

## **Efeitos spillover e conectividades dinâmicas nos mercados de commodities agrícolas no Brasil após a pandemia da Covid-19**

**DANIEL HENRIQUE DARIO CAPITANI**  
UNIVERSIDADE ESTADUAL DE CAMPINAS (UNICAMP)

**LUIZ EDUARDO GAIO**  
UNIVERSIDADE ESTADUAL DE CAMPINAS (UNICAMP)

# Efeitos *spillover* e conectividades dinâmicas nos mercados de *commodities* agrícolas no Brasil após a pandemia da Covid-19

## 1. Introdução

Os choques internacionais nos preços agrícolas e a transmissão de volatilidades entre diferentes mercados agropecuários tem sido foco de atenção em diferentes estudos, sobretudo a partir boom das *commodities* no período entre 2006 a 2008 (Serra, 2011; Tyner, 2010; Trujillo-Barreras et al., 2013; Vacha et al., 2013; Saghaian et al. 2018). Tais estudos foram aplicados ao mercado global, ou especificamente a países desenvolvidos e/ou em desenvolvimento, utilizando-se de diferentes arcabouços metodológicos e com focos específicos na busca das interconexões possíveis.

Considerando a alta dos preços no período 2006-2008, destacam-se diferentes fatores que contribuíram com o fenômeno, como o aumento na demanda de países em desenvolvimento, especialmente a China, quebras de safra em importantes países produtores, política monetária norte americana, que levou a uma desvalorização de sua moeda e o aumento na produção de biocombustíveis (Irwin e Good; 2009; Tyner, 2010; Trujillo-Barreras et al. 2012; Serra e Zilberman, 2013).

Ademais, em geral, observa-se uma relação mais próxima entre os preços de energia e das *commodities* agrícolas (Zhang et al., 2010; Serra, 2011; Tyner, 2010), inclusive perpassando o período supracitado, podendo explicar potenciais picos nos preços ao longo da década de 2010 (Vacha et al., 2013; Kristoufek et. al, 2014; Cabrera e Schulz, 2016; Saghaian et al., 2018). Em específico, tais estudos apontam maior proximidade entre os preços de petróleo e os mercados de grãos em escala global. Localmente, fatores como a taxa de câmbio também impactaram alguns mercados (Shahrestani e Rafei, 2020)

Mais recentemente, com a pandemia da Covid-19, o mundo vivenciou impactos tão ou mais intensos às crises globais anteriormente ocorridas, envolvendo diferentes cadeias produtivas, e sendo corroboradas conforme as economias se fechavam aos lockdowns (Beckman e Countryman, 2021; Dmytrów et al., 2021). Os efeitos negativos incluíram rupturas nas cadeias produtivas em escala global e, conseqüentemente, choques negativos de oferta de bens e serviços (De Vijlder, 2020; Rajput et al., 2021; Beckman e Countryman, 2021).

De início, se observou um declínio nos preços de petróleo, seguido de quedas nos preços das *commodities*. Os efeitos *spillovers* iniciais se deram com uma queda superior a 50% no preço do petróleo, quedas expressivas nos preços de metais e uma discreta queda nos preços de *commodities* agrícolas (World Bank, 2020). Com o aumento na volatilidade dos preços de petróleo e minérios, reverte-se os impactos sobre os preços agrícolas (Dmytrów et al., 2021; Beckman e Contryman, 2021). Posteriormente, no início de 2022, picos de volatilidade nos mercados agrícolas internacionais foram observados em uma janela temporal de até 90 dias após o conflito Rússia-Ucrânia (Fang e Shao, 2022; Just e Echaust, 2022; Wang et al., 2022; Gaio e Capitani, 2023).

No Brasil, não diferente, os impactos foram sentidos em diferentes mercados agropecuários. Por exemplo, considerando um intervalo entre 9 a 15 meses após o início da pandemia, os preços de milho, soja e arroz subiram até um limiar próximo a 80% a 120%, tomando como base os preços em março de 2020 (CEPEA, 2023), o que levou a um forte choque nos preços de alimentos e uma pressão inflacionária.

Neste sentido, este estudo se propõe a avaliar os efeitos da pandemia da Covid-19 nos retornos dos preços das principais *commodities* agrícolas no Brasil relações. Para isso, serão analisados os efeitos *spillover*, considerando a frequência e o tempo dos mercados agrícolas, petróleo e taxa de câmbio, uma vez que o país possui um relevante papel no comércio

internacional de *commodities* agrícolas. Especificamente, a análise será conduzida a partir de janelas de tempo, entre janeiro de 2018 a julho de 2023, considerando os períodos pré-pandemia da Covid-19, ao longo do período crítico da pandemia da Covid-19, e após o período crítico. Adicionalmente, serão testados estes efeitos do recente conflito Rússia-Ucrânia. A metodologia contextualizada por Antonakakis et al., (2020) será utilizada para análise dos efeitos *spillover* e conectividade entre os retornos desses mercados.

Entende-se que tal análise pode auxiliar o debate sobre os efeitos da pandemia nos preços das *commodities* no mercado doméstico, subsidiando a recente discussão sobre os efeitos da pandemia nos índices de preços da economia brasileira. Ademais, pode-se avaliar os potenciais efeitos do mercado internacional de petróleo sobre os custos agrícolas locais, dando uma melhor ilustração acerca da interconexão entre esses mercados. Ainda, contribui com a literatura, ao se tratar de estudo inédito sobre a correlação cruzada e transmissão de preços nos mercados agrícolas brasileiros, além de contribuir para estudos focados em mercados emergentes.

O artigo está estrutura conforme segue. Na seção dois será discutido a fundamentação teórica da pesquisa, abordando as principais e mais recentes pesquisas sobre o efeito *spillover* no mercado de commodities. Na seção três é mostrado os dados e metodologia de análise, apresentando uma breve discussão sobre a estatística descritiva das séries e a metodologia de conectividade. Na seção quatro os resultados e as discussões dos efeitos da COVID e conflito Rússia-Ucrania nos retornos das commodities são realizados. Por fim, a seção cinco conclui a pesquisa, destacando suas limitações e sugestões para futuras investigações.

## **2. Fundamentação teórica**

O aumento na volatilidade dos preços agrícolas tem sido foco de atenção, sobretudo a partir do *boom* das *commodities* vivenciado no período 2006-2008, que levaram a aumentos substanciais nos preços de diferentes culturas em escala global (Wright, 2011; Serra, 2011; Trujillo-Barreras et al., 2012; Lahiani et al. 2013). Diferentes fatores que contribuíram com o fenômeno na ocasião, como o aumento na demanda de países em desenvolvimento, especialmente a China, quebras de safra em importantes países produtores, política monetária norte americana, que levou a uma desvalorização de sua moeda e o aumento na produção de biocombustíveis, sobretudo no mercado norte-americano, com a moagem de milho para a produção de etanol (Irwin e Goodman, 2009; Trujillo-Barreras et al., 2012; Serra e Zilberman, 2013).

Além de uma ampla literatura que avaliou os efeitos a partir dos preços e mercados de referência internacional, captados a partir das principais bolsas de futuros nos EUA e União Europeia, alguns estudos focaram suas análises nos mercados emergentes, especialmente pelos efeitos sociais que uma alta generalizada nos preços das *commodities* pode acarretar domesticamente (Acemoglu et al., 2003; Huchet-Bourdon, 2011). Além disso, muitas vezes a volatilidade nesses preços pode ser derivada de crises internacionais, o que, por sua vez, contribui para uma piora dos efeitos econômicos, especialmente nesses mercados (Frenk e Turbeville, 2011).

Neste sentido, embora apontadas diferentes possíveis razões para o *boom* das *commodities* e efeitos distintos de acordo com o mercado e região em análises, observa-se na literatura que os estudos posteriores passaram a tentar explicar os principais determinantes que levaram a esta forte escalada internacional nos preços, seguida de uma repentina queda, após 2008. Seguindo a utilização de modelos econométricos clássicos e de fronteira para análise dos choques nos preços, ou da transmissão de volatilidade entre mercados agrícolas, observa-se que a vasta maioria de estudos sugerem uma relação direta entre os mercados energéticos com os agropecuários, especialmente na relação do petróleo e derivados para com os mercados

agrícolas em escala global, especialmente os graneleiros, como milho, trigo, soja, arroz e aveia, que por sua vez têm forte relação com os mercados de proteína animal (Zhang et al., 2010; Serra, 2011; Vacha et al., 2013; Kristoufek et al., 2014; Cabrera e Schulz, 2016; Saghaian et al., 2018).

Trujillo-Barreras et al. (2013) elencam, ainda, que essa relação entre os mercados energéticos e agrícolas se tornou mais próxima desde a última década, em razão do aumento do uso de biomassa, grãos e oleaginosas para a produção de biocombustíveis, em especial o milho para a produção de etanol nos EUA. Tal constatação também é feita por Tyner (2010), apontando que o aumento no consumo de etanol no mercado norte-americano deu um impulso adicional às variações nos preços das *commodities* agrícolas, que vinha acompanhando as variações nos preços do petróleo no mercado internacional. Porém, Serra e Zilberman (2013) destacam que esse efeito deve ser analisado com cautela, a depender do mercado analisado, bem como os modelos econômicos utilizados para a análise.

Neste sentido, da flutuação de preços incrementada a partir do período em questão, a temática da inter-relação entre mercados energéticos e mercados agrícolas passa a receber tanto ou maior atenção que a temática clássica da relação entre estoques e preços agrícolas (Serra, 2011; Lahiani et al., 2013).

Seguindo essa lógica, e com base nos acontecimentos mais recentes, novos estudos têm buscado compreender os efeitos da pandemia da Covid-19 nas relações de preços e volatilidades das *commodities*, primeiramente pela rápida queda nos preços de *commodities* energéticas e minerais, posteriormente, pela rápida subida nos preços das *commodities* de forma geral, com os alguns mercados agrícolas renovando o seu recorde de preços (De Vijlder, 2020; Elleby et al., 2020; Wang et al., 2020; Borgdards et al., 2021; Kamdem et al., 2020; Hung, 2021; Dmytrów et al., 2021; Farid et al., 2022; Just e Echaust, 2022; Rajput et al., 2021; Wang et al., 2022; Quintino et al., 2023).

A maior parte desses estudos têm focado na análise do efeito *spillover* de volatilidades entre os mercados agrícolas, comparando os períodos pré e ao longo da pandemia da Covid-19 (Borgdards et al., 2021; Kamdem et al., 2020; Hung, 2021; Just e Echaust, 2022; Wang et al., 2022). Outros têm se debruçado na especificidade da inter-relação relação entre as *commodities* energéticas, sobretudo petróleo, e as agrícolas, em especial grãos (Wang et al., 2020; Dmytrów et al., 2021; Farid et al., 2022; Quintino et al., 2023).

Em geral, independentemente do foco principal ou dos modelos utilizados, tais estudos têm observado para um significativo aumento na transmissão de volatilidades entre esses mercados após a pandemia da Covid-19. Especificamente, Borgdards et al. (2021) sugerem que tal efeito se aplicou a todas as *commodities*, embora com maior intensidade no mercado energético e desse para os demais. Similarmente, Farid et al. (2022) aponta para fortes efeitos *spillovers* nos retornos dos preços das *commodities*, mostrando forte interconexão entre mercados energéticos, minerais e grãos, e efeitos menos intensos nos mercados de proteína animal, açúcar, café e cacau. Hung (2021) também demonstram essa forte interconexão entre o mercado de petróleo e de *commodities* agrícolas, assim como o maior efeito sobre os mercados graneleiros, especialmente milho, soja e trigo, que passaram a ser transmissores líquidos de volatilidade após a pandemia, enquanto açúcar e aveia incrementaram seus níveis de receptores de volatilidade. Just e Echaust (2022) apontam para forte volatilidade *spillover* no mercado de grãos no período, com recordes após o conflito Rússia-Ucrânia

Importante observar que tais estudos utilizam-se de diferentes abordagens metodológicas para se avaliar a interconexão entre as volatilidades de preços, em que se constam modelos que avaliam a volatilidade *spillover* através de modelos de séries temporais, como o GARCH-DCC e Diebold-Yilmaz (Borgdards et al., 2021; Dmytrów et al., 2021; Kamdem et al., 2021; Hung, 2021; Farid et al., 2022; Just e Echaust, 2022), bem como estudos para se avaliar a correlação cruzada através de modelos multifractais (Wang et al., 2020;

Quintino et al., 2023), ou wavelets (Kamdem et al., 2020). Quanto ao horizonte temporal analisado, notam-se estudos que analisaram uma série de tempo a partir da crise de 2006-2008 (Farid et al., 2022; Quintino et al., 2023), ou buscando os intervalos logo antes ou após a pandemia da Covid-19 (Wang et al., 2020; Hung, 2021; Kamdem et al., 2020; Borgdards et al., 2021; Dmytrów et al., 2021; Just e Echaust, 2022). Em geral, a grande maioria dos estudos utilizou dados de retornos preços diários, à exceção de Quintino et al. (2023), que usaram preços semanais e Borgdards et al. (2021), que aplicaram a análise com base nos retornos de preços intradiários.

Para o Brasil, no entanto, não se encontram trabalhos que buscam examinar os impactos da pandemia da Covid-19 sobre a volatilidade dos preços das *commodities* e suas conexões, havendo uma lacuna a ser explorada, a partir dos diferentes métodos supracitados.

### 3. Dados e Metodologia

#### 3.1 Dados

Os dados utilizados neste estudo consistem em preços físicos de milho, soja, arroz, trigo, boi gordo, açúcar e café no Brasil, considerando as praças de referência dos indicadores de preços do Cepea/Esalq/USP. De forma a buscar captar os potenciais efeitos exógenos a esses mercados, também são utilizados os preços de petróleo no mercado externo (Brent), visando captar os efeitos desta importante *commodity* para o mercado energético e a taxa de câmbio US\$/R\$ (Ptax), com o propósito de captar potenciais influências do comércio internacional na dinâmica das volatilidades das *commodities* agrícolas domesticamente, uma vez da importante participação do país no mercado global de alimentos.

O período analisado se inicia em 1º de janeiro de 2018 e termina em 10 de julho de 2023. Com o objetivo de analisar o impacto de diferentes fenômenos históricos nas séries de retornos, os dados foram divididos em cinco subamostras. A primeira subamostra, denominada pré-COVID, abrange o período que antecede a pandemia de COVID-19, compreendido entre 2 de janeiro de 2018 e 30 de janeiro de 2020. A segunda subamostra, chamada de pandemia COVID, refere-se ao período durante a pandemia de COVID-19, que ocorreu entre 31 de janeiro de 2020 e 30 de junho de 2021. A terceira subamostra, intitulada conflito da Rússia-Ucrânia, abarca o período durante o conflito entre Rússia e Ucrânia, que ocorreu de 1 de fevereiro de 2022 a 31 de julho de 2022. Por fim, a quarta subamostra, denominada pós-conflito, engloba o período após o conflito da Rússia-Ucrânia, compreendido entre 1 de agosto de 2022 e 10 de julho de 2023. Além dessas, considera-se uma janela para todo o período apenas para comparação. Ressalta-se que se definiu o período de início da pandemia quando a OMS torna pública a disseminação do vírus a outros continentes. O ciclo do conflito Rússia-Ucrânia também contempla alguns dias anteriores, em razão das movimentações militares nas fronteiras.

Para a investigação utilizou-se os retornos dos preços das *commodities* e do câmbio, estimados conforme expressão 01 a seguir.

$$r_t = \ln\left(\frac{P_t}{P_{t-1}}\right) \times 100 \quad (01)$$

A figura 1 a seguir apresenta o comportamento dos retornos das sete *commodities* agrícolas do Brasil, do petróleo Brent e do dólar.

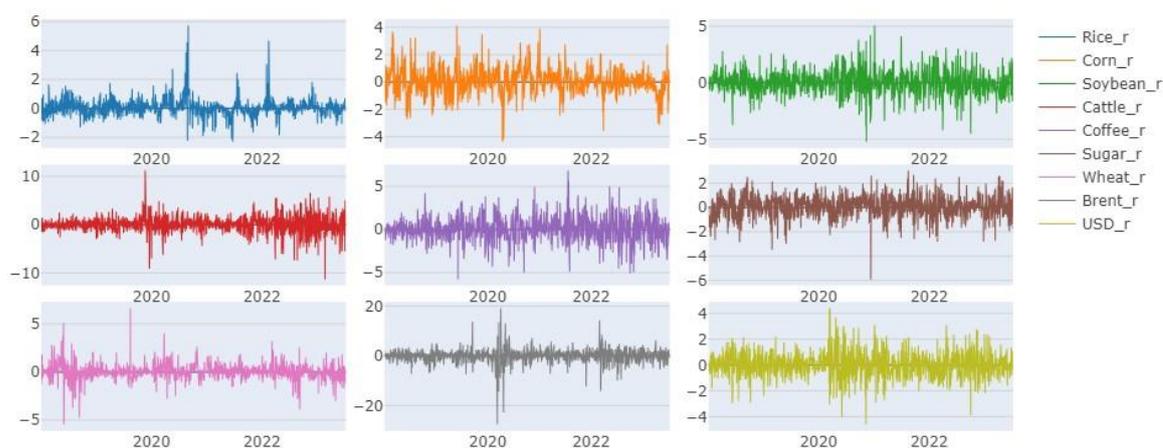


Figura 1 – Gráfico dos retornos das *commodities* e dólar

A tabela 1 sintetiza os resultados das estatísticas descritivas dos retornos das séries para os diferentes períodos analisados.

Tabela 1 – Estatística descritiva dos retornos

	Rice	Corn	Soybean	Cattle	Coffee	Sugar	Wheat	Brent	USD
<i>Amostra toda (1376 observações)</i>									
Mean	0.057	0.036	0.05	0.04	0.043	0.053	0.05	0.011	0.029
Variance	0.363	0.849	1.108	2.816	1.861	0.802	0.69	7.703	0.924
Skewness	1.98***	0.077	-0.055	-0.42***	0.135**	-0.47***	0.20***	-0.991***	0.038
Ex.Kurtosis	14.95***	2.11***	2.16***	5.65***	2.15***	2.01***	8.09***	15.26***	1.771***
JB	13730***	255.91***	268***	1874***	270***	282.7***	3768***	13587***	180.12***
Q(10)	619.98***	475.33***	17.13***	160.77***	29.53***	45.05***	83.80***	8.0	13.05**
Q2(10)	476.98***	126.45***	93.17***	79.17***	117.32***	50.89***	82.34***	181.63***	145.80***
<i>Pré-COVID-19 (519 observações)</i>									
Mean	0.06	0.08	0.033	0.052	0.006	0.024	0.071	-0.026	0.051
Variance	0.222	1.054	0.66	1.778	1.18	0.807	0.869	3.645	0.604
Skewness	0.389***	0.33***	0.044	0.333***	-0.104	-0.41***	0.42***	0.024	-0.31***
Ex.Kurtosis	0.682***	0.95***	1.48***	15.25***	2.76***	0.75***	10.77***	6.20***	1.15***
JB	23.13***	29.02***	47.84***	5041.77***	165.41***	27.06***	2523***	832.0***	37.42***
Q(10)	36.81***	90.31***	14.74***	48.02***	13.36**	53.92***	19.92***	6.69	7.079
Q2(10)	6.034	21.89***	6.83	38.23***	31.59***	32.54***	30.38***	8.94	28.50***
<i>Pandemia COVID-19 (351 observações)</i>									
Mean	0.087	0.159	0.174	0.146	0.167	0.113	0.127	0.072	0.046
Variance	0.706	0.973	1.624	1.596	1.775	0.805	0.575	15.036	1.52
Skewness	2.02***	-0.33**	-0.168	-0.27**	-0.069	-1.16***	0.382***	-1.24***	0.066
Ex.Kurtosis	10.83***	2.72***	2.00***	2.66***	1.38***	5.41***	2.972***	12.95***	1.33***
JB	1955.42***	114.54***	60.37***	107.78***	28.07***	508.2***	137.7***	2544***	26.20***
Q(10)	295.88***	182.67***	7.461	42.58***	17.64***	11.38**	56.52***	8.47	3.957
Q2(10)	175.69***	35.58***	37.63***	20.49***	6.78	10.92**	12.82**	45.77***	35.42***
<i>Conflito Rússia-Ucrânia (103 observações)</i>									
Mean	0.146	-0.149	0.055	-0.069	-0.078	-0.142	0.246	0.223	-0.022
Variance	0.531	0.615	1.598	4.573	2.389	0.897	0.618	12.976	0.974
Skewness	2.85***	-0.44*	-0.137	-0.45*	0.47**	-0.145	0.76***	-0.105	0.56**

Ex.Kurtosis	15.92***	3.74***	0.689	1.70***	0.99*	0.528	1.33**	3.27***	0.446
JB	1227.18***	63.31***	2.361	15.92***	8.13**	1.559	17.79***	46.22***	6.33**
Q(10)	24.89***	30.16***	6.193	27.12***	5.01	7.541	7.727	5.769	12.71**
Q2(10)	2.389	8.556	7.282	20.61***	4.21	35.832***	12.56**	14.14***	12.55**
<i>Pós-Conflito (235 observações)</i>									
Mean	0.025	-0.169	-0.133	-0.105	-0.195	0.024	-0.193	-0.148	-0.027
Variance	0.161	0.523	1.002	6.49	2.403	0.702	0.671	5.226	0.882
Skewness	0.21	-0.81***	-0.227	-0.51***	-0.17	-0.015	-0.70***	-0.41***	0.106
Ex.Kurtosis	2.54***	3.34***	1.82***	1.57***	0.49	1.22***	3.24***	0.535	1.289***
JB	64.97***	134.80***	34.65***	34.26***	3.62	14.78***	122.73***	9.56***	16.716***
Q(10)	82.74***	148.61***	9.95*	35.78***	7.13	14.17***	16.29***	5.736	9.663*
Q2(10)	20.07***	90.94***	7.30	1.43	2.071	7.918	33.173***	1.857	9.324*

Ao analisar os diferentes períodos, como pré-COVID, pandemia de COVID-19, conflito Rússia-Ucrânia e pós-conflito, observamos variações significativas nas médias e variâncias dos retornos. Durante a pandemia e o conflito, em comparação com os períodos pré e pós, várias séries apresentaram um aumento tanto nas médias como nas variâncias. Em particular, destacam-se o milho e a soja, que tiveram uma elevação considerável durante a pandemia. Esses resultados sugerem que esses mercados foram mais impactados pelos fenômenos históricos, refletindo a volatilidade e incerteza associadas a esses eventos.

De forma geral, o fenômeno que apresentou maior variância nos retornos das commodities e ativos analisados foi a pandemia, principalmente para o câmbio e petróleo. Isso significa que durante o surto da COVID, houve uma maior volatilidade e instabilidade nos mercados, resultando em retornos mais variáveis e imprevisíveis.

### 3.2 Metodologia

Para análise dos dados, utilizou-se a metodologia TVP-VAR que combina o trabalho de Diebold e Yilmaz (2012) e Koop e Korobilis (2014) com a abordagem proposta por Antonakakis et al. (2020). Essa técnica, conhecida como *Time-Varying Parameter Vector Autoregressive Model* (TVP-VAR), tem como objetivo superar algumas limitações da abordagem original de Diebold e Yilmaz (2012). Os estudos de Mishra et al. (2023) e Balcilar et al. (2021) são exemplos de aplicações do TVP-VAR para o mercado financeiro de commodities.

O *Time-Varying Parameter Vector Autoregressive Model* (TVP-VAR) de Antonakakis et al. (2020) é um modelo econométrico que permite a estimativa de parâmetros que variam ao longo do tempo em um sistema de equações vetoriais autorregressivas (VAR). Diferentemente do VAR tradicional, no qual os parâmetros são fixos ao longo do tempo, o TVP-VAR reconhece que as relações entre as variáveis podem ser sujeitas a mudanças estruturais ao longo do tempo. O TVP-VAR permite a análise das conectividades entre os mercados de commodities em períodos de crise. O modelo baseia-se na ideia de que as séries de preços de commodities estão interligadas e que essas interligações podem mudar ao longo do tempo. O TVP-VAR permite capturar essas mudanças nas interligações entre os mercados de commodities e, assim, fornece uma melhor compreensão de como os mercados reagem a eventos de crise (Mishra et al., 2023; Balcilar et al., 2021).

De acordo com Antonakakis et al., (2020) uma das principais vantagens da abordagem TVP-VAR é sua menor sensibilidade a *outliers*, o que contribui para uma estimativa mais precisa dos parâmetros do modelo. Além disso, essa técnica não requer um tamanho de janela arbitrário, o que é uma deficiência da abordagem original. Em vez disso, o modelo TVP-VAR é estimado utilizando o critério de informação bayesiano (BIC) com uma duração de defasagem

de ordem um. Ao estimar um TVP-VAR, é comum utilizar técnicas de inferência bayesiana ou métodos de filtragem recursiva, como o filtro de Kalman, para obter estimativas dos parâmetros variantes no tempo. Essas estimativas permitem acompanhar as mudanças estruturais e capturar os efeitos dinâmicos que podem ocorrer em diferentes períodos.

Portanto, nesta pesquisa, aplicamos a metodologia TVP-VAR juntamente com a técnica de conectividade expandida proposta por Balcilar et al. (2021). Isso nos permite superar as limitações da abordagem original de Diebold e Yilmaz (2012), obtendo estimativas mais precisas dos parâmetros e uma análise mais abrangente da interligação entre as variáveis econômicas.

## 4. Resultados

### 4.1 Conectividades médias

Primeiramente, a análise foca na média das conectividades entre os retornos dos preços de mercado e suas volatilidades considerando as janelas para todo o período, período pré-pandemia da Covid-19, período crítico da pandemia da Covid-19, período crítico do conflito Rússia-Ucrânia, período recente, após momentos críticos da pandemia e do conflito militar (Tabela 2). A média das conectividades para todo o período (painel A da Tabela 2) revela que a soja e a taxa de câmbio são os maiores transmissores (25,74 e 25,43) e receptores dos choques nos retornos (23,92 e 21,69). São transmissores líquidos de choques nos retornos de preços a taxa de câmbio, a soja, o petróleo, o boi gordo e o açúcar, enquanto as demais séries de retornos de preços são receptoras líquidas dos choques.

Tabela 2 – Média das conectividades

	Rice	Corn	Soybean	Cattle	Coffee	Sugar	Wheat	Brent	USD	FROM
<i>Painel A: Amostra toda (1376 observações)</i>										
Rice	92.55	1.42	0.54	0.56	0.83	1.41	0.91	0.91	0.87	7.45
Corn	1.48	84.58	6.08	1.53	1.2	1.31	1.05	0.51	2.26	15.42
Soybean	0.63	3.38	76.08	1.12	0.76	1.31	0.89	1.54	14.31	23.92
Cattle	0.46	1.32	0.62	93.31	1.23	0.5	0.92	0.97	0.66	6.69
Coffee	0.59	0.86	1.28	1.01	91.37	0.82	0.73	1.66	1.68	8.63
Sugar	1.24	1	0.89	0.83	0.72	92.28	0.68	1.41	0.95	7.72
Wheat	0.96	2.29	1.6	1.04	0.65	0.5	91.29	0.85	0.82	8.71
Brent	0.76	0.49	1.54	0.77	1.4	1.35	0.71	89.1	3.89	10.9
USD	0.72	0.85	13.21	0.73	1.22	0.71	0.47	3.78	78.31	21.69
TO	6.84	11.61	25.74	7.58	8.01	7.92	6.37	11.62	25.43	111.13
Inc.Own	99.4	96.19	101.82	100.9	99.38	100.2	97.66	100.71	103.74	cTCI/TCI
NET	-0.6	-3.81	1.82	0.9	-0.62	0.2	-2.34	0.71	3.74	13.89/12.35
NPT	3	1	3	6	3	4	2	7	7	
<i>Painel B: Pré-COVID-19 (519 observações)</i>										
Rice	91.62	0.67	0.49	0.82	0.78	2.43	1.14	1.31	0.75	8.38
Corn	0.77	86.47	4.64	2.04	0.99	1.9	0.85	0.42	1.92	13.53
Soybean	0.51	1.89	75.29	1.63	0.91	0.85	0.27	1.56	17.09	24.71
Cattle	0.69	1.22	0.47	92.71	1.87	0.51	0.6	0.88	1.05	7.29
Coffee	0.48	0.63	0.98	1.75	91.19	1.08	0.37	1.37	2.15	8.81
Sugar	0.59	0.89	0.54	0.77	0.84	94.41	0.45	0.69	0.83	5.59
Wheat	0.65	1.02	0.34	0.6	0.41	0.51	94.83	1	0.65	5.17
Brent	1.12	0.41	0.96	0.96	1.33	0.77	0.36	91.71	2.38	8.29

USD	0.39	0.55	14.91	0.62	2.03	0.64	0.35	1.74	78.78	21.22
TO	5.2	7.29	23.32	9.19	9.15	8.69	4.37	8.97	26.81	102.99
Inc.Own	96.82	93.75	98.62	101.9	100.34	103.1	99.19	100.68	105.59	cTCI/TCI
NET	-3.18	-6.25	-1.38	1.9	0.34	3.1	-0.81	0.68	5.59	12.87/11.44
NPT	2	1	3	5	4	6	2	5	8	

*Painel C: Pandemia COVID-19 (351 observações)*

Rice	95.43	1.05	0.26	0.69	0.53	0.41	0.51	0.27	0.84	4.57
Corn	0.83	84.34	5.98	1.26	2.63	0.53	0.98	0.23	3.24	15.66
Soybean	0.48	3.77	71.94	1.02	0.54	2.09	0.91	0.54	18.7	28.06
Cattle	0.23	1.38	1.36	91.54	2.8	0.81	0.57	0.6	0.72	8.46
Coffee	0.63	1.55	2.93	1.66	89.64	0.61	0.33	0.79	1.86	10.36
Sugar	1.18	1.57	1.38	0.8	0.78	86.99	0.77	5.12	1.42	13.01
Wheat	1.81	3.68	1.75	0.44	1.05	0.78	89.46	0.25	0.79	10.54
Brent	0.13	0.2	0.48	0.3	0.99	3.29	0.73	87.26	6.61	12.74
USD	0.95	1.94	17.44	1.27	0.34	0.88	0.65	5.73	70.79	29.21
TO	6.24	15.13	31.57	7.43	9.67	9.4	5.45	13.52	34.17	132.59
Inc.Own	101.7	99.48	103.52	98.97	99.32	96.39	94.91	100.79	104.96	cTCI/TCI
NET	1.67	-0.52	3.52	-1.03	-0.68	-3.61	-5.09	0.79	4.96	16.57/14.73
NPT	5	4	4	2	5	3	2	5	6	

*Painel D: Conflito Rússia-Ucrânia (103 observações)*

Rice	87.29	2.98	1.15	0.83	1.46	1.84	1.3	0.87	2.27	12.71
Corn	3.04	73.4	8.26	0.3	3.48	0.78	2.85	3.24	4.66	26.6
Soybean	0.71	3.9	77.54	0.37	1.45	5.34	0.94	2.97	6.78	22.46
Cattle	2.35	0.12	0.16	88.61	0.59	0.26	1.95	3.41	2.55	11.39
Coffee	0.95	3.57	0.45	0.96	88.02	0.42	3.03	0.97	1.65	11.98
Sugar	6.66	1.56	2.32	4.56	0.61	76.47	2.9	0.72	4.2	23.53
Wheat	0.92	6.53	5.03	0.37	2.47	1.63	76.23	4.77	2.04	23.77
Brent	1.23	1.59	3.22	2.47	1.75	2.61	6.15	79.05	1.94	20.95
USD	0.9	0.59	7.54	4.47	0.47	2.98	0.88	3.87	78.32	21.68
TO	16.77	20.84	28.12	14.32	12.3	15.85	19.99	20.81	26.08	175.08
Inc.Own	104.1	94.24	105.66	102.93	100.31	92.33	96.22	99.86	104.39	cTCI/TCI
NET	4.06	-5.76	5.66	2.93	0.31	-7.67	-3.78	-0.14	4.39	21.88/19.45
NPT	4	3	5	5	4	2	5	3	5	

*Painel E: Pós-Conflito (235 observações)*

Rice	88.15	2.26	0.33	1.09	2.58	2.16	2.17	0.33	0.93	11.85
Corn	3.1	86.08	3.09	1.37	0.38	2.04	0.74	1.22	1.98	13.92
Soybean	0.21	1.82	82.7	0.92	0.91	0.27	1.19	0.28	11.71	17.3
Cattle	0.18	0.29	1.55	91.47	2.34	0.14	0.95	2.58	0.49	8.53
Coffee	0.47	0.31	0.93	0.94	91.02	0.31	3.26	0.98	1.8	8.98
Sugar	3.11	1.06	0.94	0.83	0.53	88.91	0.36	2.39	1.86	11.09
Wheat	0.82	1.01	1.32	4.65	0.97	1.41	88.13	1.26	0.44	11.87
Brent	0.38	0.52	0.25	1.15	1.08	2.82	0.37	86.61	6.84	13.39
USD	0.25	0.31	11.61	0.37	0.93	1.65	0.68	3.74	80.46	19.54
TO	8.53	7.58	20.02	11.31	9.7	10.78	9.72	12.78	26.04	116.48
Inc.Own	96.67	93.67	102.72	102.79	100.72	99.69	97.85	99.39	106.5	cTCI/TCI
NET	-3.33	-6.33	2.72	2.79	0.72	-0.31	-2.15	-0.61	6.5	14.56/12.94
NPT	3	1	6	4	5	3	3	4	7	

Pode-se notar, pela Tabela 2, que o painel B indica o período anterior à pandemia da Covid-19. Neste período, observa-se entre conectividade mais forte apenas entre soja e taxa de câmbio, reforçando o papel das exportações do país, que nesse período se consolidava como o maior exportador e produtor mundial desse grão. O petróleo, por sua vez, pouca conectividade apresentou com os mercados agrícolas brasileiros. Quanto aos efeitos *spillover*, o preço da soja e a taxa de câmbio se mostraram como os mercados que mais enviaram transmissão aos demais mercados, enquanto o milho, junto com a própria soja e taxa de câmbio também se sobressaltam na recepção desses efeitos, sinalizando a importância desses mercados graneleiros e da taxa de câmbio nas volatilidades dos demais mercados agrícolas, mesmo em um período de estabilidade conjuntural nesses mercados. Em termos líquidos, os resultados apontam que a taxa de câmbio, soja, boi gordo, petróleo e açúcar, nesta ordem de grandeza, foram transmissores líquidos de volatilidade, enquanto milho, trigo, café e arroz foram receptores.

Por sua vez, ao se analisar os resultados do painel C (Tabela 2), reforça-se a forte conectividade entre soja e taxa de câmbio no período crítico da pandemia da Covid-19. Nota-se, também, que embora os demais mercados apresentem uma menor conectividade entre si, há um aumento nas inter-relações se comparado ao período anterior à pandemia, tal como também observam Borgdads et al. (2021) e Hung (2021) no mercado global de *commodities*. Neste período, a soja e a taxa de câmbio reforçam suas posições como principais transmissoras de volatilidade, enquanto o petróleo e o arroz passam a ter uma posição relevante na transmissão. Há um aumento evidente, também, na recepção de volatilidade na maior parte dos mercados. Além da soja e taxa de câmbio, se destacam o milho, açúcar, petróleo, trigo e café. Em termos líquidos tem-se como principais transmissores a taxa de câmbio, soja e arroz, respectivamente, como todo os demais se mostrando receptores, com destaque para trigo e açúcar. Os resultados vão de encontro ao que Farid et al. (2022) e Hung (2021). Porém, se diferenciam quando comparados às transmissões do petróleo aos preços em escala global.

No painel D da Tabela 2, referente ao período do conflito Rússia-Ucrânia, é possível observar um aumento substancial na interconectividade entre todos mercados, embora ocorra uma queda na interconexão entre a soja e a taxa de câmbio. Chama-se a atenção o fato do petróleo aumentar sua relação com os mercados agrícolas, especialmente com trigo e soja, sinalizando-se os fortes efeitos derivados da guerra nos mercados internacionais de petróleo e grãos (Fang e Shao, 2022; Just e Echaust, 2022; Gaio e Capitani, 2023). Quanto à transmissão e recepção de volatilidade, todos os mercados passaram a ter papel relevante. Os efeitos líquidos da transmissão são positivos nos mercados de soja, taxa de câmbio, arroz, boi gordo e café, nesta ordem de grandeza, e negativos para açúcar, milho, trigo e petróleo. As possíveis explicações para o grande efeito de receptores de volatilidade em milho e trigo se dá pelo fato da Ucrânia e Rússia serem, respectivamente, grandes exportadores desses grãos, que foram fortemente impactados no período do conflito. Quanto ao açúcar, a Rússia é tradicionalmente uma grande importadora, o que pode ter impactado o mercado.

Por fim, no painel E (Tabela 2), no período pós períodos críticos do conflito Rússia-Ucrânia e da pandemia da Covid-19, observa-se uma queda substancial na interconexão dos mercados, se aproximando da observada no painel B (tabela 2), referente ao período pré-pandemia. Tais evidências também foram observadas por Quintino et al. (2023) ao avaliarem a relação recente entre os mercados energéticos internacionais. A principal diferença entre os dois períodos supracitados se dá na queda da conectividade entre soja e taxa de câmbio. Uma possível razão é a estabilidade cambial vivenciada no Brasil no período e a uma safra de soja sem grandes intercorrências no país. Observa-se, também, que o petróleo perde sua conexão com os mercados, ao contrário do período do conflito Rússia-Ucrânia, assim como a transmissão e recepção de volatilidade se recuam para todas as *commodities* e mercados em análise. Ainda apresentam transmissão mais significativa, na ordem, taxa de câmbio, soja, petróleo e boi gordo, e na recepção, taxa de câmbio, soja, petróleo, milho, trigo, arroz e açúcar.

Os efeitos líquidos são positivos para taxa de câmbio, boi gordo, soja e café, com a soja perdendo seu poder de transmissão se comparado aos demais períodos. Já os efeitos líquidos de receptividade de transmissão foram mais expressivos para o milho, arroz, trigo, petróleo e açúcar.

Os resultados acima discutidos, são melhores evidenciados a partir da Figura 02, que ilustra a rede de conectividade entre os retornos de preços das *commodities* agrícolas, além do petróleo e do câmbio analisadas. É possível constatar como os períodos críticos da pandemia da Covid-19 e do conflito Rússia-Ucrânia impulsionaram a conectividade entre os mercados, inclusive com consequências posteriores (2022-2023), em que essa rede se altera em relação ao período prévio desses eventos (2018-2020). Corrobora-se, ainda, o papel da soja e da taxa de câmbio nos choques, sempre como transmissores de volatilidade. Também se nota o milho com relação constante com soja e taxa de câmbio, sendo sempre receptor dos choques de volatilidade, e trigo emergindo de forma significativa como receptor ao longo dos ciclos de crise.

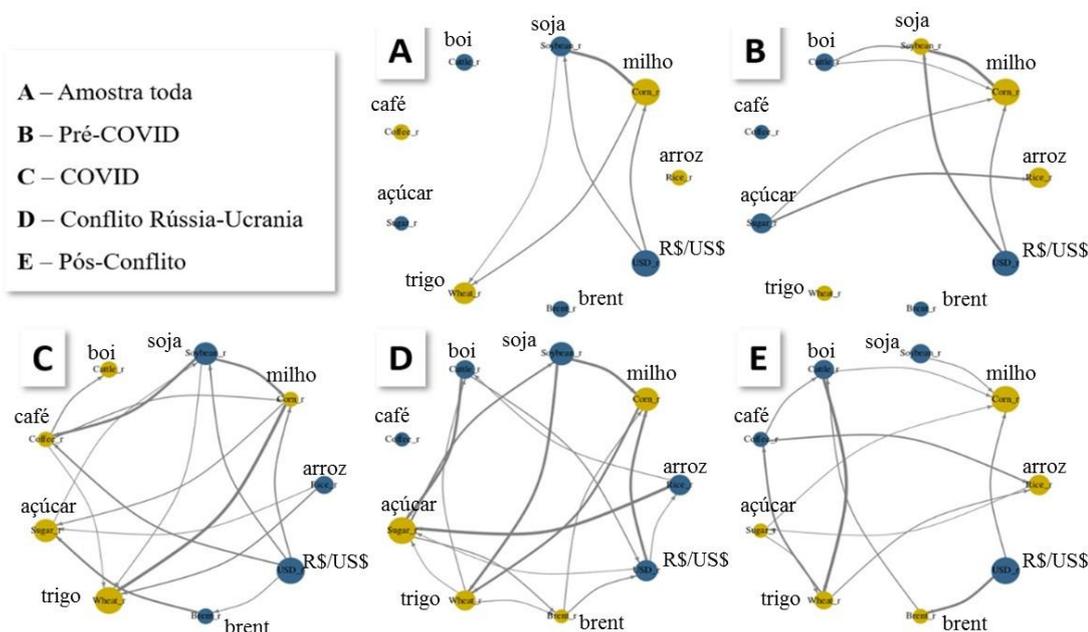


Figura 02 – Rede de conectividade da volatilidade *spillover* nos períodos analisados

#### 4.2 Conectividades dinâmicas

Em relação às conectividades totais para todo o período, observa-se na Figura 03 um pico mais acentuado a partir do início de 2020, após deflagrado o cenário de propagação do vírus SARS-COV-2 e da pandemia da Covid-19, perpetuando-se em um ciclo dos *spillovers* até aproximadamente a metade de 2021. Outro pico significativo se observa após o início do conflito Rússia-Ucrânia, porém com uma janela temporal menor. Em geral, pode-se afirmar que o período impacto mais expressivo (e longo) nas volatilidades dos mercados no Brasil foi o da Covid-19. Uma possível explicação para esse impacto ainda mais significativo que no período do conflito militar pode ser a forte desvalorização cambial vivenciada no país com a pandemia em associação com a forte conexão da taxa de câmbio com os preços das *commodities*.

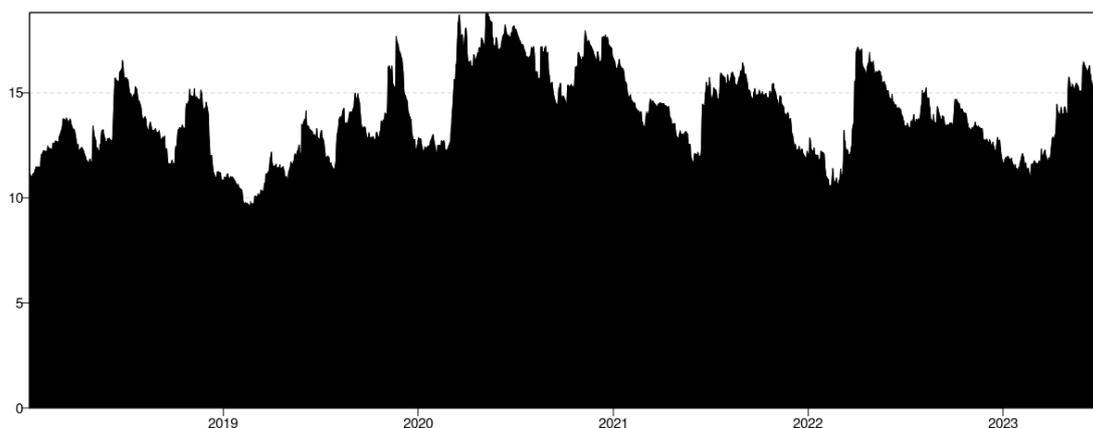


Figura 03 – Conectividades dinâmicas totais

Ao se avaliar a conectividade dinâmica para cada um dos mercados analisados, corrobora-se os maiores efeitos sobre a soja, taxa de câmbio e milho, com os dois primeiros sendo majoritariamente transmissores dos choques, e o segundo, receptor (Figura 04). No caso do trigo, há um impacto mais tardio da pandemia (receptor), acentuado com o conflito militar. O arroz também apresenta comportamento de forte transmissor no período da pandemia, invertendo seu papel prévio de receptor. O petróleo tem dois breves picos de transmissão no começo da pandemia e do conflito Rússia-Ucrânia. Já as séries de boi gordo, café e açúcar pouco oscilam no período, com exceção do açúcar no período pré-pandemia.

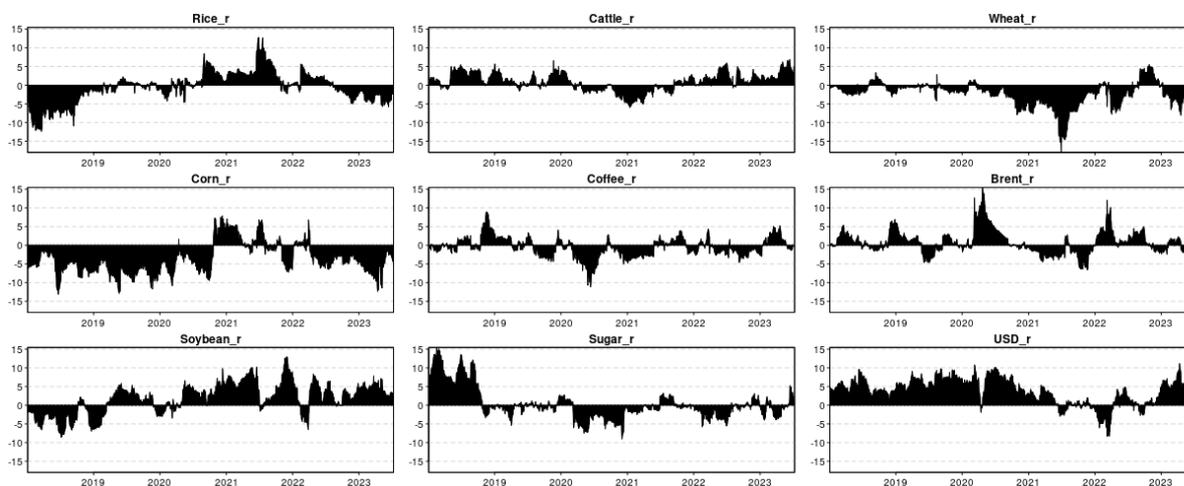


Figura 04 – Conectividade direcional dinâmica total líquida

Para uma melhor ilustração direcional entre os mercados, a Figura 05 apresenta os resultados líquidos totais a partir de uma análise dual entre cada um dos diferentes mercados. Em suma, observa-se que a maior conectividade se dá (i) nas relações entre os mercados graneleiros, ou seja, soja (transmissor) e milho (receptor), milho (transmissor) e trigo (receptor), soja (transmissor) e trigo (receptor); (ii) nas relações entre câmbio e algumas *commodities* exportadoras, as quais, taxa de câmbio (transmissor) e soja (receptor), taxa de câmbio (transmissor) e milho (receptor) e taxa de câmbio (transmissor) e café (receptor). Ademais, algumas relações particulares são observadas, como no caso de arroz e açúcar, com a relação se invertendo após a pandemia. No entanto, a esse caso pode-se associar as dissonâncias entre ambos os mercados e seus movimentos opostos após o início da pandemia. Também se observa que a pandemia foi um fator propulsor dos choques na maior parte das relações apresentadas.

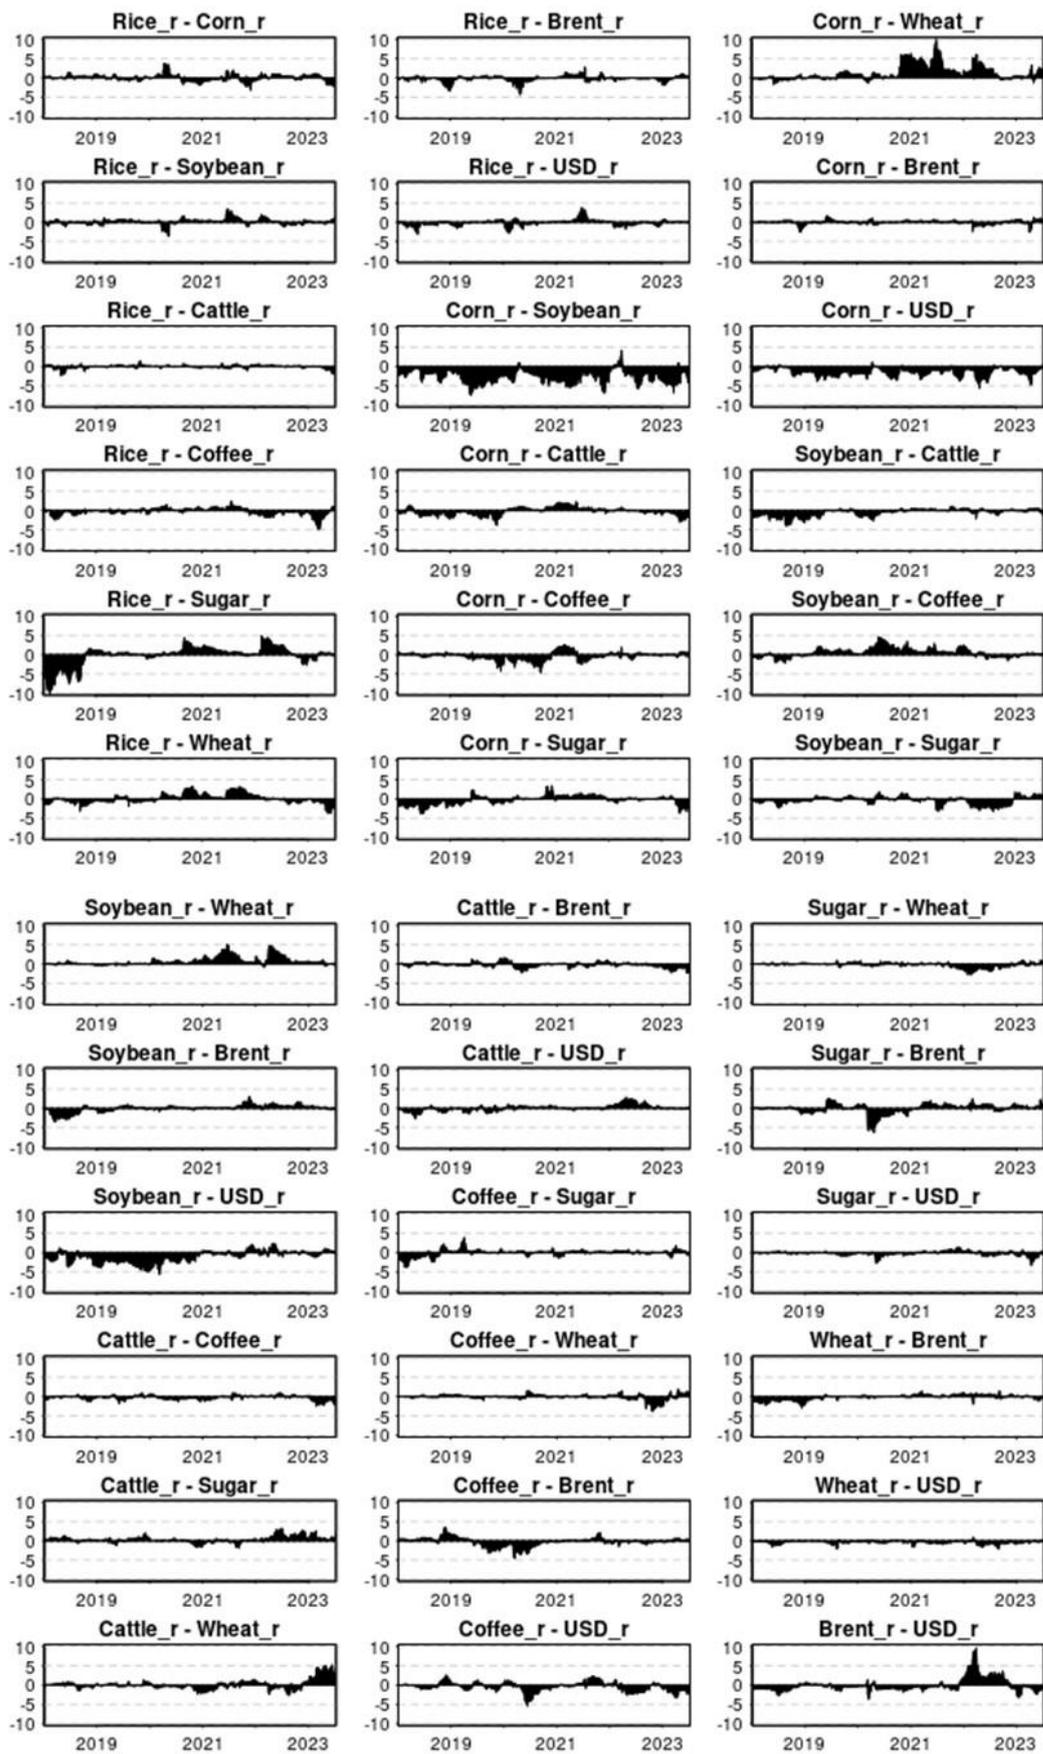


Figura 05 - Conectividade direcional dinâmica em pares

## 5. Considerações finais

Este estudo teve como objetivo avaliar os efeitos da volatilidade *spillover* nos mercados agrícolas brasileiros após a pandemia da Covid-19, considerando o período de 2018 a 2023. Especificamente, o estudo considerou os retornos dos preços nos mercados domésticos de soja, milho, trigo, arroz, café, açúcar e boi gordo, incluindo, também, a taxa de câmbio e os preços internacionais de petróleo (Brent).

Para isso, aplicou-se o modelo TVP-VAR de Antonakakis et al., (2020) que permite avaliar os efeitos de transbordamento (*spillover*) e a conectividade dinâmica entre os mercados. Os impactos foram avaliados a partir de janelas distintas, considerando o período pré- e pós-pandemia, com o segundo momento dividido entre o ciclo crítico da pandemia, o conflito Rússia-Ucrânia, e o período de retomada de estabilização nos mercados, com dissipação dos efeitos principais dos ciclos de crises.

Em geral, pôde-se observar que a rede de conectividade entre os mercados analisados se alterou substancialmente após a pandemia da Covid-19, perpetuando-se além dos ciclos de crise evidenciados. A taxa de câmbio apresentou forte conexão com a maior parte dos mercados, assim como a soja, ambas se mostrando como transmissoras líquidas de volatilidade. Ademais, observou-se um forte efeito entre ambas, com a taxa de câmbio afetando o mercado de soja. O petróleo, por sua vez, não mostrou conexão relevante com os mercados agrícolas, a exceção de pequenos picos no início da pandemia e do conflito Rússia-Ucrânia. Dentre os demais mercados, destacam-se os graneleiros, com o milho exibindo alta conectividade com os demais mercados em todos os períodos, assumindo, majoritariamente, papel de receptor de volatilidade, o trigo como forte receptor no período da pandemia e do conflito Rússia-Ucrânia, e o arroz, como transmissor no período da pandemia. Não foram observadas relações relevantes para os mercados de boi gordo, café e açúcar.

Os resultados convergem com a literatura recente, quando se demonstra o forte aumento dos efeitos *spillovers* e da conectividade entre os mercados agrícolas após a pandemia (Borgdards et al., 2021; Hung, 2021; Farid et al., 2022) e no início do conflito Rússia-Ucrânia (Just e Echaust, 2022; Fang e Shao, 2022; Gaio e Capitani, 2023). Ainda, converge com os estudos de Wang et al. (2020), Borgdards et al. (2021) e Farid et al. (2022), ao observar que as *soft commodities*, como o açúcar e café, além dos mercados de proteína animal, se comportam como receptores de volatilidade após a pandemia. No entanto, diverge-se de outros estudos, que apontam uma forte conectividade advinda dos mercados energéticos, sobretudo o petróleo (Kamdem et al., 2020; Dmytrów et al., 2021; Hung, 2021; Quitino et al. 2023). Entretanto, há de se considerar que tais estudos aplicaram suas análises aos preços internacionais. E, nesse sentido, a consideração da taxa de câmbio traz novos elementos para o entendimento da relação em mercados emergentes e exportadores líquidos de *commodities* agrícolas, como o Brasil.

Este estudo tem implicações práticas, teóricas e sociais significativas. Em termos práticos, os resultados fornecem *insights* valiosos para os participantes do mercado agrícola brasileiro, auxiliando na tomada de decisões e no gerenciamento de riscos. No aspecto teórico, os achados contribuem para o avanço do conhecimento econômico ao aplicar a metodologia TVP-VAR e ampliar a compreensão das relações entre os mercados agrícolas e a taxa de câmbio. Socialmente, fornece informações relevantes para os formuladores de políticas, permitindo o desenvolvimento de estratégias de estabilização de mercado e apoio ao setor agrícola brasileiro.

Ressalta-se, no entanto, uma limitação amostral para o período mais recente, após as recentes crises, sendo necessário uma posterior atualização das informações que possa captar melhor como as conexões se dão em longo prazo em uma conjuntura de mercado menos instável. Ademais, uma temática adicional seria explorar as relações entre os preços agrícolas do Brasil e dos mercados internacionais, de forma a entender melhor tais conectividades. Outro

estudo futuro pode adotar novas metodologias de fronteira para se analisar a relação na frequência-tempo, podendo-se adotar modelos de coerência *wavelet*, assim como modelos fractais para se examinar as correlações cruzadas entre os mercados.

## Referências

Acemoglu D., Johnson S., Robinson J. A., & Thaicharoen Y. (2003). Institutional causes, macroeconomic symptoms: volatility, crises and growth. *Journal of Monetary Economics*. 50: 49-123.

Antonakakis, N., Chatziantoniou, I., & Gabauer, D. (2020). Refined Measures of Dynamic Connectedness based on Time-Varying Parameter Vector Autoregressions. *Journal of Risk and Financial Management*, 13(4), 84. <https://doi.org/10.3390/jrfm13040084>

Balcilar, M., Gabauer, D., & Umar, Z. (2021). Crude Oil futures contracts and commodity markets: New evidence from a TVP-VAR extended joint connectedness approach. *Resources Policy*, 73, 102219. <https://doi.org/10.1016/j.resourpol.2021.102219>

Beckman, J., & Countryman, A. (2021). The importance of agriculture in the economy: impacts from Covid-19. *American Journal of Agricultural Economics*, 103(5): 1595-1611. <https://doi.org/10.1111/ajae.12212>

Borgdards, O., Czudaj, R. L., & Van Hoang, T. H. (2021). Price overreactions in the commodity futures market: An intraday analysis of the Covid-19 pandemic impact. *Resources Policy*, 71: 101966. <https://doi.org/10.1016/j.resourpol.2020.101966>

Cabrera, B. L., & Schulz, F. (2016). Volatility linkages between energy and agricultural commodity prices. *Energy Economics*. 54: 190-203. <https://doi.org/10.1016/j.eneco.2015.11.018>

CEPEA - Centro de Estudos Avançados em Economia Aplicada. Indicadores de preços físicos. Acesso em: <http://www.cepea.org.br>.

De Vijlder, W. (2020). *The COVID-19 Pandemic: Economic Consequences Pervasive Uncertainty, Delayed Recovery*. BNP Paribas, Economic Research Department: Paris, France, p. 1–51.

Diebold, F. X., & Yilmaz, K. (2012). Better to give than to receive: predictive directional measurement of volatility spillovers. *International Journal of Forecasting*, 28(1): 57-66. <https://doi.org/10.1016/j.ijforecast.2011.02.006>

Dmytrów, K., Landmesser, J., & Bieszk-Stolorz, B. (2021). The Connections between COVID-19 and the Energy Commodities Prices: Evidence through the Dynamic Time Warping Method. *Energies*, 14: 4024. <https://doi.org/10.3390/en14134024>

Elleby, C., Domínguez, I. P., & Adenauer, M. (2020). Impacts of the COVID-19 Pandemic on the Global Agricultural Markets. *Environmental and Resource Economics*. 76:1067–1079. <https://doi.org/10.1007/s10640-020-00473-6>

- Fang, Y., & Shao, Z. (2022). The Russia-Ukraine conflict and volatility risk of commodity markets. *Finance Research Letters*, 50: 103264. <https://doi.org/10.1016/j.frl.2022.103264>
- Farid, S., Naeem, M. A., Paltrinieri, A., & Nepal, R. (2022). Impact of COVID-19 on the quantile connectedness between energy, metals and agriculture commodities. *Energy Economics*. 109: 105962. <https://doi.org/10.1016/j.eneco.2022.105962>
- Frenk, D., & Tuberville, W. (2011). *Commodity Index Traders and the Boom/Bust Cycle in Commodities Prices*. Better Markets, (Outubro, 2011). <https://doi.org/10.2139/ssrn.1945570>
- Gaio, L. E., & Capitani, D. H. D. Multifractal cross-correlation analysis between crude oil and agricultural futures markets: evidence from Russia–Ukraine conflict. *Journal of Agribusiness in Developing and Emerging Economies*, Vol. ahead-of-print, No. ahead-of-print. <https://doi.org/10.1108/JADEE-11-2022-0252>
- Huchet-Bourdon, M. (2011) *Agricultural Commodity Price Volatility: An Overview*. OECD Food, Agriculture and Fisheries Papers No. 52, OECD Publishing. <http://dx.doi.org/10.1787/5kg0t00nrhc-en>
- Hung, N. T. (2021). Oil prices and agricultural commodity markets: Evidence from pre and during COVID-19 outbreak. *Resources Policy*. 73: 102236. <https://doi.org/10.1016/j.resourpol.2021.102236>
- Irwin, S. H., & Good, D. L. (2009). Market instability in a new era of corn, soybean and wheat prices. *Choices* 24(1), 6–11.
- Just, M., & Echaust, K. (2022) Dynamic spillover transmission in agricultural commodity markets: What has changed after the COVID-19 threat?. *Economics Letters*. 217: 110671. <https://doi.org/10.1016/j.econlet.2022.110671>
- Kamdem, J. S., Essomba, R. B., & Berinyuy, J. N. (2020). Deep learning models for forecasting and analyzing the implications of COVID-19 spread on some commodities markets volatilities. *Chaos, Solitons and Fractals*, 140: 110215. <https://doi.org/10.1016/j.chaos.2020.110215>
- Koop, G., & Korobilis, D. (2014). A new index of financial conditions. *European Economic Review*, 71, 101–116. <https://doi.org/10.1016/j.euroecorev.2014.07.002>
- Kristoufek, L., Janda, K., & Zilberman, D. (2014). Price transmission between biofuels, fuels, and food commodities. *Biofuels, Bioproducts & Biorefining*. 8: 362-373. <https://doi.org/10.1002/bbb.1464>
- Lahiani, A., Nguyen, D. K., & Vo, T. (2013). Understanding Return and Volatility. *The Journal of Applied Business Research*, 29(6): 1781-1790. <https://doi.org/10.19030/jabr.v29i6.8214>
- Mishra, A. K., Arunachalam, V., Olson, D., & Patnaik, D. (2023). Dynamic connectedness in commodity futures markets during Covid-19 in India: New evidence from a TVP-VAR extended joint connectedness approach. *Resources Policy*, 82, 103490. <https://doi.org/10.1016/j.resourpol.2023.103490>

Quintino, D., Ogino, C., Haq, I. U., Ferreira, P., & Oliveira, M. (2023). An Analysis of Dynamic Correlations among Oil, Natural Gas and Ethanol Markets: New Evidence from the Pre- and Post-COVID-19 Crisis. *Energies*, 16: 2349. <https://doi.org/10.3390/en1605234>

Rajput, H., Changotra, R., Gautam, S., Gollakota, A. R. K., & Arora, A. S. (2021). A shock like no other: coronavirus rattles commodity markets. *Environment, Development and Sustainability*, 23: 6564-6574. <https://doi.org/10.1007/s10668-020-00934-4>

Saghaian, S., Nemati, M., Walters, C., & Chen, B. (2018). Asymmetric Price Volatility Transmission between U.S. Biofuel, Corn, and Oil Markets. *Journal of Agricultural and Resource Economics*. 43: 46-60.

Serra, T. (2011). Volatility spillover between food and energy market: a semiparametric approach. *Energy Economics*, 33: 1155-1164. <https://doi.org/10.1016/j.eneco.2011.04.003>

Serra, T., & Zilberman, D. (2013). Biofuel-related price transmission literature: A review. *Energy Economics*. 37: 141-151. <https://doi.org/10.1016/j.eneco.2013.02.014>

Shahrestani, P., & Rafei, M. (2020). The impact of oil price shocks on Tehran Stock Exchange returns: Application of the Markov switching vector autoregressive models, *Resources Policy*, 65, 101579. <https://doi.org/10.1016/j.resourpol.2020.101579>

Trujillo-Barreras, A., Mallory, M., & Garcia, P. (2012). Volatility Spillovers in U.S. Crude Oil, Ethanol, and Corn Futures Markets. *Journal of Agricultural and Resource Economics*. 37(2): 247-262. <https://doi.org/10.22004/ag.econ.134275>

Tyner, W. E. (2010). The integration of energy and agricultural markets. *Agricultural Economics*. 41: 193-201. <https://doi.org/10.1111/j.1574-0862.2010.00500.x>

Vacha, L., Karrel, J., Kristoufek, L., & Zilberman, D. (2013). Time-frequency dynamics of biofuel-fuel-food system. *Energy Economics*. 40(1), 233-241. <https://doi.org/10.1016/j.eneco.2013.06.015>

Wang, J., Shao, W., & Kim, J. (2020). Analysis of the impact of COVID-19 on the correlations between crude oil and agricultural futures. *Chaos, Solitons and Fractals*. 136: 109896. <https://doi.org/10.1016/j.chaos.2020.10989>

Wang, Y., Bouri, E., Fareed, Z., & Dai, Y. (2022). Geopolitical risk and the systemic risk in the commodity markets under the war in Ukraine. *Financial Research Letters*, 49: 103066. <https://doi.org/10.1016/j.frl.2022.103066>

World Bank. *Commodity markets outlook*. Special Focus (April) 2020. p. 7–16. Disponível em: <https://thedocs.worldbank.org/en/doc/c5de1ea3b3276cf54e7a1dff4e95362b-0350012021/original/CMO-April-2021.pdf>. Acesso em 02 jul. 2023.

Wright, B. D. (2011). The economics of grain price volatility. *Applied Economic Perspectives and Policy*, 33(1), 32–58. <https://doi.org/10.1093/aep/ppq033>

Zhang, Z., Lohr, L., Escalante, C. L., & Wetzstein, M. E. (2010). Food versus fuel: What do prices tell us? *Energy Policy*, 38(1), 445–451. <https://doi.org/10.1016/j.enpol.2009.09.034>