDE-FAO, 2008; USDA, 2008). Porém, a escala da recente crise mundial tenha se igualado à crise de 1973-1974, as explicações mais populares da crise alimentar de 2007-2008 parecem inconsistentes com a citação acima, visto que, em grande parte, não estão relacionadas às exportações ou ao comércio (HEADEY, 2011). A lista de explicações populares inclui o aumento dos preços do petróleo, o crescimento da demanda de biocombustíveis, a evolução das dietas asiáticas, o declínio da pesquisa e do desenvolvimento na agricultura, a desaceleração do crescimento das safras, baixos estoques, desequilíbrios macroeconômicos, especulação financeira, secas e restrições às exportações (HEADEY, 2011). Enquanto algumas dessas explicações podem ser direta ou indiretamente ligadas a eventos comerciais, poucos ou nenhum observador enfatizou os choques comerciais como "a grande incerteza" subjacente à mais recente volatilidade nos preços dos alimentos (HEADEY, 2011).

Durante 2007 a 2008, o mercado global de grãos alimentícios foi volátil devido a uma mudança repentina na demanda e oferta (AKHTER, 2016).

Bouet e Debucquet (2012) identificaram que quando os preços mundiais dos alimentos aumentam, tanto a implementação de novas restrições às exportações quanto a redução das tarifas de importação sobre commodities agrícolas alimentam o aumento dos preços mundiais e prejudicam os pequenos países importadores líquidos de alimentos. Isso representa uma clara falta de coordenação internacional. Pequenos países importadores líquidos de alimentos não têm capacidade de reagir e são prejudicados.

Por exemplo, no Nepal, o país depende fortemente da Índia para o comércio de commodities, já que a Índia é o único país que fornece trânsito terrestre para o Nepal. Sempre que o Nepal enfrenta eventuais deficiências na produção de arroz, grandes quantidades de importações da Índia ajudam a estabilizar o preço do arroz no mercado interno (SANOGO e MALIKI, 2010). No entanto, com base na demanda ou choques de oferta, os governos desses países frequentemente impõem diferentes tipos de políticas comerciais, como tarifas de importação, impostos de exportação, subsídios à exportação, restrições quantitativas e proibições de exportação de arroz para manter os preços domésticos estáveis (DOROSH 2009; DAWE et al., 2010).

Desequilíbrios macroeconômicos têm sido vistos como um canal significativo de superação nos mercados de commodities (FRANKEL, 1984; SCHUH, 1974). Baixas taxas de juros reais e crises nos mercados imobiliário e de ações, especialmente nos Estados Unidos, poderiam ter causado dinheiro fluindo de instrumentos que geram juros para moedas estrangeiras, ações de mercados emergentes, outros títulos e mercados futuros de commodities. A depreciação do dólar americano poderia ter impulsionado significativamente as exportações agrícolas dos EUA, levando a preços mais altos nos Estados Unidos e a aumentos de preços menores em outros países (HEADEY, 2011). Comparando o recente aumento nos preços dos alimentos com episódios históricos, Abbott et al. (2009) argumentam que o dólar fraco foi responsável por cerca de 50% do pico recente. No entanto, as evidências econométricas sobre o impacto dos movimentos do dólar nos preços das commodities até agora não conseguiram fornecer um consenso sobre a importância dos movimentos da taxa de câmbio (Orden e Cheng, 2007; Piesse e Thirtle, 2009).

O impacto dos desequilíbrios macroeconômicos nos preços das commodities via atividades de mercado futuro é ainda mais controverso (HEADEY, 2011).

O etanol de milho dos EUA explica 70% do aumento do preço mundial do milho de acordo com o FMI. O Banco Mundial estimou que a política dos EUA seja responsável por

65% do aumento nos preços agrícolas e, para o ex-economista-chefe do USDA, explica 60% do aumento de preços. O Banco Mundial declara que: “Os preços das culturas usadas como biocombustível aumentaram mais rapidamente do que outros preços dos alimentos nos últimos dois anos, com os preços dos grãos subindo 144%, as oleaginosas 157% e outros alimentos apenas subindo 11%”. Os EUA, como resultado de sua produção de etanol de milho, são claramente responsáveis pela explosão dos preços agrícolas mundiais (MCMICHAEL, 2009). O segundo maior exportador mundial de milho, o Brasil, produz etanol a partir da cana-de-açúcar e, portanto, não influenciou os preços do milho no mercado mundial. Além do milho dos EUA o programa de etanol, o programa de biodiesel dos EUA [soja] também contribui para os preços crescentes (BERTHELOT, 2008).

2.6 Consequências da crise alimentar no Brasil

A adesão de antigos países do terceiro mundo ao Acordo Geral de Tarifas e Comércio (GATT) e à sua repentina conversão ao livre comércio sinaliza a subordinação da reestruturação alimentar à dívida internacional (MCMICHAEL, 2009). A promoção da agricultura de exportações, especialmente aquelas chamadas "não tradicionais" (voltadas para novos nichos de mercado para alimentos exóticos, flores e outras culturas), é um objetivo explícito de condições de ajuste estrutural impostas pelos credores. Eles geralmente intensificam desigualdades sociais e conflitos nos países pobres.

Por exemplo, no Brasil, que é um sucesso impressionante, medido pelo investimento na produção e exportação de alimentos agroalimentares, também é um pesadelo de despejos da terra, deslocamento de sistemas alimentares locais, fome e agitação social (VIERA, 2018). A agitação das principais questões sociais precipitou uma distribuição massiva de alimentos para os pobres. É certamente menos ordenado e menos integrado às políticas públicas do que os subsídios alimentares na última década de austeridade. Faz parte de uma das políticas do Fundo Monetário Internacional (FMI), impor tarifas sobre os preços dos alimentos, isso durante a última década de austeridade (VIERA, 2018). Eles refletem o sofrimento imposto em novos centros de acumulação como o Brasil, não menos do que nas vastas regiões empurradas para as margens de acumulação, que incluem grande parte do continente africano.

Os países devedores estão presos em uma tesoura entre o imperativo de exportação e as restrições de importação nos mercados do norte. Eles são, portanto, forçados a apoiar o livre comércio, por mais difícil que seja a mudança de décadas de substituição de importações, fluxos

controlados de bens e dinheiro e empresas estatais. Pagamento da dívida, reforma monetária e o restante, exigem acesso a mercados de alimentos altamente protegidos na América do Norte, Europa e Japão. O capitalismo liberal é o novo imposto de forma externa de austeridade no final do século XX. É oposto à austeridade pelos estados revolucionários do terceiro mundo da era da Guerra Fria, que assumiu a forma de socialismo autárquico. A coletivização, independentemente das circunstâncias nacionais, costumava ser fútil e até desastrosa. O mesmo pode ser dito da criação de plataformas de exportação de produtos agroalimentares, independentemente das circunstâncias nacionais (FRIEDMANN, 2019).

Enfim, as principais consequências que afetaram o Brasil são semelhantes as consequências em outros países, são elas: i) Aumento na taxa de inflação; ii) intensificação das consequências da crise mundial; aumento nos índices de fome, subnutrição e miséria; iii) aumento ou intensificação dos conflitos sociais (IVANIC, 2012; BELLEMARE, 2015; ROSEGRANT e CLINE, 2003).

2.7 Complexidade das séries temporais

Complexidade pode ser considerada uma das mais importantes propriedades das séries temporais. As medidas de complexidade de séries temporais podem ser divididas em três grupos: fractalidade e multifractalidade que descreve auto similaridade; medidas derivadas de dinâmica não linear e entropias para medir o estado de desordem de um sistema não linear (TANG et al, 2015).

A seguir os principais estudos sobre as técnicas de análise de complexidade das séries temporais:

- Kantelhardt, (2012), elaborou métodos de análise de mono e multifractalidade para séries temporais estacionárias e não estacionárias.
- Lopes e Betrouni, (2009), apresentaram os métodos da análise de fractalidade e multifractalidade para dados de sinais médicos.
- Sun et al., (2006) forneceram um levantamento dos métodos mais usados para estimar a dimensão fractal e suas aplicações em análise de dados de sensoriamento remoto.
- Zanin et al., (2012), analisaram os fundamentos teóricos da Permutation Entropy (PE) bem como as aplicações em estudos em economia, biologia e medicina.
- Alcaraz e Rieta, (2010), avaliaram o uso da Sample Entropy (SampEn) na análise não invasiva de estados patológicos fisiológicos como fibrilação atrial.

- Rosso et al., (2007), apresentaram uma abordagem baseada na teoria de informação de distinção entre ruído e caos.

- Marwan et al., (2007), apresentaram uma revisão abrangente de métodos baseados em recorrência dos sistemas dinâmicos e suas aplicações em economia, fisiologia, neurociência, astrofísica e engenharia.

Nesse trabalho analisa-se a complexidade das séries de preços de commodities, através de medidas de Entropia de Permutação, Complexidade Estatística e Informação de Fisher para fazer uma análise da eficiência desses mercados, obter um ranking entre elas e avaliar a influência de crise financeira e alimentar ocorridos entre 2008/2012.

2.7.1 Medidas de Entropia

2.7.1.1 Entropia de Shannon

Em teoria da informação o conceito de entropia foi introduzido por Shannon (1948) para estudar a transmissão de sinais. A entropia é uma medida de incerteza na estatística, associada com uma variável aleatória. Essa metodologia tem sido aplicada com sucesso, entre outras áreas, em sensoriamento remoto e aplicação de sistemas de informações geográficas (MAHDI et al., 2011), na diversidade do uso do solo e da terra (YABUKI, et al. 2009), ontologias geográficas de múltiplas fontes (LI et al., 2013), em química (FLORES-GALLEGOS, 2016), sistemas hamiltonianos clássicos (KIM, 2009) e na análise de complexidade de mercados (NIU, et al., 2018).

Para uma variável aleatória discreta X com função de probabilidade $p(x) = Pr\{X = x\}$, $x \in X$ a entropia Shannon é definida como:

$$H(x) = \sum_{x \in X} p(x) \log p(x) \quad (1)$$

considera-se esta expressão na base 2 e, a entropia é expressa em bits. A entropia $H(X)$ tem as seguintes propriedades (COVER e THOMAS, 1991):

- i) $H(X) \geq 0$
- ii) $H_b(X) = \log_b(a) H_a(X)$

2.7.1.2 Entropia conjunta e Entropia condicional

A entropia conjunta $H(X, Y)$ das variáveis aleatórias discretas X e Y com a distribuição conjunta $p(x, y) = Pr\{X = x, Y = y\}$, $x \in X$, $y \in Y$ é definida como:

$$H(X, Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x, y) \quad (2)$$

A entropia conjunta $H(X, Y)$ é uma medida de incerteza quando duas variáveis X e Y são consideradas simultaneamente (COVER e THOMAS, 1991).

Para quantificar a entropia ou a incerteza de X , uma outra medida de incerteza foi criada, condicionada a Y , chamada entropia condicional, definida como:

$$H(X|Y) = \sum_{y \in Y} p(y) H(X|Y = y) = \sum_{y \in Y} \sum_{x \in X} p(x, y) \log p(x|y) \quad (3)$$

A entropia condicional é uma medida de incerteza associada com a variável Y quando se sabe o valor da variável X (COVER e THOMAS, 1991). Entropia condicional é caracterizada por assimetria:

$$H(Y|X) \neq H(X|Y) \quad (4)$$

A entropia conjunta e a entropia condicional são relacionadas pela seguinte expressão:

$$H(X, Y) = H(X) + H(Y|X) \quad (5)$$

Essas entropias tem sido utilizadas, entre outras áreas, em efeitos da memória em séries temporais geradas por sistemas dinâmicos não caóticos (COURBAGE e MALHERBE, 2002), otimizar redes de monitoramento de fluxo (STOSIC et al. 2017), mercado de ações (ASMA, 2010,) na medicina (ALONSO et al., 2012; HELEN MARY, 2018).

2.7.1.3 Entropia Relativa e Informação Mútua

A entropia relativa é uma medida de distância entre duas distribuições de probabilidade.

Essas metodologias são aplicadas em diversos segmentos, tais como, extrair propriedades geográficas (XIAO e HE, 2016), análise de imagens (ZHAO et al. 2015), gerar rapidamente campos de força reativos precisos e altamente eficientes (ARNTSEN, et al., 2017), mercados mistos fracionários (CORDERO, et al., 2018).

Para distribuições $p(x)$ e $q(x)$, a entropia relativa (ou a distância Kullback Leibler) é definida como:

$$D(p||q) = \sum_{x \in X} p(x) \log \frac{p(x)}{q(x)} \quad (6)$$

representa também uma medida de incerteza de assumir que a distribuição de probabilidade de variável X é q quando a distribuição verdadeira é p . A entropia relativa é sempre não-negativa e assume o valor zero quando as distribuições p e q são iguais (COVER e THOMAS, 1991).

A informação mútua é uma medida de quantidade de informação que uma variável aleatória contém acerca da outra. A informação mútua $I(X; Y)$ entre duas variáveis aleatórias X e Y com distribuições marginais $p(x)$ e $p(y)$, e distribuição conjunta $p(x, y)$, é definida como entropia relativa entre $p(x, y)$ e produto $p(x)p(y)$:

$$I(X; Y) = D(p(x, y)||p(x)q(y)) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \quad (7)$$

A informação mútua $I(X; Y)$ tem as seguintes propriedades (COVER e THOMAS, 1991):

- i) $I(X; Y) = H(X) - H(X|Y)$
- ii) $I(X; Y) = H(Y) - H(Y|X)$
- iii) $I(X; Y) = H(X) + H(Y) - H(X, Y)$
- iv) $I(X; Y) = I(Y; X)$

2.7.1.4 Entropia de Rényi e Entropia de Tsallis

A entropia de Rényi foi introduzida por Rényi (1961) como uma generalização da entropia de Shannon. Estas metodologias são utilizadas, entre outros temas, na aplicação física simples, como sistemas em contato com banho de calor finito ou sistemas com flutuações de temperatura (KORBEL, 2017), no mercado de ações (CHEN et al., 2018), fisiologia (LI e SHANG, 2019), sistemas atômicos (FLORES-GALLEGOS, 2018), sistemas dinâmicos (MARKECHOVÁ e RIEČAN, 2018).

Para uma determinada distribuição de probabilidade discreta $p = (p_1, \dots, p_n)$, a entropia de Rényi de ordem α é definida como:

$$H_\alpha(p) = \frac{1}{1-\alpha} \log \left(\sum_{k=1}^n p_k^\alpha \right) \quad (8)$$

A entropia de Shannon é obtida como o limite de $H_\alpha(p)$ quando $\alpha \rightarrow 1$ (RENYI, 1961).

A entropia de Tsallis foi introduzida por Tsallis (1988) como uma generalização da entropia de Boltzmann-Gibbs. Para uma determinada distribuição de probabilidade discreta $p = (p_1, \dots, p_n)$, a entropia de Tsallis é definida como:

$$S_q(p) = \frac{k}{q-1} \left(1 - \sum_{i=1}^n p_i^q \right) \quad (9)$$

onde q é um parâmetro real positivo, e quando $q \rightarrow 1$ obtemos a entropia de Boltzmann-Gibbs $S_{BC} = S_i(p) = k \sum p_i \ln p_i$. Na teoria da informação usa-se $k = 1$, e a entropia de Shannon é obtida para $q \rightarrow 1$. A entropia de Tsallis foi utilizada em estudos de fisiologia (CAPURRO, et al., 1999), em geofísica (KALIMERI, et al., 2008) e análise de imagens (DE ALBUQUERQUE, et al., 2004).

2.7.1.5 Entropia amostral (Sample Entropy)

O método *SampleEntropy* ($SampEn(m,r,N)$), introduzido por Richman e Moorman (2000), é definido como sendo o logaritmo natural da probabilidade condicional de que duas sequências similares (dentro de um nível de tolerância r), para m pontos, permanecem similares para $m + 1$ pontos.

Seja $u(1), \dots, u(N)$ uma série temporal de tamanho N . O cálculo da $SampEn(m,r,N)$ é feito seguindo as etapas descritas abaixo (RICHMAN e MOORMAN, 2000):

- i) Construimos $N - m + 1$ vetores $x_m(i)$ de tamanho m :

$$x_m(i) = \{u(i+k): k = 0, \dots, m-1\}, i = 1, \dots, N - m + 1 \quad (10)$$

Definimos a distância entre os vetores $x_m(i)$ e $x_m(j)$ como a diferença máxima entre seus componentes:

$$d[x_m(i), x_m(j)] = \max\{|u(i+k) - u(j+k)|: k = 0, \dots, m-1\} \quad (11)$$

- ii) Para cada $i = 1, \dots, N - m$ calcula-se o número B_i de vetores $x_m(j)$ tal que $d[x_m(i), x_m(j)] \leq r$ onde r é o nível de tolerância ($r: r \equiv r\sigma$, σ -desvio padrão da série $u(1), \dots, u(n)$).
- iii) Na sequência definimos

$$B_i^m(r) = \frac{B_i}{N - m + 1} \quad (12)$$

e

$$B^m(r) = \frac{1}{N-m} \left(\sum_{i=1}^{N-m} B_i^m(r) \right) \quad (13)$$

onde $B^m(r)$ é a probabilidade de dois vetores serem similares para m pontos.

Repetimos os passos para i – iii para os vetores de tamanho $m + 1$ e definimos:

$$A_i^m(r) = \frac{A_i}{N-m-1} \quad (14)$$

e

$$A^m(r) = \frac{1}{N-m} \left(\sum_{i=1}^{N-m} A_i^m(r) \right) \quad (15)$$

onde A_i é o número de vetores $x_{m+1}(j)$ tal que $d[x_{m+1}(i), x_{m+1}(j)] \leq r$, e $A^m(r)$ é a probabilidade de dois vetores serem similares para $m + 1$ pontos.

iv) Por fim, calcula-se o índice *SampleEntropy*:

$$SampEn(m, r, N) = \ln \frac{A^m(r)}{B^m(r)} \quad (16)$$

que representa a probabilidade condicional de duas sequências que são similares para m pontos permaneçam similares para $m + 1$ pontos (quando um dado consecutivo é adicionado).

Essa metodologia tem sido aplicada com sucesso no problema de segurança na bateria de íons de lítio causado pela estabilidade térmica (LI, et al., 2014), em medicina (YOO, et.al., 2012; MONTIROSSO, 2010; JIE, et al., 2014), no estudo da precipitação (XAVIER, et al., 2019), finanças (YIN e SHANG, 2015), mercado de ações (XU, et al., 2016), eficiência de mercados (ANOOP e KAMAIAH, 2014).

2.7.1.6 Entropia de Permutação

O método da entropia de permutação (PE) foi introduzido por Bandt e Pompe (2002) como a entropia de Shannon das probabilidades dos padrões ordinais. Em sua forma original e em suas variantes, o PE tem sido aplicado em fisiologia (GRAFF, et al., 2013; ZENG, et al., 2018), engenharia (YAN e GAO, 2012; GAO, et al., 2017), geofísica (CONSOLINI e MICHELIS, 2014), climatologia (BARREIRO, et al., 2011; SACO, et al., 2010), hidrologia (MIHAILOVIĆ et al., 2014) e finanças (ZUNINO, et al., 2009; YIN e SHANG, 2016). O algoritmo de entropia de permutação procede da seguinte forma (BANDT e POMPE, 2002):

Para uma determinada série temporal x_t , $t = 1, \dots, T$, primeiro $T - (d - 1)$ segmentos sobrepostos $X_t = (x_t, x_{t+1}, \dots, x_{t+d-1})$ de comprimento d (dimensão de incorporação) são gerados e dentro de cada segmento os valores são classificados em ordem crescente, que fornece o conjunto de índices $r_0, r_1, \dots, r_{d-1}$ de tal modo que $x_{t+r_0} \leq x_{t+r_1} \leq \dots \leq x_{t+r_{d-1}}$. As sequências correspondentes $\pi = r_0, r_1, \dots, r_{d-1}$ pode assumir qualquer um dos $d!$ permutações possíveis do conjunto $\{0, 1, \dots, d - 1\}$ e são representantes simbólicos dos segmentos originais. A entropia de permutação de ordem $d \geq 2$ agora é definido como uma entropia de Shannon de distribuição de probabilidade $p(\pi)$:

$$H(d) = - \sum_{\{\pi\}} p(\pi) \log p(\pi) \quad (17)$$

onde $\{\pi\}$ denota somatório sobre todas as $d!$ permutações possíveis de ordem d , e $p(\pi)$ é a frequência relativa de cada permutação π . Segue que $0 \leq H(d) \leq \log d!$ onde o limite inferior é atingido para uma série estritamente crescente ou decrescente (apenas uma permutação aparece), e o limite superior para uma série completamente aleatória onde todos os $d!$ permutações possíveis aparecem com a mesma probabilidade. O ideal d depende fortemente do fenômeno observado, mas a fim de garantir boas estatísticas como regra geral, é normalmente recomendado (RIEDL et al., 2013) escolher o máximo d de tal modo que $T > 5d!$.

3 DADOS E METODOLOGIA

3.1 Dados

Na seção 4.1 os dados utilizados são os preços diários das commodities agrícolas brasileiras obtidos no Centro de Estudos Avançados em Economia Aplicada / Escola de Agricultura Luiz de Queiroz / Universidade de São Paulo - CEPEA / ESALQ / USP, disponíveis no endereço eletrônico <http://www.cepea.esalq.usp.br/> (Data de acesso: 09/2019). Analisamos 11 commodities agrícolas e também incluímos o etanol, cuja variação de preço está diretamente relacionada aos preços do açúcar (ambas as commodities são produzidas a partir da cana-de-açúcar) e indiretamente (em relação aos preços da energia) com outras commodities (Tabela 1). Todas as commodities são analisadas durante o mesmo período 04/01/2010 - 07/2018, com 2120 dados. Esses dados são mostrados na Figura 1.

Tabela 1. Commodities agrícolas

Nome	Moeda/Unidade de medida
Açúcar	R\$/Saca de 50 <i>kg</i>
Algodão	R\$/Libra-peso de pluma (0,453597 <i>kg</i>)
Arroz	R\$/Saca de 50 <i>kg</i>
Bezerro	Animal vivo (R\$/cabeça);
Boi gordo	R\$/arroba
Café	R\$/Saca de 60 <i>kg</i>
Etanol	R\$/Litro
Frango	R\$/ <i>Kg</i>
Milho	R\$/saca de 60 <i>kg</i>
Soja	R\$/saca de 60 <i>kg</i>
Suíno	R\$/ <i>Kg</i>
Trigo	R\$/Tonelada




Figura 1 - Séries temporais de preços de commodities agrícolas registradas diariamente durante o período de 04 de janeiro de 2010 a 03 de julho de 2018.

Na seção 4.2 os dados utilizados são os preços diários das commodities agrícolas brasileiras: algodão, açúcar, café, boi gordo e soja registrados no período 1996-2018. Os dados são obtidos no Centro de Estudos Avançados em Economia Aplicada / Escola de Agricultura Luiz de Queiroz / Universidade de São Paulo - CEPEA/ESALQ/USP, obtidos no endereço eletrônico <http://www.cepea.esalq.usp.br/>. Os preços são apresentados em reais por unidade de medida: algodão (R\$/libra), açúcar (R\$/saca de 50 kg), café (R\$/saca de 60 kg), boi gordo (R\$/15 kg) e soja R\$/saca de 60 kg. Seguindo Zunino et al. (2011) analisamos os preços diários de commodities que são mostrados na Figura 2.




Figura 2 - Séries temporais de preços de commodities agrícolas registradas diariamente durante o período 1996 a 2018.

Tabela 2 - Commodities utilizadas no estudo e suas descrições

Comodities	Descrição
Açúcar	Por saca de 50 kg, com ICMS (7%) até 12/03/2013, eram considerados também PIS/Cofins (9,25%), que deixaram de incidir sobre o açúcar cristal, segundo Medida Provisória nº 609, de 8/3/13. A inclusão do açúcar cristal (código 1701.99.00 da TIPI) nesta lista foi divulgada no Diário Oficial de 13/3/13.
Algodão	Preços de algodão pluma, tipo 41-4, posto na mesorregião da cidade de São Paulo. O prazo médio de pagamento se refere à média de dias para pagamento dos negócios com prazos, considerados para o cálculo. Todos os valores que atendem aos critérios estatísticos foram convertidos para pagamento em 8 dias com base na taxa de desconto NPR. Nota1: No dia 1 de junho de 2018, o Indicador foi arbitrado.

	Centavos de reais por libra-peso. centavos de reais para reais, desloque a vírgula duas casas para a esquerda. Conversões: Um libra-peso equivale a 0,453597 quilo. Para transformar de libra-peso para arroba, multiplique por 33,069. Para converter de arroba para libra-peso, dividida por 33,069. Para levar libra-peso para kg, multiplique por 2,2046; para tonelada, multiplique este resultado por 1.000.
Arroz	Por saca de 50 kg, tipo 1, 58/10, posto indústria Rio Grande do Sul, à vista (Prazo de Pagamento descontado pela taxa CDI/CETIP)
Bezerro	Valor por unidade - descontado o prazo de pagamento pela taxa CDI.
Boi Gordo	Por arroba, descontado o Prazo de Pagamento pela taxa CDI/CETIP. Os valores divulgados são livres de Funrural.
Café	Por saca de 60kg líquido, bica corrida, tipo 6, bebida dura para melhor, valor descontado o Prazo de Pagamento pela taxa da NPR, posto na cidade de São Paulo.
Etanol	Sem frete e sem impostos (sem ICMS e sem PIS/Cofins). De 02/01/17 a 20/07/17, as informações que compunham este Indicador eram descontadas do valor de R\$ 120 por m ³ comercializado, referentes a R\$ 21,43 por m ³ para o PIS e R\$ 98,57 por m ³ no caso da Cofins. A partir de 21 de julho de 2017, no entanto, as informações que compõem este Indicador são descontadas do valor de R\$ 130,9 por m ³ comercializado, referentes a R\$ 23,38 por m ³ para o PIS e R\$ 107,52 por m ³ no caso da Cofins.
Frango	Preço da carne negociada no atacado, média (Reais por quilo) das regiões: Grande São Paulo, São José do Rio Preto e Descalvado.
Soja	Reais por saca de 60 kg. Entre os dias 10 e 17 de novembro, foram consideradas todas as ofertas para o cálculo do Indicador.
Milho	À vista por saca de 60 kg, descontado o Prazo de Pagamento pela taxa CDI/CETIP.
Suíno	Preço recebido pelo produtor R\$/Kg sem ICMS.
Trigo	Trigo pão ou melhorador. preço por tonelada. mercado disponível, à vista (prazo descontado pela taxa NPR).

3.2 Plano Complexidade - Entropia (*Complexity entropy causality plane* – CECp)

O plano Complexidade-Entropia (CECP) é uma nova abordagem de complexidade introduzida por Rosso et al. (2007) como ferramenta para quantificar conjuntamente o conteúdo informacional e a complexidade estrutural em séries temporais. Foi demonstrado que o CECP é útil para distinguir entre ruído estocástico e comportamento caótico determinístico (ROSSO et al., 2007), levando a muitas aplicações na análise de dados, como em fisiologia (LEGNANI, et al., 2018), física (WECK et al., 2015; MAGGS e MORALES, 2013), oceanografia (SIDDAGANGAIAH, et al., 2016), ecologia (SIPPEL, 2016), hidrologia (STOSIC, et al., 2016; JOVANOVIĆ, et al., 2017; SERINALDI, et al., 2014) e finanças (ZUNINO, et al., 2010; ZUNINO, et al., 2012; BARIVIERA, et al., 2018; BARIVIERA, et al., 2013). Neste espaço de representação, os eixos horizontal e vertical são a entropia de permutação descrita em 2.8.6 e uma medida de complexidade estatística definida como:

$$C[P] = \frac{J[P, U]}{J_{max}} H_s[P] \quad (18)$$

onde $H_s[P] = \frac{H[P]}{\log d!}$ é a entropia de permutação normalizada, $J[P, U]$ é a divergência de Jensen-Shannon

$$J[P, U] = \left\{ H \left[\frac{(P + U)}{2} \right] - \frac{H[P]}{2} - \frac{H[U]}{2} \right\} \quad (19)$$

que quantifica a diferença entre a distribuição de probabilidade P de Bandt-Pompe e a distribuição uniforme U , e o valor máximo possível de $J[P, U]$ é obtido quando um dos componentes de P é igual a um, e todos os outros são iguais a zero

$$J_{max} = -\frac{1}{2} \left[\frac{d! + 1}{d!} \log(d! + 1) - 2 \log(2d!) + \log(d!) \right] \quad (20)$$

Para cada valor dado da entropia de permutação normalizada $H_s \in [0,1]$ existe uma gama de possíveis valores de complexidade, $C_{min} \leq C \leq C_{max}$, que produz os envelopes inferior e superior no CECP (MARTIN, et al., 2006).

Entropia de permutação e complexidade estatística fornecem informações sobre duas propriedades distintas de um conjunto de dados. A entropia de permutação quantifica o grau de aleatoriedade inerente a um processo: sinais mais previsíveis (que mostram tendência a repetir apenas alguns padrões ordinais) têm entropia de permutação mais baixa do que sinais menos previsíveis (que tendem a exibir todos os padrões ordinais possíveis). Para um determinado valor de entropia, a complexidade estatística quantifica o grau em que existem flutuações privilegiadas (padrões ordinais) entre aquelas acessíveis ao sistema. A definição de complexidade estatística garante que tanto séries estritamente crescentes quanto decrescentes (para as quais $H_s[P] = 0$) e séries completamente aleatórias (para as quais $J[P, U]=0$) tem zero complexidade. Para valores intermediários de entropia diferente de zero, a complexidade máxima corresponde a distribuições que diferem mais de uniformes, exibindo, portanto, a maior complexidade estrutural. Ao calcular essas quantidades para uma determinada série temporal, tanto a aleatoriedade quanto o grau de estrutura correlacional nas flutuações do sistema podem ser avaliados simultaneamente (ROSSO, et al., 2007).

3.3 Informação de Fisher

A medida de informação de Fisher pode ser interpretada de várias formas como uma medida da capacidade de estimar um parâmetro, como a quantidade de informação que pode ser extraída de um conjunto de medidas e também como uma medida do estado de desordem de um fenômeno sistêmico (FRIEDEN, 2004; MAYER, et al., 2006). Esta medida foi amplamente utilizada em física (SEN et al., 2007; BOUMALI & LABIDI, 2018), fisiologia (MARTIN et al., 1999), geofísica (TELESCA et al, 2011; BALASIS et al, 2016), ecologia (LANORTE et al, 2014), meteorologia (PIERINI et al, 2016; GUIGNARD et al., 2019) e hidrologia (PIERINI et al, 2015).

Para uma variável contínua X com função densidade de probabilidade $f(x)$, a informação de Fisher é definida como (VIGNAT and BERCHER 2003)

$$I_X = \int_{-\infty}^{+\infty} \left(\frac{\partial}{\partial x} f(x) \right)^2 \frac{dx}{f(x)} \quad (21)$$

É importante observar que o operador de gradiente influencia significativamente a contribuição de minúsculas f -variações locais para o valor da informação de Fisher, de modo

que o quantificador é chamado de “local”. Observe que a entropia de Shannon diminui com a distribuição inclinada, enquanto as informações de Fisher aumentam nesse caso. A sensibilidade local é útil em cenários cuja descrição requer um apelo a uma noção de "ordem" (ROSSO et al., 2010; OLIVARES et al., 2012 (a); OLIVARES et al., 2012 (b)).

Para uma distribuição discreta P , a informação de Fisher é definida como (GONÇALVES et al., 2019)

$$F[P] = F_0 \sum_{i=1}^{N-1} (\sqrt{p_{i+1}} - \sqrt{p_i})^2 \quad (22)$$

em que p_i and p_{i+1} são probabilidades consecutivas de distribuição discreta P e F_0 é uma constante de normalização ($F_0 = 1$ se $p_1 = 1$ ou $p_N = 1$, e $F_0 = 1/2$ caso contrário).

Diferente de entropia de Shannon, informação de Fisher assume o valor máximo $F[P] = 1$ quando o conhecimento sobre o sistema é completo e o valor mínimo $F[P] = 0$ para uma distribuição uniforme quando a informação sobre o sistema é mínima.

O plano de entropia-informação de Fisher (FI) introduzido por Vignat e Bercher (2003), e construído de forma que os eixos horizontal e vertical sejam a entropia de Shannon $H_s[P]$ e informação de Fisher $F[P]$, respectivamente. Neste trabalho calculamos ambos quantificadores para distribuição de probabilidade Bandt-Pompe. Esta versão de FI mostrou-se útil na análise de sinais fisiológicos (MONTANI et. al, 2014; BARAVALLE et al, 2014) e séries temporais financeiras (GONÇALVES et al., 2019; BARIVIERA et al, 2019).

3.4 Implementação do algoritmo de Entropia de Permutação, Complexidade Estatística e Informação de Fisher

Como exemplo de procedimento do método de entropia de permutação descrito na seção 2.8.6 consideramos uma série temporal:

10, 5, 18, 12, 20, 25, 15.

Agora escolhemos o tamanho do subconjunto d , isto como primeiro passo. Para este exemplo, escolhemos $d = 3$. A série acima possui 5 subconjuntos dados por (10, 5, 18), (5, 18, 12), (18, 12, 20), (12, 20, 25) e (20, 25, 15).

Cada subconjunto é classificado de acordo com o padrão ordinal dos seus elementos. Para o primeiro subconjunto (10, 5, 18), a primeira entrada é intermediária (2), a segunda é a menor

(1) e a terceira é a maior (3). Essa ordem pode ser representada pela categoria 213. Da mesma forma, o segundo ao quinto subconjunto pode ser categorizado por 132, 213, 123 e 231, respectivamente. Observe que o tamanho das diferenças não é levado em consideração. Também deve-se observar que é assumido que as entradas em cada par são únicas, portanto valores iguais não precisam ser considerados.

Em geral, o número de categorias possíveis é dado por $d!$. Como resultado, existem seis categorias possíveis para $d = 3$, ou seja,

123, 132, 213, 231, 312, 321.

Do mesmo modo é observado na Figura 3 abaixo:




Figura 3 – Figura das seis permutações ordinais possíveis para $d = 3$ (OLIVIER, et al., 2019).

É conveniente representar essas probabilidades como um vetor $P = [p_1, p_2, \dots, p_6]$. Embora a escolha dos índices no vetor seja arbitrária, uma maneira natural de rotular as categorias é em valores numéricos ascendentes. No nosso exemplo, os índices 1 a 6 correspondem às seis categorias mostradas na acima (Figura 3), respectivamente.

Para calcular cada probabilidade, dividimos a frequência de cada categoria pelo número total de subconjuntos. Na ausência de lacunas de dados, o número total de subconjuntos é dado por $N - d + 1$, onde N é a duração da série temporal.

Para o nosso exemplo, o número total de subconjuntos é dado por 5. Há duas ocorrências de 213 (primeiro e terceiro subconjuntos), de modo que $p = 2 / 5$. Há uma ocorrência de 123 (quarto conjunto), de modo que $p = 1 / 5$. Da mesma forma, $p = p = 1 / 5$, enquanto $p = p = 0$. Portanto, temos o vetor de probabilidade $P = [0, 2, 0, 2, 0, 4, 0, 2, 0, 0]$.

Uma vez que o vetor P é construído, simplesmente se utiliza as fórmulas de Lamberti et al., (2004), dado por:

$$H(P) = \frac{S(P)}{\ln(d!)} \quad (23)$$

onde

$$S(P) = - \sum_{j=1}^{d!} p_j \ln p_j \quad (24)$$

Note-se que os valores zero de p devem ser excluídos da soma S , uma vez que o logaritmo zero é indefinido.

Para o nosso exemplo, segue-se $H \approx 0,7435$ para a série temporal em questão.

A segunda variável, a complexidade estatística C , é dada por:

$$C[P] = Q_j(P, P_e)H(P) \quad (25)$$

onde

$$Q_j = Q_0 \left[S\left(\frac{P + P_e}{2}\right) - \frac{1}{2}S(P) - \frac{1}{2}S(P_e) \right], \quad (26)$$

$$Q_0 = -2 \left(\frac{d! + 1}{d!} \ln(d! + 1) - 2 \ln(2d!) + \ln d! \right)^{-1} \quad (27)$$

e P é o vetor de probabilidade que representa a entropia de permutação perfeita, onde $p = 1/d!$ para todo j . Para exemplo em questão, esse vetor consiste em seis entradas de $1/6$. Segue-se que $C \approx 0,2335$ para a série temporal analisada.

A Informação de Fisher é calculada como

$$F[P] = F_0 \sum_{i=1}^{N-1} (\sqrt{p_{i+1}} - \sqrt{p_i})^2 \quad (28)$$

e obtemos para esta série (com $F_0 = 1/2$) $F[P] \cong 0.417$.

3.5 Evolução temporal, janelas deslizantes

A análise CECF dependente do tempo é baseada na técnica de janela deslizante e gera uma evolução temporária de complexidade no sistema. Dada uma série temporal $x_1, \dots, x_N$, janelas deslizantes $z_t = x_{1+t\Delta}, \dots, x_{w+t\Delta}$, $t = 0, 1, \dots, \left\lfloor \frac{(N-w)}{\Delta} \right\rfloor$, são construídos onde $w \leq N$ é o tamanho da janela, $\Delta \leq w$ é a etapa de deslizamento e $\lfloor \cdot \rfloor$ denota a tomada de parte inteira do argumento. Os valores das séries temporais em cada janela z_t são então utilizados para calcular a entropia de permutação H_s , complexidade estatística C e a Informação de Fisher F num dado momento t utilizando os métodos descritos acima. Isso nos permite obter a evolução temporal da posição da janela no CECF e no plano entropia-informação de Fisher (FI).

4 RESULTADOS E DISCUSSÃO

4.1 Análise de previsibilidade das commodities agrícolas brasileiras utilizando CECP

Os resultados apresentados nesta seção foram publicados no artigo:

DE ARAUJO, F. H. A., BEJAN, L., ROSSO O. A., & STOSIC, T. Permutation entropy and statistical complexity analysis of Brazilian agricultural commodities. *Entropy*, 21(12), 1220, 2019.

Como dito na seção 4.1, analisamos 11 commodities agrícolas e também incluímos o etanol, cuja variação de preço está diretamente relacionada aos preços do açúcar. Levando em conta que cada uma das séries temporais de commodities analisadas contém $T = 2120$ pontos de dados (preços diários durante o período 04/01/2010 - 07/2018, Figura 1) escolhemos a dimensão de incorporação $d = 4$ e $d = 5$ (satisfazendo a condição $T > 5d!$) para calcular quantificadores de informação em CECP, entropia de permutação $H_s[P]$ e complexidade estatística $C[P]$. As localizações das séries analisadas no plano complexidade - entropia para dimensões de incorporação $d = 4$ e $d = 5$ juntamente com as localizações das séries randomizadas correspondentes são mostradas na Figura 4 e Figura 5, respectivamente. Pode-se ver que para ambos $d = 4$ (Figura 4) e $d = 5$ (Figura 5) alguns pares específicos de commodities etanol/açúcar, soja/milho e boi gordo/bezerro têm posições semelhantes no CECP.

Os mercados de etanol e açúcar estão fortemente interligados, pois ambas as commodities são produzidas a partir da mesma safra agrícola (cana de açúcar) e são influenciadas por fatores globais (preços do petróleo bruto) e características locais específicas do desenvolvimento econômico brasileiro (políticas governamentais e avanços tecnológicos como usinas flexíveis, que podem facilmente mudar a produção do etanol para o açúcar, e vice-versa) (LIMA, et al., 2019; CAVALETT, et al., 2012). O aumento no preço do etanol (açúcar) leva à maior produção de etanol (açúcar) da cana-de-açúcar e consequentemente menor produção de açúcar (etanol) resultando em um desequilíbrio de longo prazo entre demanda e oferta (maior demanda que oferta) e maiores preços do açúcar (etanol). Portanto, espera-se que as duas commodities tenham previsibilidade similar de variações de preço, o que resulta em sua posição similar no

plano CECP. No caso da soja/milho, uma razão para tal resultado pode ser o fato de que no Brasil (que está entre os maiores produtores e consumidores de carne de frango) a ração de frangos é baseada principalmente no milho e farelo de soja, que fornece a maior parte da energia e proteína na dieta (DA SIVA, et al., 2014). O boi gordo e bezerro pertencem à cadeia produtiva da carne bovina e também apresentam previsibilidade semelhante (posição no CECP). Preços de suínos e frangos apresentaram maior previsibilidade (menor entropia) que bezerro e boi gordo, enquanto entre os grãos o trigo apresentou menor previsibilidade (maior entropia). O algodão apresentou uma previsibilidade relativamente alta (baixa entropia), perdendo apenas para suíno. A distância euclidiana ao vértice direito da CECP ($H_s = 1, C = 0$) representando o resultado para séries completamente aleatórias pode ser usada como uma medida de ineficiência do mercado (ZUNINO, et al., 2011). A classificação da eficiência das commodities agrícolas (ordenada pela diminuição da distância de posição no CECP do vértice direito (1,0), que representa um mercado eficiente cujos preços seguem um passeio aleatório) é mostrada na Tabela 2, onde se observa que o mais eficiente (menos previsível) é o mercado de café, e o menos eficiente (mais previsível) é o mercado de suíno. O ranking de commodities idêntico (com exceção de boi gordo e bezerro) é obtido com diferentes dimensões de incorporação.

Tabela 3 Classificação de commodities agrícolas por eficiência decrescente. Valores de entropia de permutação H_s e complexidade estatística C e distância do vértice (1,0) são calculados para $d = 4$ e $d = 5$.

Posição	Comodities	$d = 4$			Comodities	$d = 5$		
		H_s	C	Dist. à (1,0)		H_s	C	Dist. à (1,0)
1.	Café	0.950	0.058	0.076	Café	0.926	0.109	0.132
2.	Trigo	0.946	0.060	0.081	Trigo	0.916	0.114	0.142
3.	Bezerro	0.923	0.088	0.117	Boi gordo	0.884	0.139	0.181
4.	Boi gordo	0.915	0.088	0.122	Bezerro	0.891	0.155	0.189
5.	Arroz	0.901	0.106	0.144	Arroz	0.862	0.176	0.224
6.	Açúcar	0.854	0.140	0.202	Açúcar	0.803	0.213	0.290
7.	Milho	0.850	0.146	0.209	Milho	0.798	0.219	0.298
8.	Soja	0.822	0.160	0.240	Soja	0.780	0.226	0.316
9.	Etanol	0.820	0.161	0.241	Etanol	0.766	0.227	0.326
10.	Frango	0.744	0.214	0.334	Frango	0.703	0.289	0.414
11.	Algodão	0.716	0.217	0.357	Algodão	0.657	0.267	0.434
12.	Suíno	0.638	0.253	0.441	Suíno	0.570	0.312	0.531




Figura 4 - Posição no plano complexidade - entropia das séries de mercadorias originais (A) e (B) randomizadas para dimensão de incorporação $d = 4$.




Figura 5 - Posição no plano complexidade - entropia das séries de mercadorias originais (A) e (B) randomizadas para dimensão de incorporação $d = 5$.

Para avaliar como a eficiência das commodities muda ao longo do tempo, aplicamos a análise CECP em janelas deslizantes de tamanho de 1000 dados (em torno de quatro anos) com um salto de 20 dados (em torno de um mês comercial) e calculamos em cada janela a distância da posição CECP do vértice direito (1,0). A evolução temporal desta distância (medida de ineficiência) é mostrada na Figura 6, da qual podemos observar que 8 de 12 mercados (frango, suíno, etanol, milho, açúcar, bezerro, trigo e café) exibem eficiência relativamente estável durante o período analisado, com carne de porco apresentando a menor eficiência e trigo e café

a maior eficiência. A eficiência do mercado de algodão, arroz e boi gordo aumenta, mas em geral os mercados de boi gordo e arroz são mais eficientes do que o mercado de algodão (indicado por valores mais baixos do índice de ineficiência). O mercado de soja mostra a queda na eficiência (maior previsibilidade) até 2014, seguido do aumento da eficiência (menor previsibilidade) para o restante do período estudado. Esse padrão coincide com a variação dos preços da soja, que foram menores e mais previsíveis no período 2010-2014, seguidos pelo período de preços mais altos e maior eficiência do mercado. Zunino et al., (2011) analisaram a previsibilidade do mercado internacional de commodities, incluindo diversas commodities agrícolas, que comparando com nossos resultados em commodities agrícolas brasileiras mostraram maior eficiência de mercado. No entanto, o período analisado em (ZUNINO et al., 2011) foi 1991-2009, antes e durante a crise alimentar de 2007/2008 e os nossos resultados nos dados de 2010-2018 revelam a evolução pós-crise da eficiência do mercado. A diminuição da eficiência do mercado agrícola após a crise também foi relatada em outros estudos. Ceballos et al., (2016) analisaram a transmissão da volatilidade do preço dos alimentos (milho, arroz, sorgo e trigo) do mercado internacional para mercados de países em desenvolvimento e descobriram que a volatilidade internacional dos preços é mais provável de ser transmitida aos mercados da América do Sul. Eles também descobriram que, com exceção do sorgo, que mostrou apenas um aumento moderado, a volatilidade para o resto das commodities aumentou em mais de 30% após a crise, indicando uma menor eficiência do mercado




Figura 6 - Evolução temporal da medida de ineficiência (distância do ponto CECP $H_S = 1$, $C = 0$) para séries de mercadorias para dimensão de incorporação $d = 5$.

4.2 Análise de previsibilidade das commodities agrícolas brasileiras utilizando CECF: a influência da crise financeira

Os resultados apresentados nesta seção foram publicados no artigo:

DE ARAUJO, F. H. A., 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*, 139, 110081, 2020.

Como cada uma das séries temporais de mercadoria analisada contém $T = 5320$ pontos de dados, escolhemos a dimensão de incorporação $d = 5$ e $d = 6$ (satisfazendo a condição $T > 5d!$) para calcular quantificadores de informação entropia $Hs[P]$, complexidade estatística $C[P]$ e informações de Fisher $F[P]$. As posições das mercadorias analisadas no plano de causalidade complexidade-entropia para a dimensão de incorporação $d = 5$ e $d = 6$ foram quase idênticas, e os resultados para $d = 6$ juntamente com as localizações das séries aleatórias correspondentes nos planos CECF e FI são mostrados em Figura 7. Os pontos correspondentes às séries aleatórias foram incluídos nessas Figuras para demonstrar o fato de que o embaralhamento move esses pontos para perto dos vértices $(Hs[P] = 1, C[P] = 0)$ e $(Hs[P] = 1, F[P] = 0)$ que correspondem a séries completamente aleatórias (mercado eficiente) e, portanto, a ordem de valores da série original está longe de ser aleatória. Observa-se que o menor valor de entropia corresponde às séries do algodão, indicando o mercado menos eficiente entre as cinco commodities em estudo, enquanto a série do café apresenta a maior entropia e, conseqüentemente, o mercado mais eficiente.




Figura 7 - Posição no plano de entropia-complexidade (CECP) e plano de entropia-informação de Fisher (FI) da série de commodities original e aleatória para a dimensão de incorporação $d = 6$

Considerando uma janela de 500 dias (cerca de dois anos de dados), deslocando-se através da série temporal com uma etapa de 20 dias (cerca de 1 mês de dados), calculamos a variação de tempo da entropia de permutação $Hs[P]$, complexidade estatística $C[P]$ e informações de Fisher $F[P]$ para todas as séries analisadas usando a dimensão de incorporação $d = 4$. Os resultados desses cálculos nos planos CECP e FI correspondentes são mostrados na Fig. 8 e na Fig. 9, respectivamente. Observa-se na Fig.8 que as commodities alimentares bovino e açúcar apresentam comportamento semelhante: os valores de entropia aumentam durante o período de crise (2007-2011) e novamente aumentam no período pós-crise (após 2011) indicando o aumento da eficiência do mercado. A soja mostra a mesma tendência, mas com maiores valores

de entropia e maior eficiência de mercado. A eficiência do mercado de algodão permanece semelhante para os períodos antes e durante a crise (evolução temporal semelhante dos pontos azuis e vermelhos no CECP), e aumenta após a crise, conforme indicado por valores de entropia mais elevados, mas permanece menos eficiente do que as commodities alimentares (menor entropia valores para os pontos verdes). As séries temporais do café apresentam comportamento diferente: a posição de todas as janelas deslizantes fica próxima ao vértice direito ($H_s = 1, C = 0$) indicando alta eficiência do mercado durante todo o período analisado. Qualitativamente, esses achados são confirmados com os resultados do plano de informação de Fisher (Fig. 9).




Figura 8 - Trajetória no plano de entropia-complexidade (CECP) de séries temporais de commodities agrícolas para a dimensão de incorporação $d = 4$, tamanho da janela $w = 500$ e passo deslizante $\Delta = 20$.




Figura 9 - Trajetória no plano de informação de entropia-Fisher (HF) de séries temporais de commodities agrícolas para a dimensão de incorporação $d = 4$, tamanho da janela $w = 500$ e passo deslizante $\Delta = 20$.

Em seguida, seguindo Bariviera et al. (2015; 2019), analisamos a evolução temporal do grau de eficiência informacional dos mercados de commodities. Eles propuseram o índice de eficiência $E[P] = H[P] - F[P]$, que pode assumir valores entre -1 e 1, onde $E = 1$ representa o comportamento mais informacionalmente eficiente: para uma série completamente aleatória $H[P] = 1$ e $F[P] = 0$. Para comportamento completamente regular, $H[P] = 0$ e $F[P] = 1$, o que dá $E = -1$. A evolução temporal desse índice é mostrada na Figura 10, onde observamos que as séries de café e soja apresentam comportamento de eficiência informacional elevada e estável para todos os períodos analisados, sendo o café mais eficiente do que a soja. A eficiência do mercado de açúcar mostra aumento constante, enquanto o mercado de gado e algodão,

embora pertencendo a diferentes tipos de commodities, apresentam comportamento semelhante: primeiro, o período de queda da eficiência (até 2003 para o algodão e 2007 para o gado) seguido pelo período de maior aumento da eficiência. O mercado de gado apresenta um comportamento muito claro que está relacionado com o período de picos dos preços dos alimentos 2007-2011. Até 2007, a eficiência do mercado foi diminuindo, depois começou a aumentar até 2011, e a partir daí continua com eficiência elevada e relativamente estável.




Figura 10 - Evolução temporal do índice de eficiência $E=H-FI$ de séries temporais de commodities agrícolas para dimensão de embutimento $d=4$, tamanho de janela $w=500$ e passo deslizante $\Delta=20$.

Também calculamos o valor médio e o desvio padrão do índice de eficiência obtido de todas as janelas deslizantes para os períodos anteriores (1997-2006), durante (2007-2011) e após (2012-2018) a crise alimentar. Os resultados são apresentados na Tabela 3 onde se verifica que o mercado de café apresenta maior e estável eficiência para os três períodos, seguido pelo mercado de soja que apresenta tendência semelhante, mas com menor eficiência. Outros mercados são menos eficientes em todos os períodos, com o algodão exibindo a eficiência mais baixa. A exceção é o mercado de gado que mostra alta eficiência após a crise. Em nosso artigo anterior (de Araujo et al. 2019), comparamos a eficiência de 12 commodities agrícolas brasileiras para o período de 2010-2018 usando a distância do canto direito (1,0) no plano de entropia-complexidade. Usando o índice de eficiência baseado na entropia - plano de informação de Fisher, encontramos a mesma ordem de eficiência decrescente para o terceiro período (2012-2018) como em (Rosso et al., 2007) para todas as cinco commodities.

Tabela 4. Valores médios e desvio padrão do índice de eficiência $E = H[P] - F[P]$ para commodities agrícolas calculados para janelas deslizantes para os períodos antes (1996-2006), durante (2007-2011) e após (2012-2018) alimentos crise.

	Até 2006		2007 - 2011		Após 2011	
Comodities	Média	Desvio Padrão	Média	Desvio Padrão	Média	Desvio Padrão
Café	0.892	0.024	0.912	0.024	0.888	0.028
Boi Gordo	0.516	0.134	0.520	0.213	0.837	0.081
Açúcar	0.503	0.085	0.743	0.039	0.764	0.040
Algodão	0.470	0.150	0.407	0.081	0.538	0.159
Soja	0.774	0.053	0.777	0.016	0.801	0.030

5 CONCLUSÃO

Durante a última década, as commodities foram incluídas na diversificação do portfólio. A financeirização de commodities (aumento dos investimentos em commodities por meio de instrumentos financeiros) que ocorreu entre 2004 e 2005, gerou um aumento na integração nos mercados de commodities e, em particular, no setor de commodities agrícolas (Hamadi and Nehme, 2017). Diferentemente de outros tipos de commodities, as commodities agrícolas exibiram flutuações extremas inesperadas, especialmente durante o período de 2007-2009, o que faz com que os participantes do mercado, como produtores, consumidores e investidores, estejam seriamente preocupados com os movimentos de commodities agrícolas, bem como seus co-movimentos em ambos os níveis de mercado único e entre diferentes mercados.

As commodities agrícolas exibiram picos de preços inesperados, especialmente durante a crise alimentar em 2007/2008 e novamente em 2010/2011. O aumento dos preços dos alimentos afeta as condições de segurança alimentar, especialmente nos países em desenvolvimento, gerando grande preocupação de governos e organizações internacionais. A mitigação de tais efeitos requer uma análise abrangente da variabilidade temporal dos preços das commodities com relação aos períodos de picos de preços.

Neste trabalho investigamos as variações de preços no mercado agrícola brasileiro, especificamente a previsibilidade das commodities agrícolas brasileiras para o período após a crise alimentar de 2007/2008 e antes, durante e após a crise alimentar, abordamos essa questão analisando a previsibilidade de cinco preços de commodities agrícolas brasileiras (algodão, açúcar, café, soja e gado) durante o período 1997-2018, que abrange os períodos de picos de preços de commodities agrícolas entre 2007 e 2011. Usamos o novo método, plano de causalidade de entropia-complexidade (CECP), que é uma ferramenta livre de modelos para quantificar conjuntamente o conteúdo da informação e a complexidade estrutural em séries temporais. CECP é uma representação gráfica de dois quantificadores de informações complementares: entropia de permutação, que quantifica o grau de aleatoriedade inerente a um processo, e complexidade estatística que quantifica o grau em que existem flutuações privilegiadas (padrões ordinais) entre aqueles acessíveis ao sistema. Ao investigar a localização das commodities analisadas no CECP e os desvios da posição associados a um processo totalmente aleatório ($H_s = 1$, $C = 0$), comparamos a eficiência de seus mercados

(previsibilidade). Usamos também informações dos métodos teóricos plano de entropia-complexidade (CECP) e entropia-plano de informação do pescador (FI) para comparar a previsibilidade das commodities agrícolas brasileiras para os períodos anteriores e posteriores à crise alimentar.

Os principais resultados deste trabalho são: i) pares específicos de commodities etanol / açúcar, soja / milho e gado / bezerros têm posições semelhantes no CECP, refletindo sua interligação no mercado agrícola brasileiro; ii) comparar o desvio da extremidade direita do CECP (que corresponde a um processo completamente aleatório) revela que o mais eficiente (menos previsível) é o mercado de café, e o menos eficiente (mais previsível) é o mercado de carne suína; iii) ao analisar a evolução temporal dos preços das commodities no plano de causalidade complexidade-entropia, observamos que durante o período pós-crise a eficiência do mercado de algodão, arroz e gado aumenta, o mercado de soja mostra queda de eficiência (maior previsibilidade) até 2012, seguido pelo aumento da eficiência (menor previsibilidade), enquanto outras commodities apresentam eficiência relativamente estável (com o mercado de carne suína apresentando a menor eficiência e os mercados de trigo e café a maior eficiência).

Ao analisar a evolução temporal do índice de eficiência derivado dos quantificadores do plano FI, observamos que as séries de café e soja apresentam alta e estável eficiência informacional para todo o período analisado, a eficiência do mercado de açúcar mostra aumento constante, enquanto o mercado de gado e algodão apresenta primeiro um período de diminuição da eficiência (até a crise), seguido por um período de maior aumento da eficiência (sendo mais pronunciado para o mercado de boi gordo). Embora a literatura explore principalmente o comportamento das commodities agrícolas internacionais, muito menos se sabe sobre o comportamento dos mercados locais, principalmente nos países em desenvolvimento, cuja população é mais vulnerável a mudanças repentinas nos preços dos alimentos. Nosso trabalho revela como o mercado agrícola nacional, neste caso o mercado brasileiro, reage às altas globais dos preços dos alimentos, indicando que mais estudos devem ser feitos nos mercados locais de outros países.

Comparando nossos resultados com os de Zunino et al. (2011), observamos que os mercados agrícolas tornaram-se menos eficientes (mais previsíveis) após a crise alimentar de 2007/2008, o que está de acordo com os resultados de alguns estudos recentes (Balcombe, 2007). Embora a importância da compreensão das variações de preços de commodities agrícolas e seus fatores contribuintes fosse amplamente reconhecida, produzindo uma grande quantidade de resultados em economia agrícola, na literatura economofísica a maioria dos

estudos concentra-se no comportamento dos índices do mercado de ações e preços de ações individuais, enquanto os mercados de commodities são muito menos explorados.

Nossos resultados contribuem também para um melhor entendimento das commodities agrícolas como sistemas complexos, e no caso particular do mercado brasileiro identificamos intervalos de aumento e diminuição da eficiência (menor e maior previsibilidade) na dinâmica das commodities durante o período pós-crise. As informações extraídas do CECP revelam que algumas commodities se comportam de maneira semelhante (exibem valores semelhantes de quantificadores de informações), o que pode ser valioso para investidores e formuladores de políticas na investigação de movimentos anômalos de mercado, como bolhas ou especulações. Essas anomalias são extremamente importantes para os mercados agrícolas, pois qualquer mudança abrupta na dinâmica dos preços pode causar graves consequências para o bem-estar de ambos os grupos, compradores e vendedores de alimentos. Os estudos futuros devem enfocar as diferenças e semelhanças com os mercados agrícolas de outros países de forte comércio com o Brasil, bem como a influência de outras variáveis financeiras dos mercados doméstico e internacional.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ABBOTT, P.C., BOROT de BATTISTI, A., *Recent Global Food Price Shocks: Causes, Consequences and Lessons for African Governments and Donors*, AERC Plenary Session on Global Food Price Shocks: Causes, Consequences and Policy Options in Africa, Mombasa, Kenya, 2009.

ADÄMMER, P., & BOHL, M. T. *Speculative bubbles in agricultural prices*. The Quarterly Review of Economics and Finance, 55, 67-76, 2015.

AGRÍCOLAS, N. COMMODITIES, 2010.

http://www.noticiasagricolas.com.br/educacional/mercado-futuro/44200-commodities.html#.VOcq4_nF_Cs.

AKHTER, SABIHA. *Market integration between surplus and deficit rice markets during global food crisis period*. Australian Journal of Agricultural and Resource Economics, 61, pp. 172–188, 2016.

ALCARAZ, R.; RIETA, J. J. *A novel application of sample entropy to the electrocardiogram of atrial fibrillation*. Nonlinear Analysis: Real World Applications, v. 11, n. 2, p. 1026-1035, 2010.

AL-MAADID, A., CAPORALE, G. M., SPAGNOLO, F., & SPAGNOLO, N. *Spillovers between food and energy prices and structural breaks*. International Economics, 150, 1-18, 2017.

ALONSO, J. ; MAÑANAS, M. ; ROMERO, S. ; ROJAS-MARTÍNEZ, M. ; RIBA, J. *Cross-conditional entropy and coherence analysis of pharmaco-EEG changes induced by alprazolam*. Psychopharmacology, Vol.221(3), pp.397-406, 2012.

ANOOP S. KUMAR; B. KAMAIAH. *Wavelet based sample entropy analysis: A new method to test weak form market efficiency*. Theoretical and Applied Economics, Vol.XXI(8), pp.17-24, 2014.

ARNTSEN, CHRISTOPHER ; CHEN, CHEN ; VOTH, GREGORY A. *Reactive molecular dynamics models from ab initio molecular dynamics data using relative entropy minimization*. Chemical Physics Letters, Vol.683, pp.573-578, 2017.

ASMA, SENAY. *Conditional entropy distribution of Istanbul stock market value*. Applied Economics Letters, Vol.17 (17), pp.1709-1713, 2010.

BALASIS, G., POTIRAKIS, S. M., & MANDEA, M. *Investigating dynamical complexity of geomagnetic jerks using various entropy measures*. Frontiers in Earth Science, 4, 71, 2016.

BALCOMBE, K., BAILEY, A., & BROOKS, J. *Threshold effects in price transmission: the case of Brazilian wheat, maize, and soya prices*. American Journal of Agricultural Economics, 89(2), 308-323, 2007.

BANDT, C., & POMPE, B. *Permutation entropy: a natural complexity measure for time series*. Physical review letters, 88(17), 174102, 2002.

BARAVALLE, R., ROSSO, O. A., & MONTANI, F. *Causal Shannon–Fisher Characterization of Motor/Imagery Movements in EEG*. Entropy, 20(9), 660, 2018.

BARIVIERA, A. F., FONT-FERRER, A., SORROSAL-FORRADELLAS, M. T., & ROSSO, O. A. *An information theory perspective on the informational efficiency of gold price*. The North American Journal of Economics and Finance, 50, 101018, 2019.

BARIVIERA, A. F., GUERCIO, M. B., MARTINEZ, L. B., & ROSSO, O. A. *A permutation information theory tour through different interest rate maturities: the Libor case*. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 373(2056), 20150119, 2015.

BARIVIERA, A. F., ZUNINO, L., & ROSSO, O. A. *An analysis of high-frequency cryptocurrencies prices dynamics using permutation-information-theory quantifiers*. Chaos: An Interdisciplinary Journal of Nonlinear Science, 28(7), 075511, 2018.

BARIVIERA, A. F., ZUNINO, L., GUERCIO, M. B., MARTINEZ, L. B., & ROSSO, O. A. *Efficiency and credit ratings: a permutation-information-theory analysis*. Journal of Statistical Mechanics: Theory, 2013.

BARREIRO, M., MARTI, A. C., & MASOLLER, C. *Inferring long memory processes in the climate network via ordinal pattern analysis*. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 21(1), 013101, 2011.

BARROS, G. S. C. *Do subprime nos Estados Unidos ao agronegócio brasileiro*. 2008

BECKMANN, J., & CZUDAJ, R. *Volatility transmission in agricultural futures markets*. *Economic Modelling*, 36, 541-546, 2014.

BELLEMARE, M. F. *Rising food prices, food price volatility, and social unrest*. *American Journal of Agricultural Economics*, 97(1), 1-21, 2015.

BERTHELOT, J. 2008. *The food crisis explosion: Root causes and how to regulate them*. *Kurswechsel* 3: 23–31, 2008.

BODIE, Z.; KANE, A.; MARCUS, A. J. *Fundamentos de investimentos*. 3. ed. Porto Alegre: Bookman, 2000. 632p.

BORGES, M.; GUIMARÃES, A. P.; BELLINI, R. & REPEZZA, M. T. C., A. P. LÉLIS. *As exportações brasileiras e os ciclos de commodities: tendências recentes e perspectivas*. *Boletim Conjuntura e Estratégia – Apex-Brasil*, (1):14–29, 2011.

BOUET, ANTOINE E DEBUCQUET, DAVID LABORDE. *Food crisis and export taxation: the cost of non-cooperative trade policies*. *Rev World Econ* 148:209–233, 2012.

BOUMALI, A., & LABIDI, M. *Shannon entropy and Fisher information of the one-dimensional Klein–Gordon oscillator with energy-dependent potential*. *Modern Physics Letters A*, 33(06), 1850033, 2018.

CABRERA, B. L., & SCHULZ, F. *Volatility linkages between energy and agricultural commodity prices*. *Energy Economics*, 54, 190-203, 2016.

CAPURRO, A., DIAMBRA, L., LORENZO, S., MACADAR, O., MARTINS, M. T., MOSTACCIO, C., ... & VELLUTI, J. *Human brain dynamics: the analysis of EEG signals with*

Tsallis information measure. Physica A: Statistical Mechanics and its Applications, 265(1-2), 235-254, 1999.

CARNEIRO, R. *O Brasil em face da crise*. Interesse Nacional, 2(5):20–30, 2009.

CAVALETT, O., JUNQUEIRA, T. L., DIAS, M. O., JESUS, C. D., MANTELATTO, P. E., CUNHA, M. P., ... & BONOMI, A. *Environmental and economic assessment of sugarcane first generation biorefineries in Brazil*. Clean Technologies and Environmental Policy, 14(3), 399-410, 2012.

CEBALLOS, F., HERNANDEZ, M. A., MINOT, N., & ROBLES, M. *Transmission of Food Price Volatility from International to Domestic Markets: Evidence from Africa, Latin America, and South Asia*. In Food price volatility and its implications for food security and policy (pp. 303-328). Springer, Cham, 2016.

CHEN, SHIJIAN; SHANG, PENGJIAN; WU, YUE. *Weighted multiscale Rényi permutation entropy of nonlinear time series*. Physica A: Statistical Mechanics and its Applications, Vol.496, pp.548-570, 2018.

CONSOLINI, G., & De MICHELIS, P. *Permutation entropy analysis of complex magnetospheric dynamics*. Journal of Atmospheric and Solar-Terrestrial Physics, 115, 25-31, 2014.

CORDERO, F.; KLEIN, I.; PEREZ-OSTAFE, L. *Asymptotic arbitrage in fractional mixed markets*. Modern Stochastics: Theory and Applications, Vol.5(4), pp.415-428, 2018.

COURBAGE, M.; MALHERBE, J.-G. *Extended memory processes generated by simple dynamical systems and scaling behavior of the entropy*. Chaos, Solitons and Fractals, Vol.13(2), pp.253-260, 2002.

COVER, T. M ; THOMAS J. A. *Elements of Information Theory*. John Wiley, New York, 1991.

DA SILVA, V. P., VAN DER WERF, H. M., SOARES, S. R., & CORSON, M. S. *Environmental impacts of French and Brazilian broiler chicken production scenarios: An LCA approach*. Journal of environmental management, 133, 222-231, 2014.

DAWE, D., BLOCK, S., GULATI, A., HUANG, J. AND ITO, S. *Domestic rice price, trade, and marketing policies. Rice in the global economy: strategic research and policy issues for food security*. International Rice Research Institute, Los Banos, Philippines, pp. 379–407, 2010.

DE ALBUQUERQUE, M. P., ESQUEF, I. A., & MELLO, A. G. *Image thresholding using Tsallis entropy*. Pattern Recognition Letters, 25(9), 1059-1065, 2004.

DE ARAUJO, F. H. A., BEJAN, L., ROSSO O. A., & STOSIC, T. *Permutation entropy and statistical complexity analysis of Brazilian agricultural commodities*. Entropy, 21(12), 1220, 2019.

DE ARAUJO, F.H.A., BEJAN, L., STOSIC, B., STOSIC, T. *An analysis of Brazilian agricultural commodities using permutation e information theory quantifiers: the influence of food crisis*. Chaos, Solit. Fractals 139, 110081, 2020.

DOROSH, P.A. *Price stabilization, international trade and national cereal stocks: world price shocks and policy response in South Asia*, Food Security 1, 137–149, 2009.

DU, X., CINDY, L. Y., & HAYES, D. J. *Speculation and volatility spillover in the crude oil and agricultural commodity markets: A Bayesian analysis*. Energy Economics, 33(3), 497-503, 2011.

EICHENGREEN, B.; ALMUNIA, M.; BÉNÉTRIX, A.; O’ROURKE, K. & RUA, G. *From great depression to great credit crisis: similarities, differences and lessons*. Economic Policy, 25:219–265, 2010.

FAO. *The State of Agricultural Commodity Markets 2018. Agricultural trade, climate change and food security*. Rome, 2018.

FERNANDES, D. & PEDRO, J. G. *A crise do subprime e os efeitos na balança comercial do agronegócio brasileiro*. Uma análise da 10ª região administrativa de Presidente Prudente-SP.

In Encontro de Ensino, Pesquisa e Extensão, Presidente Prudente, 17 a 20 de outubro, volume 8, páginas 203–212, 2011.

FLORES-GALLEGOS, N. TSALLIS. *Entropy as a possible measure of the electron correlation in atomic systems*. Chemical Physics Letters, Vol.692, pp.61-68, 2018.

FLORES-GALLEGOS, N. *A new approach of Shannon's entropy in atoms*. Chemical Physics Letters, Vol.650, pp.57-59, 2016.

FRANKEL, J.A. *Commodity prices and money: lessons from international finance*. American Journal of Agricultural Economics 66, 560–566, 1984.

FRIEDEN, B.R. *Science from Fisher Information: A Unification*; Cambridge University Press: Cambridge, UK; ISBN 0-521-81079-5, 2004.

FRIEDMANN, HARRIET. *The Political Economy of Food: a Global Crisis*. Acesso: 2019. <http://www.wphna.org/htdocs/downloads/may2012/Harriet%20Friedman%20The%20Political%20Economy%20of%20Food%20pdf.pdf>

GALLE, J. M.; CAVALI, R. & SANTOS, E. O. *Crise norte-americana: um modelo explicativo de sua causa*. Revista Multidisciplinar da Unesp, (7):170–175, Junho 2009.

GAMBOA, J. C. R., MARQUES, E. C., & STOSIC, T. *Complexity analysis of Brazilian agriculture and energy market*. Physica A: Statistical Mechanics and its Applications, 523, 933-941, 2019.

GAO, Y., VILLECCO, F., LI, M., & SONG, W. *Multi-Scale permutation entropy based on improved LMD and HMM for rolling bearing diagnosis*. Entropy, 19(4), 176, 2017.

GITMAM, L. J. *Princípios de administração financeira*. São Paulo: Harbra, 7ª ed., 1997, 841p.

GONÇALVES, B. A., CARPI, L., ROSSO, O. A., RAVETTI, M. G., & ATMAN, A. P. F. *Quantifying instabilities in financial markets*. Physica A: Statistical Mechanics and its Applications, 525, 606-615, 2019.

GRAFF, G., GRAFF, B., KACZKOWSKA, A., MAKOWIEC, D., AMIGÓ, J. M., PISKORSKI, J., ... & GUZIK, P. *Ordinal pattern statistics for the assessment of heart rate variability*. The European Physical Journal Special Topics, 222(2), 525-534, 2013.

GUIGNARD, F., LOVALLO, M., LAIB, M., GOLAY, J., KANEVSKI, M., HELBIG, N., & TELESKA, L. *Investigating the time dynamics of wind speed in complex terrains by using the Fisher–Shannon method*. Physica A: Statistical Mechanics and its Applications, 523, 611-621, 2019.

HAMADI, H., BASSIL, C., & NEHME, T. *News surprises and volatility spillover among agricultural commodities: The case of corn, wheat, soybean and soybean oil*. Research in International Business and Finance, 41, 148-157, 2017.

HAN, L., ZHOU, Y., & YIN, L. *Exogenous impacts on the links between energy and agricultural commodity markets*. Energy Economics, 49, 350-358, 2015.

HE, L. Y., & CHEN, S. P. (a). *Nonlinear bivariate dependency of price–volume relationships in agricultural commodity futures markets: a perspective from multifractal detrended cross-correlation analysis*. Physica A: Statistical Mechanics and its Applications, 390(2), 297-308, 2011.

HE, L. Y., & CHEN, S. P. *Are developed and emerging agricultural futures markets multifractal? A comparative perspective*. Physica A: Statistical Mechanics and its Applications, 389(18), 3828-3836, 2010.

HE, L. Y., & CHEN, S. P. (b) *Multifractal detrended cross-correlation analysis of agricultural futures markets*. Chaos, Solitons & Fractals, 44(6), 355-361, 2011.

HEADEY, DEREK. *Rethinking the global food crisis: The role of trade shocks*. Food Policy 36. 136-146, 2011.

HELEN MARY, M. C; SINGH, Dilbag ; DEEPAK, K. K. *Identifying deep breath effect on cardiovascular signals using conditional entropy: an information domain approach*. Biomedical Engineering: Applications, Basis and Communications, Vol.30(2), 2018.

HERTEL, T. W., TYNER, W. E., & BIRUR, D. K. *The global impacts of biofuel mandates*. The Energy Journal, 75-100, 2010.

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

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

JEBABLI, I., AROURI, M., & TEULON, F. *On the effects of world stock market and oil price shocks on food prices: An empirical investigation based on TVP-VAR models with stochastic volatility*. Energy Economics, 45, 66-98, 2014.

JIE, XIANG ; CAO, RUI ; LI, LI. *Emotion recognition based on the sample entropy of EEG*. Bio-medical materials and engineering, Vol.24(1), pp.1185-92, 2014.

JOVANOVIĆ, T., GARCÍA, S., GALL, H., & MEJÍA, A. *Complexity as a streamflow metric of hydrologic alteration*. Stochastic Environmental Research and Risk Assessment, 31(8), 2107-2119, 2017.

KALIMERI, M., PAPADIMITRIOU, C., BALASIS, G., & EFTAXIAS, K. *Dynamical complexity detection in pre-seismic emissions using nonadditive Tsallis entropy*. Physica A: Statistical Mechanics and its Applications, 387(5-6), 1161-1172, 2008.

KANTELHARDT, JAN W. *Fractal and multifractal time series*. In *Mathematics of complexity and dynamical systems*. Springer New York, 2012. p. 463-487.

KIM, SUNGYUN. *Computability of entropy and information in classical Hamiltonian systems*. Physics Letters A, Vol.373(16), pp.1409-1414, 2009.

KORBEL, JAN. *Rescaling the nonadditivity parameter in Tsallis thermostatics*. Physics Letters A, Vol. 381 (32), pp. 2588-2592. 2017.

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

KRISTOUFEK, L., JANDA, K., & ZILBERMAN, D. (a). *Correlations between biofuels and related commodities before and during the food crisis: A taxonomy perspective*. Energy Economics, 34(5), 1380-1391, 2012.

KRISTOUFEK, L., JANDA, K., & ZILBERMAN, D. (b). *Regime-dependent topological properties of biofuels networks*. The European Physical Journal B, 86(2), 40, 2013.

KRISTOUFEK, L., JANDA, K., & ZILBERMAN, D. *Comovements of ethanol-related prices: evidence from Brazil and the USA*. Gcb Bioenergy, 8(2), 346-356, 2016.

LAMBERTI, P. W., MARTIN, M. T., PLASTINO, A., & ROSSO, O. A. *Intensive entropic non-triviality measure*. Physica A, 334, 119–131, 2004.

LANORTE, A., LASAPONARA, R., LOVALLO, M., & TELESKA, L. *Fisher–Shannon information plane analysis of SPOT/VEGETATION Normalized Difference Vegetation Index (NDVI) time series to characterize vegetation recovery after fire disturbance*. International Journal of Applied Earth Observation and Geoinformation, 26, 441-446, 2014.

LEGNANI, W., TRAVERSARO, F., REDELICO, F. O., CYMBERKNOP, L. J., ARMENTANO, R. L., & ROSSO, O. A. *Analysis of ischaemic crisis using the informational causal entropy-complexity plane*. Chaos: An Interdisciplinary Journal of Nonlinear Science, 28(7), 075518, 2018.

LI, CHAO; SHANG, PENGJIAN. *Multiscale Tsallis permutation entropy analysis for complex physiological time series*. Physica A: Statistical Mechanics and its Applications, Vol.523, pp.10-20, 2019.

LI, JUNFU; LYU, CHAO; WANG, LIXIN; ZHANG, LIQIANG; LI, CHENHUI. *Remaining capacity estimation of Li-ion batteries based on temperature sample entropy and particle filter*. Journal of Power Sources, Vol.268, pp.895-903, 2014.

LI, JUNLI ; HE, ZONGYI ; ZHU, QIAOLI. *An Entropy-Based Weighted Concept Lattice for Merging Multi-Source Geo-Ontologies*. Entropy, Vol.15(6), pp.2303-2318, 2013.

LIMA, C. R. A., de MELO, G. R., STOSIC, B., & STOSIC, T. *Cross-correlations between Brazilian biofuel and food market: Ethanol versus sugar*. Physica A: Statistical Mechanics and its Applications, 513, 687-693, 2019.

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

LOPES, RENAUD; BETROUNI, NACIM. *Fractal and multifractal analysis: a review*. Medical image analysis, v. 13, n. 4, p. 634-649, 2009.

LOVALLO, M., SHABAN, A., DARWICH, T., & TELESCA, L. *Investigating the time dynamics of monthly rainfall time series observed in northern Lebanon by means of the detrended fluctuation analysis and the Fisher-Shannon method*. Acta Geophysica, 61(6), 1538-1555, 2013.

MADIMAN, M.; JOHNSON, O.; KONTOYIANNIS, I. *Fisher Information, compound Poisson approximation, and the Poisson channel*. In Proceedings of the 2007 IEEE International Symposium on Information Theory, Nice, France, 24–29 June 2007; IEEE: Piscataway, NJ, USA, 2007.

MAGGS, J. E., & MORALES, G. J. *Permutation entropy analysis of temperature fluctuations from a basic electron heat transport experiment*. Plasma Physics and Controlled Fusion, 55(8), 085015, 2013.

MAHDI, SABET SARVESTANI; IBRAHIM, AB. LATIF ; KANAROGLOU, PAVLOS. *Three decades of urban growth in the city of Shiraz, Iran: A remote sensing and geographic information systems application*, Vol.28 (4), pp.320-329, 2011.

MAPA, Ministério da Agricultura, Pecuária e Abastecimento, 2019.
<http://www.agricultura.gov.br/noticias/exportacoes-do-agro-em-alta-de-quase-6-ultrapassam-us-100-bi>

MARKECHOVÁ, D.; RIEČAN, B. *Tsallis entropy of product MV-algebra dynamical systems*. Entropy, Vol.20(8), 2018.

MARTIN, M. T., PENNINI, F., & PLASTINO, A. *Fisher's information and the analysis of complex signals*. Physics Letters A, 256(2-3), 173-180, 1999.

MARTIN, M. T., PLASTINO, A., & ROSSO, O. A. *Generalized statistical complexity measures: Geometrical and analytical properties*. Physica A: Statistical Mechanics and its Applications, 369(2), 439-462, 2006.

MARWAN, NORBERT ET AL. *Recurrence plots for the analysis of complex systems*. Physics reports, v. 438, n. 5, p. 237-329, 2007.

MAYER, A.L.; PAWLOWSKI, C.W.; CABEZAS, H. *Fisher Information and dynamic regime changes in ecological systems*. Ecol. Model. 195, 72–82, 2006.

MCMICHAEL, Philip. *A food regime analysis of the 'world food crisis'*. Agric Hum Values 26:281–295, 2009.

MEICES – Ministério da Economia, I. C. E. e S. *Exportações de Commodities 2018*. <http://www.mdic.gov.br/index.php/component/content/article/61-noticias/2829-mdic-projeta-saldo-comercial-entre-us-65-e-us-70-bilhoes-para-este-ano>.

MELO, FERNANDO HOMEM DE, *'Unbalanced Technological Change and Income Disparity in a Semi-Open Economy'*, in F.L. Tullis and W.L. Hollist, eds., Food, State, and International Political Economy, Lincoln 1986.

MIHAILOVIĆ, D. T., NIKOLIĆ-ĐORIĆ, E., DREŠKOVIĆ, N., & MIMIĆ, G. *Complexity analysis of the turbulent environmental fluid flow time series*. Physica A: Statistical Mechanics and Its Applications, 395, 96-104, 2014.

MONTANI, F., DELEGLISE, E. B., & ROSSO, O. A. *Efficiency characterization of a large neuronal network: A causal information approach*. Physica A: Statistical Mechanics and its Applications, 401, 58-70, 2014.

MONTIROSSO, ROSARIO; RICCARDI, BRUNO; MOLTENI, ERIKA; BORGATTI, RENATO ; RENI, GIANLUIGI. *Infant's emotional variability associated to interactive*

stressful situation: A novel analysis approach with Sample Entropy and Lempel–Ziv Complexity. *Infant Behavior and Development*, Vol.33(3), pp.346-356, 2010.

MUELLER, B., & MUELLER, C. *The political economy of the Brazilian model of agricultural development: Institutions versus sectoral policy*. *The quarterly review of economics and finance*, 62, 12-20, 2016.

NAZLIOGLU, S., & SOYTAS, U. *Oil price, agricultural commodity prices, and the dollar: A panel cointegration and causality analysis*. *Energy Economics*, 34(4), 1098-1104, 2012.

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

NIU, HONGLI; WANG, JUN; LIU, CHENG. *Analysis of crude oil markets with improved multiscale weighted permutation entropy*. *Physica A: Statistical Mechanics and its Applications*, Vol.494, pp.389-402, 2018.

OECD–FAO, *OECD–FAO Agricultural Outlook 2008–2017. Organisation for Economic Co-operation and Development (OECD) and the Food and Agriculture Organization (FAO) of the United Nations*, Geneva and Rome, 2008

OLIVARES, F.; PLASTINO, A.; ROSSO, O.A. *Ambiguities in the Bandt–Pompe’s methodology for local entropic quantifiers*. *Physica A*, 391, 2518–2526, 2012.

OLIVARES, F; PLASTINO, A.; ROSSO, O.A. *Contrasting chaos with noise via local versus global information quantifiers*. *Phys. Lett A*, 376, 1577–1583, 2012.

OLIVIER, C. P., ENGELBRECHT, N. E., & STRAUSS, R. D. *Permutation entropy analysis of magnetic field turbulence at 1AU revisited*. *Journal of Geophysical Research: Space Physics*, 124. <https://doi.org/10.1029/2018JA026102>, 2019.

ORDEN, D., CHENG, F. *Currency Policy and Agriculture, Toward a Global Food and Agricultural Policy for an Open International Economy in Honor of G. Edward Schuh*. Humphrey Institute, University of Minnesota, 2007.

PARDO, L.; MORALES, D.; FERENTINOS, K.; ZOGRAFOS, K. *Discretization problems on generalized entropies and R-divergences*. Kybernetika. 30, 445–460, 1994.

PIERINI, J. O., LOVALLO, M., GÓMEZ, E. A., & TELESCA, L. *Fisher–Shannon analysis of the time variability of remotely sensed sea surface temperature at the Brazil–Malvinas Confluence*. Oceanologia, 58(3), 187-195, 2016.

PIERINI, J. O., RESTREPO, J. C., LOVALLO, M., & TELESCA, L. *Discriminating Between Different Streamflow Regimes by Using the Fisher-Shan Method: An Application to the Colombia Rivers*. Acta Geophysica, 63(2), 533-546, 2015.

PIESSE, J., THIRTLE, C. *Three bubbles and a panic: an explanatory review of recent food commodity price events*. Food Policy 34, 119–129, 2009.

RENYI, A. *On measures of entropy and information*. In: *Fourth Berkeley Symposium on Mathematical Statistics and Probability*. 1961. p. 547–561.

RICHMAN J. S., MOORMAN J. R. *Physiological time-series analysis using approximate entropy and sample entropy*. *American journal of physiology Heart and circulatory physiology*. Am Physiological Soc, v. 278, n. 6, p. H2039 – H2049, 2000.

RIEDL, M., MÜLLER, A., & WESSEL, N. *Practical considerations of permutation entropy*. The European Physical Journal Special Topics, 222(2), 249-262, 2013.

ROBERTS, M. J., & SCHLENKER, W. *Identifying supply and demand elasticities of agricultural commodities: Implications for the US ethanol mandate*. American Economic Review, 103(6), 2265-95, 2013.

ROCHA, HENRIQUE RIBEIRO DA, PEREIRA, BRUNA LEAL E MARTIN, JÚLIA SAINT. *POLITIZE! O que são commodities agrícolas..* Disponível em: <https://www.politize.com.br/commodities-agricolas/#toggle-id-1>. 2018. Acesso em outubro de 2019.

ROSEGRANT, M. W., & CLINE, S. A. *Global food security: challenges and policies*. Science, 302(5652), 1917-1919, 2003.

ROSS, M. C.; WESTERFIELD, R.W.; JAFFE, J.F. *Administração financeira: corporate finance*. São Paulo: Atlas, 1995. 698p.

ROSSO, O.A.; De MICCO, K.; PLASTINO, A.; LARRONDO, H. *Info-quantifiers' map-characterization revisited*. Physica A, 389, 249–262, 2010.

ROSSO, O. A., LARRONDO, H. A., MARTIN, M. T., PLASTINO, A., & FUENTES, M. A. *Distinguishing noise from chaos*. Physical review letters, 99(15), 154102, 2007.

SACO, P. M., CARPI, L. C., FIGLIOLA, A., SERRANO, E., & ROSSO, O. A. *Entropy analysis of the dynamics of El Niño/Southern Oscillation during the Holocene*. Physica A: Statistical Mechanics and its Applications, 389(21), 5022-5027, 2010.

SANCHEZ-MORENO, P.; DEHESA, J.S.; YANEZ, R.J. *Discrete Densities and Fisher Information*. In *Proceedings of the 14th International Conference on Difference Equations and Applications*, Ug̃ ur-Bahçes,ehir University Publishing Company, Istanbul, Turkey, pp. 291–298, 2009.

SANOGO, I. and MALIKI, A.M. *Rice market integration and food security in Nepal: the role of cross-border trade with India*, Food Policy 35, 312–322, 2010.

SCHUH, G.E. *The Exchange rate and US agriculture*. American Journal of Agricultural Economics 56, 1–13, 1974.

SEN, K. D., ANTOLÍN, J., & ANGULO, J. C. *Fisher-Shannon analysis of ionization processes and isoelectronic series*. Physical Review A, 76(3), 032502, 2007.

SERINALDI, F, *Use and misuse of some Hurst parameter estimators applied to stationary and non-stationary financial time series*, Physica A 389 2770–2781, 2010.

SERINALDI, F., ZUNINO, L., & ROSSO, O. A. *Complexity–entropy analysis of daily stream flow time series in the continental United States*. Stochastic environmental research and risk assessment, 28(7), 1685-1708, 2014.

VIEIRA, Luciana Marques; DE ARAÚJO, Gustavo Porpino; DE CARVALHO, Ícaro Célio Santos. *Desafios para reduzir o desperdício*. AgroANALYSIS, v. 38, n. 10, p. 30-31, 2018.

SIDDAGANGAIAH, S., LI, Y., GUO, X., CHEN, X., ZHANG, Q., YANG, K., & YANG, Y. *A complexity-based approach for the detection of weak signals in ocean ambient noise*. Entropy, 18(3), 101, 2016.

SIPPEL, S., LANGE, H., MAHECHA, M. D., HAUHS, M., BODESHEIM, P., KAMINSKI, T., ... & ROSSO, O. A. *Diagnosing the dynamics of observed and simulated ecosystem gross primary productivity with time causal information theory quantifiers*. PloS one, 11(10), e0164960, 2016.

SIQUEIRA Jr, E. L., STOŠIĆ, T., BEJAN, L., & STOŠIĆ, B. *Correlations and cross-correlations in the Brazilian agrarian commodities and stocks*. Physica A: Statistical Mechanics and its Applications, 389(14), 2739-2743, 2010.

SOARES, RODRIGO OLIVEIRA; ROSTAGNO, LUCIANO MARTIN; SOARES, KARINA TALAMINI COSTA. *Estudo de evento: o método e as formas de cálculo do retorno anormal*. XXVI Encontro Nacional dos Programas de Pós Graduação em Administração, 2002.

STOSIC, T., NEJAD, S. A., & STOSIC, B. *Multifractal analysis of Brazilian agricultural market*. Fractals, 28(05), 2050076, 2020.

STOSIC, T., TELESCA, L., DE SOUZA FERREIRA, D. V., & STOSIC, B. *Investigating anthropically induced effects in streamflow dynamics by using permutation entropy and statistical complexity analysis: A case study*. Journal of Hydrology, 540, 1136-1145, 2016.

STOSIC, TATIJANA ; STOSIC, BORKO ; SINGH, VIJAY P. *Optimizing streamflow monitoring networks using joint permutation entropy*. Journal of Hydrology, Vol.552, pp.306-312, 2017.

SUN, W. et al. *Fractal analysis of remotely sensed images: A review of methods and applications*. International Journal of Remote Sensing, v. 27, n. 22, p. 4963-4990, 2006.

TABAK, B. M., SERRA, T. R., & CAJUEIRO, D. O. *Topological properties of commodities networks*. The European Physical Journal B, 74(2), 243-249, 2010.

TADASSE, G., ALGIERI, B., KALKUHL, M., & VON BRAUN, J. *Drivers and triggers of international food price spikes and volatility*. In Food price volatility and its implications for food security and policy (pp. 59-82). Springer, Cham, 2016.

TANG, LING ET AL. *Complexity testing techniques for time series data: A comprehensive literature review*. Chaos, Solitons & Fractals, v. 81, p. 117- 135, 2015.

TELESCA, L., LOVALLO, M., HSU, H. L., & CHEN, C. C. *Analysis of dynamics in magnetotelluric data by using the Fisher–Shannon method*. Physica A: Statistical Mechanics and its Applications, 390(7), 1350-1355, 2011.

TSALLIS, C. *Possible generalization of boltzmann-gibbs statistics*. Journal of statistical physics, Springer, v. 52, n. 1-2, p. 479–487, 1988.

USDA, *Agricultural Projections to 2017*. US Department of Agriculture, Washington, DC, 2008.

VASQUEZ, J. L. *Comércio exterior brasileiro*. Atlas, 9 edição, 2008.

VIGNAT, C. and BERCHER, J.-F. *Analysis of signals in the fisher–shannon information plane*. Physics Letters A 312, 27 – 33, 2003.

VIZI, B. *Depois da crise - desafios faz uma retrospectiva, revendo os impactos, os canais de transmissão, e as consequências da turbulência que modificou, e ainda modifica, a economia global*. Desafios do desenvolvimento, 8(1):11–27, 2011.

WALTON, JOHN, *‘Debt, Protest, and the State in Latin America’*, in Susan Eckstein, ed., Power and Popular Protest, Berkeley 1989.

WECK, P. J., SCHAFFNER, D. A., BROWN, M. R., & WICKS, R. T. *Permutation entropy and statistical complexity analysis of turbulence in laboratory plasmas and the solar wind*. Physical Review E, 91(2), 023101, 2015.

XAVIER, SÍLVIO FERNANDO ALVES; DA SILVA JALE, JADER; STOSIC, TATJANA; DOS SANTOS, CARLOS ANTONIO COSTA; SINGH, VIJAY P. *An application of sample entropy to precipitation in Paraíba State, Brazil*. Theoretical & Applied Climatology, Vol.136 (1/2), p.429-441, 2019.

XIAO, JIA ; HE, ZONGYI. *A Concept Lattice for Semantic Integration of Geo-Ontologies Based on Weight of Inclusion Degree Importance and Information Entropy*. Entropy, Vol.18(11), p.399, 2016.

XU, MENGJIA; SHANG, PENGJIAN; HUANG, JINGJING. *Modified generalized sample entropy and surrogate data analysis for stock markets*. Communications in Nonlinear Science and Numerical Simulation, Vol.35, pp.17-24, 2016.

YABUKI, TETSUO; MATSUMURA, YUMI; NAKATANI, YOKO NAKATANI, YOKO (PACREPOSITORY.ORG). *Evaluation of pedodiversity and land use diversity in terms of the Shannon Entropy*. arXiv.org, May 18, 2009

YAN, R., LIU, Y., & GAO, R. X. *Permutation entropy: a nonlinear statistical measure for status characterization of rotary machines*. Mechanical Systems and Signal Processing, 29, 474-484, 2012.

YIN, Y., & SHANG, P. *Weighted permutation entropy based on different symbolic approaches for financial time series*. Physica A: Statistical Mechanics and its Applications, 443, 137-148, 2016.

YIN, Yi; SHANG, Pengjian. *Modified cross sample entropy and surrogate dataanalysis method for financial time series*. Physica A: Statistical Mechanics and its Applications, Vol.433, pp.17-25, 2015.

YOO, CHEOL SEUNG; JUNG, DONG CHUNG; AHN, YONG MIN; KIM, YONG SIK; KIM, SU-GYEONG ; YOON, HYERI; LIM, YOUNG JIN; YI, SANG HOON. *Automatic detection of seizure termination during electroconvulsive therapy using sample entropy of the electroencephalogram*. Psychiatry Research, Volume 195, Issues 1–2, Pages 76-82, 2012.

ZANIN, MASSIMILIANO ET AL. *Permutation entropy and its main biomedical and econophysics applications: a review*. Entropy, v. 14, n. 8, p. 1553-1577, 2012.

ZENG, K., OUYANG, G., CHEN, H., GU, Y., LIU, X., & LI, X. *Characterizing dynamics of absence seizure EEG with spatial-temporal permutation entropy*. Neurocomputing, 275, 577-585, 2018.

ZHAO, JIAN; SUN, MEILING; HAN, FAN; LIU, SHAN. *Image Watermark Based on Extended Shearlet and Insertion Using the Largest Information Entropy on Horizontal Cone*. Mathematical Problems in Engineering, Vol. 2015, 2015.

ZOGRAFOS, K.; FERENTINOS, K.; PAPAIOANNOU, T. *Discrete approximations to the Csiszár, Renyi, and Fisher measures of information*. Can. J. Stat. 14, 355–366, 1986.

ZUNINO, L., BARIVIERA, A. F., GUERCIO, M. B., MARTINEZ, L. B., & ROSSO, O. A. *On the efficiency of sovereign bond markets*. Physica A: Statistical Mechanics and its Applications, 391(18), 4342-4349, 2012.

ZUNINO, L., TABAK, B. M., SERINALDI, F., ZANIN, M., PÉREZ, D. G., & ROSSO, O. A. *Commodity predictability analysis with a permutation information theory approach*. Physica A: Statistical Mechanics and its Applications, 390(5), 876-890, 2011.

ZUNINO, L., ZANIN, M., TABAK, B. M., PÉREZ, D. G., & ROSSO, O. A. *Complexity-entropy causality plane: A useful approach to quantify the stock market inefficiency*. Physica A: Statistical Mechanics and its Applications, 389(9), 1891-1901, 2010.

ZUNINO, L., ZANIN, M., TABAK, B. M., PÉREZ, D. G., & ROSSO, O. A. *Forbidden patterns, permutation entropy and stock market inefficiency*. Physica A: Statistical Mechanics and its Applications, 388(14), 2854-2864, 2009.

Artigos Publicados durante o período do doutorado:

ANTUNES DE ARAUJO FH, HENRIQUE SILVA FERNANDES L. *Multifractal Detrended Fluctuations Analysis for Ibovespa assets*. Fractals, 2021.

DE ARAUJO FHA, FERNANDES LHS, TABAK BM. *Effects of COVID-19 on Chinese sectoral indices: a multifractal analysis*. Fractals, 2150198;

DE ARAUJO FHA. *Equações paramétricas em um parque de diversões*. Revista do Professor de matemática 100, 12-14, 2019;

FERNANDES LHS, ARAUJO FHA, SILVA JWL, SILVA MAR. *Insights into the predictability and similarity of COVID-19 worldwide lethality*. Fractals, 2021.

FERNANDES LHS, ARAUJO FHA, SILVA MAR, ACIOLI-SANTOS B. *Predictability of COVID-19 worldwide lethality using permutation-information theory quantifiers*. Results in Physics 26, 104306, 2021;

FERNANDES LHS, DE ARAUJO FHA, SILVA JWL, SILVA IEM, TABAK BM. *Evaluating the Efficiency of Brazilian Stock Market Indices: The Case of COVID-19*. Fractals, 2021.

FERNANDES LHS, DE ARAÚJO FHA, SILVA IEM, NETO JSP. *Macroeconophysics indicator of economic efficiency*. Physica A: Statistical Mechanics and its Applications 573, 125946, 2021;

FERNANDES LHS, DE ARAUJO FHA, TABAK BM. *Insights from the (in) efficiency of Chinese sectoral indices during COVID-19*. Physica A: Statistical Mechanics and its Applications 578, 126063, 2021.

FERNANDES, LHS, ARAÚJO, FHA, ET AL. *Multifractal behavior in the dynamics of Brazilian inflation indices*. Physica A: Statistical Mechanics and its Applications 550, 124158, 2020.

FERNANDES, LHS, ARAÚJO, FHA. *Taxonomy of commodities assets via complexity-entropy causality plane*. Chaos, Solitons & Fractals 137, 109909, 2020.

FERNANDES, LHS, DE ARAÚJO FHA, SILVA IEM. *The (in) efficiency of NYMEX energy futures: A multifractal analysis*. Physica A: Statistical Mechanics and its Applications 556, 124783, 2020;

FERNANDES, LHS, DE ARAÚJO FHA, SILVA MAR, ACIOLI-SANTOS B. *COVID-19 lethality in Brazilian States using information theory quantifiers*. Physica Scripta 96 (3), 035003, 2021.

FERNANDO H A DE ARAUJO; FERNANDES, L. H. S.. *Lighting the populational impact of COVID-19 vaccines in Brazil*. FRACTALS-COMPLEX GEOMETRY PATTERNS AND SCALING IN NATURE AND SOCIETY, 2022.

Artigos publicados antes do doutorado:

FHA ARAUJO. *Análise multifractal do contorno de otólitos como indicador do metabolismo de peixes*. Dissertação de mestrado em Biometria e Estatística Aplicada, Universidade Federal Rural de Pernambuco – UFRPE, 2018.

FHA de ARAUJO. *A matemática nas redes sociais: use com moderação*. Revista do Professor de Matemática 85, 33-35. 2014.

FHA de ARAUJO. *Email "corrente" e equações diofantinas*. Revista do Professor de Matemática 77, 18-19. 2012.

FHA de ARAUJO. *Ângulos entre ponteiros de um relógio*. Revista do Professor de Matemática 72, 19-21. 2010.

FHA de Araújo. *MÉDIAS E PROBLEMAS DE OTIMIZAÇÃO*. Revista do Professor de Matemática 76, 27-29.

7 ANEXO – Artigos publicados

Primeira página de cada artigo gerado por esta tese:

Open Access Article

Permutation Entropy and Statistical Complexity Analysis of Brazilian Agricultural Commodities

by  Fernando Henrique Antunes de Araujo ¹ ,  Lucian Bejan ¹ ,  Osvaldo A. Rosso ^{2,3}   and  Tatijana Stosic ^{1,*}  

¹ Departamento de Estatística e Informática, Universidade Federal Rural de Pernambuco, Rua Dom Manoel de Medeiros s/n, Dois Irmãos, Recife, PE 52171-900, Brazil

² Instituto de Física, Universidade Federal de Alagoas (UFAL). Avenida Lourival Melo Mota s/n, Tabuleiro do Martins, Maceió, AL CEP 57072-900, Brazil

³ Instituto de Medicina Traslacional e Ingeniería Biomedica, Hospital Italiano de Buenos Aires & CONICET. Tte. Gral. Juan Domingo Perón 4190, Ciudad Autónoma de Buenos Aires C1199ABB, Argentina

* Author to whom correspondence should be addressed.

Entropy 2019, 21(12), 1220; <https://doi.org/10.3390/e21121220>

Received: 27 October 2019 / Revised: 4 December 2019 / Accepted: 10 December 2019 /

Published: 14 December 2019



Chaos, Solitons & Fractals

Volume 139, October 2020, 110081



An analysis of Brazilian agricultural commodities using permutation – information theory quantifiers: The influence of food crisis

Fernando Henrique Antunes de Araujo  , Lucian Bejan, Borko Stosic, Tatijana Stosic

Universidade Federal Rural de Pernambuco, Departamento de Estatística e Informática, Rua Dom Manoel de Medeiros s/n, Dois Irmãos - 52171-900, Recife/PE, Brazil

Received 20 May 2020, Revised 26 June 2020, Accepted 2 July 2020, Available online 12 July 2020.