



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE ECONOMIA AGRÍCOLA
CURSO DE AGRONOMIA

VALESCA FARIAS FEITOSA

IMPACTO DAS ENCHENTES NO RIO GRANDE DO SUL NO PREÇO DO ARROZ
EM 2024

FORTALEZA
2025

VALESCA FARIAS FEITOSA

IMPACTO DAS ENCHENTES NO RIO GRANDE DO SUL NO PREÇO DO ARROZ EM
2024

Monografia apresentada ao curso de Graduação em Agronomia, do Centro de Ciências Agrárias da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Engenheiro(a) Agrônomo(a).

Orientador: Prof. Dr. Vitor Hugo Miro Couto Silva.

Coorientador: Ms. Ivan de Oliveira Holanda Filho.

FORTALEZA

2025

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

F336i Feitosa, Valesca Farias.
Impacto das enchentes no Rio Grande do Sul no preço do arroz em 2024 / Valesca Farias Feitosa. – 2025.
38 f.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Curso de Agronomia, Fortaleza, 2025.

Orientação: Prof. Dr. Vitor Hugo Miro Couto Silva.

Coorientação: Prof. Me. Ivan de Oliveira Holanda Filho.

1. Arroz. 2. Previsão de preços. 3. Holt-winters. I. Título.

CDD 630

VALESCA FARIAS FEITOSA

IMPACTO DAS ENCHENTES NO RIO GRANDE DO SUL NO PREÇO DO ARROZ EM
2024

Monografia apresentada ao curso de Graduação em Agronomia, do Centro de Ciências Agrárias da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Engenheiro(a) Agrônomo(a).

Aprovada em: 18/02/2025.

BANCA EXAMINADORA

Prof. Dr. Vitor Hugo Miro Couto Silva (Orientador)
Universidade Federal do Ceará (UFC)

Ms. Ivan de Oliveira Holanda Filho (Coorientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Francisco José Silva Tabosa
Universidade Federal do Ceará (UFC)

Prof. Ms. Willy Farias Albuquerque
Universidade do Estado do Rio Grande do Norte (UERN)

Dedico este trabalho a Deus e à minha família,
pelo apoio incondicional.

AGRADECIMENTOS

Agradeço a Deus por me confortar em momentos em que o impossível se fez acontecer. A minha querida família, sempre ao meu lado, em especial aos meus pais, Valéria e Renato, e minhas irmãs Nathália, Vanessa e Valerri, por trazer alegria em dias difíceis.

Aos meus amigos Vinícius e Raylane, que me acompanham desde o início da minha jornada na universidade, mesmo que longe, por apoiar minhas ideias, por mais que absurdas, pela inspiração de suas mentes brilhantes, e pelas boas energias.

Agradeço a todos os professores que me orientaram ao longo do curso na universidade, em especial ao Prof. Dr. Vitor Hugo Miro Couto Silva, sempre dedicado e atencioso, pelo auxílio na construção deste trabalho.

Aos meus amigos Alice, Bianca, Marcela, Marcia, Rafael, por toda a paciência e parceria.

À Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (Funcap), pelo apoio financeiro durante o desenvolvimento deste trabalho.

Aos participantes da banca examinadora Vitor Hugo Miro Couto Silva, Ivan de Oliveira Holanda Filho, Francisco José Silva Tabosa e Willy Farias Albuquerque pelo tempo disponibilizado, paciência, e valiosas colaborações e sugestões no trabalho.

RESUMO

O arroz é um alimento essencial na dieta brasileira e sua precificação está sujeita a fatores como oferta, demanda e eventos climáticos. Em 2024, uma catástrofe climática no Rio Grande do Sul, Estado que concentra cerca de 70% da produção de arroz do país, impactou significativamente a produção e os preços do grão, e demonstrou fundamental a análise dos efeitos desse evento sobre o mercado. Este estudo avalia a dinâmica dos preços do arroz por meio da aplicação de modelos estatísticos, como regressão linear e suavização exponencial de Holt-Winters, buscando compreender a magnitude do impacto climático sobre os preços. A pesquisa utilizou dados históricos de preços corrigidos pelo IGP-M entre 2005 e 2024. Os resultados indicam que o evento climático elevou os preços acima da média histórica, com um impacto médio de R\$3,14/saca entre abril e dezembro de 2024, atingindo R\$7,46/saca nos meses mais afetados. O modelo Holt-Winters apresentou um erro médio absoluto (MAE) de 8,02 e um erro quadrático médio (RMSE) de 9,26, demonstrando precisão moderada na previsão dos preços. O estudo destaca a importância de previsões precisas para auxiliar produtores em tomadas de decisão, subsidiar políticas públicas e auxiliar na mitigação de impactos econômicos decorrentes de eventos climáticos.

Palavras-chave: arroz; previsão de preços; Holt-Winters.

ABSTRACT

Rice is an essential food in the Brazilian diet, and its pricing is influenced by factors such as supply, demand, and climate events. In 2024, a climate catastrophe in Rio Grande do Sul, the state responsible for approximately 70% of the country's rice production, significantly impacted production and grain prices, highlighting the need to analyze the effects of such events on the market. This study evaluates rice price dynamics through the application of statistical models, such as linear regression and Holt-Winters exponential smoothing, aiming to understand the magnitude of the climate impact on prices. The research used historical price data adjusted by the IGP-M index from 2005 to 2024. The results indicate that the climate event raised prices above the historical average, with an average impact of R\$3.14 per sack between April and December 2024, reaching R\$7.46 per sack in the most affected months. The Holt-Winters model presented a Mean Absolute Error (MAE) of 8.02 and a Root Mean Squared Error (RMSE) of 9.26, demonstrating moderate accuracy in price forecasting. The study emphasizes the importance of accurate predictions to assist producers in decision-making, support public policies, and help mitigate the economic impacts of climate events.

Keywords: rice; price forecasting; Holt-Winters.

LISTA DE FIGURAS

Figura 1 – Impacto de um choque de oferta no equilíbrio de mercado	17
Figura 2 – Decomposição da série temporal	31

LISTA DE GRÁFICOS

Gráfico 1 – Evolução dos preços nominais e reais do arroz (R\$/saca) entre julho de 2005 e dezembro de 2024.....	29
Gráfico 2 – Distribuição dos preços do arroz entre os meses	30
Gráfico 3 – Evolução dos preços observados para treino, teste e previsão	33

LISTA DE TABELAS

Tabela 1 – Estatísticas mensais de preços do arroz	30
Tabela 2 – Resultados da análise de regressão com dummies mensais	32

LISTA DE ABREVIATURAS E SIGLAS

CDO	Cooperação e Defesa da Orizicultura
CEPEA	Centro de Estudos Avançados em Economia Aplicada
CESSR	Contribuição do Empregador Rural para Seguridade Social
Conab	Companhia Nacional de Abastecimento
DAP	Declaração de Aptidão ao Pronaf
ESALQ	Escola Superior de Agricultura Luiz de Queiroz
Fealq	Fundação de Estudos Agrários Luiz de Queiroz
FIERGS	Federação das Indústrias do Estado do Rio Grande do Sul
FGV	Fundação Getúlio Vargas
IBGE	Instituto Brasileiro de Geografia e Estatística
IBRE	Instituto Brasileiro de Economia
IGP-M	Índice Geral de Preços – Mercado
IRGA	Instituto Rio Grandense do Arroz
ITU	Índice de Temperatura e Umidade
MAE	Erro Absoluto Médio
MDA	Ministério do Desenvolvimento Agrário
MDS	Ministério do Desenvolvimento Social
MQO	Método de Mínimos Quadrados Ordinários
MSE	Erro Quadrático Médio
Proagro	Programa de Garantia da Atividade Agropecuária
RMSE	Root Mean Squared Error (Raiz do Erro Quadrático Médio)
Sada	Secretaria da Assistência Técnica e Defesa Agropecuária
SVM	Support Vector Machine
USP	Universidade de São Paulo

LISTA DE SÍMBOLOS

% – Porcentagem

R\$ – Reais

SUMÁRIO

1	INTRODUÇÃO	13
2	REFERENCIAL TEÓRICO	14
2.1	Análise de preços agrícolas	14
2.2	Influência do Clima	16
3	METODOLOGIA	18
3.1	Fonte de dados e ferramentas de análise	18
3.2	Análise de séries temporais	19
3.3	Método de regressão linear	20
3.4	Método de suavização exponencial	21
3.5	Medidas de ajuste e desempenho preditivo dos modelos	25
4	RESULTADOS E DISCUSSÕES	26
4.1	Movimentos recentes do preço do arroz	26
4.2	Análise exploratória dos dados	27
4.3	Modelando os preços com regressão linear	30
4.4	Previsão com o modelo de suavização exponencial	31
5	CONSIDERAÇÕES FINAIS	33
	REFERÊNCIAS	35

1. INTRODUÇÃO

O arroz é um dos alimentos mais consumidos no mundo e desempenha um papel fundamental na segurança alimentar de milhões de pessoas, especialmente em países em desenvolvimento. No Brasil, o arroz é um item essencial na dieta da população. Segundo IBGE (2017), o Brasil obteve mais de 11 milhões de toneladas de arroz com casca cultivados em aproximadamente 1,7 milhão de hectares, distribuídos por quase 180 mil estabelecimentos. Essa produção gerou um valor de R\$8,5 bilhões, sendo R\$6,4 bilhões provenientes do Rio Grande do Sul, o maior produtor nacional.

No contexto brasileiro, o arroz não apenas desempenha um papel essencial na dieta da população, mas também é um importante produto agrícola com forte impacto na economia nacional. E assim como qualquer produto, o preço do arroz é determinado por fatores relacionados à oferta (produção) e a demanda (consumo).

Os preços cumprem um papel essencial na economia, funcionando como sinalizadores que orientam tanto produtores quanto consumidores. Quando os preços sobem, produtores tendem a expandir a produção em busca de maiores lucros, enquanto consumidores podem ajustar seus hábitos, reduzindo o consumo. Em contrapartida, preços em queda podem desencorajar novos investimentos no cultivo, reduzindo a oferta em períodos futuros, ao passo que consumidores aumentam seu consumo.

Contudo, os preços do arroz não são determinados exclusivamente por fatores de mercado. Eventos climáticos, decisões de política agrícola, variações cambiais e mudanças no cenário internacional também exercem influência significativa, gerando oscilações que impactam o planejamento e os resultados de todos os agentes envolvidos no mercado.

Em 2024, o mercado de arroz foi profundamente afetado por uma catástrofe climática no Rio Grande do Sul, que trouxe severas consequências para a produção e os preços. O desastre mais grave no Estado havia sido registrado em 1941 (Rocha; Reboita; Crespo, 2024). Segundo a Secretaria do Meio Ambiente e Infraestrutura do Rio Grande do Sul (Benites, 2022), foi feito um levantamento dos desastres naturais ocorridos no Rio Grande do Sul entre 2003 e 2021, e entre esses anos, foram mencionadas 256 ocorrências de inundações e 801 enxurradas com mais de 43 mil pessoas atingidas.

As chuvas excessivas no final de abril de 2024 geraram preocupações sobre possíveis perdas nas áreas em fase de colheita, além de impactos nos estoques armazenados. Como resultado, as cotações do arroz subiram rapidamente, atingindo patamares elevados até meados de novembro, antes de apresentarem queda no final do ano (CEPEA, 2024). Este

evento destaca a relevância de compreender a dinâmica dos preços em cenários adversos, uma vez que as oscilações podem comprometer a segurança alimentar e o equilíbrio do mercado.

Nesse contexto, a análise de séries temporais do preço do arroz torna-se essencial. Tal análise não apenas permite compreender o comportamento histórico da variável, mas também contribui para identificar os fatores que influenciam sua volatilidade e projetar tendências futuras. As previsões de preços são ferramentas valiosas para auxiliar na tomada de decisões estratégicas no setor agrícola, além de fornecer subsídios para a formulação de políticas públicas que visem estabilizar o mercado e garantir o abastecimento.

O presente trabalho tem como objetivo compreender o impacto da catástrofe climática no Rio Grande do Sul sobre os preços do arroz. Especificamente, a análise da série de preços é conduzida por meio de técnicas estatísticas, como regressão e o método de suavização exponencial de Holt-Winters. Parte-se da hipótese de que o evento climático foi determinante para elevar os preços acima da média histórica. A proposta é realizar previsões com base em dados anteriores ao evento climático e compará-las com os preços observados posteriormente. Dessa forma, pretende-se construir um cenário contrafactual que represente a trajetória esperada dos preços na ausência do desastre, possibilitando estimar a magnitude do impacto sobre o mercado.

Compreender os efeitos desse evento climático e a dinâmica dos preços agrícolas é fundamental para o planejamento de ações que mitiguem os riscos econômicos e garantam a sustentabilidade do setor em cenários adversos.

2. REFERENCIAL TEÓRICO

2.1. Análise de preços agrícolas

De forma geral, a teoria econômica estabelece que os preços agrícolas são determinados pela interação entre oferta e demanda no mercado. A oferta reflete a quantidade de produto disponibilizada pelos produtores, enquanto a demanda indica a quantidade que os consumidores estão dispostos a adquirir a diferentes níveis de preço. Em mercados competitivos, o equilíbrio é obtido quando a quantidade de demanda e oferta são iguais (Pindyck; Rubinfeld, 2009).

A dinâmica de preços agrícolas apresenta particularidades associadas à natureza dos produtos agrícolas, como sazonalidade da produção (padrão cíclico dentro de um ano), baixa elasticidade preço da demanda e a dependência de condições climáticas e políticas

agrícolas (Tomek; Kaiser, 2014).

A sazonalidade caracteriza padrões nos movimentos de preço ao longo do ano. Ela ocorre devido aos ciclos de plantio e colheita, determinando períodos em que existem excessos de oferta e períodos em que a oferta é escassa. Consequentemente, é comum observar flutuações de preços entre diferentes períodos do ano.

A baixa elasticidade da demanda, por sua vez, reflete o fato de que os consumidores ajustam pouco a quantidade consumida mesmo diante de variações de preço, dada a essencialidade de muitos alimentos. Como no caso do arroz, com consumo *per capita* no Brasil de 131,4 g/dia, o grão é um dos alimentos consumidos com mais frequência no país (76,1%), perdendo apenas para o café (78,1%), levando em consideração o percentual de entrevistados que consumiram os alimentos nas últimas 24 horas da pesquisa (IBGE, 2020).

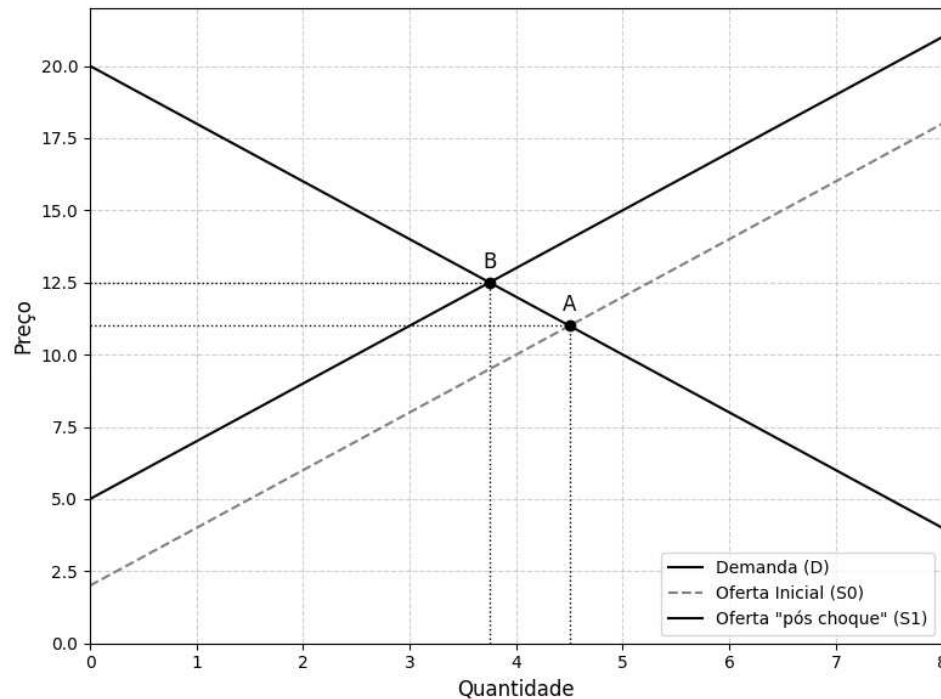
Além disso, choques externos, como eventos climáticos extremos, têm um impacto significativo sobre a oferta, o que gera deslocamentos no equilíbrio de mercado e, consequentemente, flutuações nos preços. Esses eventos podem causar quebras de safra, aumento nos custos de produção e redução na quantidade ofertada, que desencadeia efeitos diretos no comportamento dos preços agrícolas.

Eventos climáticos adversos, como secas, enchentes e tempestades, podem ser representados, do ponto de vista teórico, como choques de oferta. Em um diagrama de oferta e demanda, tais choques deslocam a curva de oferta para a esquerda, e indica uma redução na quantidade de produto ofertada a cada nível de preço. Este deslocamento resulta em um novo equilíbrio de mercado, com preços mais elevados e uma menor quantidade transacionada.

A Figura 1 ilustra um diagrama de oferta e demanda, e caracteriza um modelo microeconômico simples de equilíbrio de mercado, com a ideia de representar, por meio da análise de estática comparativa, o efeito de um choque de oferta adverso.

Nesse diagrama tem-se um equilíbrio inicial estabelecido no ponto A , com a interseção da curva de demanda (D) e oferta (S_0). O choque de oferta adverso pode muito bem representar consequências de um evento climático, como uma seca ou uma enchente, que reduz a oferta disponível do produto agrícola. Teoricamente, esse choque é representado por um deslocamento da curva de oferta para a esquerda, de S_0 (oferta inicial) para S_1 (oferta reduzida).

Figura 1 – Impacto de um choque de oferta no equilíbrio de mercado



Fonte: elaborado pelo autor.

Devido ao choque de oferta, a nova curva de oferta (S_1) reflete uma redução na quantidade ofertada a cada nível de preço. Com a redução na oferta, o novo equilíbrio é alcançado no ponto B , onde a curva de demanda intersecta a curva de oferta “pós choque” (S_1). Neste novo equilíbrio, o preço de equilíbrio aumenta para P_B , enquanto a quantidade de equilíbrio diminui para Q_B . Esse movimento reflete o efeito clássico de um choque negativo de oferta: aumento de preços e redução da quantidade transacionada no mercado.

Esse exemplo teórico retrata um cenário típico para mercados agrícolas, onde a produção é altamente sensível a condições climáticas adversas. A análise desse tipo de choque é fundamental para compreender as dinâmicas de mercado e planejar políticas públicas que mitiguem seus impactos.

Além do efeito direto sobre os preços, os choques climáticos podem ter consequências secundárias, como mudanças nas expectativas dos agentes de mercado. Estas expectativas podem amplificar as flutuações de preços em cenários de incerteza, uma vez que produtores podem ajustar suas decisões de plantio e colheita e consumidores podem alterar padrões de compra.

2.2. Influência do Clima

Na agricultura o clima é um fator que pode interferir positivamente ou não na produção. Em 2014 a onda de calor mais impactante dos últimos cem anos ocasionada por um bloqueio atmosférico interferiu negativamente na produtividade do arroz, a temperatura elevada da massa de ar seco impediu a geração de chuvas no sul do país no período reprodutivo do grão com redução estimada de 7,70 para 7,24 toneladas por ha-1 (Lopes; Breseghello, 2015).

Trentin (2023) cita como o aquecimento global causa impactos ambientais. A temperatura das regiões mais frias do mundo sobe acima da média global, e essa mudança da temperatura causa derretimento de geleiras e afeta a mudança de processos biológicos de agroecossistemas. Como exemplo que afeta a agricultura, pode-se destacar o período de floração e de germinação das plantas. Segundo o autor, a alteração da temperatura da terra gera mudança na posição das chuvas do Pacífico gera secas no nordeste do Brasil e enchentes na região sul do país. Essas irregularidades climáticas estão relacionadas ao *El Niño* e *La Niña* e podem ocasionar prejuízos para os produtores.

Marengo e Camargo (2007) analisaram temperaturas mínimas e máximas do ar e amplitude térmica diurna no sul do Brasil entre 1960 e 2002 e detectou um aquecimento sistemático na região sul. Tazzo *et al.* (2024) comenta que no Rio Grande do Sul é registrado aumento da temperatura média anual do ar desde a década de 1990. Entre 1961 e 2022 os dois maiores extremos foram registrados nos anos de 2015 e 2019 com 0,9°C acima da média histórica. No ano de 2022 foi registrada a mais intensa onda de calor, na qual Junges *et al.* (2022) afirmam que no mesmo ano foi registrado índices de temperaturas médias mensais em janeiro acima da média, com médias mínimas e máximas mensais também superiores.

Em setembro de 2023 o Rio Grande do Sul foi acometido por chuvas intensas. Alvalá *et al.* (2024) comentam que o acontecimento afetou mais de 400 mil pessoas. Segundo o estudo, uma frente fria quase estacionária da Argentina, que faz fronteira com o estado, aumentou a intensidade das chuvas. Uma área de baixa pressão nos níveis superiores da atmosfera amplificou a intensidade da precipitação, contribuindo para a formação de um ciclone extratropical, que rapidamente se afastou do continente. O estudo relacionou os eventos com o *El Niño* de 2023-2024 que afetou aquele ano, e resultou em inundações que afetaram 107 municípios, e revelou que o sistema frontal e a baixa pressão são os principais responsáveis, e não o ciclone extratropical que se formou posteriormente.

Em pesquisas direcionadas ao Estado do Rio Grande do Sul, Tazzo *et al.* (2024) destacam a relação do elevado Índice de Temperatura e Umidade (ITU) no verão com a produção de bovinos, Possani (2024) relaciona o impacto das mudanças climáticas na

produção de uva.

Segundo Rocha, Reboita e Crespo (2024) os eventos extremos ocorridos no Rio Grande do Sul em 2024 foram os mais severos desde 1941, com a elevação do nível do Rio Guaíba em 5,35 metros, superando o último recorde de 4,76 metros. Segundo os autores, o desastre ocorrido foi causado por uma combinação de fatores atmosféricos e oceânicos. Anomalias de circulação anticiclônica sobre o Centro-Sudeste do Brasil, associadas a águas mais quentes no oceano Índico, que criaram condições para intensas chuvas no estado. Além disso, a interação entre sistemas atmosféricos e a passagem de uma frente fria em abril contribuíram para a intensa chuva.

3. METODOLOGIA

3.1. Fonte de dados e ferramentas de análise

A análise empírica do trabalho foi realizada com dados secundários do preço do arroz, entre junho de 2005 a dezembro de 2024 obtidos a partir da Metodologia do Indicador do Arroz em Casca CEPEA/IRGA-RS, através de um convênio entre a Fundação de Estudos Agrários Luiz de Queiroz (Fealq) e o Instituto Rio Grandense do Arroz (IRGA), com a colaboração de cooperativas, secadores, armazenadores, indústrias, engenhos, produtores e comerciantes de arroz (CEPEA, 2022). O principal responsável pela execução desse indicador de preço é o Centro de Estudos Avançados em Economia Aplicada (CEPEA), associado ao Departamento de Economia, Administração e Sociologia da Escola Superior de Agricultura Luiz de Queiroz (ESALQ) da Universidade de São Paulo (USP).

O preço obtido dos colaboradores é relativo ao preço nominal, em reais (R\$) e em dólares americanos (US\$), do arroz em casca na modalidade *spot*, e os valores coletados a prazo foram convertidos à vista. A cotação refere-se ao valor por saca de 50kg posto-indústria com frete, líquido da Contribuição do Empregador Rural para Seguridade Social (CESSR) e da Taxa de Cooperação e Defesa da Orizicultura (CDO) (CEPEA, 2022).

A análise foi realizada com preços corrigidos do efeito inflacionário. Para isso, foi usado o Índice Geral de Preços – Mercado (IGP-M), calculado pelo Instituto Brasileiro de Economia (IBRE) da Fundação Getúlio Vargas (FGV). Esse índice mede a quantidade de variação dos preços no mercado em diversos setores da economia, como agricultura, construção civil e bens industriais. Por meio dele é possível identificar inflação ou deflação nos preços desses setores (Debit, 2024).

A correção foi realizada com a aplicação do seguinte cálculo em 1:

$$PR_t = PN_t \cdot \frac{IGPM_t}{IGPM_{base}} \quad [1]$$

Os dados estão originalmente armazenados em planilhas, mas foram carregados na plataforma Google Colaboratory e analisados com o uso da linguagem de programação Python. A escolha pela plataforma da Google se deu por sua interface intuitiva e pela oferta de funções gratuitas. A linguagem de programação Python, por sua vez, foi escolhida pela quantidade de bibliotecas que facilitam a manipulação e análise de dados, bem como a modelagem estatística. Dentre as principais bibliotecas temos a Pandas, a Numpy, Statsmodels e Scipy.

3.2. Análise de séries temporais

Uma série temporal é qualquer conjunto de observações ordenadas no tempo. Visualmente, o gráfico de uma série temporal deve representar a variável analisada no eixo Y e o tempo no eixo X. O gráfico deve permitir a visualização de componentes da série, como tendência, ciclo, sazonalidade ou componentes residuais (Montgomery; Runger, 2024).

Segundo Doane e Seward (2014) e Sharpe *et al.* (2011) a tendência representa movimento geral no decorrer dos anos, não representando mudanças a curto prazo. Essa característica pode ser estável e previsível. O ciclo das séries temporais representa graficamente os movimentos em torno da tendência, flutuações que não possuem uma frequência bem estabelecida. A sazonalidade é um padrão cíclico dentro de um ano, e possui uma frequência que não se modifica, relacionada ao calendário. Em análise de preços agrícolas o efeito sazonal pode ser efeito sobre a época de colheita e o clima que afetam a oferta e a demanda dos produtos. Por fim, a componente residual, que é um distúrbio aleatório na série de dados. Em 2, pode ser observado valor da série (Y) no seu modelo aditivo, que terá como resultado o somatório de tendência (T), ciclo (C), sazonalidade (S) e resíduo (R):

$$Y = T + C + S + R \quad [2]$$

Entre os componentes analisados, a sazonalidade é o mais perceptível a curto prazo e o que mais guia a formação dos preços de produtos agrícolas.

O preço de produtos agrícolas pode variar por influência de vários fatores, principalmente sazonalidade e em razão de incertezas do mercado (Rufino; Alves; Neto; Carneiro, 2024).

As flutuações de preço e a incerteza sobre os valores que podem ser assumidos, impõe riscos para todos os agentes que dependem destes preços. Nesse sentido, a análise de preços e o emprego de ferramentas de previsão são de grande relevância para as tomadas de decisão.

3.3. Método de regressão linear

A regressão linear é um modelo estatístico que permite avaliar a relação (linear) entre duas ou mais variáveis. Um modelo de regressão estabelece uma variável a ser explicada, y , em função de uma ou mais variáveis explicativas, representadas por X .

O objetivo principal do modelo é estimar os coeficientes que descrevem o impacto das variáveis explicativas sobre a variável explicada, possibilitando tanto a interpretação do relacionamento entre elas quanto a realização de previsões. No caso de um modelo de regressão linear simples, a representação pode ser dada pela seguinte expressão em 3:

$$y = \alpha + \beta X + \epsilon \quad [3]$$

Nesse modelo, os termos α e β são parâmetros deste modelo e representam, respectivamente, um intercepto e o coeficiente angular. O ϵ representa um termo de distúrbio estocástico que, por hipótese, possui média zero e variância (desconhecida) σ^2 (adaptado de Hoffmann, 2016; Montgomery e Runger, 2024).

O modelo acima descreve uma relação populacional, denominada por função de regressão populacional. Com base em dados amostrais, observados, o método estatístico estabelece um algoritmo para estimar os parâmetros α e β . As estimativas são dadas por $\hat{\alpha}$ e $\hat{\beta}$. Considerando as observações amostrais indexadas por $t = 1, \dots, T$, é possível ter uma estimativa da função de regressão amostral dada em 4 por:

$$y = \hat{\alpha} + \hat{\beta}X + e \quad [4]$$

Com base nessa expressão, pode-se obter uma estimativa dada por $\hat{y}_t = \hat{\alpha} + \hat{\beta}X_t$. Diferenças entre o valor estimado e o valor observado na amostra são denominados resíduos:

$$y_t - \hat{y}_t = e_t.$$

A estimação empregando o Método de Mínimos Quadrados Ordinários (MQO) consiste em obter os valores de α e β de forma que a soma do quadrado dos resíduos $(\sum_{t=1}^T e_i^2)$ seja a menor possível. Assim, o método resolve o problema em 5:

$$\sum_{t=1}^T e_i^2 = \text{Min}_{\hat{\alpha}, \hat{\beta}} \sum_{t=1}^T \left(y_t - \hat{\alpha} - \hat{\beta}X \right)^2 \quad [5]$$

Resolvendo o problema de minimização, temos expressões para o cálculo dos parâmetros deste modelo podem ser calculados da forma em 6 e 7:

$$\hat{\alpha} = \bar{y} + \hat{\beta}\bar{X} \quad [6]$$

$$\hat{\beta} = \frac{\sum_{t=1}^T (y_t - \bar{y})(X - \bar{X})}{\sum_{t=1}^T (X - \bar{X})^2} \quad [7]$$

No caso de dados de séries temporais, é possível ajustar um modelo de regressão linear para valores de y em função do tempo, dado por t . Considerando um modelo com dados ordenados temporalmente, podemos definir a seguinte expressão para o modelo 8:

$$y_t = \alpha + \beta t + \epsilon_t \quad [8]$$

Nesse modelo, a estimativa de β representa uma taxa de crescimento aritmético. Em outra perspectiva, o modelo pode ser especificado da forma em 9:

$$y_t = A e^{\beta t + \epsilon_t} \quad [9]$$

Especificado dessa forma, uma versão linearizada pode ser obtida e estimada como em 10:

$$\ln y_t = \alpha + \beta t + \epsilon_t \quad [10]$$

Com $\alpha = \ln A$.

É possível adicionar variáveis binárias (*dummies*) para captar efeitos sazonais. No caso de *dummies* para meses do ano, temos em 11:

$$\ln y_t = \alpha + \beta t + \sum_{m=1}^{11} \gamma_m D_m + \epsilon_t \quad [11]$$

No entanto, é importante estimar o modelo e realizar testes de significância para avaliar a importância estatística destes elementos.

3.4. Método de suavização exponencial

Segundo Morettin e Tolo (2006) os métodos de previsão são calculados a partir de dados passados para desenvolver um padrão de série temporal. As técnicas de suavização foram desenvolvidas para reduzir ruídos que possam constar nos dados e prever valores

futuros com melhor precisão. Existem diferentes técnicas de suavização que adotam valores extremos dos dados e suavizam para apresentar um padrão desses valores.

O modelo de suavização exponencial é um tipo especial de médias móveis, usado para fazer previsões de um passo à frente, que vão sendo atualizadas conforme há a ocorrência de dados. Para o caso do modelo mais simples, conforme apresentado por Doane e Seward (2014), a atualização pode ser dada pela expressão 12:

$$\hat{y}_{t+1|t} = \alpha y_t + (1 - \alpha) \hat{y}_{t|t-1} \quad [12]$$

Nesta expressão os termos são definidos da seguinte forma:

- $\hat{y}_{t+1|t}$ = previsão para o próximo período (realizada em t).
- $\hat{y}_{t|t-1}$ = previsão para y_t (realizada em $t - 1$).
- y_t = valor atual
- α = constante de suavização ($0 \leq \alpha \leq 1$)

A constante de suavização α representa um peso atribuído ao valor mais recente.

Em sua versão mais simples, a suavização exponencial é destinada para dados sem tendência. Se os dados tiverem uma tendência, pode-se tentar o método de Holt com duas constantes de suavização (uma para a tendência e outra para o nível). Por sua vez, se os dados tiverem uma tendência e apresentarem flutuações sazonais, o método de Holt-Winters se torna a técnica adequada.

No método de suavização exponencial simples, o tem que começar em algum lugar, então o primeiro valor é ajustado no tempo 1 ser denotado por l_0 (que deve ser estimado).

$$\begin{aligned} \hat{y}_{2|1} &= \alpha y_1 + (1 - \alpha) l_0 \\ \hat{y}_{3|2} &= \alpha y_2 + (1 - \alpha) \hat{y}_{2|1} \\ \hat{y}_{4|3} &= \alpha y_3 + (1 - \alpha) \hat{y}_{3|2} \\ &\vdots \\ \hat{y}_{T|T-1} &= \alpha y_{T-1} + (1 - \alpha) \hat{y}_{T-1|T-2} \\ \hat{y}_{T+1|T} &= \alpha y_T + (1 - \alpha) \hat{y}_{T|T-1} \end{aligned}$$

Após um processo de substituições recursivas, em que cada equação acima, na ordem em que são apresentadas, é substituída na equação seguinte, temos como resultado a expressão 13:

$$\hat{y}_{T+1|T} = \sum_{j=0}^{T-1} \alpha(1 - \alpha)^j y_{T-j} + (1 - \alpha)^T l_0 \quad [13]$$

Uma representação alternativa do método é a representação em forma de componentes. As representações em forma de componentes dos métodos de suavização exponencial compreendem uma equação de previsão e uma equação de suavização para cada um dos componentes incluídos no modelo.

Para a suavização exponencial simples, o único componente incluído é o nível. Dessa forma o modelo é composto pelas 14 e 15:

- Equação de previsão

$$\hat{y}_{t+h|t} = l_t \quad [14]$$

- Equação de suavização

$$l_t = \alpha y_t + (1 - \alpha) l_{t-1} \quad [15]$$

A equação de previsão mostra que o valor da previsão no momento $t + 1$ é o nível estimado no momento t . A equação de suavização para o nível (geralmente chamada de equação de nível) fornece o nível estimado da série em cada período t . Se substituirmos l_t por $\hat{y}_{t+1|t}$ e l_{t-1} por $\hat{y}_{t|t-1}$ na equação de suavização, é recuperada a forma média ponderada de suavização exponencial simples.

O trabalho de Holt (1957) estendeu a suavização exponencial simples para permitir a previsão de dados com tendência. Este método envolve uma equação de previsão e duas equações de suavização (uma para o nível e outra para a tendência). Como em 16, 17 e 18:

- Equação de previsão

$$\hat{y}_{t+h|t} = l_t + h b_t \quad [16]$$

- Equação de nível

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad [17]$$

- Equação de tendência

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad [18]$$

A equação de previsão estabelece uma previsão do valor de y no futuro $\hat{y}_{t+h|t}$ para h passos à frente, usando o nível estimado da série (l_t) e uma média da tendência (b_t). A previsão é calculada como o nível atual mais h vezes a tendência b_t . Essa equação se

assemelha a uma função de previsão linear.

A equação de nível atualiza a estimativa do nível l_t com base em uma média ponderada do valor atual observado y_t e a previsão um passo à frente feita no período anterior $(l_{t-1} + b_{t-1})$.

O parâmetro α (com $0 \leq \alpha \leq 1$) controla o quanto a nova observação influencia a estimativa do nível.

Por sua vez, na última equação, a tendência b_t é atualizada com base em uma média ponderada da mudança no nível $(l_t - l_{t-1})$ e da tendência anterior b_{t-1} . O parâmetro β (com $0 \leq \beta \leq 1$) controla o quanto a nova estimativa de tendência se baseia na mudança recente de nível em comparação com o valor da tendência anterior.

Os trabalhos de Holt (1957) e Winters (1960) ampliaram o método de Holt para capturar componentes de sazonalidade. O método que passou a ser denominado como Holt-Winters compreende a equação de previsão e três equações de suavização: uma para o nível (l_t), uma para a tendência (b_t) e uma para o componente sazonal (s_t), com os seguintes parâmetros de suavização, α , β^* e γ . O termo m é empregado para representar a frequência da sazonalidade. Por exemplo, $m = 12$ para dados de frequência mensal, ou $m = 4$ para dados trimestrais. Como em 19, 20, 21 e 22:

- Equação de previsão

$$\hat{y}_{t+h|t} = l_t + hb_t + s_{t+h-m(k+1)} \quad [19]$$

- Equação de nível

$$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad [20]$$

- Equação de tendência

$$b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)b_{t-1} \quad [21]$$

- Equação de sazonalidade

$$s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m} \quad [22]$$

A equação de previsão h passos à frente passa a contar com uma combinação do nível estimado (l_t), da tendência h períodos à frente (b_t), e um componente sazonal ajustado, que depende do índice sazonal do período específico ($s_{t+h-m(k+1)}$). O termo k é o quociente inteiro de $\frac{h-1}{m}$, onde o termo m é empregado para representar a frequência da sazonalidade. Por exemplo, $m = 12$ para dados de frequência mensal, ou $m = 4$ para dados trimestrais.

Isso garante que o índice sazonal usado na previsão corresponda ao ciclo correto.

Por exemplo, considerando o caso de uma previsão para 6 meses à frente ($h = 6$) para dados mensais onde $m = 12$. Assim k é dado por $\frac{6-1}{12} = 0,416$. Como a parte inteira de k é zero, o termo $s_{t+h-m(k+1)}$ é escrito $s_{t+6-12(0+1)} = s_{t-6}$. Se estivermos em janeiro de 2024 (t), nossa previsão para 6 meses à frente será para julho de 2024. O componente sazonal s_{t-6} usado será o valor sazonal de julho de 2023. Esse ajuste permite capturar a sazonalidade corretamente, garantindo que, por exemplo, a previsão para julho utilize o componente sazonal de julho do ano anterior, mantendo a consistência do padrão sazonal.

Na equação de nível, o nível l_t passa a ser atualizado com base em uma média ponderada entre a observação ajustada sazonalmente ($y_t - s_{t-m}$) e a previsão de um passo à frente do nível e tendência combinados ($l_{t-1} + b_{t-1}$). A equação de tendência se mantém a mesma.

A equação de sazonalidade atualiza o componente sazonal s_t como uma média ponderada entre o ajuste sazonal atual ($y_t - l_{t-1} - b_{t-1}$) e o valor sazonal do mesmo período no ciclo anterior (s_{t-m}). O parâmetro γ controla o grau de suavização para o componente sazonal.

3.5. Medidas de ajuste e desempenho preditivo dos modelos

A avaliação dos modelos preditivos é fundamental para verificar a precisão e a confiabilidade dos resultados obtidos. Dois critérios amplamente utilizados para essa avaliação são o Erro Absoluto Médio (MAE) e o Erro Quadrático Médio (MSE).

O MAE mede a média das diferenças absolutas entre os valores previstos e os valores observados, oferecendo uma visão direta sobre a magnitude dos erros sem dar peso a erros maiores ou menores (Hyndman; Koehler, 2006). Matematicamente, o MAE é definido como em 23:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad [23]$$

onde n é o número de previsões realizadas.

Já o MSE calcula a média dos quadrados das diferenças entre os valores previstos e os

observados, penaliza de forma mais severa os grandes erros, tornando-o sensível a outliers e mais apropriado para modelos onde grandes desvios são críticos (Chai; Draxler, 2014). Matematicamente, o MSE é definido como em 24:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad [24]$$

Uma vez que o MSE está na escala dos erros quadrados, ele não tem uma interpretação direta. De forma a contornar isso, é bastante comum reportar a raiz quadrada do MSE, denominada Root Mean Squared Error (RMSE).

4. RESULTADOS E DISCUSSÕES

4.1. Movimentos recentes do preço do arroz

Na análise de preço de um produto agrícola, deve-se considerar os diversos fatores que podem influenciá-lo, aspectos que afetam a oferta e a demanda, como por exemplo, os custos de produção, políticas governamentais e o clima. No caso do arroz, Zanin (2023) relata características importantes para variação do preço deste cereal no Brasil nas últimas duas décadas. Dentre os fatores, o autor cita que o consumo dos brasileiros sofreu estagnação entre 1999 e 2023, com variação de 10 a 13 milhões de toneladas, assim como nas importações e crescimento das exportações. Nesse mesmo período, a redução da área plantada foi de 61%, e houve crescimento de 120% de produtividade. Além disso, um fator que influencia fortemente o preço do arroz é a concentração de maior parte da produção (cerca de 70%) no Estado do Rio Grande do Sul.

Entre abril e maio de 2024, o Estado do Rio Grande do Sul foi atingido por um desastre natural de grandes proporções, causado por chuvas intensas na qual os impactos afetaram significativamente a produção agrícola da região.

Segundo dados de 27 de maio de 2024, da entidade de representação sindical da indústria do estado, a Federação das Indústrias do Estado do Rio Grande do Sul (FIERGS, 2024), os municípios atingidos de forma mais grave, representavam cerca de 15,7% do território e contavam com 5,4 milhões de pessoas, quase 50% da população do estado.

Como o estado é o maior produtor do país, o Governo tomou medidas para interferir na recuperação do preço do arroz. Um exemplo é o programa arroz da gente, parceria estabelecida com a Companhia Nacional de Abastecimento (Conab), os Ministérios do Desenvolvimento Agrário e do Desenvolvimento Social (MDA e MDS), com o apoio da

Secretaria da Assistência Técnica e Defesa Agropecuária (Sada), para auxiliar produtores na produção com suporte técnico de profissionais em 17 estados brasileiros (Governo do Estado do Piauí, 2024). O programa tem como objetivo estimular a produção e estoque do arroz, com a possibilidade de compra da produção por parte do Governo, com investimento de 1 bilhão de reais (Brasil, 2024a).

Outra medida foi a importação de arroz comprados em leilão. Diante do desastre ocorrido e a especulação do preço do arroz, o Mercosul teve um aumento de 30% no mês de maio. Como medida protetiva, o Governo cancelou o leilão que seria realizado e zerou o custo de importação de países fora do Mercosul para reduzir o preço no exterior (O globo, 2024). Em 6 de junho, a Conab comprou 263 mil toneladas destinadas a áreas do país com maior insegurança alimentar para reduzir o preço do arroz no mercado interno (Brasil, 2024b).

O diário oficial da união publicou em 23 de maio de 2024 a portaria nº 835 que atribui descontos para os financiamentos destinados a crédito rural com benefício aos produtores que sofreram com danos materiais. Já em 13 de maio de 2024, publicou a portaria MDA nº 13 com o objetivo de prorrogar em seis meses a vigência da declaração de aptidão do Pronaf (DAP) no Estado do Rio Grande do Sul diante dos acontecimentos da catástrofe (Brasil, 2024c).

A medida provisória nº 1218 de maio de 2024 abre crédito extraordinário com mais de R\$ 12 bilhões destinados a órgãos do poder executivo, encargos financeiros da união e operações oficiais de crédito, como exemplos das medidas, o dinheiro deve ser direcionado para obtenção de arroz em estoques públicos pela Conab e distribuição de alimentos para famílias com insegurança alimentar (Brasil,, 2024d).


A resolução CMN de nº 5.132, de 10 de maio de 2024, permite a renegociação de crédito rural nos municípios atingidos pela tragédia no Rio Grande do Sul (Brasil, 2024e).

A resolução nº 5135 de 13 de maio de 2024 determina medidas que simplificam comprovação de perdas e cobertura de até todo o valor para produtores enquadrados no Programa de Garantia da Atividade Agropecuária (Proagro) localizados nos municípios do estado do Rio Grande do Sul (Brasil, 2024f).

4.2. Análise Exploratória dos dados

O gráfico 1 demonstra que os dados coletados permitem identificar de forma geral padrões no comportamento do preço, como tendências ou componentes residuais. Pode-se observar no gráfico uma tendência de aumento do preço ao longo dos anos, em especial um aumento a partir de 2020.

Gráfico 1. Evolução dos Preços Nominais e Reais do Arroz (R\$/saca) entre julho de 2005 e dezembro de 2024




Fonte: elaborado pelo autor.

Entre 2005 e 2019 há menor volatilidade em relação aos anos a partir de 2020, portanto apresentou maior estabilidade de flutuações (mudanças dos preços). Não foram observados distúrbios aleatórios que não seguem um padrão.

A identificação de padrões sazonais foi realizada com a avaliação da distribuição de preços segmentada por trimestres ou meses. O gráfico 2 apresenta por meio de gráficos de caixa (boxplot), a distribuição de preços em cada mês do ano. Embora a mediana seja muito semelhante entre os meses, as distribuições não são tão homogêneas ao longo dos anos.

Gráfico 2 – Distribuição dos preços do arroz entre os meses



Fonte: elaborado pelo autor.

Outra questão, que se avaliou, diz respeito à identificação dos outliers.

De forma mais detalhada, a Tabela 1 apresenta informações estatísticas completas da série de preços reais segmentados por mês. Os meses de setembro e outubro são os que apresentam maior média e desvio padrão, o que pode demonstrar sazonalidade. As médias mais baixas foram identificadas entre março e agosto.

Tabela 1 - Estatísticas mensais de preços do arroz

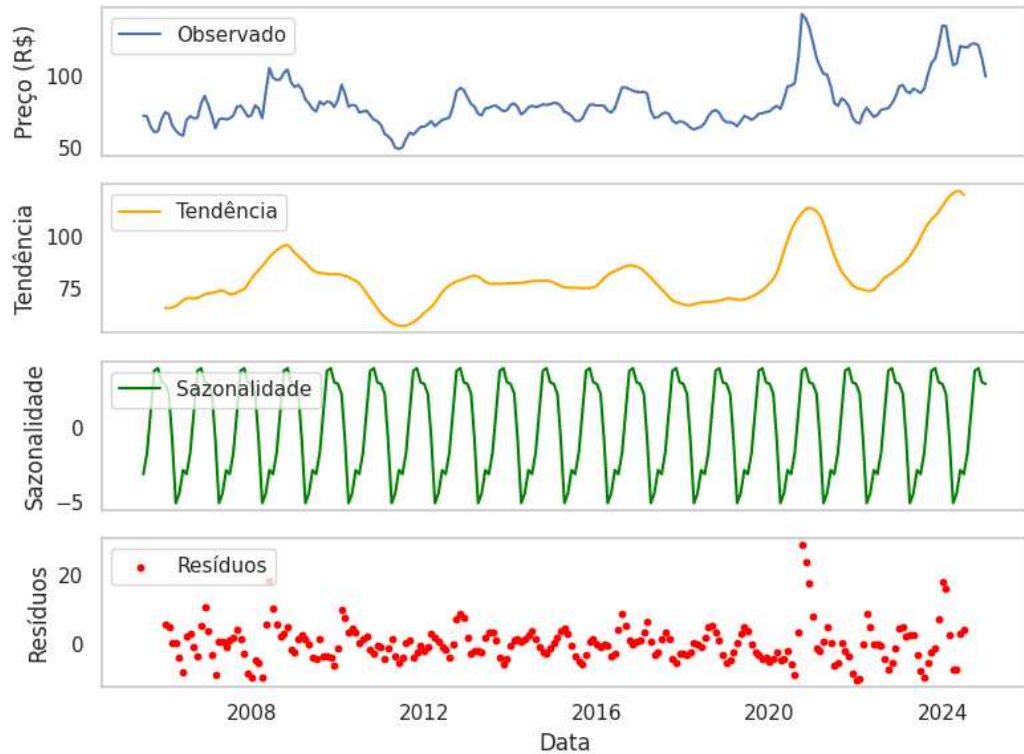
mês	n	média	Desvio-padrão	min	25%	50%	75%	max
janeiro	19	82.83	18.11	59.71	70.07	79.74	91.67	135.46
fevereiro	19	80.00	15.46	58.18	67.82	78.82	88.28	120.70
março	19	75.88	12.97	55.27	67.49	75.27	78.46	107.96
abril	19	76.82	14.06	49.98	69.60	74.75	82.70	109.23
maio	19	78.63	16.59	49.11	70.68	77.31	84.83	121.48
junho	20	78.21	14.45	50.35	70.53	74.13	82.37	120.72
julho	20	79.94	13.88	56.27	72.08	75.97	84.75	120.51
agosto	20	82.49	15.83	60.60	73.06	78.84	86.59	122.80
setembro	20	85.02	20.76	59.28	73.58	78.68	90.04	143.95
outubro	20	85.32	20.32	61.52	74.46	80.13	90.54	140.77
novembro	20	84.65	18.92	64.64	71.11	79.46	89.60	134.49
dezembro	20	84.12	18.52	64.78	71.70	79.96	89.92	135.69

Fonte: elaborado pelo autor.

Empregando a função ‘seasonal_decompose()’ do módulo ‘tsa’ da biblioteca *Statsmodels*, é possível decompor a série temporal em termos dos componentes de tendência,

sazonalidade e resíduos. A Figura 2 apresenta o resultado desta função aplicada à série de preços reais do arroz no período considerado.

Figura 2 - Decomposição da série temporal



Fonte: elaborado pelo autor.

Nesse gráfico é possível visualizar claramente o comportamento sazonal. Nos resíduos, observa-se que estes ocorrem, como esperado, com valores próximos de zero, mas que apresentam alguns outliers que se destacam, principalmente entre 2020 e 2021. Também se observa alguns outliers em 2024.

4.3. Modelando os preços com regressão linear

Foi aplicada uma análise de regressão linear para os preços do arroz, para explicar os movimentos do preço por um componente de tendência e componentes sazonais. A variável explicada do modelo é dada pelos preços reais em escala logarítmica. Como regressores, foram considerados um componente de tendência e variáveis binárias (*dummies*) para os meses, de forma a testar a significância do componente sazonal.

A equação estimada é a seguinte:

$$\ln \ln p_t = 4,2515 + 0,0013 T$$

A Tabela 2 apresenta os resultados detalhados da análise de regressão, e considera os regressores de tendência e meses.

A aplicação do teste de significância mostra que o intercepto e o componente de tendência são estatisticamente significantes. Por sua vez, as dummies para os meses não se mostraram significantes¹. O R² ajustado indica que a regressão linear explica 19,6% da variação dos preços, isso sugere que esse modelo não é o mais adequado para representar a sazonalidade.

Tabela 2 - Resultados da análise de regressão com dummies mensais

Variáveis	Coeficiente	Erro Padrão	Estatística de teste (t)	p-valor	Intervalo de Confiança	
					[0.025	0.975]
<i>Intercepto</i>	4,2515	0,0436	97,5305	0,0000	4,1656	4,3374
<i>Tendência</i>	0,0013	0,0002	7,6238	0,0000	0,0009	0,0016
<i>Fev</i>	-0,0325	0,0554	-0,5865	0,5582	-0,1418	0,0767
<i>Mar</i>	-0,0832	0,0554	-1,5010	0,1348	-0,1925	0,0260
<i>Abr</i>	-0,0748	0,0554	-1,3490	0,1787	-0,1840	0,0345
<i>Mai</i>	-0,0572	0,0554	-1,0325	0,3030	-0,1665	0,0520
<i>Jun</i>	-0,0514	0,0547	-0,9381	0,3492	-0,1592	0,0565
<i>Jul</i>	-0,0287	0,0547	-0,5236	0,6011	-0,1365	0,0792
<i>Ago</i>	-0,0013	0,0547	-0,0245	0,9805	-0,1092	0,1065
<i>Set</i>	0,0190	0,0547	0,3479	0,7282	-0,0888	0,1269
<i>Out</i>	0,0223	0,0547	0,4068	0,6845	-0,0856	0,1302
<i>Nov</i>	0,0160	0,0547	0,2918	0,7707	-0,0919	0,1239
<i>Dez</i>	0,0093	0,0547	0,1691	0,8659	-0,0986	0,1171
R ²	0,237					
R ² ajustado	0,196					

Fonte: elaborado pelo autor.

4.4. Previsão com o modelo de suavização exponencial

O modelo de suavização exponencial foi aplicado considerando uma técnica bastante comum em modelos de séries temporais e de aprendizado de máquina, que é a divisão dos dados em conjuntos de treino e teste.

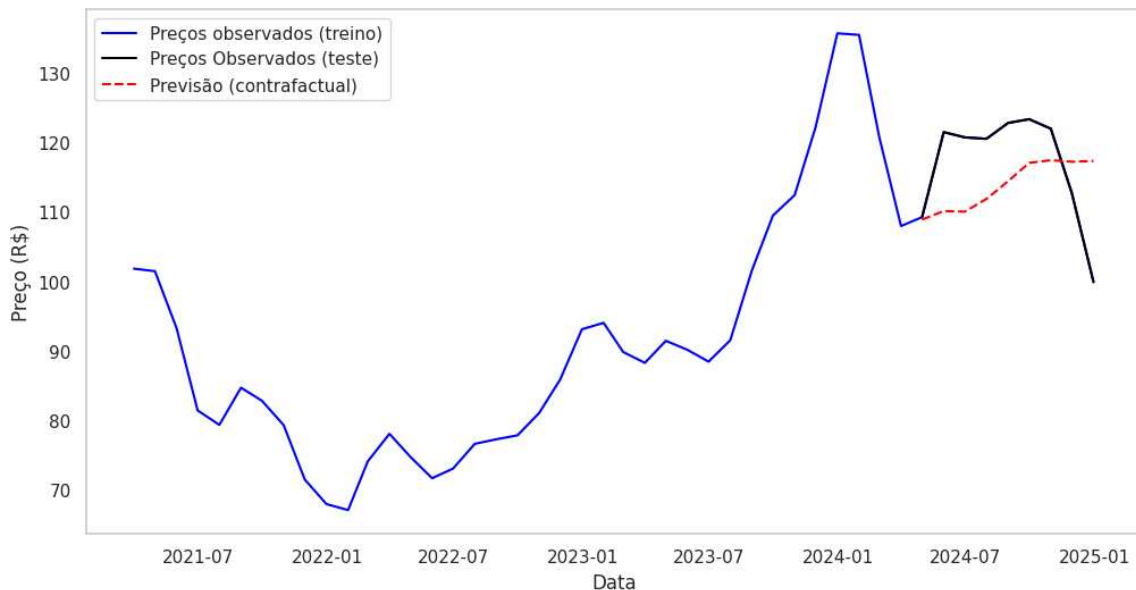
O conjunto de treino compreende os preços até março de 2023, definindo o conjunto de testes com os preços de abril de 2023 até dezembro de 2024. O objetivo dessa divisão é treinar um modelo para realizar previsões, isento dos efeitos do evento climático de abril/maio de 2024. Com esse modelo, a ideia é construir uma previsão, no conjunto de dados de teste, que fornece um cenário contrafactual em que não houvesse o choque sobre os preços.

¹ Também foram testadas *dummies* para os trimestres, mas os resultados mostram que estas variáveis não são estatisticamente significantes.

O Gráfico 3 mostra a série de dados a partir de março de 2021 até dezembro de 2024, uma série mais curta para permitir uma melhor visualização da previsão e dos dados observados. Neste gráfico estão destacados, em cores diferentes, os dados observados de acordo com o conjunto de dados de treino (azul) e de teste (preto). A linha pontilhada vermelha é dada pela previsão gerada pelo modelo de suavização exponencial de Holt-Winters. Essa linha vermelha representa o cenário contrafactual em que a série de preços do arroz não foi afetada pelo fenômeno climático.

O impacto médio sobre os preços, mensurado ao longo de todo o período de entre abril e dezembro de 2024 foi de R\$3,14/saca. Uma vez que se observa uma redução brusca dos preços nos últimos meses, foi calculado o impacto médio para os três primeiros meses diretamente afetados pelo evento climático adverso (abril, maio, junho). Nesse caso, o impacto médio foi de R\$7,46/saca.

Gráfico 3 - Evolução dos preços observados para treino, teste e sua previsão



Fonte: elaborado pelo autor.

O valor do Erro Médio Absoluto (MAE) foi de 8,02 para mais ou para menos, e da Raiz do Erro Quadrático Médio (RMSE) de 9,26, o valor é superior pois é uma métrica que mede a magnitude de erros. Ela eleva cada erro ao quadrado antes de calcular a média e extrair a raiz quadrada, sendo mais sensível a erros grandes, pois eles são elevados ao quadrado e possuem maior impacto. Esses valores são relativamente moderados, mas ainda apresentam significativa margem de erro.

Pinheiro, Tavares e Oliveira (2022) também utilizaram o método de suavização

exponencial para prever preços de arroz irrigado e sequeiro no Paraná com dados entre 1995 e 2015, com os dados corrigidos através do Índice Geral de Preços de Mercado (IGP-M). A pesquisa obteve dados satisfatórios na previsão e o modelo se mostrou eficiente.

Marchezan e Souza (2010) também estudaram modelos estatísticos para tentar prever o preço de arroz, soja e milho no Rio Grande do Sul com uso de dados entre 1995 e 2006. Utilizaram o método de Box & Jenkins e o modelo SARIMA (1,1,0)(1,0,1)₁₂ com EQM de 4,22 se mostrou o mais adequado para estimativa do arroz.

Outros autores também utilizaram modelos estatísticos para tentar prever o preço do arroz, mas apenas na literatura internacional, sem relacionar a volatilidade da precificação com eventos climáticos extremos. Também existem pesquisas que relacionam a produção do arroz com as mudanças climáticas.

Bilal *et al.* (2024) estudaram modelos para previsão do preço do arroz na Malásia, mas usaram abordagem diferente com uso de modelos de séries temporais *fuzzy* multivariados. Na Indonésia Muchtar e Afiyati (2024) utilizou o algoritmo *Random Forest* com precisão de 98,69% e regressão linear com precisão de 95,08% para prever o preço de arroz premium.

Tan *et al.* (2021) relacionou o impacto na produção de arroz da Malásia com alterações climáticas na temperatura e padrões de precipitação, assim como eventos extremos. Oguntunde *et al.* (2017) relacionaram a produtividade do arroz com variáveis climáticas na região do sudoeste da Nigéria com o uso de regressão linear múltipla e análise de análise de *Support Vector Machine* (SVM). A pesquisa destaca a radiação solar como variável climática que mais atingiu a produtividade.

5. CONSIDERAÇÕES FINAIS

O arroz desempenha um papel fundamental na segurança alimentar e na economia do país. Como um dos alimentos mais consumidos, sua disponibilidade e preço afetam diretamente a população. Com cerca de 70% da produção do Brasil voltada para o Rio Grande do Sul, os desastres climáticos tornam o mercado mais suscetível a impactos climáticos, como os observados em 2024. Compreender as flutuações nos preços do arroz é essencial para garantir a estabilidade do setor e reduzir os riscos de desabastecimento e inflação alimentar.

O presente estudo analisou o impacto de eventos climáticos extremos, e utilizou técnicas estatísticas para compreender e projetar esses efeitos. A análise revelou que fatores climáticos foram determinantes para os picos de preços observados em 2024, fato que

evidencia a vulnerabilidade do preço do arroz em condições meteorológicas adversas e imprevisíveis, especialmente devido à concentração da produção na região sul.

A utilização de regressão linear demonstrou que o coeficiente de determinação (R^2) foi relativamente baixo, sugerindo que o modelo linear simples não captura bem a variação dos preços ao longo do tempo. Além disso, significa que componentes residuais (como clima) podem ter um impacto mais significativo na variação dos preços, esse fato reforça a necessidade de modelos mais sofisticados, como Holt-Winters. O Erro Médio Absoluto (MAE) de 8,02 e a Raiz do Erro Quadrático Médio (RMSE) 9,26 indicam que as previsões feitas pelo modelo foram moderadamente precisas mas com erros significativos. A regressão linear pode identificar uma tendência crescente nos preços, mas não obtém boa previsão das oscilações causadas por eventos externos como na suavização exponencial.

Ainda existem lacunas significativas na literatura nacional sobre o tema. Estudos sobre a precificação do arroz no Brasil são escassos, especialmente no que diz respeito à sua relação entre o clima e mais ainda para desastres extremos. Por conta disto, este estudo reforça a importância de pesquisas utilizando modelos de previsão para auxiliar com a compreensão do comportamento de preços agrícolas e fornecer contribuições científicas relevantes para a formulação de políticas públicas na prevenção de desastres e para a tomada de decisão no setor agropecuário, tanto na produção como na precificação do arroz.

REFERÊNCIAS

- ALVALÁ, R. C. dos S.; RIBEIRO, D. F.; MARENGO, J. A.; SELUCHI, M. E.; GONÇALVES, D. A.; SILVA, L. A.; PINEDA, L. A. C.; SAITO, S. M. **Analysis of the hydrological disaster occurred in the state of Rio Grande do Sul, Brazil in September 2023: Vulnerabilities and risk management capabilities.** *International Journal of Disaster Risk Reduction*, v. 110, 2024, 104645. ISSN 2212-4209. Disponível em: <https://doi.org/10.1016/j.ijdr.2024.104645>. Acesso em: 21 jan. 2025.
- BENITES, V. **Estudo inédito detalha ocorrências de desastres naturais no RS entre 2003 e 2021.** Porto Alegre: *Secretaria do Meio Ambiente e Infraestrutura do Rio Grande do Sul*, 23 nov. 2022. Disponível em: <https://sema.rs.gov.br/estudo-inedito-detalha-ocorrencias-de-desastres-naturais-no-rs-entre-2003-e-2021>. Acesso em: 5 fev. 2025.
- BILAL, M.; ALRASHEEDI, M. A.; AAMIR, M.; ABDULLAH, S.; NORRULASHIKIN, S. M.; REZAIY, R. **Enhanced forecasting of rice price and production in Malaysia using novel multivariate fuzzy time series models.** *Scientific Reports*, Aug. 2024. DOI: <https://doi.org/10.1038/s41598-024-77907-4>.
- BRASIL. **Governo Federal compra 263 mil toneladas de arroz importado em leilão.** Gov.br, 23 jun. 2024b. Disponível em: <https://www.gov.br/secom/pt-br/assuntos/noticias/2024/06/governo-federal-compra-263-mil-toneladas-de-arroz-importado-em-leilao>. Acesso em: 04 jan. 2025.
- BRASIL. **Medida Provisória nº 1.218, de 11 de maio de 2024.** *Diário Oficial da União*, 21 maio 2024d. Disponível em: <https://www.gov.br/saude/pt-br/composicao/svsa/coes/chuvas-intensas-e-inundacoes-no-sul/legislacao/medida-provisoria-no-1-218-de-11-de-maio-de-2024.pdf/view>. Acesso em: 5 jan. 2025.
- BRASIL. **Ministério do Desenvolvimento Agrário e Agricultura Familiar. Programa do MDA, Arroz da Gente impulsiona produção do grão e promove segurança alimentar no país.** Gov.br, 31 out. 2024a. Disponível em: <https://www.gov.br/mda/pt-br/noticias/2024/10/programa-do-mda-arroz-da-gente-impulsiona-producao-do-grao-e-promove-seguranca-alimentar-no-pais>. Acesso em: 22 dez. 2024.
- BRASIL. **Ministério do Desenvolvimento Agrário e Agricultura Familiar. Portaria MDA nº 13, de 13 de maio de 2024.** *Diário Oficial da União*, edição 92, seção 1, p. 20, 14 maio 2024c. Disponível em: <https://www.in.gov.br/en/web/dou/-/portaria-mda-n-13-de-13-de-maio-de-2024-559371191>. Acesso em: 04 jan. 2025.
- BRASIL. **Resolução CMN nº 5.132, de 10 de maio de 2024.** *Diário Oficial da União*, seção 1, p. 137, 13 de maio de 2024e. Disponível em: <https://www.bcb.gov.br/estabilidadefinanceira/exibenormativo?tipo=Resolu%C3%A7%C3%A3o%20CMN&numero=5132>. Acesso em: 5 jan. 2025.
- BRASIL. **Resolução CMN nº 5.135, de 13 de maio de 2024.** *Diário Oficial da União*, seção 1, p. 45-46, 14 maio de 2024f. Disponível em:

<https://www.bcb.gov.br/estabilidadefinanceira/exibenormativo?tipo=Resolu%C3%A7%C3%A3o%20CMN&numero=5135>. Acesso em: 5 jan. 2025.

CEPEA - Centro de Estudos Avançados em Economia Aplicada. **Metodologia do Indicador de Preços do Arroz CEPEA/IRGA-RS**. Piracicaba: Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, fevereiro de 2022. Disponível em: https://www.cepea.esalq.usp.br/upload/kceditor/files/Metodologia_do%20arroz_para_site_Cepea_IrgaRS_Fev22.pdf. Acesso em: 12 dez. 2024.

CEPEA - Centro de Estudos Avançados em Economia Aplicada. **Indicador de Preços do Arroz**. Piracicaba: Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, 2024. Disponível em: <https://www.cepea.esalq.usp.br/br/indicador/arroz.aspx>. Acesso em: 12 dez. 2024.

DEBIT. **IGP-M: Índice Geral de Preços - Mercado**. Disponível em: <https://www.debit.com.br/tabelas/igpm-fgv-indice-geral-de-precos-mercado>. Acesso em: 6 jan. 2025.

DOANE, D. P.; SEWARD, L. E. **Estatística aplicada à administração e economia**. 4. ed. Porto Alegre: *AMGH Editora Ltda*, 2014. ISBN 978-85-8055-394-9

FIERGS – Federação das Indústrias do Estado do Rio Grande do Sul. **Principais indicadores econômicos dos municípios atingidos pelas enchentes no Rio Grande do Sul: Estado de Calamidade x Situação de Emergência**. Porto Alegre: *Unidade de Estudos Econômicos*, 2024. Disponível em: https://static.portaldaindustria.com.br/portaldaindustria/noticias/media/filer_public/8e/88/8e88c7b2-fab6-4f16-99d9-59c0f08ca60b/estudo_fiergs.pdf. Acesso em: 22 dez. 2024

GOVERNO DO ESTADO DO PIAUÍ. **Programa vai fortalecer a produção de arroz em várias regiões do Piauí**. *Acesse Piauí*, 20 nov. 2024. Disponível em: <https://www.acessepiaui.com.br/noticia/17315-programa-vai-fortalecer-a-producao-de-arroz-em-varias-regioes-do-piaui>. Acesso em: 22 dez. 2024.

HOFFMANN, Rodolfo. **Análise de regressão: uma introdução à econometria**. 5. ed. Piracicaba: O Autor, 2016. 393 p. DOI: 10.11606/9788592105709.

HOLT, C. C. **Forecasting Trends and Seasonals by Exponentially Weighted Averages**. *ONR Memorandum*, n. 52, Carnegie Institute of Technology, Pittsburgh, USA, 1957.

HYNDMAN, R. J.; KOEHLER, A. B. **Another look at measures of forecast accuracy**. *International Journal of Forecasting*, v. 22, n. 4, p. 679-688, Oct./Dec. 2006. Disponível em: <https://doi.org/10.1016/j.ijforecast.2006.03.001>. Acesso em: 10 fev. 2025.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Censo Agro 2017**. Disponível em: https://censoagro2017.ibge.gov.br/templates/censo_agro/resultadosagro/agricultura.html?localidade=0&tema=78329. Acesso em: 04 jan. 2025.

IBGE – Instituto Brasileiro de Geografia e Estatística. **POF 2017-2018: Brasileiro ainda mantém dieta à base de arroz e feijão, mas consumo de frutas e legumes é abaixo do**

esperado. Agência de Notícias IBGE, 21 out. 2020. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/28646-pof-2017-2018-brasileiro-ainda-mantem-dieta-a-base-de-arroz-e-feijao-mas-consumo-de-frutas-e-legumes-e-abaixo-do-esperado#:~:text=Os%20alimentos%20com%20maiores%20m%C3%A9dias,%2C1%20g%2Fdia>). Acesso em: 20 fev. 2025.

JUNGES, A. H.; TAZZO, I. F.; CARDOSO, L. S.; CERA, J. C. **Avaliação da onda de calor ocorrida em janeiro de 2022 no Rio Grande do Sul.** *Agrometeoros*, v. 30, e027078, 2022. ISSN 2526-7043. Disponível em: <http://dx.doi.org/10.31062/agrom.v30.e027078>. Acesso em: 5 jan. 2025.

LOPES, S. I. G.; BRESEGHELLO, F. **Aceleração do ganho genético para produtividade e outras características chaves para a competitividade da cultura de arroz irrigado.** In: XII *Conferência Internacional de Arroz para América Latina e Caribe*, 12., 2015, Porto Alegre. Anais... Porto Alegre: IRGA, 2015. Disponível em: <http://www.alice.cnptia.embrapa.br/alice/handle/doc/1015008>. Acesso em: 5 jan. 2025.

MARCHEZAN, A.; SOUZA, A. M. Previsão do preço dos principais grãos produzidos no Rio Grande do Sul. *Ciência Rural*, Santa Maria, v. 40, n. 11, p. 2368-2374, nov. 2010. Disponível em: <https://doi.org/10.1590/S0103-84782010001100019>. Acesso em: 07 fev. 2025.

MARENGO, José A.; CAMARGO, Cláudia C. **Surface air temperature trends in southern Brazil for 1960–2002.** *International Journal of Climatology*, Chichester, v. 28, n. 7, p. 893–904, 2007. DOI: <https://doi.org/10.1002/joc.1584>

MONTGOMERY, Douglas C.; RUNGER, George C. **Estatística aplicada e probabilidade para engenheiros.** 7. ed. Rio de Janeiro: LTC, 2024. Tradução de: *Applied statistics and probability for engineers*. ISBN 978-8-521-63743-1.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais.** ed. 2. São Paulo: Egard Blucher, 2006. ISBN 978-85-212-0389-6.

MUCHTAR, I. R.; AFIYATI, A. **Comparison of Linear Regression and Random Forest Algorithms for Premium Rice Price Prediction (Case Study: West Java).** *Jurnal Indonesia Sosial Teknologi*, [S. l.], v. 5, n. 7, p. 3122–3132, 2024. DOI: 10.59141/jist.v5i7.1184. Disponível em: <https://jist.publikasiindonesia.id/index.php/jist/article/view/1184>. Acesso em: 10 fev. 2025.

O GLOBO. **Governo suspende leilão de compra de arroz após altas de preços no Mercosul.** 21 maio 2024. Disponível em: <https://oglobo.globo.com/economia/noticia/2024/05/21/governo-suspende-leilao-de-compra-d-e-arroz-apos-altas-de-precos-no-mercosul.ghtml>. Acesso em: 14 jan. 2025.

OGUNTUNDE, P. G.; LISCHIED, G.; DIETRICH, O. **Relationship between rice yield and climate variables in southwest Nigeria using multiple linear regression and support vector machine analysis.** *Int J Biometeorol* 62, p. 459–469, 2017. DOI: <https://doi.org/10.1007/s00484-017-1454-6>

PINDYCK, R. S.; RUBINFELD, D. L. **Microeconomía.** 7. ed. Madrid: Pearson Educación, 2009. 888 p. ISBN 978-84-832-2706-0.

PINHEIRO, D. R. O.; TAVARES, M.; OLIVEIRA, K. G. de. **Previsão de preços para a cultura do arroz irrigado e sequeiro do estado do Paraná utilizando séries temporais.** *Atena Editora*, 2022. DOI: 10.22533/at.ed.0702211033.

POSSANI, L.; WAQUIL, P. D.; MAMBRIN, R. B.; POSSANI, I. T. P. **Percepções das mudanças climáticas e seus impactos nos processos produtivos de uvas nas vinícolas do Rio Grande do Sul.** *Contribuciones a Las Ciencias Sociales*, São José dos Pinhais, v. 17, n. 9, p. 01-26, 2024. DOI: 10.55905/revconv.17n.9-174. Disponível em: <https://ojs.revistacontribuciones.com/ojs/index.php/clcs/article/view/10557/6344>. Acesso em: 5 jan. 2025.

ROCHA, R. P.; REBOITA, M. S.; CRESPO, N. M. **Análise do evento extremo de precipitação ocorrido no Rio Grande do Sul entre abril e maio de 2024.** *Journal Health NPEPS*, v. 9, n. 1, p. e12603, 2024. Disponível em: <https://periodicos.unemat.br/index.php/jhnpeps/article/view/12603/8513>. Acesso em: 03 jan. 2025.

RUFINO, J. P. F.; ALVES, F. F.; NETO, P. Q. C.; CARNEIRO, S. B. **Planejamento e previsão do preço do açaí no Amazonas: análise com base no modelo X12-ARIMA.** *Revista Observatorio de la Economía Latinoamericana*, Curitiba, v. 22, n. 6, p. 1-20, 2024. DOI: 10.55905/oelv22n6-124.

SHARPE, N. R.; VEAUX, R. D. de; VELLEMAN, P. F. **Estatística aplicada à economia.** Porto Alegre: *Bookman*, 2011. ISBN 978-85-7780-865-6.

TAN, B. T. ; FAM, P. S.; FIRDAUS R. B. R; TAN, M. L; GUNARATNE, M. S.. **Impact of climate change on rice yield in Malaysia: a panel data analysis.** *Agriculture*, 2021. Disponível em: <https://doi.org/10.3390/agriculture11060569>. Acesso em: 10 jan. 2025.

TAZZO, I. F.; TAROUÇO, A. K.; JUNIOR, P. H. C. A. ; BREMM, C.; CARDOSO, L. S.; JUNGES, A. H. **Índice de Temperatura e Umidade (ITU) ao longo do verão de 2021/2022 e estimativas dos impactos na bovinocultura de leite no Rio Grande do Sul, Brasil.** *Ciência Animal Brasileira*, v. 25, e-77035P, 2024. Disponível em: <https://doi.org/10.1590/1809-6891v25e-77035P>. Acesso em: 5 jan. 2025.

TOMEK, W. G.; KAISER, H. M. **Agricultural product prices.** *Ithaca: Cornell University Press*, 2014.

TRENTIN, I. C. L. **A crise da agropecuária e as mudanças climáticas no Rio Grande do Sul-Brasil.** *Revista Foco, A [S. l.]*, v. 16, n. 11, p. e3361, 2023. DOI: 10.54751/revistafoco.v16n11-125. Disponível em: <https://ojs.focopublicacoes.com.br/foco/article/view/3361>. Acesso em: 6 jan. 2025.

WINTERS, P. R. **Forecasting Sales by Exponentially Weighted Moving Averages.** *Management Science*, v. 6, n.3, p.324-342, 1960.

ZANIN, Vanclei. **Análise do padrão sazonal dos preços ao produtor de arroz no estado do Rio Grande do Sul.** *Revista de Economia e Agronegócio*, v. 21, n. 2, 2023. Disponível em: <https://periodicos.ufv.br/rea/article/view/15643/9574>. Acesso em: 6 jan. 2025.