

## Previsão do Preço do Milho Baseado na Otimização de Hiperparâmetros Optuna e na Rede Neural Cnn-Lstm

## Maize Price Forecasting Based on Optuna Hyperparameter Optimization and Cnn-Lstm Neural Network

**Dalila Natalia Costa da Luz**

Mestranda no Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio (PPGTCA)  
Graduação em Engenheira de Produção pela Universidade Tecnológica Federal do Paraná  
E-mail: dalilanataliacostadaluz@gmail.com

**José Airton Azevedo dos Santos**

Doutor em Engenharia Elétrica, Universidade Federal de Santa Catarina  
Professor da Universidade Tecnológica Federal do Paraná  
E-mail: airton@utfpr.edu.br

---

**Endereço: Dalila Natalia Costa da Luz**

Universidade Tecnológica Federal do Paraná – Campus  
Medianeira - Avenida Brasil, 4232 CEP 85884-000 -  
Caixa Postal 271 - Medianeira - PR - Brasil.

**Endereço: José Airton Azevedo dos Santos**

Universidade Tecnológica Federal do Paraná – Campus  
Medianeira - Avenida Brasil, 4232 CEP 85884-000 -  
Caixa Postal 271 - Medianeira - PR - Brasil

**Editor-Chefe: Dr. Tonny Kerley de Alencar Rodrigues**

**Artigo recebido em 14/11/2025. Última versão  
recebida em 30/01/2025. Aprovado em 31/01/2025.**

**Avaliado pelo sistema Triple Review: a) Desk Review  
pelo Editor-Chefe; e b) Double Blind Review  
(avaliação cega por dois avaliadores da área).**

**Revisão: Gramatical, Normativa e de Formatação**

## RESUMO

Este trabalho tem como objetivo propor, para previsão do preço do milho no estado do Paraná, um modelo que combina a rede híbrida CNN-LSTM (*Convolutional Neural Network - Long Short-Term Memory*) com a otimização de hiperparâmetros por meio da biblioteca Optuna. A base de dados, disponibilizada pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), apresenta uma série histórica do preço do milho, no estado do Paraná, no período entre jan/2014 e jul/2024. Modelos de previsão CNN-LSTM e SARIMA (*Seasonal Autoregressive Integrated Moving Average*) foram implementados na linguagem de programação Python. Resultados de previsão, dos dois modelos, foram comparados por meio das métricas: MAE, RMSE e MAPE. Verificou-se, para um horizonte de 6 meses, que o modelo, proposto neste trabalho, apresentou o melhor desempenho de previsão (MAE (R\$) =1.67, RMSE (R\$)=2.06 e MAPE (%)=2.95).

**Palavras-chave:** Redes Híbridas. Séries Temporais. Keras. Python.

## ABSTRACT

This work aims to propose, for corn price forecasting in the state of Paraná, a model that combines the hybrid CNN-LSTM (Convolutional Neural Network - Long Short-Term Memory) network with hyperparameter optimization through Optuna. The database, made available by the Brazilian Agricultural Research Corporation (EMBRAPA), presents a historical series of corn prices in the state of Paraná, from Jan/2014 to Jul/2024. CNN-LSTM and SARIMA (Seasonal Autoregressive Integrated Moving Average) forecasting models were implemented in the Python programming language. Forecasting results of the two models were compared using the metrics: MAE, RMSE and MAPE. It was found, for a 6-month horizon, that the model proposed in this work presented the best forecasting performance (MAE (R\$) =1.67, RMSE (R\$)=2.06 e MAPE (%)=2.95).

**Keywords:** Hybrid Networks. Time Series. Keras. Python.

## 1 INTRODUÇÃO

A cadeia produtiva do milho, um dos cereais mais cultivados no mundo, é muito importante para o agronegócio brasileiro. O milho, em termos de produção e área plantada, fica somente atrás da soja. Em conjunto com a soja, é um insumo básico para avicultura e suinocultura. Portanto, tem influência direta, por ser essencial na produção de rações, no preço das carnes (SANTOS, 2021; ATLAS, 2021).

Os maiores produtores mundiais de milho são Estados Unidos, China, Brasil, União Europeia e Índia. No Brasil, os maiores produtores de milho, segundo a safra de 2022/23, são os estados: Mato Grosso, Paraná, Mato Grosso do Sul, Goiás e Minas Gerais. O cultivo do milho permite três safras anuais, sendo a segunda de maior produção (BOSHIERO, 2024).

O milho, por ser uma cultura de alta produtividade, está sujeito a oscilações no seu preço. Essa oscilação, nos preços dessa *commodity*, impacta diretamente toda a cadeia produtiva, influenciando custos e margens de lucro dos produtores e indústrias associadas. Portanto, torna-se necessário desenvolver e aperfeiçoar técnicas de previsão de preços que auxiliem produtores, investidores e formuladores de políticas públicas na tomada de decisão (SANTOS, 2021; SANTOS *et al.* 2023).

Dentre as técnicas utilizadas, para previsão de preços, estão a rede neural híbrida CNN-LSTM e o modelo SARIMA. A rede CNN-LSTM, para séries temporais, combina a capacidade das redes convolucionais (CNN) de extrair padrões locais e características relevantes dos dados com a habilidade das redes LSTM de modelar dependências temporais de longo prazo. Já o modelo SARIMA, extensão do ARIMA que incorpora componentes sazonais, é especialmente eficaz na modelagem e previsão de séries temporais que apresentam padrões recorrentes ao longo do tempo (MEDEIROS, 2024; STENGHELE *et al.*, 2020).

A integração de arquiteturas híbridas de redes neurais, como a CNN-LSTM, com bibliotecas avançadas de otimização de hiperparâmetros, como o Optuna, pode contribuir significativamente para o desenvolvimento de modelos preditivos mais precisos e com maior capacidade de generalização (DENG *et al.*, 2024).

Vários trabalhos, apresentados na literatura, utilizaram modelos, de séries temporais, para preverem o preço do milho. Dentre eles podem-se citar: Cas (2018) que utilizou um modelo ARIMA (*Autoregressive Moving Average*) para prever o preço da *commodity* milho brasileira. O período de análise foi de mar/2004 a mar/2016. Concluiu, para um horizonte de curto prazo, que o modelo ARIMA apresentou uma previsão satisfatória para o preço do milho. Almeida (2018) utilizou modelos de previsão ARIMA e SARIMA para previsão do

preço do milho no estado do Ceará. Santos (2021) utilizou redes neurais BLSTM (*Bidirectional Long Short-Term Memory*) e MLP (*Multilayer Perception*), para previsão do preço do milho no estado do Paraná. Verificou, para um período de 6 meses, que os dois modelos apresentaram estimativas confiáveis. Tibulo e Carli *et al.* (2014) utilizaram modelos, de Séries Temporais ARIMA e de Alisamento Exponencial de Holt-Winters, para preverem o preço do milho no Rio Grande do Sul. Observaram que o modelo Holt-Winters aditivo apresentou melhores resultados. Já Santos *et al.* (2023) utilizaram redes neurais LSTM e modelos SARIMA para prever o preço do milho, no estado do Rio Grande do Sul, no período entre 2011 e 2021. Concluíram que o modelo LSTM apresentou melhor desempenho.

Nesse contexto, este trabalho tem como objetivo propor, para previsão do preço do milho no estado do Paraná, um modelo que combina a rede híbrida CNN-LSTM com a otimização de hiperparâmetros por meio do Optuna.

## 2 FUNDAMENTAÇÃO TEÓRICA

### 2.1 Rede CNN-LSTM

A rede CNN-LSTM baseia-se na integração da rede neural convolucional (CNN) com a rede de memória de longo e curto prazo (LSTM). Essa abordagem híbrida é amplamente adotada para o processamento de séries temporais complexas, como previsão de demandas, detecção de anomalias ou análise de sinais financeiros. Essa combinação aproveita as forças complementares das duas arquiteturas: a CNN, proposta por Lecun *et al.* (1998), foca na extração automática de padrões locais e hierárquicos, enquanto a LSTM, proposta por Hochreiter e Scimdhuber (1997), gerencia a propagação de informações ao longo da sequência temporal, mitigando problemas como o *vanishing gradient* em redes recorrentes tradicionais (ZHA *et al.*, 2022; SANTOS, 2022; LIVIERIS *et al.*, 2020, LU *et al.*, 2020).

### 2.2 SARIMA

O modelo ARIMA é um dos mais populares modelos estatísticos utilizados na análise de séries temporais. Este modelo, proposto por Box-Jenkins na década de 1970, originou-se dos modelos autorregressivos (AR), médias móveis (MA) e de combinação de modelos AR e MA (ARMA). Neste estudo, para realizar as previsões do preço do milho no estado do

Paraná, utilizou-se o modelo ARIMA com sazonalidade (SARIMA) (WALTER *et al.*, 2013; MONTGOMERY *et al.*, 2008; BOX; JENKINS, 1976 ).

A equação do modelo SARIMA, definido como SARIMA(p,d,q)(P,D,Q), é dada por (SANTOS; CHAUCOSKI, 2020):

$$\varnothing(B)\varnothing(B^s)\Delta^d\Delta_s^D X_t = \theta(B)\theta(B^s)\varepsilon_t \quad 1$$

Onde:

$\varnothing(B) = 1 - \varnothing_1 B - \dots - \varnothing_p B^p$  - é o operador autorregressivo estacionário de ordem  $p$ ;

$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$  - é o operador de médias móveis invertível de ordem  $q$ ;

$\varnothing(B^s) = 1 - \varnothing_1 B^s - \dots - \varnothing_p B^{sp}$  - é o operador autorregressivo sazonal de ordem  $P$ ;

$\theta(B^s) = 1 - \theta_1 B^s - \dots - \theta_q B^{sq}$  - é o operador de médias móveis sazonal de ordem  $Q$ ,

$\Delta^d = (1 - B)^d$  -  $d$  indicando o número de diferenças;

$\Delta_s^D = (1 - B^s)^D$  -  $D$  indicando o número de diferenças sazonais;

$\varepsilon_t$  - representa o ruído branco com média zero.

## 2.3 Optuna

O desempenho dos algoritmos *deep learning* dependem de como são ajustados os seus hiperparâmetros. Em redes neurais artificiais, vários hiperparâmetros necessitam ser ajustados, por exemplo, a taxa de aprendizagem, o número de épocas de treinamento, a função de ativação, entre outros. Ajustes manuais são ineficientes e propensos a erros, especialmente em espaços de busca de alta dimensionalidade, cujas combinações subótimas podem levar a *overfitting*, *underfitting* ou treinamento excessivamente demorado.

Nesse contexto, técnicas de otimização automática de hiperparâmetros emergem como soluções essenciais para explorar eficientemente o espaço de configurações possíveis. O Optuna é uma biblioteca *open-source* em Python projetada especificamente para o ajuste automático de hiperparâmetros em tarefas de *machine learning* e *deep learning*, permitindo uma busca inteligente e eficiente por meio de algoritmos bayesianos (DENG *et al.*, 2024).

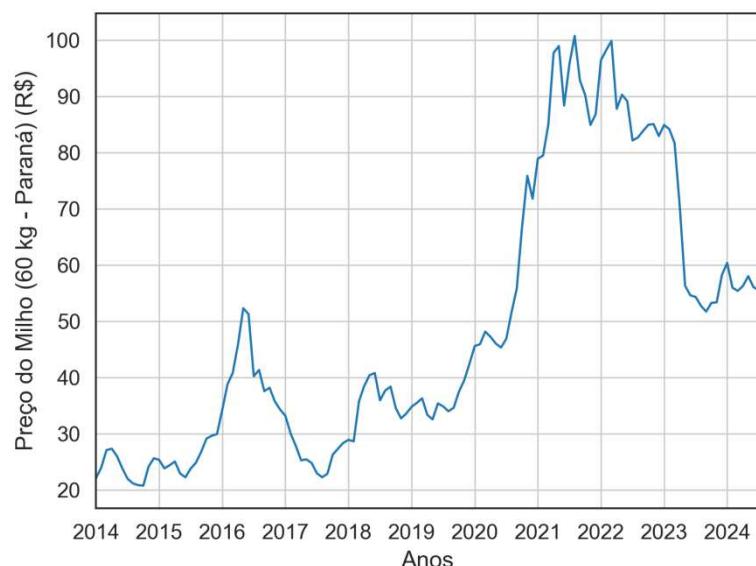
### 3 MATERIAIS E MÉTODOS

Aborda-se, nesta seção, a metodologia utilizada neste trabalho, apresentando a base de dados, as etapas do trabalho, bem como as métricas utilizadas.

#### 3.1 Base de dados

Utilizou-se, para previsão, no estado do Paraná, do preço do milho em grãos no varejo (60kg - R\$), uma base de dados com 127 meses (Jan/2014 - Jul/2024) obtida da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). Na Figura 1 apresenta-se a série histórica do preço do milho.

**Figura 1 – Série histórica do preço do milho**



Fonte: Os autores.

A série histórica do preço do milho no Paraná entre 2014 e 2024 revela forte volatilidade, com destaque para os picos registrados em 2021 e 2022, quando o valor ultrapassou R\$ 90 por saca de 60 kg. Os picos de preço do milho em 2021 e 2022 coincidem com o período da pandemia de Covid-19 (11 de março de 2020 até 05 de maio de 2023 (OPAS, 2023)) e estão fortemente associados aos impactos econômicos e logísticos causados por ela.

Observa-se, que os dados, para eliminar as diferenças de dimensão, foram normalizados por meio da função MinMax (ARUKUMAR *et al.*, 2022; POLO *et al.*, 2024) (Equação 2).

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad 2$$

Onde  $x$  são dados da série original,  $x_{\min}$  é valor mínimo da série temporal e  $x_{\max}$  o valor máximo.

### 3.2 Etapas do trabalho

Basicamente este trabalho foi dividido em três etapas. Na primeira etapa, com o objetivo de obter informações sobre os dados obtidos da EMBRAPA, realizou-se uma análise exploratória (Etapa de Análise de Dados). Na sequência, na Etapa de Treinamento e Validação, implementaram-se os modelos SARIMA e CNN-LSTM. Na última etapa, Etapa de Teste, realizaram-se os testes nos modelos SARIMA e CNN-LSTM. Analisando-se seus desempenhos, na previsão do preço do milho, por meio de dados que não participaram do processo de treinamento e validação

### 3.3 Métricas

O desempenho dos modelos, implementados neste trabalho, foram avaliados pelas seguintes métricas (OLIVEIRA; SANTOS, 2024; CANKURT; SUBASI, 2015):

*Mean Absolute Error (MAE):*

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)| (R\$) \quad 3$$

*Root Mean Squared Error (RMSE):*

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n ((y_i - \hat{y}_i)^2)} (R\$) \quad 4$$

*Mean Absolute Percent Error (MAPE):*

$$MAPE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)/y_i| \times 100(%) \quad 5$$

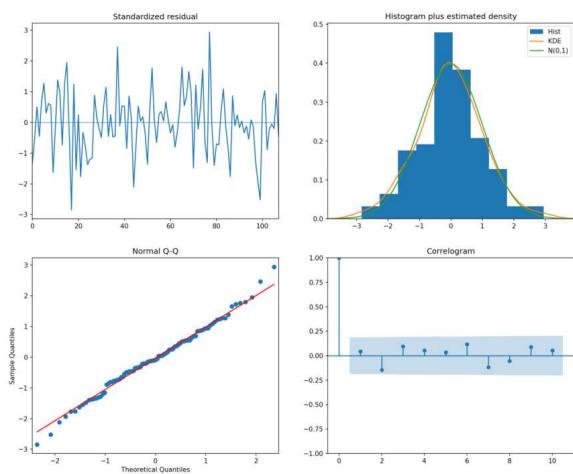
Onde:  $y_i$  é o valor real do período  $i$ ,  $\hat{y}_i$  é a previsão para o período  $i$  e  $n$  é o número de observações. Quanto mais próximo de zero, os valores de MAE, RMSE e MAPE, maior a precisão dos modelos (LU et al., 2020).

## 4 RESULTADOS E DISCUSSÕES

### 4.1 SARIMA

Inicialmente, na modelagem SARIMA, identificou-se, por meio do teste de AKAIKE (AIC) da biblioteca pmdarima, o modelo SARIMA(1,1,0)(3,1,1)<sub>12</sub>. Na sequência, a normalidade dos resíduos foi verificada por meio do teste de normalidade Jarque-Bera (*Jarque-Bera normality test*), que obteve um p-valor de 0.73. Observou-se, também, devido aos coeficientes de correlação não ultrapassarem os limites de confiança (*Correlogram* – Figura 2), que os resíduos não são autocorrelacionados. Portanto, os testes estatísticos realizados bem como o diagnóstico dos resíduos validaram o modelo proposto.

**Figura 2 – Gráficos do modelo SARIMA**



Fonte: Os autores.

### 4.2 CNN-LSTM

Na Etapa de Treinamento e Validação, com o objetivo de encontrar os melhores modelos de previsão, vários hiperparâmetros foram otimizados por meio do Optuna. Na Tabela 1, apresentam-se os hiperparâmetros, os intervalos de buscas e os parâmetros ótimos encontrados pelo Optuna. As redes neurais foram treinadas com 84 amostras (70%) e

validadas com 37 amostras (30%). Observa-se que para convergência do algoritmo de busca utilizou-se a métrica MAE.

**Tabela 1 – Parâmetros da rede CNN-LSTM**

Hiperparâmetro	Intervalo de Busca	Valores Ótimos
Epochs	[100,500]	300
<i>Batch</i>	[10,60]	55
<i>LSTM activation function</i>	[tanh,relu]	tanh
<i>Convolution layer kernel size</i>	[3,9]	3
<i>Convolution layer filters</i>	[8,128]	128
<i>Numbers of hidden units in LSTM layer</i>	[8,128]	128
<i>Pooling layer pool size</i>	[1,2]	1
<i>Dropout</i>	[0.1,0.5]	0.32
<i>Learning rate</i>	[0.00001,0.1]	0.00021
<i>Optimizer</i>	[RMSprop, Adam]	RMSprop

Fonte: Os autores.

Na sequência, realizaram-se previsões, do preço do milho, para os meses de fevereiro, março, abril, maio, junho e julho de 2024 (Conjunto de Teste), que não participaram da etapa de seleção dos hiperparâmetros (Tabela 2).

**Tabela 2 – Dados observados (EMBRAPA) e preditos (SARIMA e CNN-LSTM) – R\$**

MESES	EMBRAPA	SARIMA	CNN-LSTM
fev/24	55.98	60.5	56.26
mar/24	55.39	57.97	55.04
abr/24	56.28	54.54	55.23
mai/24	58.02	57.74	54.66
jun/24	56.07	57.74	54.01
jul/24	55.5	52.74	52.54

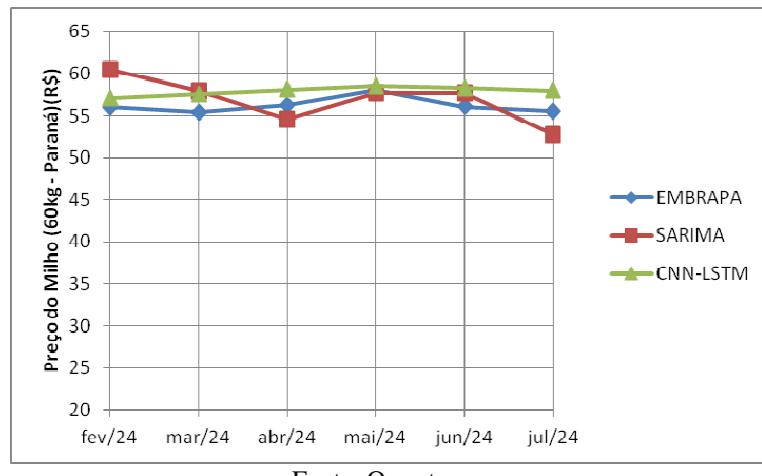
Fonte: Os autores.

Observa-se, a partir dos resultados apresentados na Tabela 2, que o modelo híbrido CNN-LSTM apresentou, quando comparado ao modelo estatístico SARIMA, valores preditos mais próximos aos observados pela EMBRAPA. Essa proximidade indica melhor capacidade da rede neural em capturar padrões complexos e não lineares nos preços do milho, refletindo maior precisão nas previsões.

Os resultados das previsões, em termos gráficos, são apresentados na Figura 3. Observa-se, desta figura, que o modelo CNN-LSTM acompanha de forma mais consistente a tendência dos preços reais (EMBRAPA), mantendo-se próximo aos valores observados ao longo do período. Já o modelo SARIMA tende a apresentar maiores desvios, notadamente nos

meses de fevereiro, abril e julho, nos quais os preços previstos se afastam mais dos valores reais.

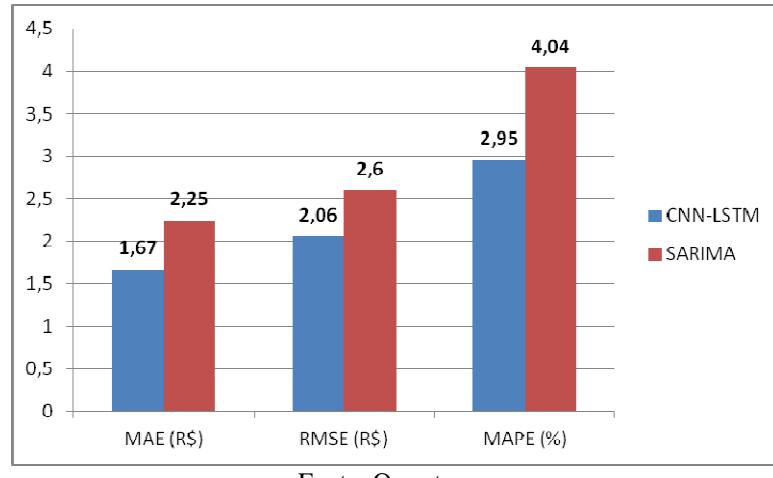
**Figura 3 – Resultados das previsões – Conjunto de Teste**



Fonte: Os autores.

Os resultados das métricas MAE, RMSE e MAPE, para o Conjunto de Teste, são apresentados na Figura 4.

**Figura 4 – Resultados das métricas – Conjunto de Teste**



Fonte: Os autores.

Os valores, apresentados na Figura 4, indicam que o modelo CNN-LSTM superou o SARIMA em todos os critérios avaliados. O MAE do CNN-LSTM foi de R\$ 1,67 contra R\$ 2,25 do SARIMA, evidenciando menor erro médio nas previsões do modelo híbrido. Da mesma forma, o RMSE do CNN-LSTM (R\$ 2,06) ficou abaixo do SARIMA (R\$ 2,6), o que reforça o menor desvio padrão dos erros e indica maior precisão, especialmente na presença de eventuais *outliers*.

Quanto ao MAPE, o valor para o CNN-LSTM foi de 2,95%, enquanto o SARIMA obteve 4,04%, mostrando que o erro relativo, em termos percentuais, também é

significativamente menor para o modelo de rede neural. Isso sugere maior capacidade de generalização do CNN-LSTM em relação ao SARIMA, além de maior robustez frente às variações no comportamento dos dados de preço do milho.

## 5 CONSIDERAÇÕES FINAIS

Este estudo propôs a utilização do modelo CNN-LSTM-Optuna para previsão do preço do milho no estado do Paraná, combinando a arquitetura híbrida CNN-LSTM com a otimização de hiperparâmetros por meio da biblioteca Optuna. A eficácia, do modelo proposto, foi avaliada por meio da comparação de desempenho entre a rede híbrida CNN-LSTM, otimizada com o Optuna, e o modelo SARIMA. Foram utilizados, na construção dos modelos, dados reais de preços do milho, coletados entre janeiro de 2014 e julho de 2024, totalizando 127 observações mensais, o que conferiu robustez à análise temporal.

Os resultados das previsões, dos dois modelos, foram avaliados no conjunto de teste (Fev/2024 a Jul/2024), utilizando as métricas MAE, RMSE e MAPE. Na comparação entre o modelo proposto e o tradicional SARIMA, o CNN-LSTM otimizado apresentou menor erro absoluto médio (MAE: R\$ 1,67), raiz do erro quadrático médio (RMSE: R\$ 2,06) e erro percentual absoluto médio (MAPE: 2,95%), enquanto o SARIMA obteve MAE de R\$ 2,25, RMSE de R\$ 2,60 e MAPE de 4,04%. Esses indicadores demonstram que a abordagem baseada em redes neurais híbridas, para um horizonte de seis meses, é mais eficaz para capturar a dinâmica dos preços do milho e oferecer previsões mais precisas.

Em síntese, este trabalho contribui com uma ferramenta de suporte potente e adaptável ao contexto agrícola, potencializando o apoio à tomada de decisões para produtores e agentes do setor. Propõe-se, como sugestão para trabalhos futuros, a aplicação e validação do modelo CNN-LSTM-Optuna em outras regiões produtoras de milho do país, a fim de testar sua generalização e robustez em diferentes dinâmicas de mercado e condições regionais.

## REFERÊNCIAS

- ALMEIDA, J. W. R. Previsão do preço do milho para o Estado do Ceará. [Dissertação]. 2018. Disponível em: <https://repositorio.ufc.br/handle/riufc/47153> > Acesso em: 6 set. 2024.
- ATLAS, S. E. **O Rio Grande do Sul é atualmente o sexto maior produtor de milho em grãos do Brasil.** Disponível em: <<https://atlassocioeconomico.rs.gov.br/milho>>. Acesso em: 28 jul. 2021.
- ARUNKUMAR, K. E.; KALAG, D. V.; KUMAR, C. M. S; KAWAJI, M.; BRENZA, M.



Comparative analysis of Gated Recurrent Units (GRU), long Short-Term memory (LSTM) cells, autoregressive Integrated moving average (ARIMA), seasonal autoregressive Integrated moving average (SARIMA) for forecasting COVID-19 trends. **Alexandria Engineering Journal**, 2022.

BOSCHIERO, B. N. **Quem são e quanto produzem os 5 maiores produtores de milho do mundo?** Disponível em: <<https://agroadvance.com.br/blog-5-maiores-produtores-de-milho-do-mundo/>> Acesso em: 6 set. 2024.

BOX, G. E. P.; JENKINS, G. M. **Time series analysis forecasting and control.** San Francisco: Holden-Day, 1976.

CANKURT, S.;SUBASI, A. Comparasion of linear regression and neural network models forecasting tourist arrivals to turkey. **Eurasian Journal of Science & Engineering**, 2015.

CAS, C. G. Aplicação do Modelo ARIMA para Previsão do Preço da Commodity Milho. **Revista Gepros**, v. 13, n. 1, 2018.

DENG, Z.; ZHOU, D.; KANG, Z.; DONG, H. Deep learning-based dynamic forecasting method and application for ultra-deep fractured reservoir production. **Frontiers in Energy Research**, 2024.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **MIT press**, v. 9, 1997.

LECUN, Y.; BOTTOU L.; BENGIO Y.; HAFFNER P. Gradient-based learning applied to document recognition., Proc. IEEE , v. 86, 1998.

LIVIERIS, I. E.; PINTELAS, E.; PINTELAS, P. A CNN–LSTM model for gold price time-series forecasting. **Neural Computing and Applications**, 2020.

LU, W.; LI, J.; SUN, A. A CNN–LSTM–based model to forecast stock prices. **Complexity**, 2020.

MEDEIROS, M. M. **Modelos de previsão de vazão afluente da UHE-Tucuruí: uma abordagem com redes neurais LSTM e CNN.** Disponível em: <[https://bdm.ufpa.br/bitstream/prefix/6518/1/TCC\\_ModelosPrevisaoVazao.pdf](https://bdm.ufpa.br/bitstream/prefix/6518/1/TCC_ModelosPrevisaoVazao.pdf)> Acesso em: 6 set. 2024.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting.** New Jersey: John Wiley& Sons. Inc, 2008.

OLIVEIRA, L.; SANTOS; J. A. A. Previsão do preço futuro do óleo de girassol: uma abordagem baseada no modelo CNN-Attention. **Revista Cereus**, 2024.

**OPAS. OMS declara fim da Emergência de Saúde Pública de Importância Internacional referente à COVID-19.** Site Institucional. Disponível em: <<https://www.paho.org/pt/noticias/5-5-2023-oms-declara-fim-da-emergencia-saude-publica-importancia-internacional-referente>>. Acesso em: 15 jan. 2024.

POLO, A. N. B.; SANTOS, J. A. A.; SANDMANN, A. Previsão do consumo de eletricidade da região sudeste: um estudo comparativo utilizando modelos univariado e multivariado. **RETEC.** vol. 12, 2024.

SANTOS, J. A. A. Aplicação de redes neurais artificiais na previsão do preço do milho no estado do Paraná. **Revista de Engenharia e Tecnologia**, v. 13, p. 124-134, 2021.

SANTOS, J. A. Previsão do preço do café arábica: uma aplicação de redes neurais CNN-BLSTM. **Research, Society and Development**, v. 11, 2022.

SANTOS, J. A. A.; CHAUCOSKI, Y. Previsão do Consumo de Energia Elétrica na Região Sudeste: Um Estudo de Caso Usando SARIMA e LSTM. **Revista Cereus**, v. 4, 2020.

SANTOS, J. A. A.; SANDMANN, A.; HLENKA, V.; HELLMANN, L.; HALLAL, R.; SANTOS, C. O. Previsão do preço do milho: uma comparação entre os modelos SARIMA e LSTM. **Peer Review**, v. 5, 2023.

STENGHELE, G ; SANTOS, J. A. A.; MIURA, F. S.; PASA, L. A.; SCHMIDT, C. A. Previsão do consumo de energia elétrica na região sudeste: um estudo de caso usando SARIMA. **Revista FSA**, v. 17, 2020.

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

WALTER, O. M. F. C.; HENNING, E.; MORO, G., SAMOHYL, R. W. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. **Exacta – EP**. vol. 11, 2013.

ZHA, W.; LIU, Y.; WAN, Y. Forecasting monthly gas field production based on the CNN-LSTM model. **Energy**, 2022.

**Como Referenciar este Artigo, conforme ABNT:**

LUZ, D. N. C; SANTOS. J. A. A. Previsão do Preço do Milho Baseado na Otimização de Hiperparâmetros Optuna e na Rede Neural Cnn-Lstm. **Rev. FSA**, Teresina, v. 23, n. 1, art. 5, p. 109-121, jan. 2026.

Contribuição dos Autores	D. N. C. Luz	J. A. A. Santos
1) concepção e planejamento.	X	X
2) análise e interpretação dos dados.	X	X
3) elaboração do rascunho ou na revisão crítica do conteúdo.	X	X
4) participação na aprovação da versão final do manuscrito.	X	X