

Caio Perez Casagrande¹

ORCID: [0000-0002-0830-9999](https://orcid.org/0000-0002-0830-9999)

Gabrielito Rauter Menezes²

ORCID: [0000-0001-7649-5132](https://orcid.org/0000-0001-7649-5132)

¹ Mestre em Economia Aplicada
pela Universidade Federal de
Pelotas (UFPel)

cpcasagrande@ufpel.edu.br

² Doutor em Economia Aplicada
pela Universidade Federal do Rio
Grande do Sul (UFRGS)

Professor Adjunto da UFPel

gabrielito.menezes@ufpel.edu.br

PREVISIBILIDADE DE PREÇOS DAS PRINCIPAIS COMMODITIES AGRÍCOLAS BRASILEIRAS

RESUMO

O Brasil se destaca como um dos principais produtores de commodities agrícolas do mundo, sendo as suas exportações responsáveis por uma grande parcela do Produto Interno Bruto (PIB) nacional. Dentro deste contexto, o presente trabalho visa ajustar o melhor modelo Autorregressivo Integrado de Médias Móveis (ARIMA) para a previsão dos preços da soja, milho e café arábica, as principais exportações agrícolas brasileiras. O objetivo é auxiliar os produtores e demais agentes do agronegócio brasileiro em tomadas de decisões e em seus planejamentos operacionais. Assim, utilizou-se a série histórica mensal, entre março de 2006 e novembro de 2022, para prever o preço das commodities no curto prazo futuro. De acordo com os resultados, os modelos que se adaptaram para as previsões foram um ARIMA (0,1,1) para a soja, um ARIMA (1,1,0) para o milho e um ARIMA (1,1,0) para o café arábica.

Palavras-chave: Previsão; Modelos ARIMA; Commodities.

ABSTRACT

Brazil stands out as one of the main producers of agricultural commodities in the world, and its exports are responsible for a large portion of the national Gross Domestic Product (GDP). Within this context, the present work aims to adjust the best Autoregressive Integrated Moving Average (ARIMA) model for forecasting soybean, corn and arabica coffee prices, the main Brazilian agricultural exports. The goal is to assist producers and other agents of Brazilian agribusiness in decision-making and in their operational planning. Thus, the monthly historical series between March 2006 and November 2022 was used to predict the price of commodities in the future short term. According to the results, the models that best adapted to the predictions were an ARIMA (0,1,1) for soybean, an ARIMA (1,1,0) for corn, and an ARIMA (1,1,0) for arabica coffee.

Keywords: Forecast; ARIMA Models; Commodities.

Código JEL: C32, F17, Q13

INTRODUÇÃO

A injeção de capital estrangeiro proveniente de exportações possui grande relevância para países em desenvolvimento, sobretudo através de produtos agropecuários no caso brasileiro. De acordo com a base de dados Estatísticas de Comércio Exterior do Agronegócio Brasileiro (MAPA, 2022), essas exportações atingiram o valor de U\$120,5 bilhões em 2021, frente aos U\$ 49,4 bilhões em 2006. Economicamente, esses recursos são importantes para manter o fluxo de importação de bens de capital e de energia, capazes de incentivar e garantir o desenvolvimento econômico nacional (FAVRO; CALDARELLI; CAMARA, 2015).

Diante do dinâmico comércio internacional do século XXI, o Brasil se destaca como um dos principais produtores e exportadores do setor agropecuário. Sua qualificação ocorreu a partir do desenvolvimento econômico de países emergentes, o qual impulsionou o consumo e a demanda mundial por *commodities*, como as agrícolas. Ao longo dos anos, com o aumento da urbanização e da renda per capita desses países, surgiram novos hábitos alimentares por parte da população que deseja se distanciar do passado de escassez (ESCHER; WILKINSON, 2019). Assim, diante da nova configuração geral em demanda por alimentos e produtos primários, o Brasil tem utilizado cada vez mais das exportações do agronegócio como estratégia de inserção na economia internacional.

Conforme os dados do comércio exterior brasileiro, desde 2006, as exportações de soja, milho e café em grãos são as três que mais arrecadam dólares para o Brasil entre os produtos agrícolas, aqueles do reino vegetal conforme a Nomenclatura Comum do Mercosul (NCM). Juntos, em 2020, suas exportações corresponderam por 18,79% do valor geral obtido pelo país em exportações e 17,28% no ano seguinte; ou seja, quase um quinto da arrecadação, em um conjunto de aproximadamente oito mil produtos, vem de apenas três tipos de grãos (COMEX STAT, 2022).

Amplamente produzidos ao longo das regiões, as variações de produção, preços e faturamento dessas culturas geram reflexos diretos em outros setores e, indiretamente, na renda doméstica dos brasileiros, uma vez que o Produto Interno Bruto (PIB) agregado do agronegócio alcançou participação de 27,4% no PIB total do Brasil em 2021 (CEPEA, 2022). Assim, evidencia-se o papel significativo que os três produtos desempenham para o comércio internacional e a economia nacional, seja através da injeção de capital estrangeiro ou dos empregos e serviços gerados no mercado interno.

Considerando isto, o objetivo deste estudo é selecionar o modelo Autorregressivo Integrado e de Médias Móveis (ARIMA) para cada uma das culturas agrícolas supracitadas, conhecer seus comportamentos e projetar seus valores no curto prazo. Como resultado, o estudo visa auxiliar gestores públicos, investidores e produtores rurais quanto a decisões em planejamento das produções agropecuárias e nas comercializações dos seus produtos, a fim de maximizarem os lucros e minimizarem sua exposição ao risco.

O presente artigo está organizado, além desta introdução, em mais cinco seções. Na próxima, apresenta-se uma visão geral sobre a relação das *commodities* com o Brasil e o mercado. A terceira seção discorre sobre a importância da previsibilidade de preços e como ela está relacionada com o agronegócio. Na quarta, são apresentados os dados, a metodologia aplicada e seus procedimentos. A quinta seção expõe os modelos, as previsões das culturas agrícolas e uma perspectiva sobre os resultados. Por fim, a última seção apresenta as considerações finais e sugestões para pesquisas futuras.

AS COMMODITIES E O BRASIL

A soja é o produto de maior relevância para a economia brasileira, constituindo-se como a sua principal *commodity* agrícola produzida e exportada. Segundo Oliveira e Hecht (2016), a soja é um ícone do desenvolvimento rural e serve como elo para a produção de alimentos, ração animal e centenas de produtos industriais, se posicionando como uma questão internacional de segurança alimentar. A partir da década de 2010, o país se tornou o maior exportador e produtor do grão, ultrapassando os Estados Unidos da América (EUA) nos últimos anos em volume produzido da cultura, de acordo com o mais recente relatório publicado pelo Departamento de Agricultura dos Estados Unidos (USDA, 2022).

Sua produção está entre as atividades econômicas que apresentaram crescimento mais expressivo nas últimas quatro décadas em área plantada e produtividade. Como resultado do desenvolvimento e estruturação de um sólido mercado internacional, sua cadeia produtiva envolve grande número de instituições e atores organizacionais atualmente. Desse modo, a modernização da agricultura, a introdução de novas tecnologias e a mudança de mentalidade de gerenciamento por parte dos produtores foram capazes de impactar significativamente a agricultura brasileira em âmbito econômico, social, ambiental, tecnológico e, inclusive, político (HIRAKURI; LAZZAROTTO, 2014).

O milho, por sua vez, consolida-se atualmente como a segunda maior atividade agrícola brasileira, além de ser o cereal mais produzido no cenário mundial. Sua importância econômica encontra-se na sua diversidade, uma vez que é utilizado desde a alimentação animal e humana, até a indústria de alta tecnologia. Como grande parte da sua produção é destinada à cadeia produtiva de carnes no Brasil e nos países importadores, por ser um produto essencial na composição de ração e silagens de aves e suínos, o grão tem influência direta nos preços desses produtos (CAS, 2018; TIBULO; CARLI, 2014).

A segunda safra do milho tem aumentado consideravelmente em produção e área plantada a partir da safra 2011/12, conforme apontam séries históricas disponibilizadas pela Companhia Nacional de Abastecimento (CONAB, 2022). Com isso, o país começou a ter produção excedente e, portanto, aumentou o seu volume de exportações da cultura, configurando-se recentemente como o segundo maior exportador e terceiro maior produtor (FAVRO; CALDARELLI; CAMARA, 2015; USDA, 2022).

Já o café, ao contrário das duas culturas previamente citadas, foi introduzido no Brasil no período em que ainda era colônia de Portugal, e desde então caracteriza-se por sua importância social e econômica. Conforme Andrade et al. (2012) e corroborado por Rocha et al. (2015), o café tem participação expressiva na produção agrícola nacional e grande importância no âmbito social. Por apresentar dificuldade de mecanização em alguns aspectos, a cafeicultura brasileira é caracterizada como fixadora de mão de obra no meio rural e geradora de empregos, possibilitando grande distribuição de renda.

O café, portanto, possui participação relevante e significativa tanto para a economia brasileira quanto para o mercado externo. De acordo com dados históricos da Organização Internacional do Café (ICO, 2022), o Brasil é o seu maior produtor e exportador, com larga vantagem sobre as demais nações em ambas as categorias. Os tipos mais importantes são o café arábica e o café robusta, no qual o primeiro é mais apreciado pelas suas características sensoriais e comercializado com altos padrões de qualidade (especial e gourmet), enquanto o segundo apresenta maior rendimento, sendo consumido via *blend*. Em virtude da representatividade da variedade arábica no cenário internacional, esta *commodity* será analisada juntamente com soja e milho.

A PREVISIBILIDADE DE PREÇOS E O AGRONEGÓCIO

Consolidada como principal commodity exportada pelo Brasil, a soja é capaz de influenciar direta e indiretamente as atividades econômicas do país. Em razão disso, emprega-se ferramentas de previsibilidade capazes de administrar riscos de produção e comercialização, como o uso da metodologia Box-Jenkins por Felipe (2012). O autor analisou a série diária de preços de soja no Norte do Paraná, uma das maiores regiões produtoras do grão, para auxiliar produtores e empresários na comercialização da *commodity* ao buscar um modelo ARIMA adequado aos dados.

Exemplificando outra maneira de influência econômica, os resultados de Favro et al. (2015) sugerem que o preço da soja apresenta grande elasticidade de transmissão sobre as exportações de milho, de modo que um aumento no preço da oleaginosa é capaz de reduzir a área plantada do cereal, o que faz elevar o seu preço. Assim, conforme os autores, com a variação positiva no preço da soja, torna-se mais vantajoso exportar o milho. Essa conclusão expõe como a informação sobre preços futuros pode ser vantajosa para o produtor e lhe dá embasamento para tomadas de decisão também em outras atividades.

Sabendo da relação competitiva entre as produções das duas culturas, Kitworawut e Rungreunganun (2019) acrescentam que, além de saber os fatores que influenciam os preços do milho, é necessário entender a sua relação com eles. Por meio de um diagrama de árvore, os autores aplicaram diversos modelos de previsão ARIMA em outras variáveis para, ao fim, prever o preço do cereal por um modelo Box-Jenkins e comparar a performance com outros métodos. Similarmente, Cas (2018) lança mão do

modelo para prever o preço do milho no mercado brasileiro com o objetivo de demonstrar a tendência dos seus preços no curto prazo e auxiliar profissionais que o comercializam.

Destacando o papel social e econômico da cafeicultura em nível mundial, Silva (2018) emprega a metodologia Box-Jenkins para prever o preço do café arábica no Brasil. Conforme o autor, a antecipação de preços pode gerar uma série de benefícios aos agentes do setor, bem como servir de ferramenta de análise para auxiliar aqueles que trabalham com a compra e venda do grão. Por outro método, mas também buscando apoiar produtores e comercializadores em tomadas de decisões sobre investimentos de café, Carrasco-Gutierrez e Almeida (2013) desenvolveram um modelo econométrico capaz de prever o preço do grão no Brasil.

Outros trabalhos que utilizaram modelos de séries temporais ARIMA, a fim de realizar a previsão de preços de produtos agropecuários, foram Campos e Cordeiro (2006) para o frango congelado em São Paulo, Arêdes e Pereira (2008) para o trigo no Paraná, e Araújo et al. (2012) para o boi gordo no Rio de Janeiro. Os autores deixam claro que os modelos previstos podem ser usados como apoio às decisões gerenciais e estratégicas dos produtores, reduzindo os riscos das atividades e possibilitando maiores lucros.

Em geral, a agropecuária tem dificuldades no planejamento de produção e no abastecimento de mercados por depender de fatores instáveis, como meio ambiente, condições de oferta e demanda, tanto interna quanto externa, além dos fatores de comercialização. Para contornar este problema, a análise dos preços permite que se avalie com maior precisão o risco financeiro e a atividade rural em razão de flutuações desfavoráveis nos preços dos produtos e insumos. Desse modo, o produtor aloca melhor os recursos, eleva as margens de retorno de capital investido e diminui sua exposição ao risco (ARAÚJO; AREDES; SANTOS, 2012; ARÊDES; PEREIRA, 2008).

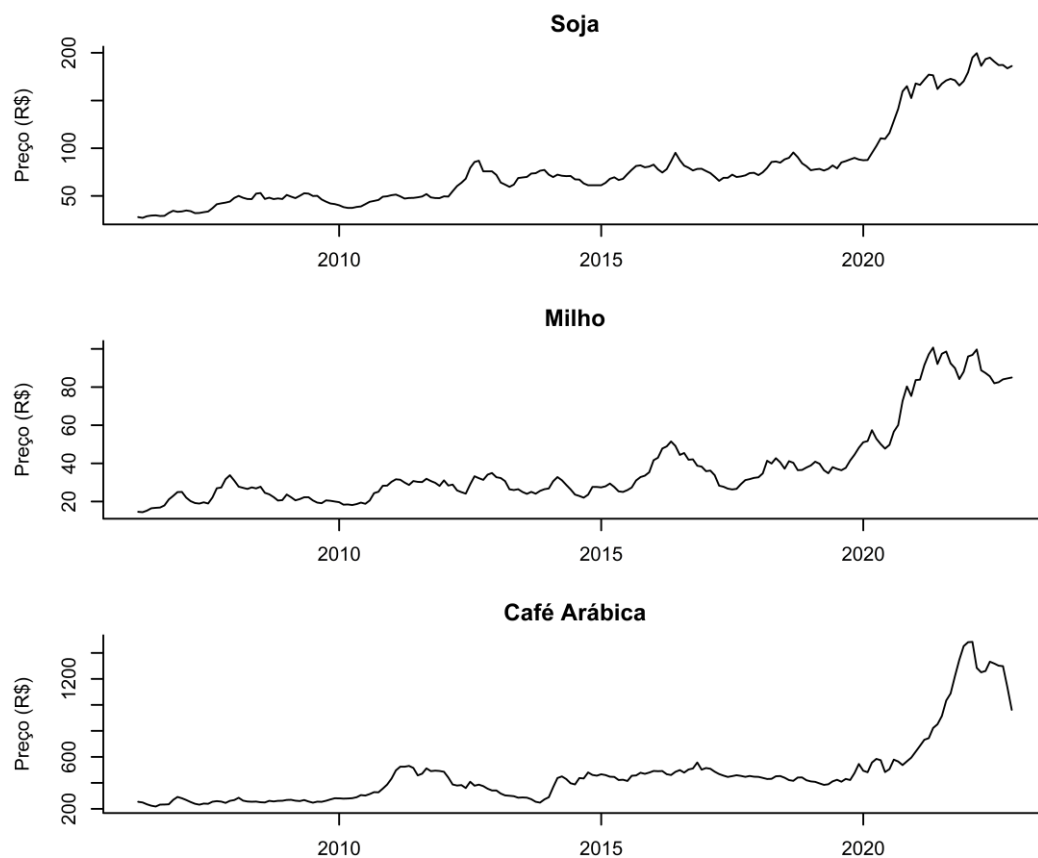
METODOLOGIA

Esta seção expõe quais foram os dados utilizados, como se caracterizam as séries temporais, o modelo a ser estimado e a metodologia empregada para a obtenção dos resultados.

Base de Dados

As informações de preços utilizadas foram obtidas do Centro de Estudos Avançados em Economia Aplicada (CEPEA), distribuídas entre março de 2006 e novembro de 2022, sendo a maior disponibilidade temporal disponível pela coleta de dados. A frequência foi definida como mensal pois se adapta melhor ao modelo conforme a literatura encontrada e porque os valores não apresentam tanta volatilidade entre si. A Figura 1 a seguir apresenta as séries históricas dos preços nominais dos grãos em sacas de 60 kg.

Figura 1: Séries históricas dos preços nominais



Fonte: Elaborado pelos autores.

Séries Temporais

Uma série temporal é o resultado de um conjunto de observações feitas sequencialmente ao longo do tempo. Sua característica mais importante é que observações adjacentes são dependentes uma das outras e, portanto, fatores que influenciaram a série no passado e atuam no presente continuarão a influenciá-la. Assim, identificando os fatores, é possível realizar previsões e beneficiar o gerenciamento das atividades (WOLFF et al., 2011).

Segundo Mendes e Padilha Junior (2007), as séries temporais são compostas por quatro itens e a sua análise baseia-se na determinação dos preços agropecuários, por meio de um componente evolutivo (tendência) e três oscilatórios (sazonalidade, ciclo e aleatoriedade). A tendência é um movimento sistemático e de longa duração, em que a introdução de novas tecnologias afeta a oferta e a educação e renda do consumidor afetam a demanda, por exemplo. A sazonalidade da série é consequência dos produtos, que tem maior oferta no período de safra. Já os ciclos são movimentos oscilatórios de longa duração, consequência das variações da oferta. A aleatoriedade, por fim, é um movimento de curta duração e sem repetição, um ruído intrínseco à variação dos dados.

Modelo

Proposta por Box e Jenkins (1976) e considerada como um importante método de previsão, a metodologia deste trabalho consiste em ajustar um modelo ARIMA para o conjunto de dados das *commodities*. Neste modelo, a série temporal é diferenciada até a sua estacionaridade e previsões sobre a variável dependente podem ser feitas através de seus valores passados e dos termos de erro estocástico.

Em Modelos Autorregressivos (AR), o valor de Y no período t depende do seu valor no período anterior e de um termo aleatório. Ou seja, o seu valor previsto equivale a uma proporção somada a um choque aleatório ou perturbação no período t , como:

$$(Y_t - \delta) = \alpha_1(Y_{t-1} - \delta) + \varepsilon_t \quad (1)$$

Onde δ equivale à média de Y e ε_t é um erro aleatório não correlacionado com média zero e variância constante; ou seja, um ruído branco. Assim, como temos uma defasagem da variável, Y_t segue um processo autorregressivo estocástico de primeira ordem, ou AR (1). Seu valor previsto é uma proporção (α_1) somada a um choque aleatório ou perturbação no período t . De modo geral, a ordem p -ésima AR (p) é descrita por:

$$(Y_t - \delta) = \alpha_1(Y_{t-1} - \delta) + \alpha_2(Y_{t-2} - \delta) + \dots + \alpha_p(Y_{t-p} - \delta) + \varepsilon_t \quad (2)$$

Já em modelos de Médias Móveis (MA), o valor de Y em t é igual a uma constante mais uma média móvel dos termos de erro atuais e passados. Nesse caso, a variável dependente segue um processo de média móvel de primeira ordem, ou MA (1), como segue:

$$Y_t = \mu + \beta_0\varepsilon_t + \beta_1\varepsilon_{t-1} \quad (3)$$

Em que μ é uma constante e ε_t , como evidenciado anteriormente, é o termo de erro estocástico de ruído branco. Genericamente, assumindo que se trata apenas de uma combinação linear de termos de ruído branco, temos a ordem q -ésima MA (q):

$$Y_t = \mu + \beta_0\varepsilon_t + \beta_1\varepsilon_{t-1} + \beta_2\varepsilon_{t-2} + \dots + \beta_q\varepsilon_{t-q} \quad (4)$$

Assim, quando Y possuir características de um processo autorregressivo e de médias móveis ao mesmo tempo, ela seguirá um processo ARMA. Em um processo AR (1) e MA (1), ele pode ser reescrito como ARMA (1,1), sendo o primeiro número a ordem do AR e o segundo, MA. Portanto, a equação fica como:

$$Y_t = \theta + \alpha_1Y_{t-1} + \beta_0\varepsilon_t + \beta_1\varepsilon_{t-1} \quad (5)$$

Logo, haverá p termos autorregressivos e q termos de média móvel em um processo ARMA (p, q). Assim, pode-se expressar o modelo da seguinte maneira:

$$Y_t = \theta + \alpha_1 Y_{t-1} + \alpha_2 Y_{t-2} + \dots + \alpha_p Y_{t-p} + \beta_0 \varepsilon_t + \beta_1 \varepsilon_{t-1} + \beta_2 \varepsilon_{t-2} + \dots + \beta_q \varepsilon_{t-q} \quad (6)$$

A metodologia Box-Jenkins, quando utilizada para a previsão, exige que a série empregada seja estacionária, pois é preciso assumir que suas características são constantes ao longo do tempo e, conseqüentemente, assim serão no tempo futuro. Contudo, a maioria dos casos é não estacionária, ou seja, apresenta média e variância condicionadas pelo tempo. Para esses casos, é necessário diferenciá-las sucessivas vezes até a sua estacionaridade (GUJARATI; PORTER, 2011; TIBULO; CARLI, 2014).

Caso faça-se necessário diferenciar uma série temporal d vezes, a fim de torná-la estacionária e poder aplicar o modelo ARMA (p, q) , diz-se que se trata de uma série temporal Autorregressiva Integrada de Médias Móveis, ou ARIMA (p, d, q) . Neste modelo, p representa o número de termos autorregressivos, d significa o número de vezes que a série precisa ser diferenciada antes de se tornar estacionária e q refere-se ao número de termos de média móvel (GUJARATI; PORTER, 2011).

Quando a variável Y_t não é estacionária, determina-se uma nova variável Z_t como sendo a primeira diferença de Y_t . A primeira diferenciação é dada por:

$$Z_t = \Delta Y_t = Y_t - Y_{t-1} \quad (7)$$

Se a variável Y_t não é estacionária, mas Z_t é, diz-se que Y_t é integrada de ordem 1, ou I (1). Como nem sempre a primeira diferença é suficiente para transformar a série em estacionária, toma-se a segunda diferença e ela será integrada de ordem 2, ou I (2). No entanto, se Y_t não é estacionária, mas a sua d -ésima diferença é, a variável é classificada como I (d). Assim, sua equação genérica pode ser expressa como:

$$Z_t = \Delta^d Y_t = \Delta^{d-1} Y_t \quad (8)$$

Se essa variável Z_t seguir um processo ARMA (p, q) , de forma como segue:

$$Z_t = \theta + \alpha_1 Z_{t-1} + \alpha_2 Z_{t-2} + \dots + \alpha_p Z_{t-p} + \beta_0 \varepsilon_t + \beta_1 \varepsilon_{t-1} + \beta_2 \varepsilon_{t-2} + \dots + \beta_q \varepsilon_{t-q} \quad (9)$$

Então, conseqüentemente, Y_t segue um processo ARIMA (p, d, q) , em que a letra I e o número d referem-se à ordem de integração. Assim, a sua d -ésima diferença segue um processo combinado autorregressivo e de médias móveis, onde α e β são os coeficientes e p e q são as ordens dos respectivos polinômios:

$$\Delta^d Y_t = \theta + \alpha_1 \Delta^d Y_{t-1} + \alpha_2 \Delta^d Y_{t-2} + \dots + \alpha_p \Delta^d Y_{t-p} + \beta_0 \varepsilon_t + \beta_1 \varepsilon_{t-1} + \beta_2 \varepsilon_{t-2} + \dots + \beta_q \varepsilon_{t-q} \quad (10)$$


No entanto, é difícil identificar qual processo uma série temporal segue apenas observando-a. Em razão disso, a metodologia Box-Jenkins foi criada para lançar luz sobre essa questão. A primeira etapa consiste em uma escolha provisória dos valores de p, d e q . Em seguida, estimam-se os

parâmetros dos termos autorregressivos e dos termos de médias móveis através do método dos mínimos quadrados ou por estimativa não linear. Assim, confirmando-se que o modelo está corretamente ajustado aos dados e que os resíduos presentes no modelo são classificados como ruído branco, o modelo pode ser utilizado para realizar previsões acerca da série temporal (ARAUJO; AREDES; SANTOS, 2012).

RESULTADOS E DISCUSSÃO

Uma vez que as séries históricas fornecem o preço nominal dos bens, ou seja, aqueles não ajustados à inflação, torna-se necessário trazê-los ao seu valor real e adequado à evolução dos preços da economia. Uma vez que a inflação distorce os dados das séries históricas, este procedimento é essencial para a análise estatística. Os preços foram deflacionados com base no Índice Nacional de Preços ao Consumidor Amplo (IPCA), pelo número índice correspondente de cada mês e atualizados para o mês de novembro de 2022, possibilitando a comparação entre os preços ao longo do período, conforme a Figura 2.

Figura 2: Séries históricas referentes aos preços reais da soja, do milho e do café arábica



Fonte: Elaborado pelos autores.

De acordo com as séries, podemos notar que soja e milho seguem uma configuração similar, visto que compartilham de finalidades semelhantes, como extração de óleo vegetal e a incorporação de seus farelos na alimentação animal. O café arábica não acompanha os movimentos oscilatórios dos outros grãos analisados, mas percebe-se que todas as *commodities* do estudo têm seus valores máximos nas safras de 2021. Esta tendência expressiva e recente de alta nos preços tem influência principalmente da pandemia de COVID-19 e seus reflexos nos mercados financeiros, nas taxas de câmbio, atrasos em logísticas, e níveis de oferta e demanda internacional.

Para compreender a dinâmica dos preços, a Tabela 1 apresenta algumas estatísticas descritivas das culturas durante o período analisado. Entre os dados, destaca-se principalmente os maiores valores do café arábica em relação às outras duas.

Tabela 1: Estatísticas descritivas das séries históricas (preço real)

	Soja	Milho	Café Arábica
Média	R\$ 115,48	R\$ 56,36	R\$ 700,05
Desvio Padrão	R\$ 32,86	R\$ 17,56	R\$ 217,40
Máximo	R\$ 203,34	R\$ 112,91	R\$ 1.550,32
Mínimo	R\$ 67,46	R\$ 34,97	R\$ 421,61

Fonte: Elaborado pelos autores.

O maior preço médio observado para o café arábica pode ser atribuído ao consumo crescente ao redor do mundo (ICO, 2022) e à dificuldade nos tratos da cultura, como a especificidade de altitude e localizações geográficas que ela exige. Além disso, estão cada vez maiores os cuidados com a qualidade do grão durante os processos agroindustriais até chegar ao consumidor final, o qual vem mudando seu perfil de consumo ao longo dos últimos anos (TAVARES, 2002).

Para dar início às previsões, verifica-se a presença de raiz unitária nas séries das *commodities* a fim de averiguar a estacionariedade delas ao longo do tempo. No teste Dickey-Fuller Aumentado, proposto por Dickey e Fuller (1981), se a série apresentar τ calculado maior em módulo que o τ tabelado, a série é dita estacionária. São incluídos tendência e intercepto nos testes caso se apresentem significativos e os resultados estão dispostos na Tabela 2.

Tabela 2: Testes Dickey-Fuller Aumentado de raiz unitária

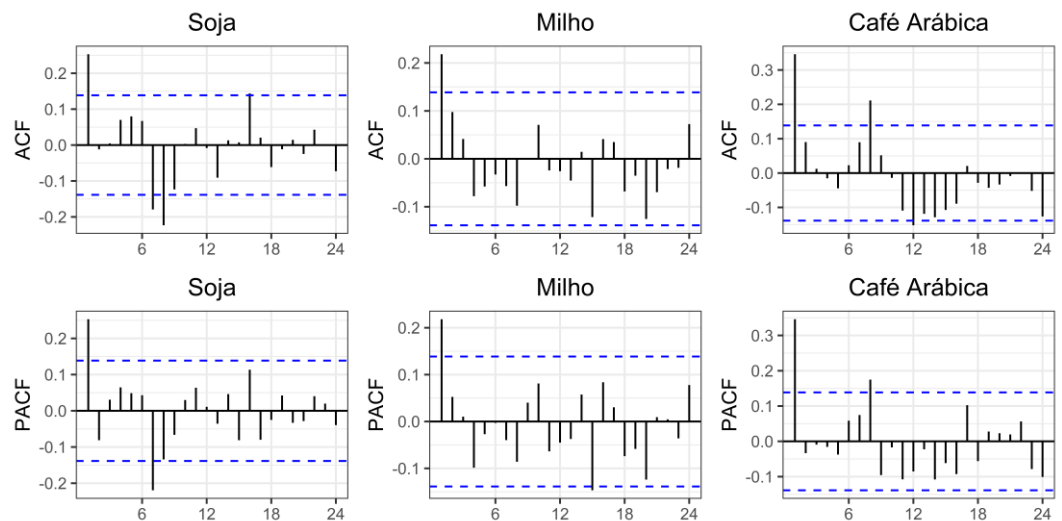
Descrição	Tend.	Int.	Lags	Dif.	τ calc.	τ 1%	τ 5%	τ 10%
Soja	Sim*	Sim*	1	0	-2,15	-3,99	-3,43	-3,13
Soja	Não	Não	1	1	-9,19	-2,58	-1,95	-1,62
Milho	Não	Sim**	1	0	-1,97	-3,46	-2,88	-2,57
Milho	Não	Não	1	1	-8,28	-2,58	-1,95	-1,62
Café A.	Não	Sim**	1	0	-2,29	-3,46	-2,88	-2,57
Café A.	Não	Não	1	1	-7,34	-2,58	-1,95	-1,62

Nota: * significativo a 10%, ** significativo a 5%

Fonte: Elaborado pelos autores.

De acordo com os testes ADF realizados, sabe-se que as três séries possuem $d = 1$ em seus modelos, em razão da presença de raiz unitária. Em seguida, para definir quais os melhores modelos, realiza-se uma análise prévia dos gráficos de função de autocorrelação (ACF) e função de autocorrelação parcial (PACF) das séries das *commodities*, estabelecendo limites e predeterminar valores de p e q . Na Figura 3 estão dispostos os gráficos das funções para as três culturas estabelecendo 24 defasagens.

Figura 3: Gráficos de Funções de Autocorrelação e Função de Autocorrelação Parcial



Fonte: Elaborado pelos autores.

Em vista do comportamento senoidal do gráfico PACF da soja, os dados diferenciados indicam um padrão de modelo ARIMA $(0, d, q)$. Como este desempenho não é observado por milho e café, os quais apresentam um pico significativo na primeira defasagem e nenhum outro além, sugere-se um modelo ARIMA $(p, d, 0)$ para estas *commodities*. Ao testar a possibilidade de os produtos seguirem modelos ARIMA $(p, d, q)(P, D, Q)$, ou ARIMA sazonal, o teste de Osborn, Chui, Smith, e Birchenhall não

captou a presença de sazonalidade nos dados, indicando se tratar de um modelo ARIMA usual.

Assim, para definir o modelo, optou-se pelo Critério de Informação Bayesiano de Schwarz (BIC) como parâmetro, de modo que o menor resultado indica o melhor ajuste aos dados. Ademais, aplicou-se o teste Ljung-Box para verificar o comportamento dos resíduos dos modelos. Um alto p -valor nesse teste indica que os resíduos se comportam como ruído branco, o que mostra ser um bom ajuste do modelo selecionado. Assim, utilizando os gráficos ACF e PACF como ponto de partida para análises, a Tabela 3 apresenta os modelos apurados para cada uma das *commodities*.

Tabela 3: Modelos ARIMA

<i>Commodity</i>	Modelo ARIMA	BIC	Ljung-Box p -valor
Soja	ARIMA (0,1,0)	1.301,34	0,004
	ARIMA (0,1,1)	1.291,51	0,185
	ARIMA (0,1,2)	1.296,81	0,149
	ARIMA (0,1,3)	1.302,04	0,132
	ARIMA (1,1,0)	1.292,74	0,117
	ARIMA (2,1,0)	1.296,88	0,170
	ARIMA (1,1,1)	1.296,81	0,149
	ARIMA (1,1,2)	1.298,73	0,198
	ARIMA (2,1,1)	1.302,07	0,126
	ARIMA (2,1,2)	1.304,76	0,187
Milho	ARIMA (0,1,0)	1.142,86	0,184
	ARIMA (0,1,1)	1.139,42	0,584
	ARIMA (0,1,2)	1.143,33	0,595
	ARIMA (1,1,0)	1.138,21	0,634
	ARIMA (2,1,0)	1.142,92	0,620
	ARIMA (3,1,0)	1.148,19	0,565
	ARIMA (1,1,1)	1.142,99	0,615
	ARIMA (1,1,2)	1.148,14	0,567
	ARIMA (2,1,1)	1.148,21	0,561
ARIMA (2,1,2)	1.152,10	0,576	
Café Arábica	ARIMA (0,1,0)	2.115,74	0,000
	ARIMA (0,1,1)	2.096,14	0,113
	ARIMA (0,1,2)	2.098,73	0,241
	ARIMA (1,1,0)	2.093,36	0,277
	ARIMA (2,1,0)	2.098,62	0,230
	ARIMA (3,1,0)	2.103,85	0,201
	ARIMA (1,1,1)	2.098,62	0,229
	ARIMA (1,1,2)	2.103,87	0,197
ARIMA (2,1,1)	2.103,87	0,193	
ARIMA (2,1,2)	2.109,17	0,158	

Fonte: Elaborado pelos autores.

A partir das escolhas dos modelos, realizou-se a previsão para os doze meses subsequentes, ou seja, até novembro de 2023. Na Tabela 4 estão as projeções de preço de comercialização da soja que o modelo ARIMA (0,1,1) retornou, bem como os preços nos limites de confiança.

Tabela 4: Previsão do preço de comercialização da soja (R\$)

Período	Limite Inferior		Projeção	Limite Superior	
	95%	80%		80%	95%
Dezembro 2022	175,29	179,34	186,98	194,62	198,67
Janeiro 2023	168,00	174,57	186,98	199,39	205,96
Fevereiro 2023	162,82	171,18	186,98	202,78	211,14
Março 2023	158,57	168,40	186,98	205,56	215,39
Abril 2023	154,87	165,99	186,98	207,97	219,09
Mai 2023	151,56	163,82	186,98	210,14	222,40
Junho 2023	148,54	161,84	186,98	212,12	225,42
Julho 2023	145,73	160,01	186,98	213,95	228,23
Agosto 2023	143,10	158,29	186,98	215,67	230,86
Setembro 2023	140,63	156,67	186,98	217,29	233,33
Outubro 2023	138,28	155,13	186,98	218,83	235,68
Novembro 2023	136,03	153,67	186,98	220,29	237,93
Média	151,95	164,08	186,98	209,88	222,01

Fonte: Elaborado pelos autores.

Pelos resultados, percebe-se que o modelo projeta a prolongação dos preços de soja em alto nível. Já as projeções na Tabela 5 são para os preços do milho, a partir do modelo ARIMA (1,1,0).

Tabela 5: Previsão do preço de comercialização do milho (R\$)

Período	Limite Inferior		Projeção	Limite Superior	
	95%	80%		80%	95%
Dezembro 2022	77,05	79,81	85,01	90,22	92,98
Janeiro 2023	72,45	76,80	85,02	93,24	97,59
Fevereiro 2023	68,90	74,48	85,02	95,57	101,15
Março 2023	65,95	72,55	85,02	97,49	104,10
Abril 2023	63,39	70,88	85,02	99,17	106,65
Mai 2023	61,10	69,38	85,02	100,66	108,94
Junho 2023	59,01	68,02	85,02	102,03	111,03
Julho 2023	57,08	66,75	85,02	103,29	112,96
Agosto 2023	55,27	65,57	85,02	104,47	114,77
Setembro 2023	53,57	64,46	85,02	105,59	116,48
Outubro 2023	51,95	63,40	85,02	106,64	118,09
Novembro 2023	50,41	62,39	85,02	107,65	119,63
Média	61,34	69,54	85,02	100,50	108,70

Fonte: Elaborado pelos autores.

Da mesma maneira que para a soja, os resultados para os preços de milho também retornaram pela manutenção dos preços em elevação nos meses seguintes. Por último, o modelo ARIMA (1,1,0) retornou na Tabela 6 as projeções de preço para o café arábica.

Tabela 6: Previsão do preço de comercialização do café arábica (R\$)

Período	Limite Inferior		Projeção	Limite Superior	
	95%	80%		80%	95%
Dezembro 2022	809,28	839,30	896,03	952,75	982,78
Janeiro 2023	724,13	775,11	871,41	967,71	1.018,69
Fevereiro 2023	665,13	733,36	862,25	991,14	1.059,37
Março 2023	619,66	702,45	858,85	1.015,25	1.098,04
Abril 2023	581,87	677,30	857,58	1.037,86	1.133,30
Mai 2023	548,89	655,58	857,11	1.058,64	1.165,33
Junho 2023	519,24	636,13	856,94	1.077,74	1.194,63
Julho 2023	492,04	618,32	856,87	1.095,42	1.221,70
Agosto 2023	466,75	601,77	856,85	1.111,92	1.246,94
Setembro 2023	443,01	586,25	856,84	1.127,42	1.270,67
Outubro 2023	420,56	571,57	856,83	1.142,10	1.293,10
Novembro 2023	399,22	557,62	856,83	1.156,05	1.314,45
Média	557,48	662,90	862,03	1.061,17	1.166,58

Fonte: Elaborado pelos autores.

Diferentemente das duas primeiras *commodities*, os resultados do modelo escolhido para prever os preços do café arábica indicam queda nos meses subsequentes. Como já mencionado, através da previsão de preços, é possível avaliar com maior precisão o retorno da atividade rural e seu risco, bem como reduzir incertezas e melhorar o processo de organização da comercialização. A partir desses resultados, gestores públicos, investidores e, principalmente, produtores rurais brasileiros dispõem de mais uma ferramenta para auxiliá-los em tomadas de decisões e em seus planejamentos operacionais.

CONCLUSÕES

O presente estudo teve como principal objetivo ajustar o melhor modelo Autorregressivo Integrado de Médias Móveis para a previsão dos preços de soja, milho e café arábica no curto prazo. Dessa forma, espera-se que este trabalho dê suporte aos produtores e demais agentes do agronegócio, ao exemplo de cooperativas e investidores, em seus processos de tomadas de decisões e em seus planejamentos operacionais.

De acordo com os resultados, os modelos ARIMA mostraram-se eficientes para realizar previsões para as séries de preços compreendidas entre março de 2006 e novembro de 2022, bem como para prever seus preços no curto prazo. Com base nos Critérios de Informação Bayesiano de Schwarz (BIC) e dos testes Ljung-Box sobre os resíduos que cada modelo testado retornou,

os escolhidos para a previsão do preço de soja, milho e café arábica, entre dezembro de 2022 e novembro de 2023 foram, nessa ordem, ARIMA (0,1,1), ARIMA (1,1,0), e ARIMA (1,1,0).

Apesar da modelagem ARIMA ter reproduzido resultados metodologicamente adequados de previsão, recomenda-se para futuras pesquisas a utilização de variáveis exógenas, a fim de aprimorar as estimativas das previsões de preços. Desse modo, seria interessante a visualização de como as variações dos preços e das produções agrícolas de outros países influenciariam nos preços brasileiros. A utilização de outros modelos, como *Auto-Regressive Integrated with Moving Average and Exogenous inputs* (ARIMAX), Heterocedasticidade Condicional Auto-Regressiva (ARCH) e Vetor Auto-Regressivo (VAR), também podem ser alternativas indicadas para a previsão de preços destas culturas.

REFERÊNCIAS

- ANDRADE, Fabrício Teixeira de; CASTRO JUNIOR, Luiz Gonzaga; COSTA, Cássio Henrique Garcia. Avaliação da cafeicultura pela abordagem do custeio variável em propriedades nas principais regiões produtoras do Brasil. **Organizações Rurais & Agroindustriais**, v. 14, n. 3, p. 356-366, 2012. Disponível em: <https://www.redalyc.org/articulo.oa?id=87825497005>.
- ARAUJO, Saulo Jardim de; AREDES, Alan Figueiredo de; SANTOS, Vladimir Faria dos. Previsão de preços do boi gordo com modelos ARIMA e SARIMA. **Revista de Economia**, v. 8, n. 2, p. 27-44, 2012.
- ARÊDES, Alan Figueiredo de; PEREIRA, Matheus Wemerson Gomes. Potencialidade da utilização de modelos de séries temporais na previsão do preço do trigo no estado do Paraná. **Revista de Economia Agrícola**, v. 55, n. 1, p. 63-76, 2008.
- BOX, George P.; JENKINS, Gwilym M. **Time series analysis, forecasting and control**. San Francisco: Ed. HoldenDay, 1976.
- CAMPOS, P. A. C.; CORDEIRO, A. A. L. de. Aplicação do modelo ARIMA para previsão do preço do frango inteiro resfriado no grande atacado do estado de São Paulo. *In: XIII CONGRESSO BRASILEIRO DE CUSTOS*. Belo Horizonte - MG, 2006.
- CARRASCO-GUTIERREZ, Carlos Enrique; ALMEIDA, Fernanda Matos de Moura. Modelagem e Previsão do Preço do Café Brasileiro. **Revista de Economia**, v. 39, n. 2, p. 7-27, 2013. Disponível em: <http://dx.doi.org/10.5380/re.v39i2.23476>. Acesso em: 7 nov. 2019.
- CAS, Carlos Gonçalves. Aplicação do modelo ARIMA para previsão do preço da commodity milho. **Revista Gestão da Produção Operações e Sistema**, v. 13, n. 1, p. 263-279, 2018. Disponível em: <https://doi.org/10.15675/gepros.v13i1.2040>. Acesso em: 7 nov. 2019.

CONAB. **Companhia Nacional do Abastecimento - Série Histórica das Safras**. Disponível em: <http://www.conab.gov.br/info-agro/safras/serie-historica-das-safras>. Acesso em: 11 abr. 2022.

CEPEA. **PIB-Agro/CEPEA: PIB do agro cresce 8,36% em 2021; participação no PIB brasileiro chega a 27,4%**. Centro de Estudos Avançados em Economia Aplicada - CEPEA-Esalq/USP. Disponível em: <https://www.cepea.esalq.usp.br/br/pib-agro-cepea-pib-do-agro-cresce-8-36-em-2021-participacao-no-pib-brasileiro-chega-a-27-4.aspx>. Acesso em: 1 ago. 2022. Publisher: Imagenet Tecnologia.

COMEX STAT. **Comex Stat**. Disponível em: <http://comexstat.mdic.gov.br/pt/home>. Acesso em: 1 ago. 2022.

ESCHER, Fabiano; WILKINSON, John. A economia política do complexo Soja-Carne Brasil-China. **Revista de Economia e Sociologia Rural**, v. 57, n. 4, p. 656-678, 2019. Disponível em: <https://doi.org/10.1590/1806-9479.2019.191017>. Acesso em: 29 abr. 2022.

FAVRO, Jackelline; CALDARELLI, Carlos Eduardo; CAMARA, Marcia Regina Gabardo da. Modelo de Análise da Oferta de Exportação de Milho Brasileira: 2001 a 2012. **Revista de Economia e Sociologia Rural**, v. 53, n. 3, p. 455-476, 2015. Disponível em: <https://doi.org/10.1590/1234-56781806-9479005303005>. Acesso em: 15 nov. 2019.

FELIPE, Israel José dos Santos. Aplicação de modelos ARIMA em séries de preços de soja no Norte do Paraná. **Tekhne e Logos**, v. 3, n. 3, p. 16-32, 2012.

GUJARATI, Damodar N; PORTER, Dawn C. **Econometria Básica**. 5. ed. São Paulo: AMGH Editora, 2011.

HIRAKURI, Marcelo Hiroshi; LAZZAROTTO, Joelsio José. O Agronegócio da Soja nos Contextos Mundial e Brasileiro. 2014. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/104753/1/O-agronegocio-da-soja-nos-contextos-mundial-e-brasileiro.pdf>. Acesso em: 9 ago. 2018.

ICO. **International Coffee Organization - Historical Data on the Global Coffee Trade**. Disponível em: https://www.ico.org/new_historical.asp. Acesso em: 11 abr. 2022.

KITWORAWUT, Paibool; RUNGREUNGANUN, Vichai. Corn Price Modeling and Forecasting Using Box-Jenkins Model. **Applied Science and Engineering Progress**, 2019. Disponível em: <http://dx.doi.org/10.14416/j.asep.2019.02.007>. Acesso em: 6 dez. 2022.

MAPA. **Indicadores Ministério da Agricultura, Pecuária e Abastecimento**. Disponível em: <https://indicadores.agricultura.gov.br/agrostat/index.htm>. Acesso em: 25 abr. 2022.

MENDES, Judas Tadeu Grassi; PADILHA JUNIOR, João Batista. **Agronegócio: uma abordagem econômica**. São Paulo: Pearson Prentice Hall, 2007.

OLIVEIRA, Gustavo; HECHT, Susanna. Sacred groves, sacrifice zones and soy production: globalization, intensification and neo-nature in South America. **The Journal of Peasant Studies**, v. 43, n. 2, p. 251–285, 2016. Disponível em: <https://doi.org/10.1080/03066150.2016.1146705>. Acesso em: 22 jul. 2018.

ROCHA, Luiz Célio Souza; CARVALHO, Leonardo Alves; ROTELA JUNIOR, Paulo; *et al.* Previsão da cotação do Café Arábica Tipo 6 utilizando o modelo de previsão ARIMA. **Produção em Foco**, v. 05, n. 1, p. 170–186, 2015. Disponível em: <https://doi.org/10.14521/P2237-5163201500070009>. Acesso em: 7 nov. 2019.

SILVA, Carlos Alberto Gonçalves da. Previsão do preço da commodity café arábica: uma aplicação da metodologia Box-Jenkins. **Revista ESPACIOS**, v. 39, n. 4, p. 18, 2018.

TAVARES, Estela Lutero Alves. *A Questão do Café Commodity e sua Precificação: o “C Market” e a Classificação, Remuneração e Qualidade do Café*. 2002. 225f. Tese (Doutorado em Engenharia Agrícola) – Planejamento e Desenvolvimento Rural, Universidade Estadual de Campinas, Campinas – SP.

TIBULO, C.; CARLI, V. Previsão do preço do milho, através de séries temporais. **Scientia Plena**, v. 10, n. 10, p. 10, 2014.

USDA. **World Agricultural Production | United States Department of Agriculture**. Disponível em: <https://www.fas.usda.gov/data/world-agricultural-production>. Acesso em: 11 abr. 2022a.

USDA. **Grain: World Markets and Trade | United States Department of Agriculture**. Disponível em: <https://www.fas.usda.gov/data/grain-world-markets-and-trade>. Acesso em: 11 abr. 2022b.

WOLFF, Laion; ALMEIDA, Silvana Gonçalves de; ZANINI, Roselaine Ruviano; *et al.* Análise do Índice Bovespa sob enfoque de séries temporais. **Revista Global Manager**, v. 1, p. 1–11, 2011. Disponível em: <https://ojs.fsg.edu.br/index.php/global/article/view/6>. Acesso em: 6 nov. 2019