

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREVISÃO DO PREÇO DO MILHO NO ESTADO DO PARANÁ

José Airton Azevedo dos Santos (UTFPR) E-mail: airton@utfpr.edu.br

Resumo: O milho, planta de origem Mesoamericana, é um dos cereais mais cultivados no mundo. Em virtude de sua capacidade nutricional é muito utilizado na alimentação humana e animal. A cadeia produtiva do milho é considerada, no agronegócio brasileiro, como uma das mais importantes. Neste contexto, o presente trabalho tem como objetivo avaliar a eficácia de modelos de Redes Neurais Artificiais (RNAs), para previsão do preço do milho no estado do Paraná. 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 2011 e 2020. Modelos de previsão, baseados em Redes Neurais BLSTM (*Bidirectional Long Short-Term Memory*) e MLP (*Multilayer Perception*), foram implementados na linguagem Python. Resultados obtidos, dos dois modelos, foram comparados. Verificou-se, para um horizonte de 6 meses, que os dois modelos de previsão fornecem estimativas confiáveis para o preço do milho.

Palavras-chave: Redes neurais artificiais; previsão de preço; milho.

APPLICATION OF ARTIFICIAL NEURAL NETWORKS IN PREDICTING THE PRICE OF MAIZE IN PARANÁ STATE

Abstract: Maize, a plant of Mesoamerican origin, is one of the most cultivated cereals in the world. Due to its nutritional capacity, it is widely used in human and animal food. The maize production chain is considered, in Brazilian agribusiness, as one of the most important. In this context, the present work aims to evaluate the effectiveness of models of Artificial Neural Networks (ANNs), for forecasting the price of maize in the state of Paraná. The database, made available by the Brazilian Agricultural Research Corporation (EMBRAPA), presents a historical series of the price of maize, in the state of Paraná, in the period between 2011 and 2020. Prediction models, based on BLSTM (Bidirectional Long Short-Term Memory) and MLP (Multilayer Perception) Neural Networks, were implemented in the Python language. Results obtained from the two models were compared. It was found, for a 6-month horizon, that the two forecast models provide reliable estimates for the price of maize.

Keywords: Artificial neural networks; price forecast; maize.

1. INTRODUÇÃO

A agricultura brasileira vem cada vez mais se desenvolvendo apoiada na utilização de técnicas modernas de plantio e colheita, gerando com isso maiores ganhos de produtividade e competitividade no mercado externo. O milho possui um alto potencial produtivo e é bastante responsivo à tecnologia. Destaca-se, em relação aos demais grãos, em termos de produção e área plantada, ficando apenas atrás da soja. A cultura encontra-se dispersa espacialmente por praticamente todo o território nacional (CHIODI, 2006; ROCHA, 2019).

O milho possui muitos nutrientes, fibras, carboidratos, vitaminas A e B, proteínas e minerais como o ferro, fósforo, potássio e cálcio. Possui também um bom potencial calórico, sendo constituído de grandes quantidades de açúcares e gorduras (MINHA VIDA, 2016). Em virtude de sua capacidade nutricional é muito utilizado na alimentação humana e animal (ALVES; AMARAL, 2011).

O milho é produzido em todo o Brasil e consumido mundialmente. Por ser uma cultura de alta produtividade, está sujeito a variações no seu preço. Um dos principais destinos, da safra do milho, são as indústrias de rações para animais. Portanto, o estudo das projeções do preço do cereal é importante, para produtores e gestores das indústrias de ração, no processo de

tomada de decisão. Considera-se que a previsão é capaz de fazer a diferença em uma tomada de decisão, auxiliando o usuário a se posicionar e confirmar ou corrigir expectativas (PINHEIRO, 2017). Segundo Marchezan (2010) a previsão não constitui um fim em si, mas um meio de fornecer informações e subsídios para uma consequente tomada de decisão, visando atingir determinados objetivos. As Redes Neurais Artificiais (RNAs) podem ser utilizadas como ferramentas de apoio no processo de tomada de decisão. São ferramentas de grande importância, em um sistema de planejamento, pois direcionam a melhor forma de aproveitar todos os recursos disponíveis.

Segundo Haykin (2001), as Redes Neurais Artificiais são abstrações de Redes Neurais Biológicas. São capazes de memorizar, analisar e processar um grande número de dados obtidos de um experimento. Seu objetivo não é replicar, mas sim servir de modelo para o aprendizado e resoluções de problemas complexos (SEBASTIAN, 2016; ABRAHAM et al.; 2019; BASTIANI et al., 2018).

As RNAs têm sido utilizadas com sucesso em tarefas de predição e modelagem de séries temporais (HAYKIN, 2001). Segundo Moore (2006), séries temporais são medidas de determinadas variáveis (preço, produção, etc) tomadas em intervalos regulares de tempo. Um modelo de séries temporais fornece previsões de observações futuras por meio da relação que possui com valores passados (MORETIN; TOLOI, 2004).

Diversos trabalhos utilizaram métodos de previsão, de preços, para *commodities* agrícolas. Dentre eles, podem-se citar os trabalhos de: Felipe (2012) que aplicou modelos ARIMA (*Autoregressive Integrated Moving Average*) em séries históricas de preços da soja no norte do Paraná. Cas (2017) que aplicou um modelo ARIMA na previsão do preço da *commodity* milho. Silva (2018) que utilizou a metodologia Box-Jenkins para previsão do preço da *commodity* café arábica. Já Ferreira et al. (2011) utilizou redes neurais artificiais como estratégia, para previsão de preços, no contexto do agronegócio.

Embora a cultura do milho tenha importância mundial são poucos os trabalhos que utilizam redes neurais recorrentes na previsão do preço do milho, principalmente utilizando a rede neural BLSTM. Em grande parte são utilizadas, na previsão do preço do milho, abordagens tradicionais como os modelos ARIMA.

Neste contexto, este trabalho tem como objetivo avaliar a eficácia de modelos, de redes neurais artificiais, para previsão do preço do milho no estado do Paraná, no período de 1 de janeiro de 2011 a 30 de julho de 2020. Observa-se que o milho é um dos principais produtos da agricultura paranaense. O estado é responsável por cerca de 15% da produção nacional de milho (GLOBAL, 2021).

2. MATERIAIS E MÉTODOS

Redes Neurais:

As Redes Neurais Artificiais (RNAs) possuem a capacidade de reconhecimento de padrões complexos e tem a função de aprendizado dentro da própria rede. Neste trabalho são utilizadas redes neurais *Multilayer Perception* (MLPs) e Recorrentes.

As redes MLPs representam uma classe de redes neurais utilizadas na modelagem de sistemas complexos. Sendo muito usadas na previsão de dados financeiros, porque podem aproximar muito bem funções não lineares. As redes MLPs são compostas por uma camada de entrada, uma ou mais camadas ocultas de unidades de processamento e uma camada de saída. Seu treinamento é supervisionado e utiliza o algoritmo *backpropagation*. O *backpropagation* é o algoritmo responsável pelo aprendizado da rede. As redes MLPs podem realizar tanto regressão quanto classificação (SEBASTIAN, 2016; BASTIANI et al., 2018).

As redes neurais recorrentes, *Recurrent Neural Network* (RNNs), são usadas em tarefas que envolvem entradas sequenciais, como fala, linguagem, entre outras. São redes em que as conexões entre as unidades ocultas formam ciclos. As RNNs são projetadas para problemas que envolvem sequências (GRAVES, 2014).

LSTMs (*Long Short-Term Memory*) são redes neurais recorrentes capazes de aprender dependências de longo prazo. As LSTMs são capazes de ignorar memórias consideradas irrelevantes para prever a próxima saída. Tem maior capacidade, quando comparadas a outras redes recorrentes, para tratar longas sequências de dados (GRAVES, 2014).

A topologia, de um neurônio, de uma LSTM, é baseada em uma célula de memória. Uma célula de memória possui um componente de memória para armazenar sequências recentes, o que a torna mais inteligente que um neurônio clássico. Cada célula contém portas, as quais controlam a quantidade de informação que é memorizada e a quantidade de informação que deve ser repassada para as próximas unidades (NELSON et al., 2017).

Um neurônio LSTM (célula) trabalha com uma sequência de entrada x_t (Figura 1) e cada porta (f_t , i_t e O_t – Quadro 1), dentro de uma célula, usa unidades de ativação (σ , \tanh) para controlar se elas são acionadas ou não, fazendo com que a mudança de estado e a adição de informações fluam através da célula. O parâmetro C_t representa o estado da célula no instante t , este estado representa as informações que chegaram até esse passo em instantes de tempos passados. Os círculos que contém os símbolos “+” e “x”, conforme mostra o circuito apresentado na Figura 1, referem-se a operações de soma e multiplicação (GRAVES, 2014).

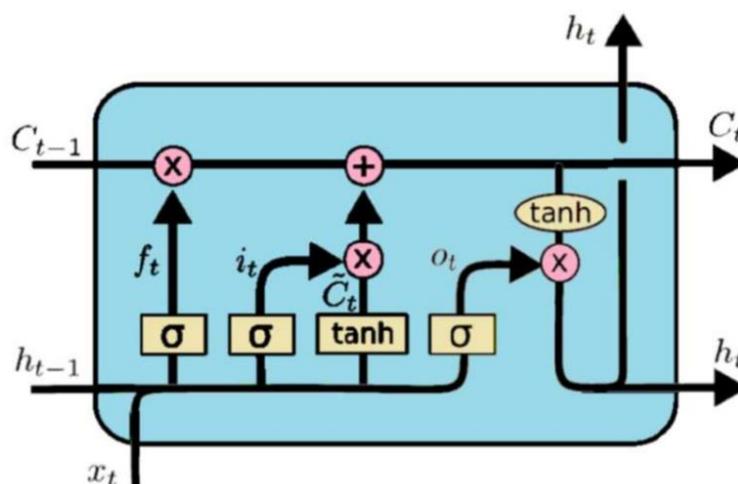


Figura 1 – Célula LSTM.
Fonte – Graves (2014).

Quadro 1 – Portas de esquecimento, entrada e saída.

Parâmetros	Definição
f_t	Porta de Esquecimento – determina quais informações devem ser jogadas fora pela célula.
i_t	Porta de Entrada – determina os valores de entrada para atualizar o estado da célula.
O_t	Porta de Saída – determina o que produzir com base na entrada e na memória da célula.

Fonte – Graves (2014).

As redes bidirecionais BLSTMs (*Bidirectional Long Short-Term Memory*), introduzidas por Schuster e Paliwal em 1997, são uma extensão do modelo LSTM. As BLSTMs são muito utilizadas no reconhecimento de fala e classificação de texto, mas muito pouco aplicadas em previsões de séries temporais (ALTHELAYA, 2018).

Segundo Sun et al. (2018) esta rede pode ser criada por meio de duas camadas intermediárias, considerando uma sequência *forward* e uma sequência *backward* que são transmitidas para a camada de saída (Figura 2). Com este tipo de rede, a camada de saída pode obter informações de estados passados e futuros simultaneamente. Isto faz com que este tipo de rede possa compreender melhor o contexto (GRAVES, 2014; NELSON et al., 2017; ZAO, 2017).

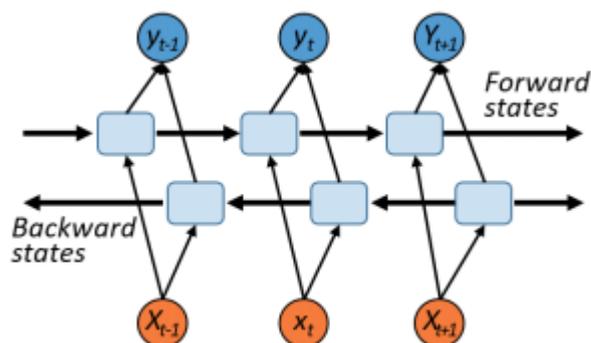


Figura 2 – Rede BLSTM.
Fonte – SUN et al. (2018).

Base de dados:

Os dados utilizados possuem periodicidade mensal, 114 meses, e o período de análise se estendeu desde o início da série histórica, obtida pela Empresa Brasileira de Pesquisa Agropecuária, de Janeiro/2011 até Junho/2020 (EMBRAPA, 2020). Observa-se que os dados obtidos, do site da EMBRAPA, não apresentavam *outliers*. Na Figura 3 apresenta-se o *boxplot* dos dados.

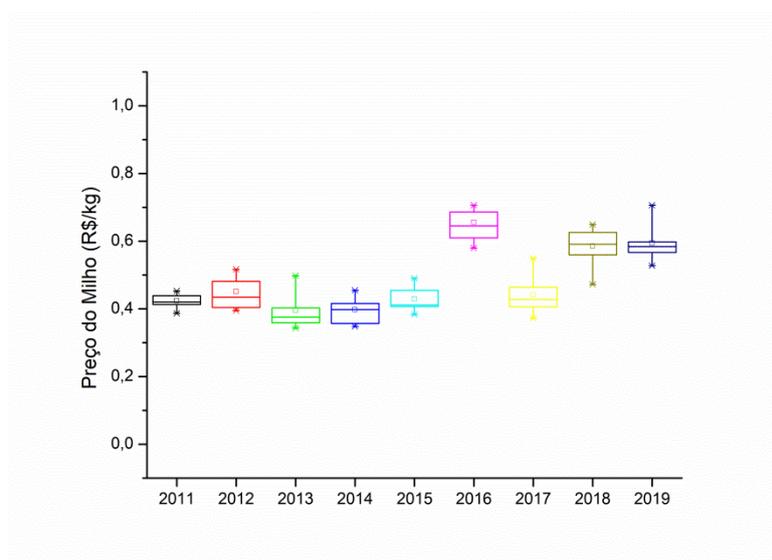


Figura 3 – *Boxplot* – Preço do milho.
Fonte - Autoria própria (2020).

A série histórica, do preço do milho, é apresentada na Figura 4.

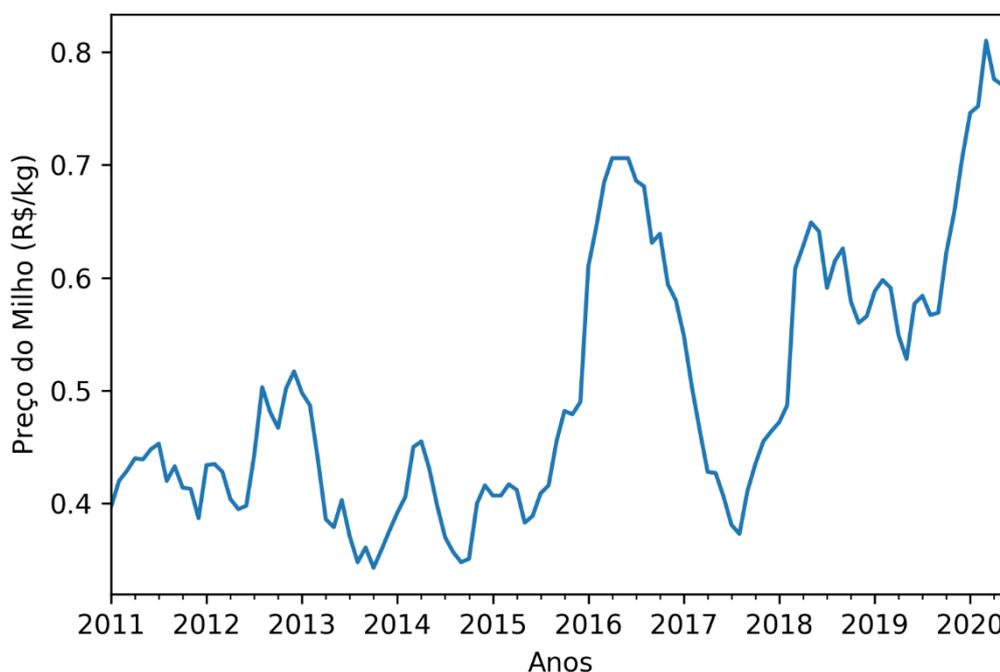


Figura 4 – Série: Preço do milho no Estado do Paraná.
Fonte - Autoria própria (2020).

Observa-se da série, apresentada na Figura 4, que primeiro semestre de 2016, em decorrência da exportação de milho e consequente diminuição dos estoques internos, o preço do milho teve um ápice de seu preço (0,833 R\$/kg em Maio/2016) (FILHO et al., 2016). Em 2020 o preço subiu e atingiu, em Março/2020, 0,81 R\$/kg. Caindo depois para 0,736 R\$/kg em Junho/2020.

Treinamento e teste:

Para criar os subconjuntos de dados, de treinamento e teste das redes neurais, foram usadas 108 observações da base de dados da EMBRAPA. Observa-se que os preços relativos aos meses de Janeiro, Fevereiro, Março, Abril, Maio e Junho de 2020 foram retirados do conjunto de dados, para serem utilizados posteriormente na validação dos modelos. Neste trabalho utilizou-se o método de fragmentação de *Houldout* onde a base de dados foi dividida com 67% (72) dos dados para treinamento dos algoritmos e 33% (36) para teste.

Métricas:

As métricas utilizadas para avaliar a precisão, das previsões obtidas pelos modelos, são o Coeficiente de Determinação (r^2), a Raiz Quadrada do Erro Médio Quadrático (RMSE) e o Erro Médio Absoluto (MAE). O r^2 indica quanto o modelo foi capaz de explicar os dados coletados. Quanto mais próximo de um, maior a qualidade dos valores preditos. O RMSE apresenta o desvio padrão do erro de predição e o MAE representa o desvio médio entre os valores observados e preditos do modelo. Quanto mais próximos de zero, os valores de RMSE

e MAE, maior a qualidade dos valores preditos (CANKURT; SUBASI, 2015; PINHEIRO, 2020).

Critério de parada:

Como critério de parada, do treinamento das redes neurais, utilizou-se o método conhecido como Método de Parada Antecipada (*Earling Stopping*). Segundo Silva (2010), este método ajuda a projetar uma rede neural com bom poder de generalização. Neste contexto, definiu-se neste trabalho, como critério de parada, a função *EarlyStopping()* com o parâmetro *patience*=50. O parâmetro *patience* indica o número de épocas, após a qual nenhuma melhoria foi observada.

Trabalhos relacionados:

Atualmente, existem diversos estudos, de análise de séries temporais, utilizando métodos como o ARIMA e as Redes Neurais Artificiais. Na previsão, do preço do milho, os estudos se concentram em abordagens tradicionais como a metodologia ARIMA. Cas (2017) investigou, por meio de modelos ARIMA, o comportamento dos preços médios recebidos pelo produtor da *commodity* milho brasileira. Obtendo resultados, de previsão, que seguem a tendência dos preços obtidos para um horizonte de curto prazo.

Um estudo feito por Tibulo (2014) abordou a comparação entre modelos ARIMA e de Alisamento Exponencial de Holt-Winters, aplicados a série histórica do preço médio mensal do milho no Rio Grande do Sul. Os resultados demonstraram que o modelo Holt-Winters aditivo apresentou melhores resultados na previsão do preço do milho. Já Silva et al. (2019) realizou, por meio de modelos de séries temporais, a previsão do preço do milho no estado do Mato Grosso. Verificou, dos resultados obtidos, que o modelo de suavização exponencial (modelo linear de Holt) apresentou os menores erros de previsão.

3. RESULTADOS E DISCUSSÃO

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados (Tabela 1).

Tabela 1 – Análise descritiva dos dados.

Parâmetro analisado	Preço do milho
Média (R\$/kg)	0,503
Mínimo (R\$/kg)	0,343
Máximo (R\$/kg)	0,833
Desvio Padrão (R\$/kg)	0,123
Coefficiente de Variação (%)	24,45

Fonte - Autoria própria (2020).

Pode-se observar, dos dados apresentados na Tabela 1, que o preço do milho, para o período em estudo, ficou em média 0,503 R\$/kg. Apresentando, neste período, preços mínimo e máximo de 0,343 R\$/kg e 0,833 R\$/kg, respectivamente.

Observa-se também, da Tabela 1, que o coeficiente de variação é 24,45%, segundo Pimentel (2009) considerado alto, o que indica variabilidade dos dados.

Modelos:

Neste trabalho implementaram-se os modelos de redes neurais MLP e BLSTM por meio da biblioteca Keras, rodando como *frontend* em TensorFlow. Os melhores modelos, implementados neste trabalho, utilizaram o algoritmo de otimização Adam com os seguintes hiperparâmetros:

- MLP neurons = 8;
- LSTM cells = 8;
- batch = 1;
- learning rate = 0.001 e;
- activate = relu.

Na Figura 5 apresenta-se, como exemplo, a curva de aprendizagem do modelo BLSTM. Pode-se observar, nesta figura, a boa estabilidade na convergência das curvas de treino e teste.

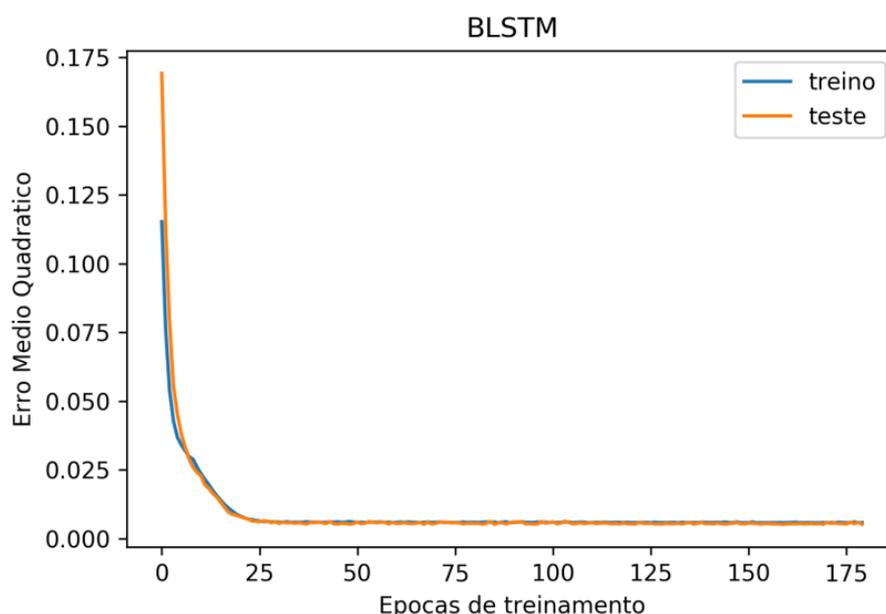


Figura 5 – Curvas de aprendizagem de treino e teste.
Fonte - Autoria própria (2020).

Na Tabela 2 apresentam-se os indicadores obtidos dos modelos.

Tabela 2 – Indicadores de desempenho (Treino e Teste).

Cenário	Treino			Teste		
	r^2	RMSE	MAE	r^2	RMSE	MAE
BLSTM	0,9	0,034	0,024	0,84	0,033	0,025
MLP	0,89	0,036	0,025	0,83	0,034	0,026

Fonte - Autoria própria (2020).

Pode-se observar, dos dados apresentados na Tabela 2, que os indicadores RMSE e MAE, obtidos pelos modelos, são muito similares. Os r^2 apresentados na Tabela 2, para os dois modelos, apresentam bons valores de treino e teste, indicando um bom ajuste dos modelos.

Na Figura 6 apresentam-se os resultados da previsão, de treino e teste, para os dois modelos.

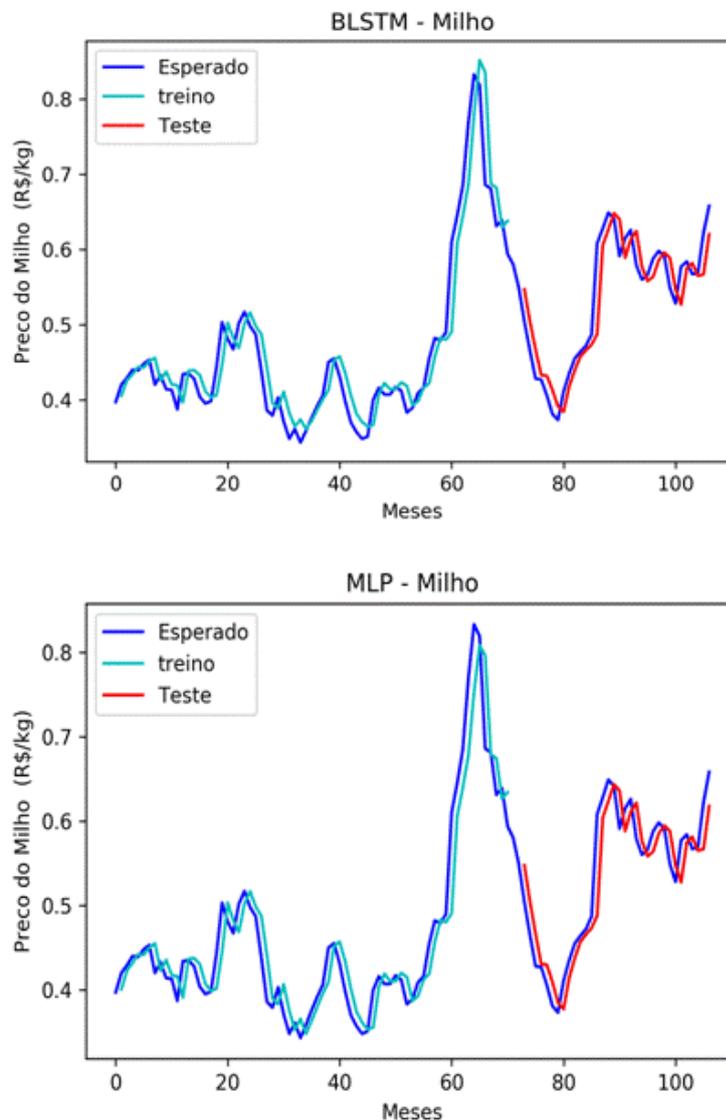


Figura 6 – Previsão de treino e teste – BLSTM e MLP.
 Fonte - Autoria própria (2020).

Previsões:

Na Tabela 3 apresentam-se os dados, observados, preditos e os Erros Relativos Percentuais (ERP), para os seis meses que não participaram da etapa de treino e teste. O ERP é obtido por meio da equação:

$$ERP = \frac{Observado - Predito}{Observado} \times 100 \quad 1$$

Tabela 3 – Previsões do preço do milho (R\$/kg) e Erros percentuais relativos (%).

Mês	Embrapa	MLP	BLSTM	ERP - MLP	ERP - BLSTM
Jan	0,746	0,697	0,709	6,568	4,959
Fev	0,752	0,689	0,712	8,377	5,319
Mar	0,81	0,682	0,716	15,802	11,604
Abr	0,776	0,675	0,72	13,015	7,216
Mai	0,771	0,668	0,724	13,359	6,095
Jun	0,736	0,662	0,729	10,054	0,951
Médio				11,196	6,024

Fonte - Autoria própria (2020).

Por meio dos resultados apresentados, na Tabela 3, conclui-se que os resultados das previsões, dos dois modelos, estão próximos aos fornecidos pela EMBRAPA. Contudo, o modelo BLSTM apresenta um erro percentual relativo médio menor que o modelo MLP (ERP-BLSTM= 6,024% e ERP-MLP= 11,196%).

Observa-se que o ajuste da inflação nem sempre é necessário ao lidar com variáveis monetárias. Às vezes é mais simples prever os dados em termos nominais ou usar uma transformação de logaritmo para estabilizar a variância (NAU, 2021).

4. CONCLUSÕES

Neste trabalho apresentou-se um estudo de eficácia de modelos, de redes neurais artificiais, para previsão do preço do milho no estado do Paraná. A série de preços do milho, no período entre 2011 e 2020, foi obtida pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). Os modelos, em estudo, passaram pelas fases de: preparação de dados, definição das estruturas, estimativas, avaliação dos resultados e validação.

Inicialmente, realizou-se uma comparação entre os modelos MLP e BLSTM, ambos implementados na linguagem Python. Observou-se que os indicadores de desempenho (r^2 , RMSE e MAE) obtidos, pelos dois modelos, apresentaram resultados muito similares.

Na sequência, observou-se, para os meses que não participaram do treinamento da rede (janeiro, fevereiro, março, abril, maio e junho de 2020), que as previsões, dos modelos MLP e BLSTM, se mostraram satisfatórias. Demonstrando a boa habilidade dos modelos para compreender a estrutura da série temporal estudada neste trabalho. Não obstante, observou-se uma superioridade na qualidade do ajuste do modelo BLSTM.

Por fim, após a análise dos modelos MLP e BLSTM, pode-se observar que ambos os modelos são válidos e têm grande potencial para auxiliarem no processo de tomada de decisão, com relação ao preço do milho, de produtores e gestores das indústrias de ração.

Apesar dos modelos, MLP e BLSTM, apresentarem resultados adequados para uma previsão de curto prazo, sugere-se, para outros trabalhos de pesquisa, proceder a estimação utilizando outros modelos, tais como: os modelos GRU (*Gated Recurrent Unit*) e BGRU (*Bi-directional Gated Recurrent Unit*).

REFERÊNCIAS

ALVES, H. C. R.; AMARAL, R. F. Produção, área colhida e produtividade do milho no nordeste. *Informe rural Etene*, 2016.

ALTHELAYA, K. A. Evaluation of bidirectional LSTM for short and long term stock market prediction. International Conference on Information as Communication System (ICICS), *Proceedings* [...]. Irbid, Jordan, 2018.

ABRAHAM, B. *Statistical methods for forecasting*. New York: Wiley & Sons, 2019.

BASTIANI, M.; SANTOS, J. A. A.; SCHMIDT, C. A P.; SEPULVEDA, G. P. L. Application of data mining algorithms in the management of the broiler production. *Geintec*, v. 8, 2018.

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. *GEPROS*, n. 1, p. 263-279, Jan./mar. 2018.

CHIODI, L. *Integração Espacial no Mercado Brasileiro de milho*. Dissertação (Mestrado em Economia Aplicada) Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba. 2006

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA). *Milho*. Disponível em: <<https://www.embrapa.br/suinos-e-aves/cias/precos>>. Acesso em: 02 mar. 2020.

FELIPE, I. J. S. Aplicação de modelos ARIMA em séries de preços de soja no norte do paraná. *Tekhne e Logos*. v. 3, n. 3, 2012.

FERREIRA, L.; MOURA, G. L.; BORESTEIN, D.; FISCHMANN Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. *Revista de Administração e Inovação*. v 8, n. 4, 2011.

FILHO, J. I. S.; TALAMINI, D. J. D.; SCHEUERMANN, G. N. *O preço do milho no mercado interno e a sua relação com o preço internacional n os últimos 10 anos*. Embrapa Suínos e Aves, 2016.

GLOBAL. Global Crop Protection. *Paraná está em alerta com o enfezamento do milho*. Disponível em: <https://globalcropprotection.com/2021/03/02/parana-em-alerta-com-o-enfezamento-do-milho/>. Acesso em: 2 de abril de 2021.

GRAVES, A. Towards end-to-end speech recognition with recurrent neural networks. In: XIV Proceedings of the 31st International Conference on Machine Learning (ICML-14),]. *Proceedings* [...]. Beijing, China, 2014.

HAYKIN, S. *Neural networks: a comprehensive foundation*. New Delhi: Pearson Prentice Hall, 2001.

MORETTIN, P. A.; TOLOI, C. M. C. *Análise de series de temporais*. São Paulo: Edgard Blucher, 2004.

MARCHEZAN, A. Previsão do preço dos principais grãos produzidos no Rio Grande do sul. *Ciência Rural*, v 40, n. 11, 2010.

MINHA VIDA (2016) *Milho é rico em vitaminas e minerais, mas deve ser consumido com moderação*. Disponível em: <https://www.minhavidacom.br/alimentacao/materias/17929->

milho-e-rico-em-vitaminas-e-minerais-mas-deve-ser-consumido-com-moderacao, Acesso em: 8 de agosto de 2020.

MOORE, D. S.; MCCABE, G. P.; DUCKWORTH, W. M.; SCLOVE, S. L. A. *A prática da estatística experimental: como usar dados para tomar decisões*. Rio de Janeiro: LTC, 2006.

NAU, R. Statistical forecasting: notes on regression and time series analysis. Disponível em: <https://people.duke.edu/~rnau/411home.htm>. Acesso em: 5 de janeiro de 2021.

NELSON, M. Q.; PEREIRA, A. C. M.; OLIVEIRA, R. A. Stock market's price prediction with LSTM neural networks. International Joint Conference of Neural Networks (IJCNN) *Proceedings* [...]. Anchorage, Alaska, 2017.

PINHEIRO, T. C., SANTOS, J. A. A., PASA, L. A. Gestão da produção de frangos de corte por meio de redes neurais artificiais, *Revista Holos*, 2020.

PINHEIRO, D. R. O. Previsão de preços para a cultura do arroz irrigado e sequeiro do estado do Paraná utilizando séries temporais. *Contabilidade, Gestão e Agronegócio*, 2017.

PIMENTEL, F. *Curso de estatística experimental*. Piracicaba: ESALQ, 2009.

ROCHA, L. G. Análise econômica de soja e milho safrinha em sucessão de culturas. *Enciclopédia Biosfera*, 2019.

SEBASTIAN, S. Performance evaluation by artificial neural network using WEKA. *International Research Journal of Engineering and Technology*, v. 3, 2016.

SILVA, C. A. G. Previsão do preço da commodity café arábica: uma aplicação da metodologia Box-jenkins. *Revista Espacios*, v. 39, n. 4, 2018.

SILVA, M. P. *Aplicação de redes neurais artificiais no diagnóstico de falha de turbina a gás*. Dissertação (Mestrado em Engenharia Mecânica). Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro. 2010.

SILVA, R. B. Z.; SILVA, R. N. Z.; AIRES, F. F. C.; SOARES, F. O. S. Uso de modelos de séries temporais para previsões de safras de milho no estado de Mato Grosso. *Research Society and Development*. v. 9, n. 1, 2019.

SUN, Q.; JANKOVIC, M. V.; BALLY, L. (2018) Predicting Blood Glucose with an LSTM and Bi-LSTM Based Deep Neural Network. Symposium on Neural Networks and Applications (NEUREL). *Proceedings* [...]. Disponível em: <https://arxiv.org/abs/1809.03817>. Acesso em: 18 de setembro de 2020.

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

ZAO, Z. LSTM network: a deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, v. 11, 2017.