

MODELO ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM (ANFIS) PARA PREDIÇÃO DO PREÇO DO CAFÉ.

ELIMAR VELOSO CONCEIÇÃO

UNIVERSIDADE DE SÃO PAULO (USP)

FABIANO GASTI LIMA

UNIVERSIDADE DE SÃO PAULO (USP)

RAFAEL DE FREITAS SOUZA

UNIVERSIDADE DE SÃO PAULO (USP)

MODELO ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM (ANFIS) PARA PREDIÇÃO DO PREÇO DO CAFÉ

1. INTRODUÇÃO

As operações inerentes ao setor agroindustrial constituem uma rede essencial de atividades com impacto significativo na economia em níveis local, regional e nacional. Historicamente, em períodos de instabilidade econômica, o agronegócio tem se destacado como um dos pilares impulsionadores de diversos indicadores econômicos, incluindo o Produto Interno Bruto (PIB) (Ribeiro & Coelho, 2020). Desta forma, a previsão de preços agrícolas é crucial para produtores, processadores, corretores e especuladores, que buscam fixar preços, cobrir necessidades e gerar resultados (Sabu & Kumar, 2020).

A previsão de preços agrícolas, emerge como uma tarefa de considerável complexidade, dada a intrincada dinâmica do mercado comercial e a variabilidade dos fatores que determinam sua trajetória de preços (Zeng et al., 2023). O café destaca-se como uma *commodity* agrícola de grande relevância nesse cenário (Xu & Zhang, 2022).

O café, uma das bebidas mais apreciadas no mundo, transcende fronteiras e é, portanto, uma das *commodities* mais produzidas e comercializadas, sendo apreciada em diversos territórios com diferentes históricos de cultivo (Barreto Peixoto et al., 2023; Magalhães Júnior et al., 2021).

Devido à sua marcante presença nos mercados, a indústria do café desempenha um papel relevante na economia global (Deina et al., 2022). O consumo doméstico e a exportação de café impactam diretamente no resultado da balança comercial internacional do país (Hundie & Biratu, 2022). No entanto, as exportações de café estão suscetíveis a flutuações de preços, o que gera riscos para diversos envolvidos, desde produtores rurais a consumidores finais do produto, decorrentes das oscilações no mercado global (Deina et al., 2022).

Modelos de prognóstico são instrumentos matemáticos empregados para antever o padrão de um fenômeno, com o propósito de facilitar o processo de tomada de decisões (Deina et al., 2022; Petropoulos et al., 2022). Ribeiro e Coelho (2020) destacam a importância crucial da precisão das previsões, diretamente relacionada à qualidade do modelo adotado. Essas previsões são fundamentais em diversas áreas, incluindo formulação de políticas públicas, planejamento estratégico empresarial e tomada de decisões no ambiente corporativo.

Diversos estudos acadêmicos exploram a aplicação dos variados modelos de prognósticos combinados, tais como modelo de suavização exponencial, modelo Autoregressivo de Médias Móveis Integradas (ARIMA) e redes neurais na previsão de preços de commodities agrícolas.

Sabu e Kumar (2020) usou a combinação de modelos para a análise preditiva do preço de diversos produtos agrícolas, Zeng et al. (2023) para obter previsões robustas do preço futuro de commodities agrícolas, Deina et al. (2022) empregou uma metodologia de previsão de preços de café utilizando Redes Neurais Artificiais (RNAs) por meio de máquinas de aprendizado extremo, comparando-a com outros modelos preditivos.

A aprendizagem de máquina, um componente da inteligência artificial, é uma ferramenta que tem ganhado relevância e pode ser empregada para abordar diversos desafios inerentes à implementação de sistemas agrícolas baseados no conhecimento (Alves et al., 2022). As Redes Neurais Artificiais (RNAs) e os Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS) emergem como abordagens proeminentes entre as técnicas computacionais contemporâneas, dada sua capacidade robusta para lidar com modelagens não lineares e conjuntos de dados estocásticos de alta complexidade (Olatunji et al., 2022).

Olatunji et al. (2022) utilizaram o modelo ANFIS para prever os parâmetros do processo de extração do óleo de casca de uva, obtendo resultados positivos. Igwilo et al. (2022) utilizou o modelo ANFIS para a modelagem da produção de açúcares fermentáveis. Não existem estudos que tenham avaliado a eficácia preditiva do Modelo Adaptivo Neuro Fuzzy (ANFIS) utilizando o Modelo de Agrupamento Subtrativo (SC) para a série temporal de café em coco.

Este trabalho se destaca pela originalidade de avaliar se o modelo ANFIS apresenta maior eficiência preditiva na análise de séries temporais sujeitas a flutuações de preços no mercado de café, em comparação com outros modelos de previsão consolidados.

Neste artigo, além da implementação dos modelos lineares e não lineares, como Suavização Exponencial (ETS), Modelo Autoregressivo de Médias Móveis Integradas (ARIMA) e Redes Neurais, realizamos uma análise comparativa para determinar se o Modelo Fuzzy (MF) apresenta um resultado mais vantajoso. Nosso objetivo é identificar o modelo que apresenta o menor Erro Percentual Absoluto Médio (MAPE) entre os dados reais e de previsão.

Esta pesquisa contribui para o entendimento e aprimoramento da previsão de preços cadeia do café, abordando uma lacuna existente na literatura, buscando enfrentar os desafios complexos e variáveis inerentes a este mercado. As contribuições abrangem o âmbito acadêmico, gerencial e do mercado, oferecendo *insights* valiosos que podem influenciar práticas e decisões estratégicas no setor cafeeiro.

Para alcançar o objetivo proposto, a próxima seção traz a revisão teórica dos modelos preditivos de séries temporais. A terceira seção apresenta os procedimentos metodológicos que permitiram a construção do modelo empírico proposto. Os resultados são apresentados e discutidos na quarta seção. Na quinta seção traz as conclusões finais com as implicações do estudo, limitações e sugestões para novas pesquisas.

2. REFERENCIAL TEÓRICO

Os modelos de previsão, enquanto ferramentas matemáticas, desempenham um papel crucial na antecipação do comportamento de fenômenos, proporcionando uma base analítica sólida para informar o processo decisório (Deina et al., 2022). A teoria de previsão é fundamentada na premissa de que a informação atual e passada pode ser utilizada para realizar projeções sobre eventos futuros (Petropoulos et al., 2022).

Dentre os variados modelos de previsão, destaca-se os modelos clássicos de predição, sendo eles: modelo de suavização exponencial (ETS), o Modelo Autoregressivo de Médias Móveis Integradas (ARIMA), as redes neurais e o Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS) (Adedeji et al., 2020; Deina et al., 2022; Hussain et al., 2022; Petropoulos et al., 2022; Zeng et al., 2023; Zhang et al., 2023).

2.1 Modelos clássicos de predição

A suavização exponencial é uma técnica amplamente empregada em diversas áreas organizacionais, como gestão de estoques, programação e administração de receitas, devido à sua robustez e facilidade de implementação (Svetunkov et al., 2022; Petropoulos et al., 2022; Deina et al., 2022). Essa abordagem baseia-se na média ponderada das observações passadas, em que os pesos diminuem exponencialmente à medida que nos afastamos das observações mais recentes (Petropoulos et al., 2022). Uma das abordagens comuns na suavização exponencial é a decomposição da série temporal em três componentes - Erro, Tendência e Sazonalidade - conhecida como ETS (Erro, Tendência e Sazonalidade), onde cada componente pode assumir valores (N) - nenhum, (A) - aditivo e (M) - multiplicativo (Svetunkov et al., 2022). O modelo ETS pode ser representado algebricamente pela Equação 1.

$$Y_t = (l_{t-1} + b_{t-1}) + \epsilon_t \quad (1)$$

Onde Y_t é a observação no período t , l_{t-1} é o nível na época $t - 1$, b_{t-1} é a tendência no período $t - 1$, e ϵ_t é o erro no período t .

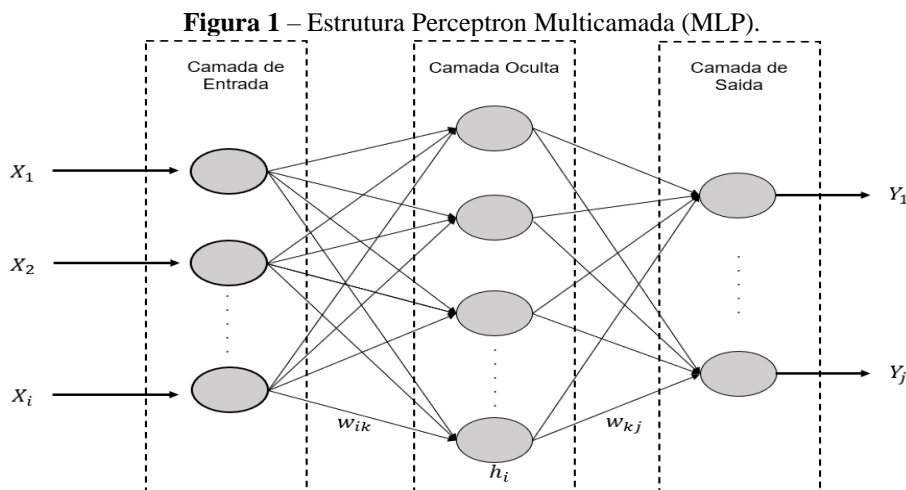
O modelo ARIMA é uma combinação dos modelos AR (Autoregressivo) e MA (Médias Móveis), complementada pela operação de diferenciação (Deina et al., 2022). Representado pela notação ARIMA(p, d, q), onde p é a ordem da parte autoregressiva, d é a ordem da diferenciação e q é a ordem da parte de média móvel (Petropoulos et al., 2022). A equação geral para um modelo ARIMA(p, d, q) é dada pela Equação 2.

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} + \epsilon_t \quad (2)$$

Onde Y_t é a série temporal no tempo t , c é a constante, $\phi_1, \phi_2, \dots, \phi_p$ são coeficiente autorregressivos, ϵ_t é o termo do erro no tempo t e $\theta_1, \theta_2, \dots, \theta_q$ são os coeficientes relacionados a média móvel.

Para aprimorar a capacidade preditiva dos modelos de regressão, como os de séries temporais, a literatura propõe várias abordagens, incluindo conjuntos de regressão. Essa técnica, fundamentada no princípio de aprendizado de máquina, visa superar as limitações dos modelos isolados (Ribeiro & Coelho, 2020). As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano, capazes de aproximar e estimar funções utilizando múltiplos valores independentes (Ali et al., 2023). Elas processam informações e aprendem a partir dos dados disponíveis, destacando-se pelos avanços na inteligência artificial (Xu & Zhang, 2022).

Com o progresso nessa área, surgiram algoritmos de aprendizado de máquina (ML) que superam os métodos tradicionais, especialmente em lidar com sistemas não lineares (Zhang et al., 2023). Alves et al. (2022) aplicaram técnicas de aprendizagem de máquina na agricultura de precisão do café para otimizar a gestão da cultura cafeeira. As RNAs não dependem de pressupostos de linearidade, sendo capazes de identificar padrões complexos entre as entradas (Ali et al., 2023). O Perceptron Multicamadas (MLP) é o tipo mais comum de RNA, como discutido por İltüzler (2022), cuja estrutura básica é ilustrada na Figura 1.



Fonte: Elaborado pelos autores.

As entradas são introduzidas na primeira camada (X_i), conhecida como camada de entrada, enquanto as saídas da rede são geradas na última camada (Y_j), chamada de camada de

saída. Entre essas camadas, encontram-se camadas ocultas com diversos neurônios (h_i), cuja configuração é ajustada durante o processo de aprendizado.

İltüzer (2022) ainda demonstra que a unidade fundamental no processamento de uma arquitetura MLP é o neurônio, o qual, por meio de conexões ponderadas (pesos, w), estabelece ligações com cada neurônio na camada seguinte, caracterizando assim uma conexão total entre eles. Cada neurônio utiliza uma função de ativação não linear, denotada por ϕ , que transforma os sinais ponderados antes de transmiti-los à camada subsequente. Dessa maneira, as entradas (X_i) são encaminhadas à camada oculta por meio de pesos (w_{ik}), e os neurônios na camada oculta, conforme expresso na Equação 3, são então direcionados à camada de saída (Y_j) com pesos (w_{kj}), como evidenciado pela Equação 4.

$$h_k = \phi(\sum_i w_{ik}x_i + b_1) \quad (3)$$

$$y_j = \phi(\sum_k w_{kj}h_k + b_2) \quad (4)$$

Onde b_1 e b_2 são os termos de polarização da camada oculta e ϕ é a função de ativação.

Sabu e Kumar (2020) utilizou métodos preditivos para previsão de produtos agrícolas, em que, o modelo de rede neural foi considerado o melhor modelo que se ajusta aos dados.

Svetunkov et al. (2022) e Nunes et al. (2023) destacam que a escolha do modelo dentro da estrutura ETS é fundamentada nos critérios de informação de Akaike (Akaike, 1974), onde o modelo com o menor AIC é selecionado e subsequentemente aplicado para fins de previsão. A Equação 5 demonstra o cálculo do AIC.

$$AIC = 2k + 2l(\theta) \quad (5)$$

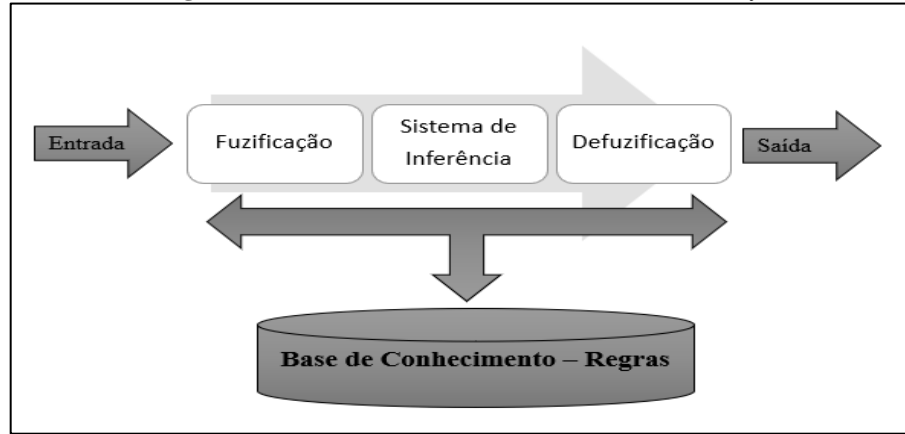
Onde k é o número de parâmetros estimados e $l(\theta)$ refere-se à log-verossimilhança, uma medida calculada para os dados a partir do vetor de parâmetros θ .

2.2 Conceitos de Lógica Fuzzy

Nas definições da teoria dos conjuntos da lógica clássica ou determinística, tem como fundamento que a o grau de pertinência de cada elemento de um conjunto é igual a 0 ou 1, ou seja, o elemento pertence inteiramente ao conjunto ou ele não pertence inteiramente a um conjunto (Więckowski & Wątróbski, 2021). Pela ótica dos conjuntos fuzzy, o grau de pertinência de cada elemento em um conjunto fuzzy varia de 0 até 1, ou seja, o elemento pertence parcialmente (ou até integralmente) ao conjunto (Es-sabery & Hair, 2019; Reyes-García & Torres-García, 2022). Madanda et al. (2023) destacam que os conjuntos fuzzy abrangem as mesmas questões da lógica clássica, porém oferecem uma ampla gama de possibilidades de respostas adicionais.

A lógica fuzzy (FL) como uma ferramenta derivada da lógica humana e da verdade parcial, forneceu uma base para o desenvolvimento de sistemas de inferência fuzzy (FIS). O FIS utiliza um conjunto de regras difusas se-então para reconhecer as características de um fenômeno (Zhang et al., 2023). A Figura 2 demonstra a estrutura básica de um Sistema de Inferência Fuzzy.

Figura 2 – Estrutura de um Sistema de Inferência Fuzzy.



Fonte: Elaborado pelos autores.

Segundo Ali et al. (2023) as cinco componentes essenciais de um Sistema de Inferência Fuzzy (FIS) compreendem: a Base de Conhecimento, que engloba as regras "se-então" fundamentadas no conhecimento humano; o Mecanismo de Inferência, responsável por aplicar as regras da Base de Conhecimento para gerar saídas fuzzy; as Entradas, as quais são processadas por conjuntos fuzzy e funções de pertinência; as Saídas, resultantes das regras e das entradas processadas; e as Regras de Controle, que determinam a aplicação das regras da Base de Conhecimento.

No desenvolvimento de sistemas fuzzy, é crucial extrair regras eficazes e escolher funções de pertinência eficientes. Qualquer perturbação na seleção desses elementos pode impactar significativamente o desempenho do sistema, levando a erros substanciais (Zhang et al., 2023).

2.5 Adaptive Neuro-Fuzzy Inference System (ANFIS)

O ANFIS é um modelo que emprega lógica fuzzy para desenvolver sistemas de regras, incorporando informações do modelo de previsão para aprimorar as funções de pertinência. Para ajustar as variáveis dessas funções, são aplicados métodos que se fundamentam em Redes Neurais Artificiais (RNAs), dada a natureza adaptativa do ANFIS, que opera como um sistema fuzzy (Olatunji et al., 2022).

Os esforços para modelar problemas complexos e altamente não lineares através do sistema de inferência fuzzy culminaram na introdução do sistema de inferência neuro-fuzzy adaptativo (ANFIS), que combina elementos de FIS e RNA de maneira adaptativa (Zhang et al., 2023). De maneira determinante, o ANFIS se destaca ao expressar e aplicar com facilidade modelos probabilísticos, conferindo-lhe flexibilidade nesse contexto (Li et al., 2024).

As regras do tipo IF-THEN fuzzy são comumente extraídas de conjuntos de dados que descrevem o evento em questão. No caso de um Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS), as expressões a seguir introduzem um modelo que combina elementos de redes neurais e lógica fuzzy. Nesse contexto, X_1 e X_2 representam as variáveis de entrada, enquanto f_1 , f_2 , f_3 e f_4 denota a variável de saída. O modelo algébrico emprega funções matemáticas e lógicas conforme apresentado nas Equações 6, 7, 8 e 9.

$$R_1: \text{Se } X_1 \text{ é } \varphi_{\tilde{F}_1} \text{ e } X_2 \text{ é } \varphi_{\tilde{F}_3} \text{ então } f_1 = w_1 X_1 + w_1 X_2 + r_1 \quad (6)$$

$$R_2: \text{Se } X_1 \text{ é } \varphi_{\tilde{F}_2} \text{ e } X_2 \text{ é } \varphi_{\tilde{F}_4} \text{ então } f_2 = w_2 X_1 + w_2 X_2 + r_2 \quad (7)$$

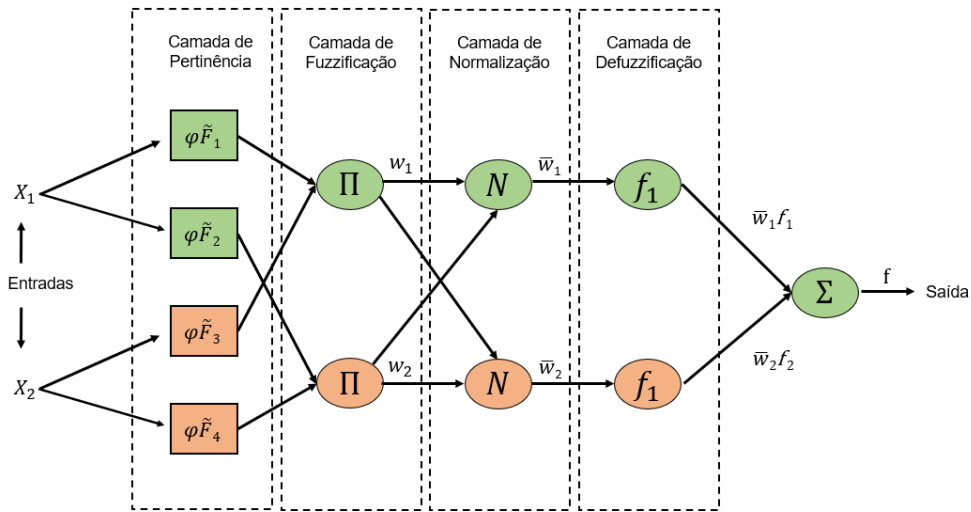
$$R_3: \text{Se } X_1 \text{ é } \varphi_{\tilde{F}_1} \text{ e } X_2 \text{ é } \varphi_{\tilde{F}_4} \text{ então } f_3 = w_1 X_1 + w_2 X_2 + r_3 \quad (8)$$

$$R_4: \text{Se } X_1 \text{ é } \varphi_{\tilde{F}_2} \text{ e } X_2 \text{ é } \varphi_{\tilde{F}_3} \text{ então } f_4 = w_2 X_1 + w_1 X_2 + r_4 \quad (9)$$

Onde X_1 e X_2 são as variáveis de entrada, $\varphi\tilde{F}_1$, $\varphi\tilde{F}_2$, $\varphi\tilde{F}_3$ e $\varphi\tilde{F}_4$ são funções de pertinência fuzzy, w_1 e w_2 são pesos associados às variáveis de entrada e r_1, r_2, r_3 e r_4 é o termo da constante adaptativa que é incorporada ao modelo.

A metodologia ANFIS, fundamentada no sistema de inferência fuzzy Takagi-Sugeno, é configurada como uma rede composta por cinco camadas. Nesse arranjo, destaca-se a adaptabilidade presente nas camadas primeira e quarta, enquanto as demais permanecem fixas e não adaptativas (Adedeji et al., 2020). Atualmente, é amplamente reconhecido como um dos algoritmos de aprendizado de máquina mais eficientes para lidar com problemas complexos de regressão (Zhang et al., 2023). A Figura 3 apresenta uma estrutura Adaptive Neuro-Fuzzy Inference System (ANFIS) com duas variáveis de entrada.

Figura 3 – Estrutura ANFIS com duas variáveis de entrada.



Fonte: Elaborado pelos autores.

Zhang et al. (2023) destacam que nas unidades adaptativas (indicadas por quadrados na figura), são utilizadas funções de pertinência variadas, tais como, função de pertinência gaussianas, trapezoidais, triangulares entre outras. Essas funções passam por um processo de treinamento conduzido por um algoritmo apropriado, transpassando pelos nós das cinco camadas, conforme apresentado por Olatunji et al. (2022)

Na primeira camada, todo nó i é um nó adaptativo que segue conforme Equação 10

$$O_{i1} = \varphi\tilde{F}_i(X_i) \quad (10)$$

Onde: O_{i1} é os valores atribuídos para os nós i da primeira camada e $\varphi\tilde{F}_i(X_i)$ é a função de pertinência de associado as variáveis de entrada (X_i) no conjunto, para cada associação ao conjunto fuzzy \tilde{F}_i .

A segunda camada, cada nós i (Π) representa a força do disparo fuzzy correspondente, conforme apresentado pela Equação 11

$$O_{i2} = w_i \quad (11)$$

Na terceira camada, cada nó i (N) calcula a intensidade de disparo normalizada, representada pela Equação 12 como:

$$O_i^3 = \bar{w}_i = \frac{w_i}{\sum_{j=1}^h w_j} \quad (12)$$

Onde h representa o número de nós nesta camada.

A quarta camada (f) corresponde à unidade de processamento adaptativo, que implementa uma função linear definida pela Equação 13.

$$O_i^4 = \bar{w}_i f_i = \bar{w}(p_i u_1 + q_i u_2 + r_i) \quad (13)$$

Os parâmetros p_i , q_i e r_i são ajustáveis e determinam a resposta da função. O conjunto desses parâmetros nesta camada é chamado de elementos consequentes. Esta é uma função que pode ser modelada linearmente, desde que descreva o comportamento do sistema dentro da região difusa especificada pela regra antecedente i .

Por fim, a quinta camada (Σ) compreende na saída geral ou variável de resposta (f) que é constituída pela soma de todos os sinais de entrada, conforme Equação 14.

$$f = O_i^5 = \sum_i \bar{w}_i \times f_i = \frac{\sum_i w_i \times f_i}{\sum_i w_i} \quad (14)$$

O resultado da rede (f) é expresso como a soma de todos os sinais recebidos, acrescidos de (z_t) como ruído branco, conforme apresentado na Equação 15 por Zanganeh e Chaji (2024)

$$f = \frac{w_1}{w_1+w_2} f_1 + \frac{w_2}{w_1+w_2} f_2 = \bar{w}_1 f_1 + \bar{w}_2 f_2 = \bar{w}_1 p_1(x_{t-1}) + \bar{w}_1 p_2(x_{t-1}) + \bar{w}_1 r_1 + \bar{w}_2 p_1(x_{t-2}) + \bar{w}_2 p_2(x_{t-2}) + \bar{w}_2 r_1 + \bar{w}_2 r_2 + z_t \quad (15)$$

Em modelos ANFIS, o número adequado de regras *se-então* é crucial para o desempenho. Muitas regras resultam em complexidade excessiva, enquanto poucas levam a uma descrição inadequada do problema. Para abordar isso, os dados de entrada-saída são categorizados por métodos de agrupamento, permitindo o uso de regras específicas para cada categoria. Isso simplifica o processo de treinamento e equilibra a complexidade do Sistema (Zhang et al., 2023).

No contexto de análise de agrupamento, o algoritmo de agrupamento (SC) destaca-se como uma abordagem eficiente e versátil para a identificação de padrões e regiões densas em conjuntos de dados (Askari, 2021).

Os algoritmos de agrupamento têm como objetivo identificar áreas densas em conjuntos de dados, utilizando medidas de similaridade entre os pontos de dados como critérios fundamentais (Askari, 2021). O algoritmo de agrupamento subtrativo (SC) constitui uma extensão do método de classificação, com o propósito de determinar o número de clusters e a posição inicial do centro de cada cluster.

Nesse método, um conjunto de pontos de dados de entrada é examinado, onde todos os pontos são inicialmente considerados como candidatos a centro de cluster (Hussain et al., 2022). O algoritmo analisa o potencial de cada ponto em relação aos seus vizinhos imediatos, determinando, desse modo, o ponto de dados com o maior número de vizinhos como o centro do primeiro cluster (Zhang et al., 2023). Hussain et al. (2022) apresentam a Equação 16 para a definição do ponto de dados

$$PD_i = \sum_{j=1}^n \exp\left(-\frac{\|a_i - a_j\|^2}{(r_1/2)^2}\right) \quad (16)$$

Onde: PD_i representa o potencial dos dados em relação ao ponto de dados a_i , enquanto r é o raio que delimita a faixa de influência para determinar uma vizinhança em que, pontos de dados fora desta região, têm poucas contribuições para o potencial de a_i e $\| \cdot \|$ indica a distância euclidiana.

Hussain et al. (2022) ainda destacam que Para determinar o centro adicional do cluster, o potencial PD i é recalculado para cada ponto de dados dentro de uma vizinhança, utilizando a seguinte Equação 17:

$$PD_i = PD_i - \widehat{PD}_1 \exp\left(-\frac{\|a_i - a_{c1}\|^2}{(r_2/2)^2}\right) \quad (17)$$

Onde: \widehat{PD}_1 representa o valor potencial do primeiro centro do cluster, r_2 é calculado como K vezes r_1 , onde K é igual a 1,5. Da mesma maneira, o próximo centro de cluster, denotado como a_{c1} , é determinado pela avaliação da densidade dos pontos de dados associados. Esse processo é iterativo, continuando até que todos os centros de cluster sejam gerados (Hussain et al., 2022).

Zhang et al. (2023) empregou algoritmos de aprendizado de máquina na previsão de propriedades termofísicas de nanofluidos híbridos de água e óxido. O ANFIS, utilizando o método de agrupamento por subtractive clustering (SC), destacou-se na precisão da determinação da densidade e viscosidade do fluido. Esses resultados sinalizam a eficácia do modelo, apontando para a promissora redução de custos e tempo em aplicações práticas.

3. PROCEDIMENTOS METODOLÓGICOS

A pesquisa apresentada é de natureza exploratória, visando identificar padrões, gerar ideias e formular hipóteses. Para alcançar esses objetivos, adota uma abordagem quantitativa para o levantamento e análise de dados. (GIL, 2008). O método utilizado está baseado em análise de séries temporais conforme apresentado por Box et al. (2013), De Gooijer e Hyndman, (2006), Hyndman e Athanasopoulos (2021) e Petropoulos et al. (2022)

3.1 Dados

Ao desenvolver um modelo preditivo, o propósito muitas vezes não se resume a uma acurada previsão de amostras já familiares, mas sim à obtenção de um modelo capaz de generalizar eficazmente para dados novos e não observados (Petropoulos et al., 2022).

Para a condução deste estudo, empregou-se a análise dos Preços Médios Recebidos pelos Agricultores (kg). Estes preços constituem um indicador significativo, obtido por meio de um levantamento dos valores percebidos pelos produtores durante a comercialização de sua safra de café em coco (IPEA, 2023).

Para avaliar o desempenho da amostra de um modelo preditivo, recorreremos a um conjunto de testes composto por dados não utilizados na fase de estimação do modelo. Nesse contexto, reservamos segmentos específicos dos dados para a construção dos modelos, enquanto outras porções são designadas para a avaliação do desempenho destes (Petropoulos et al., 2022).

A amostra deste estudo compreende 120 observações mensais (10 Anos) da série temporal dos Preços Recebidos pelo Produtor (IPEA, 2023). Foram utilizadas 90 observações para treinar o modelo (75%) – setembro/2013 a fevereiro/2021 e 30 observações para testar o modelo (25%) – março/2021 a agosto de 2023.

3.2 Método

A pesquisa no campo de previsão evoluiu do uso de modelos lineares convencionais para modelos inteligentes de previsão não linear. Enquanto os modelos lineares pressupõem uma relação linear entre os valores passados e os erros nos dados, os desafios apresentados por cenários do mundo real são inerentemente não lineares (Adedeji et al., 2020).

Para avaliar a eficiência do modelo, iniciaremos a predição por modelos lineares, de suavização exponencial, Modelo de média móvel integrado autorregressivo (ARIMA) avaliando sua acuracidade. Na sequência implementaremos modelos não lineares de redes neurais, finalizando o estudo com a implementação do modelo Adaptive Neuro-Fuzzy Inference System (ANFIS).

Utilizaremos para medir a acuracidade do modelo a *Mean Absolute Percentage Error* (MAPE). O MAPE é um método amplamente utilizado para medir a precisão da previsão, determinando o tamanho do erro em porcentagem, conforme apresentado na Equação 18 (Hussain et al., 2022a; Ribeiro & Coelho, 2020). Outros métodos amplamente utilizados também são apresentados na Equação 19, 20 e 21.

$$MAE = \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{n} \right| \quad (18)$$

$$MASE = \frac{\frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|}{\frac{1}{N-1} \sum_{t=2}^N |y_t - y_{t-1}|} \quad (19)$$

$$MAPE = 100 \times \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (20)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (21)$$

Onde: y_i é o valor observado no momento i e \hat{y}_i é o valor previsto no momento i .

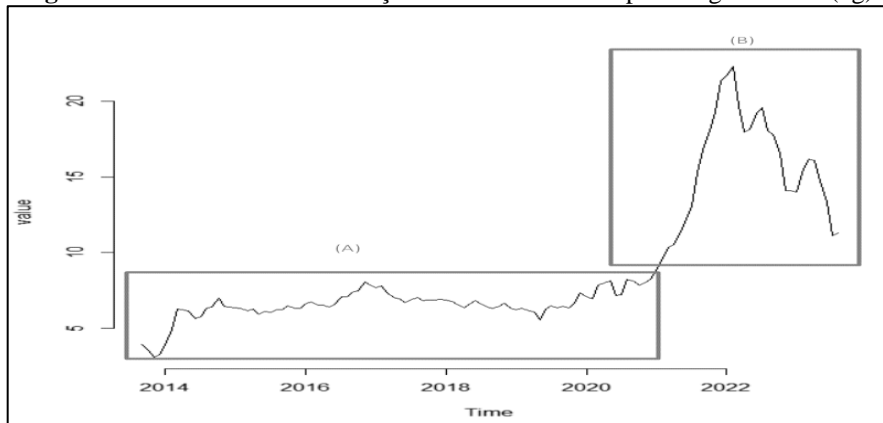
4. RESULTADOS E DISCUSSÕES

Nesta seção, apresentamos os resultados derivados da análise e processamento dos dados históricos referentes aos Preços Médios Recebidos pelos Agricultores (kg). Em seguida, serão expostas as projeções resultantes da aplicação dos métodos propostos.

Os dados temporais são comumente suscetíveis a intervenções imprevistas e incontrolláveis, originando várias formas de observações anômalas. Devido à complexidade inerente aos problemas específicos de determinados domínios, a elaboração de uma definição unificada para anomalias, sobretudo adaptada à aplicação em questão, apresenta-se como um desafio, podendo comprometer o processo de predição (Petropoulos et al., 2022).

A Figura 4 apresenta a série histórica do Preços Médios Recebidos pelos Agricultores (kg) compreendido entre o período de setembro de 2013 a agosto de 2023.

Figura 4 – Série Histórica do Preços Médios Recebidos pelos Agricultores (kg).

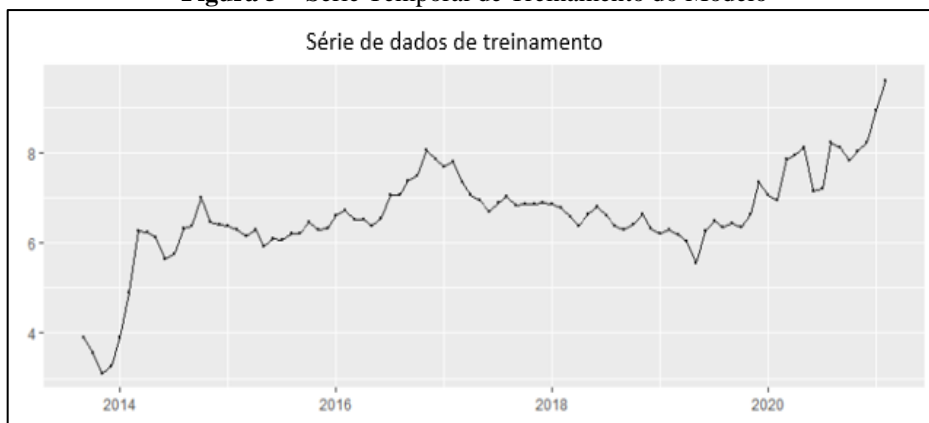


Fonte: Elaborado pelos autores por meio do software RStudio®.

A série histórica dos Preços Médios Recebidos pelos Agricultores (em quilogramas) exibe, de forma visual, uma tendência linear durante o período de março de 2014 a fevereiro de 2021. No entanto, destaca-se uma notória alteração de trajetória na série analisada, o que pode comprometer o processo de predição, como apontado por Petropoulos et al. (2022).

Na etapa subsequente, procederemos à segregação dos dados de treinamento. A Figura 5, a seguir, ilustra os dados específicos destinados ao treinamento que serão empregados nos modelos de predição.

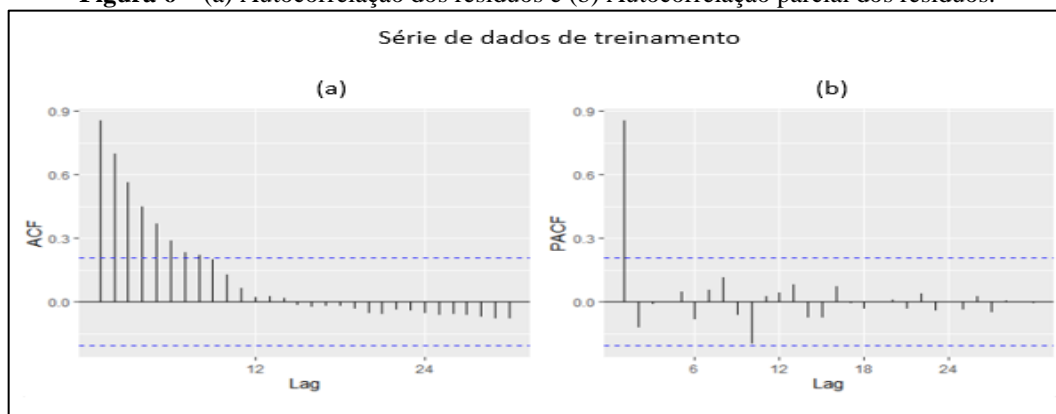
Figura 5 – Série Temporal de Treinamento do Modelo



Fonte: Elaborado pelos autores por meio do software RStudio®.

O gráfico exibe um conjunto de dados composto por 90 observações, correspondendo a 75% do período total, abrangendo de setembro de 2013 a fevereiro de 2021, utilizado para o treinamento do modelo. Na sequência, a Figura 6a ilustra o gráfico de autocorrelação dos resíduos (ACF), enquanto a Figura 6b apresenta a autocorrelação parcial desses resíduos (PACF).

Figura 6 – (a) Autocorrelação dos resíduos e (b) Autocorrelação parcial dos resíduos.



Fonte: Elaborado pelos autores por meio do software RStudio®.

No que concerne ao ACF, a redução nas barras sugere a falta de autocorrelação significativa na série temporal residual. Quanto ao PACF, a correlação com a defasagem zero (primeira barra) indica a relação direta entre a observação atual e a observação anterior, excluindo as influências das demais defasagens.

4.1 Modelos Clássicos de Predição

Os parâmetros dos modelos de predição, sejam modelos lineares de suavização exponencial, Modelo de média móvel integrado autorregressivo (ARIMA) e modelos não lineares de redes neurais são apresentados na Tabela 1.

Tabela 1 – Resultado dos Modelos Clássicos de Predição.

| Modelo | Parâmetro | Valores |
|--------|----------------------------|---------------|
| SES | ETS | {A, N, N} |
| ARIMA | Termo autorregressivo | {0, 1, 1} |
| | Termo sazonal | {0, 0, 2} |
| | Frequência Sazonal | {12} |
| RN | Modelo | NNAR(1, 1, 2) |
| | Frequência Sazonal | {12} |
| MLP | Número de unidades ocultas | {5} |
| | Número de repetições | {20} |
| | Frequência Sazonal | {12} |
| ELM | Número de unidades ocultas | {80} |
| | Número de repetições | {20} |
| | Frequência Sazonal | {12} |

Fonte: Elaborado pelos autores.

O modelo de suavização exponencial, derivado através da minimização do Critério de Informação de Akaike (AIC) para um valor mínimo de 234.0554, como evidenciado por Svetunkov et al. (2022), foi identificado como um modelo ETS(A, N, N). Isso implica que o componente de Erro é aditivo (A), enquanto os componentes de Tendência e Sazonalidade são neutros (N).

O Modelo de Média Móvel Integrado Autorregressivo (ARIMA) aplicado à amostra analisada, selecionado com base no menor Critério de Informação de Akaike (AIC), foi identificado como ARIMA(0,1,1)(0,0,2)[12] *with drift*. Essa configuração abrange aspectos não sazonais e sazonais, incorporando um termo adicional de "drift" para acomodar uma possível tendência linear na série temporal. Para esta amostra, o modelo que tem melhor acuracidade, utiliza uma diferenciação de primeira ordem, um termo de médias móveis de ordem 1 e um termo de deriva, juntamente com uma componente sazonal de período 12 para modelar uma série temporal.

As Redes Neurais *Feedforward* (RN) que obteve melhor acuracidade foi o NNAR(1,1,2)[12]. O modelo resultante foi dedicado à análise de séries temporais, com ênfase em padrões autorregressivos e sazonais. Configurado com ordem autoregressiva de 1, diferenciação de 1, duas camadas ocultas e uma sazonalidade de 12 períodos.

Já para o modelo de Perceptron Multicamada (MLP), este foi ajustado com 5 nós ocultos e 20 repetições. A modelagem foi realizada nas diferenças da série temporal (D1), incorporando *lags* univariados de ordem 5 e 7. E por fim o modelo por Máquinas de Aprendizado Extremo (ELM) com 80 nós ocultos e 20 repetições. A modelagem foi realizada nas diferenças da série temporal (D1), incorporando *lags* univariados de ordem 5 e 7. A Tabela 2 sintetiza e compara os modelos.

Tabela 2 – MAPE do Modelo ETS

| Modelo | Série de treinamento | | | | Série de teste | | | |
|----------|----------------------|--------|--------|--------|----------------|--------|--------|--------|
| | MAPE | RMSE | MASE | MAE | MAPE | RMSE | MASE | MAE |
| SES(ETS) | 4,1496 | 0,3742 | 0,3035 | 0,2647 | 36,9434 | 7,2133 | 5,1400 | 6,3744 |
| ARIMA | 4,0948 | 0,3404 | 0,2981 | 0,2600 | 32,8515 | 6,6777 | 6,5921 | 5,7499 |
| RN | 3,0371 | 0,2932 | 0,2500 | 0,2180 | 15,5833 | 3,1885 | 2,9343 | 2,5594 |
| MLP | 3,0176 | 0,2621 | 0,2384 | 0,1890 | 32,6332 | 6,9029 | 6,8304 | 5,9577 |
| ELM | 4,3167 | 0,3284 | 0,3067 | 0,2431 | 4.157,0371 | 6,6746 | 6,5776 | 5,7373 |

Fonte: Elaborado pelos autores.

Os resultados do ETS indicam que o modelo apresentou um erro percentual de 4,1496% na série de treinamento. No entanto, ao ser aplicado à série de teste, o percentual de erro aumentou significativamente para 36,9434%. Este aumento substancial sugere uma reduzida precisão do modelo preditivo ao ser confrontado com dados de teste, ressaltando limitações em sua acurácia para a previsão de séries temporais fora da amostra de treinamento.

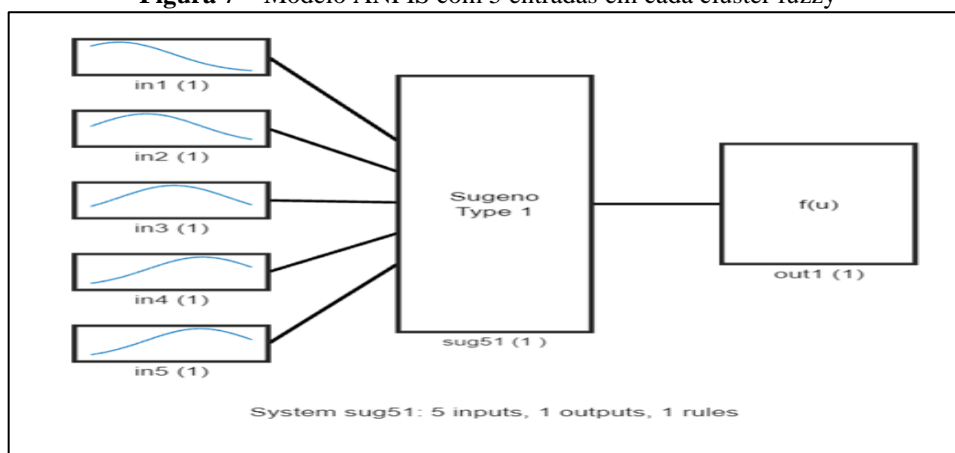
O modelo ARIMA(0,1,1)(0,0,2)[12] *with drift* registrou um erro percentual de 4,0948% na série de treinamento. Contudo, ao ser empregado na série de teste, o percentual de erro experimentou um aumento, atingindo 32,8515%. Esse acréscimo expressivo sugere uma diminuição na precisão do modelo preditivo quando confrontado com dados não empregados previamente, destacando limitações em sua capacidade de previsão para a série em análise.

Entre os modelos de redes neurais testados, aquele que apresentou o desempenho mais significativo foi a rede neural Feedforward, evidenciando um índice MAPE de 15,58326%.

4.4 Modelo ANFIS (Adaptive Neuro-Fuzzy Inference System)

Os dados foram submetidos à análise pelo sistema ANFIS através da aplicação do modelo de agrupamento subtrativo. Nesse modelo, é empregada uma função de pertinência gaussiana para a associação de entrada em cada cluster fuzzy. O Modelo ANFIS foi gerado pela Matlab® e é apresentado na Figura 7.

Figura 7 – Modelo ANFIS com 5 entradas em cada cluster fuzzy



Fonte: Elaborado pelos autores por meio do software Matlab®.

O modelo gerado é constituído por cinco variáveis de entrada, as quais empregam funções de pertinência gaussianas, juntamente com uma regra para o sistema de inferência. Além disso, o modelo incorpora uma variável de saída para a realização das inferências desejadas. Foi utilizado um raio de influência de 0,90 foi utilizado durante a execução desse processo. A Tabela 3 sintetiza os resultados do modelo ANFIS.

Tabela 3 – MAPE do modelo ANFIS


| Série | MAPE |
|-------------|--------|
| Treinamento | 3,4595 |
| Testes | 7,9194 |

Fonte: Elaborado pelos autores.

É relevante ressaltar que o modelo ANFIS subtrativo alcançou a melhor acurácia, apresentando um índice MAPE de 3,4595% na série de treinamento e 7,9194% na série de teste.

Esses resultados destacam a eficácia e precisão do modelo, consolidando sua performance superior. A Figura 8 apresenta o desempenho do modelo com a série de treinamento do café.

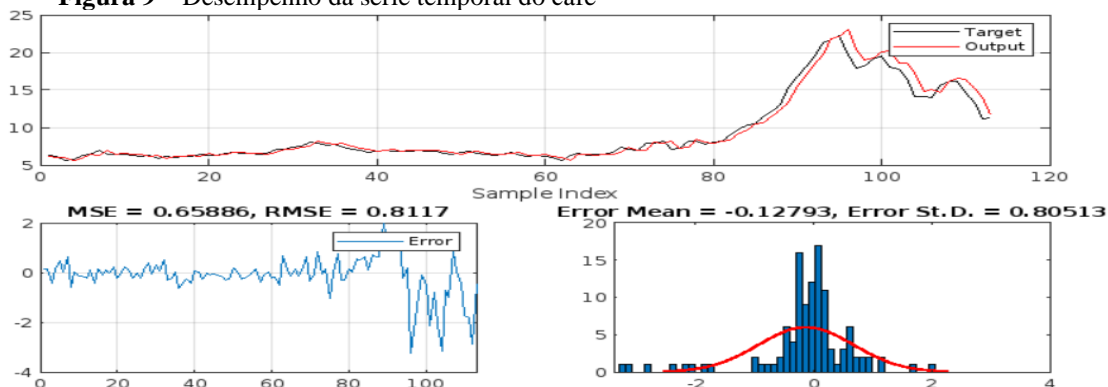
Figura 8 – Desempenho da série temporal de teste do café



Fonte: Elaborado pelos autores por meio do software Matlab®.

O modelo resultante do Adaptive Neuro-Fuzzy Inference System (ANFIS), empregando o método de agrupamento subtrativo, demonstrou um desempenho superior em comparação aos modelos lineares e não lineares tradicionais. Essa constatação ressalta a eficácia do ANFIS com agrupamento subtrativo como abordagem preditiva, superando alternativas convencionais na análise de séries temporais relacionadas aos preços de café. O desempenho da base Teste é evidenciado na Figura 9.

Figura 9 – Desempenho da série temporal do café



Fonte: Elaborado pelos autores por meio do software Matlab.

Os resultados obtidos destacam o desempenho do modelo ANFIS, particularmente quando aplicado em conjunto com o método de agrupamento subtrativo. Especificamente para a série temporal de café analisada, evidencia-se que esse método de agrupamento proporciona melhor desempenho em comparação com outras abordagens. A Tabela 4 resume os resultados alcançados.

Tabela 4 – MAPE comparativa dos modelos de predição.

| Tipo de Rede | MAPE % | |
|--|-------------|------------|
| | Treinamento | Teste |
| ETS (Erro, Tendência e Sazonalidade) | | |
| ARIMA | 4,0948 | 32,8515 |
| Feedforward | 3,0371 | 15,5833 |
| Perceptron Multicamada (MLP) | 3,0176 | 32,6332 |
| Máquinas de Aprendizagem Extremo (ELM) | 4,3167 | 4.157,0371 |
| ANIFS (Agrupamento Subtrativo) | 3,4595 | 7,9194 |

Fonte: Elaborado pelos autores.

Os resultados destacam a importância de uma avaliação criteriosa do método de previsão que seja capaz de capturar de forma precisa as características intrínsecas do ativo em questão. Essa abordagem torna-se fundamental para garantir uma previsão mais robusta e alinhada com a complexidade inerente à série temporal analisada.

5. CONCLUSÕES

Esta pesquisa destaca a importância da previsão de preços agrícolas, com ênfase na relevância do café como uma comodidade de impacto na economia global. As flutuações nos mercados globais tornam as exportações de café suscetíveis a riscos significativos, afetando produtores, processadores e outros agentes do setor. Nesse contexto desafiador, os modelos de previsão surgem como ferramentas fundamentais para a tomada de decisões estratégicas.

O objetivo foi avaliar a eficiência preditiva do modelo Adaptive Neuro-Fuzzy Inference System (ANFIS) em comparação com abordagens convencionais, incluindo Suavização Exponencial (ETS), Modelo Autoregressivo de Médias Móveis Integradas (ARIMA) e Redes Neurais. A análise comparativa visa identificar qual desses modelos oferece maior precisão na antecipação das flutuações de preços em séries temporais do mercado de café.

Os resultados obtidos revelam que o ANFIS se destaca, demonstrando superioridade em eficiência preditiva em comparação com os métodos convencionais mencionados. Esta constatação ressalta a capacidade do ANFIS em lidar com a complexidade intrínseca às variações de preços do café, consolidando-se como uma ferramenta eficaz na antecipação dessas oscilações.

Este trabalho contribui significativamente para o conhecimento acadêmico, oferecendo *insights* valiosos sobre a escolha apropriada de modelos preditivos para séries temporais, mas também apresenta implicações práticas para o setor gerencial, promovendo avanços significativos na compreensão e antecipação das flutuações nos preços do café, considerando que ele desempenha um papel estratégico e exerce um impacto direto na economia internacional.

Como limitação do trabalho destacamos a natureza dinâmica dos mercados agrícolas também pode introduzir complexidades não totalmente consideradas neste estudo. Ademais, a precisão dos resultados está intrinsecamente vinculada à qualidade e à disponibilidade dos dados históricos, ressaltando a importância de fontes de informação robustas.

Para estudos subsequentes, recomenda-se avaliar a eficácia de modelos ANFIS com diferentes métodos de agrupamento, como *k-means* ou *fuzzy c-means*, ampliando a compreensão sobre as nuances do processo de previsão.

REFERÊNCIAS

- Adedeji, P. A., Akinlabi, S., Madushele, N., & Olatunji, O. O. (2020). Wind turbine power output very short-term forecast: A comparative study of data clustering techniques in a PSO-ANFIS model. *Journal of Cleaner Production*, 254, 120135. <https://doi.org/10.1016/j.jclepro.2020.120135>
- Akaike, H. (1974). *A New Look at the Statistical Model Identification* (p. 215–222). https://doi.org/10.1007/978-1-4612-1694-0_16
- Ali, A. A., Milad, A., Hussein, A., Md Yusoff, N. I., & Heneash, U. (2023). Predicting pavement condition index based on the utilization of machine learning techniques: A case study. *Journal of Road Engineering*, 3(3), 266–278. <https://doi.org/10.1016/j.jreng.2023.04.002>
- Alves, M. de C., Sanches, L., Pozza, E. A., Pozza, A. A. A., & Silva, F. M. da. (2022). The role of machine learning on Arabica coffee crop yield based on remote sensing and mineral

- nutrition monitoring. *Biosystems Engineering*, 221, 81–104. <https://doi.org/10.1016/j.biosystemseng.2022.06.014>
- Askari, S. (2021). Fuzzy C-Means clustering algorithm for data with unequal cluster sizes and contaminated with noise and outliers: Review and development. *Expert Systems with Applications*, 165, 113856. <https://doi.org/10.1016/j.eswa.2020.113856>
- Barreto Peixoto, J. A., Silva, J. F., Oliveira, M. B. P. P., & Alves, R. C. (2023). Sustainability issues along the coffee chain: From the field to the cup. *Comprehensive Reviews in Food Science and Food Safety*, 22(1), 287–332. <https://doi.org/10.1111/1541-4337.13069>
- Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2013). Time series analysis: Forecasting and control: Fourth edition. Em *Time Series Analysis: Forecasting and Control: Fourth Edition*. John Wiley & Sons. <https://doi.org/10.1002/9781118619193>
- De Gooijer, J. G., & Hyndman, R. J. (2006). 25 years of time series forecasting. *International Journal of Forecasting*, 22(3), 443–473. <https://doi.org/10.1016/j.ijforecast.2006.01.001>
- Deina, C., do Amaral Prates, M. H., Alves, C. H. R., Martins, M. S. R., Trojan, F., Stevan, S. L., & Siqueira, H. V. (2022). A methodology for coffee price forecasting based on extreme learning machines. *Information Processing in Agriculture*, 9(4), 556–565. <https://doi.org/10.1016/j.inpa.2021.07.003>
- Es-sabery, F., & Hair, A. (2019). A MapReduce C4.5 Decision Tree Algorithm Based on Fuzzy Rule-Based System. *Fuzzy Information and Engineering*, 11(4), 446–473. <https://doi.org/10.1080/16168658.2020.1756099>
- Gil, A. C. (2008). *Métodos e técnicas de pesquisa social* (6^o ed). Atlas.
- Hundie, S. K., & Biratu, B. (2022). Response of Ethiopian coffee price to the world coffee price: Evidence from dynamic ARDL simulations and nonlinear ARDL cointegration. *Cogent Economics & Finance*, 10(1). <https://doi.org/10.1080/23322039.2022.2114168>
- Hussain, W., Merigó, J., Raza, M., & Gao, H. (2022a). A new QoS prediction model using hybrid IOWA-ANFIS with fuzzy C-means, subtractive clustering and grid partitioning. *Information Sciences*, 584, 280–300. <https://doi.org/10.1016/j.ins.2021.10.054>
- Hussain, W., Merigó, J., Raza, M., & Gao, H. (2022b). A new QoS prediction model using hybrid IOWA-ANFIS with fuzzy C-means, subtractive clustering and grid partitioning. *Information Sciences*, 584, 280–300. <https://doi.org/10.1016/j.ins.2021.10.054>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: principles and practice* (3rd edition). OTexts.
- Igwilo, C. N., Ude, N. C., Onoh, I. M., Enekwe, C. B., & Alieze, B. A. (2022). RSM, ANN and ANFIS applications in modeling fermentable sugar production from enzymatic hydrolysis of *Colocynthis Vulgaris* Shrad seeds shell. *Bioresource Technology Reports*, 18, 101056. <https://doi.org/10.1016/j.biteb.2022.101056>
- İltüzer, Z. (2022). Option pricing with neural networks vs. Black-Scholes under different volatility forecasting approaches for BIST 30 index options. *Borsa Istanbul Review*, 22(4), 725–742. <https://doi.org/10.1016/j.bir.2021.12.001>
- IPEA. (2023). *Preço médio recebido pelo agricultor: café em coco (kg / renda - Paraná)*. <http://www.ipeadata.gov.br/Default.aspx>
- Li, Y., Bao, L., Huang, K., Wu, C., & Li, X. (2024). RSFIN: A Rule Search-based Fuzzy Inference Network for performance prediction of configurable software systems. *Journal of Systems and Software*, 209, 111913. <https://doi.org/10.1016/j.jss.2023.111913>
- Madanda, V. C., Sengani, F., & Mulenga, F. (2023). Applications of Fuzzy Theory-Based Approaches in Tunnelling Geomechanics: a State-of-the-Art Review. *Mining, Metallurgy & Exploration*, 40(3), 819–837. <https://doi.org/10.1007/s42461-023-00767-5>
- Magalhães Júnior, A. I., de Carvalho Neto, D. P., de Melo Pereira, G. V., da Silva Vale, A., Medina, J. D. C., de Carvalho, J. C., & Soccol, C. R. (2021). A critical techno-economic analysis of coffee processing utilizing a modern fermentation system: Implications for

- specialty coffee production. *Food and Bioproducts Processing*, 125, 14–21. <https://doi.org/10.1016/j.fbp.2020.10.010>
- Nunes, P. M., Carozzo-Todaro, M. E., & Proenca, T. (2023). Need satisfaction and frustration scale (NSFS): adaptation and validation for Brazilian gig work context. *Management Research: Journal of the Iberoamerican Academy of Management*, 21(2), 145–166. <https://doi.org/10.1108/MRJIAM-06-2022-1320>
- Olatunji, O. M., Horsfall, I. T., Ukoha-Onuoha, E., & Osa-aria, K. (2022). Application of hybrid ANFIS-based non-linear regression modeling to predict the %oil yield from grape peels: Effect of process parameters and FIS generation techniques. *Cleaner Engineering and Technology*, 6, 100371. <https://doi.org/10.1016/j.clet.2021.100371>
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Ben Taieb, S., Bergmeir, C., Bessa, R. J., Bijak, J., Boylan, J. E., Browell, J., Carnevale, C., Castle, J. L., Cirillo, P., Clements, M. P., Cordeiro, C., Cyrino Oliveira, F. L., De Baets, S., Dokumentov, A., ... Ziel, F. (2022). Forecasting: theory and practice. *International Journal of Forecasting*, 38(3), 705–871. <https://doi.org/10.1016/j.ijforecast.2021.11.001>
- Reyes-García, C. A., & Torres-García, A. A. (2022). Fuzzy logic and fuzzy systems. Em *Biosignal Processing and Classification Using Computational Learning and Intelligence* (p. 153–176). Elsevier. <https://doi.org/10.1016/B978-0-12-820125-1.00020-8>
- Ribeiro, M. H. D. M., & Coelho, L. dos S. (2020). Ensemble approach based on bagging, boosting and stacking for short-term prediction in agribusiness time series. *Applied Soft Computing*, 86, 105837. <https://doi.org/10.1016/j.asoc.2019.105837>
- Sabu, K. M., & Kumar, T. K. M. (2020). Predictive analytics in Agriculture: Forecasting prices of Arecanuts in Kerala. *Procedia Computer Science*, 171, 699–708. <https://doi.org/10.1016/j.procs.2020.04.076>
- Svetunkov, I., Kourentzes, N., & Ord, J. K. (2022). Complex exponential smoothing. *Naval Research Logistics (NRL)*, 69(8), 1108–1123. <https://doi.org/10.1002/nav.22074>
- Więckowski, J., & Wątróbski, J. (2021). How to determine complex MCDM model in the COMET method? Automotive sport measurement case study. *Procedia Computer Science*, 192, 376–386. <https://doi.org/10.1016/j.procs.2021.08.039>
- Xu, X., & Zhang, Y. (2022). Commodity price forecasting via neural networks for coffee, corn, cotton, oats, soybeans, soybean oil, sugar, and wheat. *Intelligent Systems in Accounting, Finance and Management*, 29(3), 169–181. <https://doi.org/10.1002/isaf.1519>
- Zanganeh, M., & Chaji, A. (2024). A new aspect of the ApEn application to improve the PSO-ANFIS model to forecast Caspian Sea levels. *Regional Studies in Marine Science*, 69, 103347. <https://doi.org/10.1016/j.rsma.2023.103347>
- Zeng, L., Ling, L., Zhang, D., & Jiang, W. (2023). Optimal forecast combination based on PSO-CS approach for daily agricultural future prices forecasting. *Applied Soft Computing*, 132, 109833. <https://doi.org/10.1016/j.asoc.2022.109833>
- Zhang, Z., Al-Bahrani, M., Ruhani, B., Heybatian Ghalehsalimi, H., Zandy Ilghani, N., Maleki, H., Ahmad, N., Nasajpour-Esfahani, N., & Toghraie, D. (2023). Optimized ANFIS models based on grid partitioning, subtractive clustering, and fuzzy C-means to precise prediction of thermophysical properties of hybrid nanofluids. *Chemical Engineering Journal*, 471, 144362. <https://doi.org/10.1016/j.cej.2023.144362>