

Previsão de Custos de Produção de Frangos: Uma aplicação do Modelo CNN-LSTM

José Airton Azevedo dos Santos

Doutorado em Engenharia Elétrica pela Universidade Federal de Santa Catarina - UFSC

Professor na Universidade Tecnológica Federal do Paraná - UTFPR
Campus Medianeira. Avenida Brasil, 4232. Medianeira/PR. CEP 85.884-000
E-mail: airton@utfpr.edu.br

Aldino Normelio Brun Polo

Mestrado em andamento em Tecnologias Computacionais para o Agronegócio pela
Universidade Tecnológica Federal do Paraná - UTFPR
Campus Medianeira. Avenida Brasil, 4232. Medianeira/PR. CEP 85.884-000
E-mail: aldinopolo@alunos.utfpr.edu.br

RESUMO

A avicultura, umas das principais componentes do agronegócio paranaense, contribui significativamente para a economia estadual. O conhecimento, pelo produtor paranaense, dos custos de produção, de frangos de corte, é fundamental para economizar recursos, aumentar a eficiência e garantir a sustentabilidade de seu negócio. Neste contexto, este trabalho teve como objetivo principal propor, para previsão dos custos de produção de frangos de corte no estado do Paraná, um modelo híbrido CNN-LSTM (*Convolutional Neural Network - Long Short-Term Memory*) multivariado. A base de dados, disponibilizada pela EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária), apresenta uma série de custos mensal compreendida entre Janeiro/2010 e Abril/2024. Uma comparação detalhada de desempenho do modelo CNN-LSTM com outros modelos de aprendizado de máquina foi realizada. Resultados obtidos, dos modelos, foram comparados por meio das métricas RSME (*Root Mean Squared Error*), MAPE (*Mean Absolute Percent Error*) e MAE (*Mean Absolute Error*). Verificou-se, para um horizonte de 12 meses, que o modelo de previsão CNN-LSTM forneceu estimativas confiáveis para os custos de produção de frangos.

Palavras-chave: Modelos, Métricas, Previsão, Aprendizado de máquina.

Broiler Production Cost Forecast: A CNN-LSTM Model Application

ABSTRACT

Poultry farming, one of the main components of agribusiness in Paraná, contributes significantly to the state economy. The knowledge, by the producer from Paraná, of the production costs of broiler chickens is essential to save resources, increase efficiency and guarantee the sustainability of their business. In this context, the main objective of this work is to offer a prediction study about the production costs of broiler chickens in the state of Paraná, a hybrid multivariate CNN-LSTM (*Convolutional Neural Network - Long Short-Term Memory*) model. The available database offered by

EMBRAPA (Brazilian Agricultural Research Corporation) presents a series of monthly costs in the period of January/2010 and April/2024. A detailed performance comparison of the CNN-LSTM model with other machine learning models was performed. Results obtained from the models were compared using the metrics RSME (Root Mean Squared Error), MAPE (Mean Absolute Percent Error) and MAE (Mean Absolute Error). It was verified, for a 12-month horizon, that the CNN-LSTM forecasting model provided reliable estimates for chicken production costs.

Keywords: Models, Metrics, Prediction, Machine Learning.

Pronóstico del Costo de Producción del Pollo: Una Aplicación del Modelo CNN-LSTM

RESUMEN

La avicultura, uno de los principales componentes del agronegocio en Paraná, contribuye significativamente a la economía estatal. El conocimiento, por parte del productor paranaense, de los costos de producción de pollos de engorde es fundamental para ahorrar recursos, aumentar la eficiencia y garantizar la sostenibilidad de su negocio. En este contexto, el principal objetivo de este trabajo fue proponer, para predecir los costos de producción de pollos de engorde en el estado de Paraná, un modelo híbrido multivariado CNN-LSTM (*Convolutional Neural Network - Long Short-Term Memory*). La base de datos, puesta a disposición por EMBRAPA (Empresa Brasileña de Investigación Agropecuaria), presenta una serie de costos mensuales entre enero/2010 y abril/2024. Se realizó una comparación detallada del rendimiento del modelo CNN-LSTM con otros modelos de aprendizaje de máquina. Los resultados obtenidos de los modelos se compararon utilizando las métricas RSME (*Root Mean Squared Error*), MAPE (*Mean Absolute Percent Error*) y MAE (*Mean Absolute Error*). Se verificó, para un horizonte de 12 meses, que el modelo de pronóstico CNN-LSTM proporcionó estimaciones confiables de los costos de producción de pollo.

Palabras clave: Modelos, Métricas, Predicción, Aprendizaje de máquina.

1 INTRODUÇÃO

Os principais produtores de frango de corte do Brasil são os três estados da região sul (Rio Grande do Sul (RS), Santa Catarina (SC) e Paraná (PR)). O Paraná, em 2023, produziu 2.1 bilhões de frangos. Lidera o ranking nacional com 34.3% da produção, seguido por Santa Catarina (13.4%) e Rio Grande do Sul (12.5%) (PARANÁ, 2024; Santos, 2021).

O progresso técnico e tecnológico, no setor de avicultura, contribuíram para posicionar o Brasil no patamar atual. Produzindo, em 2023, 14.833 milhões de

toneladas (segundo maior produtor mundial de carne de frango) e exportando 5.139 milhões de toneladas (líder mundial em exportações) (ABPA, 2024).

Conhecer os custos de produção não é somente uma obrigação das empresas do mercado de carnes, mas também dos avicultores. Já que os custos de produção refletem na rentabilidade dos seus negócios. A previsão de custos permite que os produtores planejem suas finanças com antecedência, garantindo que haja recursos suficientes para cobrir despesas com ração, medicamentos, mão de obra e manutenção das instalações. Também, permite monitorar e controlar os gastos ao longo do ciclo de produção, identificando áreas onde é possível reduzir custos sem comprometer a qualidade (Sandi & Miele, 2012; Santos, 2021).

Redes neurais artificiais, abstrações das redes neurais biológicas, são muito utilizadas como ferramentas de previsão. São compostas por unidades de processamento simples, denominadas de neurônios, que possuem a habilidade de apreender padrões de dados e generalizar a informação apreendida (Sebastian, 2016; Pinheiro, Santos, & Pasa, 2020; Bastiani, Santos, Schmidt, & Sepulveda, 2018).

Diversos trabalhos, apresentados na literatura, utilizaram redes neurais para previsões de variáveis relacionadas com a avicultura. Dentre eles, pode-se destacar o trabalho de Santos (2021) que realizaram, por meio de redes neurais univariadas LSTM e MLP (*Multilayer Perceptron*), a previsão dos custos de produção de frangos de corte. Concluíram, neste trabalho, que o modelo LSTM, com relação ao modelo MLP, apresentou um melhor desempenho de previsão.

Neste contexto, este trabalho propõe uma aplicação, do modelo híbrido CNN-LSTM multivariado, para previsão dos custos de produção de frangos de corte, no estado do Paraná, no período de Janeiro de 2010 a Abril de 2024. Embora a produção de frangos de corte apresente um papel importante, para avicultura nacional, ainda tem-se, na literatura, poucos estudos que explorem a utilização, para previsão dos custos de produção de frangos de corte, de redes neurais híbridas multivariadas.

O artigo está organizado da seguinte forma: na Seção 2 é feita uma breve revisão dos modelos de séries temporais CNN, LSTM e CNN-LSTM; na Seção 3 é apresentada a metodologia utilizada na previsão dos custos de produção de frangos de corte; na Seção 4 são apresentados os resultados obtidos da aplicação desta metodologia. Comentários finais, na Seção 5, finalizam o artigo.

2 REFERENCIAL TEÓRICO

2.1 Rede CNN

A rede CNN, proposta por Lecun, Bengio e Haffener (1998), apresenta um bom desempenho em previsões de séries temporais. Esta rede é formada, além da camada de entrada, por três camadas principais: camada convolucional (*Convolution Layer*), camada de *pooling* (*Pooling Layer*) e uma camada totalmente conectada (*Fully Connected Layer*) (Figura 1). As camadas convolucional e de *pooling* são camadas especialmente projetadas para a tarefa de filtrar os dados de entrada e extrair informações úteis, que serão repassadas para uma camada totalmente conectada (Li, Abdel-Aty, & Yuan, 2020; Vargas, Paes, & Vasconcelo, 2022; Lawal, Rehman, Alems, & Alam, 2021; Santos, 2022; Wu, Wu, Feng, Yang, Liang, & Yang, 2021).




Figura 1. Rede CNN

Fonte: Elaborado pelos autores.

2.2 Rede LSTM

A topologia de uma rede LSTM baseia-se em células de memória (Figura 2). Cada célula LSTM é composta por três portas (entrada (i_t), saída (o_t) e esquecimento (f_t)). A rede LSTM, através desta topologia, consegue criar um fluxo de informações controlado, decidindo quais informações devem ser “esquecidas” e quais devem “lembradas”, conseguindo assim aprender dependências de longo prazo (Livieris, Pintelas, & Pintelas, 2020; Santos, & Chaucoski, 2021; Passos, 2021).




Figura 2. Célula LSTM
 Fonte: Graves (2014).

2.3 Rede CNN-LSTM

O modelo CNN-LSTM, proposto neste trabalho, possui uma arquitetura baseada nas redes CNN e LSTM (Figura 3).




Figura 3. Estrutura da rede CNN-LSTM
 Fonte: Elaborado pelos autores.

A camada CNN extrai as características dos dados de entrada (*Input Layer*). Nesta camada os dados de entrada passam sequencialmente pelas camadas *Convolution Layer* e *Pooling Layer*. Gerando um valor de saída que será a entrada da *LSTM Layer*. A *LSTM Layer* tem a função de calcular o resultado final da previsão.

2.4 Trabalhos Relacionados com a Rede CNN-LSTM

A rede CNN-LSTM vem sendo utilizada em várias pesquisas ao longo dos últimos anos. Zha, Liu, Wan, Luo, Li, Yang e Xu (2022) propõem a utilização da rede CNN-LSTM para prever a produção de um campo de gás na China. Realizaram a comparação da rede CNN-LSTM com os modelos LSTM, RNN (*Recurrent Neural Network*), CNN e ARIMA (*Autoregressive Integrated Moving Average*). Concluíram que o modelo CNN-LSTM apresentou melhor desempenho. Livieris et al. (2020) utilizaram o modelo CNN-LSTM para previsão do preço do ouro. Concluíram que a utilização da camada CNN em conjunto com a camada LSTM melhora o desempenho das previsões. Elmaz, Eyckerman, Castells, Latré e Hellinckx (2021) utilizaram o modelo CNN-LSTM para prever a temperatura ambiente. Compararam o modelo CNN-LSTM com os modelos MLP (*Multilayer Perceptron*) e LSTM. Concluíram que o modelo CNN-LSTM superou os outros modelos para todos os horizontes de previsão. Zhang e Li (2022) propõem a utilização do modelo CNN-LSTM para prever a qualidade do ar em Pequim. Realizaram uma comparação entre o modelo CNN-LSTM e os modelos SARIMA (*Seasonal Autoregressive Integrated Moving Average*), LSTM e GRU (*Gated Recurrent Unit*). Os resultados mostraram que o modelo CNN-LSTM apresentou maior precisão nas previsões. Já Santos et al. (2022) utilizaram o modelo CNN-LSTM para prever o consumo de energia elétrica em uma agroindústria. Realizaram uma comparação entre os modelos CNN-LSTM e LSTM. Concluíram que, para um horizonte de 24h, o modelo CNN-LSTM apresentou melhor desempenho.

3 PROCEDIMENTOS METODOLÓGICOS

3.1 Etapas do Trabalho

Neste trabalho, depois da coleta dos dados, foram seguidas as seguintes etapas:

- ✓ **Análise dos Dados:** Na etapa inicial realizou-se, para obterem-se informações dos dados, uma análise exploratória.
- ✓ **Modelagem:** Na sequência, na etapa de Treinamento e Validação, selecionaram-se, por meio das métricas MAE, RMSE e MAPE, os melhores modelos CNN-LSTM, CNN-GRU (*Convolutional Neural Network - Gated Recurrent Unit*), CNN-BiLSTM (*Convolutional Neural Network - Bidirectional Long Short Term Memory*) e CNN-BiGRU (*Convolutional Neural Network - Bidirectional Gated Recurrent Unit*).
- ✓ **Teste:** Na última etapa fez-se o teste do modelo. Analisando-se sua acurácia para dados que não participaram da etapa de Treinamento e Validação.

3.2 Bases de Dados

Para previsão, dos custos de produção de frangos de corte, utilizou-se uma base de dados com 172 meses (Jan/2010- Abr/2024) obtida do site da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA, 2024). Os dados obtidos, da base de dados, já estavam limpos e sem a presença de *outliers*. Cada instância, da base de dados, apresenta quatro variáveis: o Custo de Produção e os itens de custo Ração, Genética e Mão de Obra (Tabela 1).

Tabela 1

Cinco primeiros registros do arquivo de dados (R\$/kg vivo)

Data	Produção	Ração	Genética	Mão de Obra
01/01/2010	1.29	0.84	0.24	0.06
01/02/2010	1.22	0.77	0.23	0.06
01/03/2010	1.21	0.76	0.24	0.06
01/04/2010	1.23	0.76	0.25	0.06
01/05/2010	1.26	0.79	0.25	0.06

Nota. Fonte: Dados da pesquisa.

O *Boxplot* dos dados é apresentado na Figura 4.




Figura 4. Boxplot dos custos

Fonte: Dados da pesquisa.

A série histórica, do custos de produção de frangos, é apresentada na Figura 5, a seguir.



Figura 5. Série histórica dos custos de produção de frangos

Fonte: Dados da pesquisa.

Neste trabalho utilizou-se, para normalizar os dados antes do treinamento, a função *MinMax*. Cuja equação é dada por:

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

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

3.3 Métricas

Para avaliar o desempenho das redes, CNN-LSTM, CNN-GRU, CNN-BiLSTM e CNN-BiGRU, foram utilizadas as seguintes métricas: MAE (*Mean Absolute Error*), RMSE (*Root Mean Square Error*) e MAPE (*Mean Absolute Percentage Error*). Cujas equações são dadas por (Cankurt, & Subasi, 2015):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \left(\frac{R\$}{kg} vivo \right) \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n ((y_i - \hat{y}_i)^2) \left(\frac{R\$}{kg} vivo \right)} \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)/y_i| \times 100 (\%) \quad (4)$$

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.

4 RESULTADOS E DISCUSSÃO

Inicialmente, nesta pesquisa, realizou-se uma análise descritiva dos dados fornecidos pela EMBRAPA (172 observações) (Tabela 2).

Tabela 2

Análise descritiva dos dados

	Produção	Ração	Genética	Mão de Obra
Instâncias	172	172	172	172
Média	2.993	2,111	0.424	0.143
Desvio Padrão	1.268	0.972	0.169	0.038
Mínimo	1.210	0.760	0.230	0.050
25%	2.077	1.440	0.300	0.120
50%	2.675	1.845	0.360	0.150
75%	3.980	2.822	0.555	0.170
Máximo	5.770	4.420	0.810	0.210

Nota. Fonte: Dados da pesquisa.

Pode-se observar, dos dados apresentados na Tabela 2, que os custos para, Produção, Ração, Genética e Mão de Obra, ficaram, para o período em estudo, em média de 2.99, 2.11, 0.42 e 0.14 R\$/kg vivo, respectivamente. Com uma mediana de 2.67, 1.84, 0.36 e 0.15 R\$/kg vivo. Apresentando também, neste período, preços mínimos de 1.21, 0.76, 0.23 e 0.05 R\$/kg vivo e máximos de 5.77, 4.42, 0.81 e 0.21 R\$/kg vivo.

Observa-se que os coeficientes de variação $((\text{Desvio Padrão}/\text{Média}) \times 100)$ - 42.4%, 46%, 39.98% e 26.87%) são considerados altos, o que indicam variabilidade dos dados.

Os dados, ao realizar o treinamento de um modelo, são divididos em conjuntos de Treinamento/Validação e Teste. O conjunto de Treinamento/Validação é usado para treinar o modelo (160 observações), enquanto o Conjunto de Teste é usado para avaliar o desempenho e a precisão do modelo (12 observações).

4.1 Treinamento/validação

Inicialmente, neste trabalho, vários ajustes de hiperparâmetros foram testados. Os modelos com melhor desempenho, no conjunto de validação, foram selecionados por meio das métricas MAE, RMSE e MAPE. Os modelos selecionados utilizam o algoritmo de otimização Adam (*Adaptive moment*) com os parâmetros apresentados na Tabela 3. As redes neurais foram treinadas com 70% das amostras (112 observações) e validadas com 30% (48 observações).

Tabela 3

Parâmetros dos modelos

Parâmetros	Valor
<i>Time steps</i>	12
<i>Learning rate</i>	0,0103
<i>Epochs</i>	67
<i>Batch</i>	10
<i>Convolution layer filters</i>	4
<i>Convolution layer kernel size</i>	5
<i>Convolution layer activation function</i>	Relu
<i>Convolution layer padding</i>	Same
<i>Pooling layer pool size</i>	1
<i>Pooling layer padding</i>	Same
<i>Pooling layer activation function</i>	Relu
<i>Numbers of hidden units in LSTM layer</i>	16
<i>Dropout</i>	0.00015
<i>LSTM activation function</i>	Relu
<i>Dense units</i>	1

Nota. Fonte: Dados da pesquisa.

Na Figura 6 apresenta-se a estrutura básica do modelo CNN-LSTM.




Figura 6. Estrutura Básica do modelo CNN-LSTM

Fonte: Dados da pesquisa.

Esta estrutura foi projetada da seguinte forma: na entrada tem-se um vetor tridimensional dos dados (*None,12,4*), onde 12 representa o tamanho do passo de tempo (*Time steps*) e 4 a dimensão da entrada (Produção, Ração, Genética e Mão de Obra). Inicialmente, os dados são enviados para uma camada de convolução unidimensional. Essa camada extrai os recursos e produz um vetor de saída tridimensional (*None,12,4*), onde 4 é o tamanho dos filtros da camada de convolução (*Convolution layer filters*). Depois o vetor é enviado a camada de *pooling*, onde é convertido no vetor (*None,12,4*). Na sequência, é enviado para treinamento na camada LSTM. Os dados de saída (*None,16*), onde 16 é o número de unidades ocultas (*Numbers of hidden units in LSTM layer*), vão para a camada *dense*.

Os resultados das previsões, para o Conjunto de Validação, são mostrados na Figura 7. Nota-se, por meio desta figura, que o modelo CNN-LSTM obteve melhor aderência dos dados previstos com os dados reais.




Figura 7. Resultados das previsões– Conjunto de Validação

Fonte: Dados da pesquisa.

Os resultados das métricas, para o Conjunto de Validação, são apresentados na Tabela 4.

Tabela 4

Resultados das métricas – Conjunto de Validação

VALIDAÇÃO			
Redes	MAE	RMSE	MAPE
CNN-LSTM	0,208	0,248	4,34
CNN-GRU	0,842	0,905	19,81
CNN-BiSTM	0,404	0,441	8,7
CNN-BiGRU	0,579	0,628	12,78

Nota. Fonte: Dados da pesquisa.

Observa-se, dos resultados das métricas apresentadas na Tabela 4, que o modelo CNN-LSTM apresentou, em relação aos modelos CNN-GRU, CNN-BiLSTM e CNN-BiGRU, um melhor desempenho (MAE= 0.208, RMSE= 0.248 e MAPE= 4,34%).

4.2 Teste

Na Tabela 5 apresentam-se os dados, observados (reais) e preditos pelos modelos de previsão, para os 12 meses que não participaram da etapa de Treino e Validação (Conjunto de Teste).

Tabela 5

Resultados das previsões do Conjunto de Teste (12 meses) - (R\$/kg vivo)

Mês	EMBRAPA	CNN-LSTM	CNN-GRU	CNN-BiSTM	CNN-BiGRU
mai/23	4.61	4.741822	4.288609	4.6508627	4.3319187
jun/23	4.47	4.511735	4.146763	4,4293857	4.009196
jul/23	4.33	4.4242396	4.081815	4.308427	3.800625
ago/23	4.26	4.3471065	4.014568	4.2097692	3.6564233
set/23	4.22	4.3269463	3.915983	4.143995	3.5715854
out/23	4.27	4.315525	3.891801	4.0766497	3.4883413
nov/23	4.35	4.278814	3.898258	4.0201435	3.4410431
dez/23	4.41	4.310075	3.898248	4.0081615	3.412868
jan/24	4.39	4.3126216	3.896469	4.018822	3.4101005
fev/24	4.38	4.2949734	3.898775	4.042178	3.4432983
mar/24	4.27	4.345282	3.895032	4.0853004	3.5563343
abr/24	4.28	4.40205	3.892602	4.1443005	3.7171214

Nota. Fonte: Dados da pesquisa.

Os resultados das previsões, na forma gráfica, são apresentados na Figura 8.




Figura 8. Previsões – Conjunto de Teste

Fonte: Dados da pesquisa.

Na Tabela 6 apresentam-se, para o Conjunto de Teste, os resultados das métricas MAE, RSME e MAPE.

Tabela 6

Resultados das métricas MAE, RMSE e MAPE – Conjunto de Teste

Redes	TESTE		
	MAE	RMSE	MAPE
CNN-LSTM	0.086	.	1.96
CNN-GRU	0.376	0.386	9.52
CNN-BiSTM	0.181	0.228	4.47
CNN-BiGRU	0.7	0.733	19.6

Nota. Fonte: Dados da pesquisa.

Pode-se observar, dos resultados apresentados na Figura 8, que a curva, do modelo CNN-LSTM, se ajustou melhor a curva dos dados reais (EMBRAPA). O modelo CNN-LSTM, comparado com os modelos CNN-BiLSTM, CNN-GRU e CNN-BiGRU, apresentou erros menores (MAE, RSME e MAPE) (Tabela 6). Por exemplo, o MAPE do modelo CNN-LSTM, com relação aos outros modelos, reduziu 7.51% (CNN-GRU), 2.51% (CNN-BiLSTM) e 17.6% (CNN-BiGRU). Portanto, conclui-se que o

modelo CNN-LSTM obteve maior acurácia nas previsões dos custos de produção de frango de corte.

5 CONSIDERAÇÕES FINAIS

Buscou-se, por meio deste estudo, propor um modelo híbrido CNN-LSTM multivariado, para previsão, no estado do Paraná, dos custos de produção de frangos de corte. A série histórica de custos de produção, no período de Janeiro/2010 a Abril/2024 (172 observações mensais), foi fornecida pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA).

Inicialmente, observou-se, na etapa de Treinamento e Validação, que o modelo CNN-LSTM apresentou, para o Conjunto de Validação, um melhor desempenho. Na sequência, observou-se, para os meses que não participaram do treinamento da rede (Maio/2023 a Abril/2024 – 12 meses), que as previsões do modelo CNN-LSTM foram, para a série fornecida pela EMBRAPA, mais precisas que a dos modelos CNN-BiLSTM, CNN-GRU e CNN-BiGRU. A proximidade dos valores preditos e reais demonstram, para um horizonte de doze meses, a boa capacidade de generalização da rede CNN-LSTM proposta neste trabalho

Finalmente, pode-se concluir que o modelo CNN-LSTM multivariado pode auxiliar, os produtores paranaenses, no planejamento dos custos de produção de frangos de corte. Apesar do modelo CNN-LSTM apresentar resultados adequados para uma previsão de 12 meses, sugere-se, para futuros trabalhos de pesquisa, proceder a estimação, dos custos de produção de frangos de corte, com outros modelos de análise de séries temporais, tais como os modelos de *machine learning* XGBoost (*Xtreme Gradient Boosting*) e LighGBM (*Light Gradient Boosting Machine*).

REFERÊNCIAS

- ABPA - Associação Brasileira de Proteína Animal. (2024). *Relatório Anual 2024*. Recuperado de: https://abpa-br.org/wp-content/uploads/2024/04/ABPA-Relatorio-Anual-2024_capa_frango.pdf.
- Bastiani, M., Santos, J. A. A., Schmidt, C. A. P., & Sepulveda, G. P. L. (2018). Application of data mining algorithms in the management of the broiler production. *Geintec*, 8(3), 4573-4587.

- Cankurt, S., & Subasi, A. (2015). Comparasion of linear regression and neural network models forecasting tourist arrivals to turkey. *International Symposium on Sustainable Development*, Turquia.
- Elmaz, F., Eyckerman, R., Castells, W., Latré, S., & Hellinckx, P. (2021). CNN-LSTM architecture for predictive indoor temperature modeling. *Building and Environment*, 206(1), 2021. doi: 10.1016/j.buildenv.2021.108327
- EMBRAPA. (2024). *Custos de produção de frangos de corte por estado*. Recuperado de: <https://www.embrapa.br/suinos-e-aves/cias/custos/icpfango>.
- Graves A. (2014). Towards end-to-end speech recognition with recurrent neural networks. *Proceedings of the 31st International Conference on Machine Learning*. (ICML-14), Beijing, China.
- Lawal, A., Rehman, S., Alems, L. M., & Alam, M. (2021). Wind speed prediction using hybrid 1D CNN and BLSTM network. *IEEE Acess*, 9(1). doi: 10.1109/ACCESS.2021.3129883
- LeCun, Y., Bengio, Y., & Haffener P. (1998). *Gradient Based Learning Applied to Document Recognition*. Proc. Of the IEEE, 1998.
- Li, P., Abdel-Aty, M., & Yuan, J. (2020). Real-time crash risk prediction on arterials based on LSTM-CNN. *Accident Analysis and Prevention*, 135(1). doi: 10.1016/j.aap.2019.105371
- Livieris, I. E., Pintelas, E., & Pintelas, P. A. (2020). CNN-LSTM model for gold price time- series forecating. *Neural Compuntig and Applications*, 32(1). doi: 10.1007/s00521-020-04867-x
- Paraná. (2024). Com números recordes, Paraná lidera aumento da producao de frangos, suínos e ovos em 2023. Recuperado de: <https://www.aen.pr.gov.br/Noticia/Com-numeros-recordes-Parana-lidera-aumento-da-producao-de-frangos-suinos-e-ovos-em-2023>.
- Passos, B. T. (2021). *Long short term: redes neurais artificiais que são capazes de ler, ouvir e ler*. Recuperado de: <https://ateliware.com/blog/long-short-term-memory>.
- Pinheiro, T. C., Santos, J. A. A., & Pasa, L. A. (2020). Gestão da produção de frangos de corte por meio de redes neurais artificiais. *Revista Holos*. 2(1), 1-15. doi: <https://doi.org/10.15628/holos.2020.9043>
- Sandi, A. J., & Miele, M. (2012). Análise comparativa dos custos de produção de frangos de corte em SC e GO. *Guia Gessulli da Avicultura & Suinocultura Industrial*.

- Santos, J. A. A. (2021). Aplicação de redes neurais na previsão dos custos de produção de frangos de corte no estado do Paraná. *Revista FSA*, 18(6), 2021. doi: 10.12819/2021.18.6.9
- Santos, J. A. A. (2022). Previsão do preço do café arábica: uma aplicação de redes neurais CNN-BLSTM. *Research, Society and Development*, 11(1). doi: 10.33448/rsd-v11i3.26101
- Santos, J. A. A., & Chaucoski, Y. (2021). Aplicação de modelos de redes neurais artificiais na previsão do preço de alumínio. *Revista ABCustos*, 16(1). doi: 10.47179/abcustos.v16i2.603
- Sebastian S. (2016). Performance evaluation by artificial neural network using WEKA. *International Research Journal of Engineering and Technology*. 3(3), 1459-1464.
- Vargas, A. C. G., Paes, A., & Vasconcelo, C. N. (2022). *Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres*. Recuperado de: <http://gibis.unifesp.br/sibgrapi16/e-proceedings/wuw/7.pdf>.
- Wu, K., Wu, J., Feng, L., Yang, B., Liang, R., & Yang, S. (2021). An attention-based CNN-LSTM-BiLSTM model for short-term electric load forecasting in integrated energy system. *International Transactions on Electrical Energy Systems*, 31(1). doi: 10.1002/2050-7038.12637
- Zha, W., Liu, Y., Wan, Y., Luo, R., Li, D., Yang, S., & Xu, Y. (2022). Forecasting monthly Gas field production based on the CNN-LSTM model. *Energy*. 260(1). doi: 10.1016/j.energy.2022.124889
- Zhang, J., & Li, S. (2022). Air quality index forecast in Beijing based on CNN-LSTM multi-model. *Chemosphere*. 308(1). doi: 10.1016/j.chemosphere.2022.136180

Data de Submissão: 04/06/2024

Data de Aceite: 13/03/2025