

Gestão preditiva dos custos de alimentação de suínos utilizando redes neurais híbridas CNN-LSTM

Predictive Management of Swine Feed Costs Using CNN-LSTM Hybrid Neural Networks

Aldino Normelio Brun Polo
<https://orcid.org/0009-0000-2969-274X>

Mestrando do Programa de Pós-Graduação em
Tecnologias Computacionais para o Agronegócio – PPGTCA.
Universidade Tecnológica Federal do Paraná (UTFPR) – Brasil.
aldinopolo@alunos.utfpr.edu.br

José Airton Azevedo dos Santos
<https://orcid.org/0000-0002-2568-5734>

Doutor em Engenharia Elétrica. Universidade Tecnológica Federal do
Paraná (UTFPR) – Brasil. airton@utfpr.edu.br

RESUMO

O custo com alimentação é o fator que mais influencia o custo total de produção de suínos. Para o produtor, na gestão do seu negócio, a previsão desse custo é fundamental. Neste contexto, este trabalho propõe a utilização da rede CNN-LSTM (*Convolutional Neural Network - Long Short Term Memory*) multivariada para previsão do custo da ração para alimentação de suínos no estado do Paraná. A base de dados é formada, no período de janeiro/2007 a maio/2024, por séries mensais do custo da ração, do preço do farelo de soja e do preço do milho. Modelos de previsão univariados e multivariados foram implementados, na linguagem Python, utilizando o *framework* Keras. Resultados de modelos de previsão CNN-LSTM e LSTM, em suas versões univariada e multivariada, foram comparados por meio das métricas MAE (*Mean Absolute Error*), RMSE (*Root Mean Squared Error*) e MAPE (*Mean Absolute Percentage Error*). Verificou-se, para um horizonte de 12 meses, que o modelo CNN-LSTM multivariado apresentou o melhor desempenho (MAE=0,1 R\$/kg, RMSE=0,13 R\$/kg e MAPE=2,45%).

Palavras-chave: redes híbridas; séries temporais; Keras; Python.

ABSTRACT

The cost of feeding is the factor that most influences the total cost of swine production. For the producer, in the management of their business, forecasting this cost is fundamental. In this context, this work proposes the use of the multivariate CNN-LSTM (*Convolutional Neural Network - Long Short Term Memory*) network for forecasting the cost of feed for swine feeding in the state of Paraná. The dataset is formed, in the period from January/2007 to May/2024, by monthly series of feed cost, soybean meal price, and corn price. Univariate and multivariate forecasting models were implemented, in the Python language, using the Keras framework. Results of CNN-LSTM and LSTM forecasting models, in their univariate and multivariate versions, were compared through the metrics MAE (*Mean Absolute Error*), RMSE (*Root Mean Squared Error*), and MAPE (*Mean Absolute Percentage Error*). It was verified, for a 12-month horizon, that the multivariate CNN-LSTM model presented the best performance (MAE=0,1 R\$/kg, RMSE=0,13 R\$/kg, and MAPE=2,45%).

Keywords: hybrid networks; time series; Keras; Python.

Recebido em 02/12/2024. Aprovado em 02/06/2026. Avaliado pelo sistema *double blind peer review*. Publicado conforme normas da ABNT.
<https://doi.org/10.22279/navus.v18.2060>

1 INTRODUÇÃO

O Brasil, segundo a Associação Brasileira de Proteína Animal, é o quarto maior produtor mundial de carne suína, produzindo cerca de 5,156 milhões de toneladas em 2023, e o quarto maior exportador mundial, com 1,230 milhão de toneladas exportadas (ABPA, 2024). Além disso, a suinocultura apresenta funções sociais de grande relevância como: fornecimento de carne para a população, geração de empregos, entre outras (Portes et al., 2019). Somente a suinocultura gera mais de 1,5 milhões de empregos, diretos e indiretos (Brandt, 2023).

O fator que mais influencia os custos de produção de suínos é a alimentação. Os custos de alimentação podem atingir cerca de 70% a 80% do custo total de produção de suínos. O milho e o farelo de soja são os principais ingredientes da ração utilizada na alimentação suína (Portes et al., 2019; Summit Agro, 2021). Existe uma parcela de utilização de sorgo, aveia, centeio e arroz, na dieta dos suínos, mas ainda com baixa representatividade (Brandt, 2023).

O custo da alimentação de suínos, devido a oscilações no preço da soja e do milho, pode muitas vezes inviabilizar a presença do produtor no mercado. Portanto, a previsão do custo, por meio de redes neurais artificiais, pode fornecer informações importantes e subsídios, para os suinocultores, nos processos de tomada de decisão.

Dentre as técnicas de previsão de redes neurais artificiais têm-se as redes CNN e LSTM. As redes CNN são redes neurais artificiais adequadas para extração de características espaciais e temporais de um conjunto de dados. Já as redes LSTM são redes capazes de identificar sequências de curto e longo prazo, obtendo informações relevantes para previsões futuras (XU et al., 2020; Yao, 2018).

Diversos estudos utilizaram redes CNN-LSTM na previsão de séries temporais. Dentre eles, podem-se citar os trabalhos de Santos et al. (2022), que utilizaram a rede CNN-LSTM pra realizar a previsão do consumo de energia elétrica de uma agroindústria. Verificaram, para um horizonte de 24 horas, que a rede CNN-LSTM obteve um bom desempenho. Zha et al. (2022) utilizaram a rede CNN-LSTM para prever a produção mensal de um campo de gás. Resultados de previsão do modelo CNN-LSTM foram comparados com resultados obtidos dos modelos ARIMA (*Autoregressive Integrated Moving Average*) e SVM (*Support Vector Machine*). Concluíram que, para a previsão mensal do campo, o modelo CNN-LSTM apresentou o melhor desempenho. Khorram e Jehbez (2023) utilizaram a rede CNN-LSTM para prever a vazão mensal de um reservatório. Compararam os resultados do modelo CNN-LSTM com os modelos CNN, LSTM, SVM e ARIMA. Verificaram que o modelo CNN-LSTM obteve os melhores resultados. Já Kim e Cho (2019) utilizaram o modelo CNN-LSTM para prever o consumo de energia elétrica residencial. Constataram, comparando os resultados de previsão dos modelos CNN-LSTM, LSTM e de Regressão Linear, que o modelo CNN-LSTM também obteve o melhor desempenho.

Neste contexto, este trabalho tem como objetivo propor a utilização da rede CNN-LSTM (*Convolutional Neural Network - Long Short Term Memory*) multivariada para previsão do custo da ração para alimentação de suínos no estado do Paraná.


2 REDE CNN-LSTM

A rede CNN, proposta por Lecun et al. (1998), é muito utilizada em tarefas de classificação e visão computacional. Sua versão 1D é caracterizada por sua capacidade de extrair conhecimento útil e apreender a

representação interna de dados de séries temporais. Basicamente a rede CNN é composta por uma camada convolucional (*Convolution Layer*) e uma camada de *pooling* (*Pooling Layer*). Na camada de convolução, são extraídas informações importantes dos dados. A camada de *pooling* tem como objetivo principal reduzir o número de informações extraídas (Li et al., 2020).

A rede LSTM, proposta por Hochreiter e Schmidhuber (1997), é uma rede recorrente muito eficaz para identificar sequências de curto e longo prazo. Células de memória compõem a topologia de uma rede LSTM (Figura 1). A informação, neste tipo de rede neural, é transmitida entre as células da camada oculta, por meio de portas. Cada célula contém três portas: uma porta de entrada (*input gate* - i_t), uma porta de esquecimento (*forget gate* - f_t) e uma porta de saída (*output gate* - O_t). Estas portas determinam os dados que devem entrar (i_t), os que devem sair (O_t) e os que devem ser esquecidos (f_t) (Santos, 2022; Livieris et al., 2020, Lu et al., 2020).

Figura 1 - Célula de memória



Fonte: Adaptado de Jia et al. (2020).

As equações da rede neural LSTM são apresentadas a seguir (Shewalkar et al., 2019):

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad 1$$

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad 2$$

$$\tilde{C}_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad 3$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad 4$$


$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad 5$$

$$h_t = o_t * \tanh(C_t) \quad 6$$

Onde x_t e h_t são os vetores de entrada e saída, w_f , w_i , w_c e w_o são os pesos, b_f , b_i , b_c e b_o os bias, σ a função de ativação *sigmoid* e $\tanh$ a função de ativação tangente hiperbólica.

A combinação dos modelos CNN e LSTM (CNN-LSTM) potencializa as vantagens dos dois modelos, contribuindo para maior precisão na previsão dos custos de alimentação de suínos. A arquitetura da rede CNN-LSTM, apresentada na Figura 2, é baseada na combinação destas redes.

Figura 2 - Estrutura da CNN-LSTM



A rede CNN-LSTM usa a camada CNN para extrair características entre as variáveis que afetam a previsão dos custos de alimentação de suínos. A saída da camada CNN é usada como entrada da camada LSTM. Na camada LSTM são realizadas as previsões dos custos de alimentação dos suínos (Kim; Cho, 2019).

3 METODOLOGIA


3.1 Etapas do trabalho

Inicialmente, na primeira etapa do trabalho, realizou-se a coleta e a análise exploratória dos dados. Em seguida, na segunda etapa, os modelos de redes neurais LSTM e CNN-LSTM foram desenvolvidos. Nesta etapa, foram escolhidos os modelos com melhor desempenho no conjunto de dados de validação. Na última etapa, a etapa de teste, a acurácia dos modelos foi analisada por meio das métricas MAE, RMSE e MAPE.

3.2 Base de dados


A base de dados para previsão dos custos de alimentação de suínos, é formada por três séries temporais: *Feed* (Custos de alimentação de suínos - Paraná (R\$/kg) - (EMBRAPA, 2024)), *Soy* (preço médio do farelo de soja - Paraná (R\$/kg) - (IPEA, 2024a)) e *Corn* (Preço médio do milho - Paraná (R\$/kg) - (IPEA, 2024b)). As três séries apresentam, no período de janeiro de 2007 a maio de 2024, 222 observações cada. Os *Boxplots* dos dados, das três séries temporais, são apresentados na Figura 3.

Figura 3 - *Boxplots* das séries temporais.



A série histórica, dos custos de alimentação de suínos (*Feed*), é apresentada na Figura 4.

Figura 4 - Série histórica dos custos de alimentação de suínos



Na Tabela 1 apresentam-se os cinco primeiros registros das séries temporais (*Feed* (Custos de alimentação de suínos), *Soy* (preço médio do farelo de soja) e *Corn* (Preço médio do milho)).

Tabela 1 - Cinco primeiros registros das três séries (R\$/kg)

Date	Feed	Soy	Corn
01/01/2007	1,11	0,517363	0,321760
01/02/2007	1,14	0,541924	0,309282
01/03/2007	1,14	0,508328	0,305125
01/04/2007	1,11	0,468929	0,285740
01/05/2007	1,08	0,431543	0,277835

Inicialmente, com os dados fornecidos pela EMBRAPA para o estado do Paraná, formou-se o conjunto de teste com 12 observações (12 meses). Na sequência, construíram-se os conjuntos de treinamento e validação. O Conjunto de treino ficou com 147 observações (70%) e o Conjunto de validação com 63 observações (30%).

Neste trabalho, para otimizar e treinar os modelos, foi necessário normalizar os dados por meio da função MinMax (Arunkumar et al., 2022) (Equação 1).


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

Onde: x é o dado da série temporal; x_n é o dado normalizado; x_{min} e x_{max} são os valores mínimo e máximo da série temporal.

A correlação entre as variáveis *Feed*, *Soy* e *Corn* é apresentada na Figura 5. Observa-se, dos coeficientes de correlação, que as variáveis

preços do farelo de soja (*Soy*) e do milho (*Corn*) têm praticamente o mesmo impacto no custo de alimentação dos suínos (*Feed*) (0,98 e 0,97).

Figura 5 - Correlação entre as variáveis



3.3 Métricas

As métricas MAE, RMSE e MAPE, apresentadas na Tabela 2, foram utilizadas para avaliar, de acordo com os custos previstos e observados, o desempenho dos modelos CNN-LSTM e LSTM univariados e multivariados (Oliveira; Santos, 2024; Oliveira et al., 2023):

Tabela 2 - Equações das métricas MAE, RMSE e MAPE

Métrica	Equação
Mean Absolute Error (MAE)	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $
Root Mean Squared Error (RMSE)	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n ((y_i - \hat{y}_i)^2)}$
Mean Absolute Percentage Error (MAPE)	$MAPE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)/y_i \times 100$

Onde: y_i é o valor real do período i , $\hat{y}_i$ a previsão para o período i e n é o número de observações.

4 RESULTADOS

Inicialmente, neste estudo, realizou-se uma análise descritiva dos dados dos custos de alimentação (Tabela 3). Observou-se, nesta análise descritiva dos dados, um custo mensal médio de alimentação de 2,6799 R\$/kg


e um desvio padrão de 1,4456 R\$/kg. Obteve-se um alto coeficiente de variação (53,94%), o que indicou variabilidade dos dados.

Tabela 3 - Análise descritiva dos dados

Descrição	FEED
Média (R\$/kg)	2,679952
Valor mínimo (R\$/kg)	1,04000
Valor máximo (R\$/kg)	6,37000
Desvio padrão (R\$/kg)	1,445623
Coeficiente de variação (%)	53,94

Os custos mensais mínimos e máximos de alimentação de suínos são apresentados na Figura 6. Observou-se, dos resultados apresentados na figura, o maior custo máximo mensal para o mês de março (6,37 R\$/kg) e o menor custo mínimo mensal para o mês de julho (1,04 R\$/kg).

Figura 6 - Custos de alimentação mínimos e máximos mensais



4.1 Treinamento e validação


Na etapa de treinamento e validação, com o objetivo de encontrar os melhores modelos de previsão, vários hiperparâmetros foram otimizados. Na Tabela 4 apresentam-se os parâmetros da rede CNN-LSTM multivariada utilizados para previsão dos custos de alimentação dos suínos.

Tabela 4 - Parâmetros da rede CNN-LSTM

Parâmetros	Valores
<i>Time steps</i>	6
<i>Learning rate</i>	0,0011
<i>Epochs</i>	175
<i>Batch</i>	40
<i>Convolution layer filters</i>	16
<i>Convolution layer kernel size</i>	6
<i>Convolution layer activation function</i>	relu
<i>Convolution layer padding</i>	Same
<i>Pooling layer pool size</i>	2
<i>Pooling layer padding</i>	Same
<i>Pooling layer activation function</i>	relu
<i>Numbers of hidden units in LSTM layer</i>	32
<i>Dropout</i>	0,001
<i>LSTM activation function</i>	tanh
<i>Dense units</i>	1
<i>Optimizer</i>	Adam

Na Figura 7 apresenta-se a estrutura básica do modelo CNN-LSTM multivariado.

Figura 7 - Estrutura do modelo CNN-LSTM



Na camada *InputLayer*, tem-se um vetor $(None, 6, 3)$, onde 6 é o passo de tempo e 3 a dimensão da entrada (*Feed*, *Soy* e *Corn*). Na sequência, os dados são enviados para a camada *Conv1D*. Nessa camada, os recursos são extraídos, sendo produzido o vetor $(None, 6, 16)$, onde 16 é o tamanho dos filtros da camada de convolução. Em seguida, o vetor passa pela camada *MaxPooling1D* e é enviado para treinamento na camada *LSTM*. O vetor de saída $(None, 32)$, onde 32 é o número de unidades ocultas, é enviado para a camada *Dense*.


Os resultados dos indicadores de desempenho MAE, RMSE e MAPE, para o Conjunto de Validação, são apresentados na Tabela 5.

Tabela 5 - Resultados das métricas - Conjunto de Validação

MODELO	MAE (R\$/kg)	RMSE (R\$/kg)	MAPE (%)
CNN-LSTM - Mult.	0,31	0,42	7,25
LSTM - Mult.	0,37	0,51	8,75
CNN-LSTM - Uni.	0,43	0,57	8,99
LSTM - Uni.	0,60	0,72	12,42

Os resultados das previsões do Conjunto de Validação para os quatro modelos (63 observações), são apresentados na Figura 8.

Figura 8 - Resultados das previsões - Conjunto de Validação



Pode-se observar, dos resultados dos indicadores apresentados na Tabela 5, que o modelo CNN-LSTM multivariado apresentou as melhores métricas (MAE=0,31 R\$/kg, RMSE=0,42 R\$/kg e MAPE=7,25%) seguido pelo modelo LSTM multivariado (MAE=0,37 R\$/kg, RMSE=0,51 R\$/kg e MAPE=8,75%). A curva estimada pelo modelo CNN-LSTM multivariado, como se observa na Figura 8, é a que melhor acompanha a trajetória dos valores observados (Embrapa) no conjunto de validação. Ao contrário dos demais modelos, essa arquitetura consegue capturar com maior fidelidade os picos e as flutuações do custo da ração ao longo dos meses.

4.2 Teste


Os valores observados e previstos para o Conjunto de Teste (12 meses - jun/2023 a mai/2024) são apresentados na Tabela 6.

Tabela 6 - Valores observados e previstos - Conjunto de Teste

DATA	EMBRAPA	LSTM_Uni	LSTM_Mult	CNN-LSTM_Uni	CNN-LSTM_Mult
2023-06	4,03	4,493312	4,1475806	4,527812	3,9867969
2023-07	4,08	4,26688	4,107914	4,506483	4,0258536
2023-08	4,05	4,146584	4,1092362	4,426118	4,094895
2023-09	4	3,992144	4,128312	4,34881	4,1253443
2023-10	4,04	3,832477	4,1732535	4,325698	4,1422257
2023-11	4,26	3,704997	4,219956	4,275109	4,1459484
2023-12	4,3	3,63898	4,2688103	4,235404	4,1739492
2024-01	4,2	3,525726	4,3140545	4,191974	4,204284
2024-02	4,1	3,429132	4,340961	4,150679	4,1941357
2024-03	3,88	3,333026	4,3440223	4,10834	4,183093
2024-04	3,93	3,243929	4,3243694	4,068211	4,1062937
2024-05	4,03	3,164728	4,3013124	4,028096	4,061487


Na Figura 9 são apresentados os resultados das métricas MAE, RMSE e MAPE para o Conjunto de Teste.

Figura 9 - Resultados das métricas - Conjunto de Teste



Na Figura 10 apresentam-se, na forma gráfica, os valores observados e preditos, dos custos de alimentação de suínos, para os 12 meses do Conjunto de Teste.

Figura 10 - Curvas dos dados observados e previstos - Conjunto de Teste.



Nota-se, dos dados apresentados na Figura 9, que o modelo CNN-LSTM multivariado apresentou, para o Conjunto de Teste, o melhor desempenho, isto é, menores valores de MAE, RMSE e MAPE (MAE=0,1 R\$/kg, RMSE=0,13 R\$/kg e MAPE=2,45%). Observa-se também, do gráfico apresentado na Figura 10, que a curva do modelo CNN-LSTM multivariado se ajustou melhor, que a curva dos outros três modelos, a curva dos dados observados (EMBRAPA).

5 CONCLUSÃO

Este trabalho teve como objetivo propor, para previsão dos custos de alimentação de suínos, a utilização do modelo CNN-LSTM multivariado. Para realização deste objetivo, utilizaram-se dados, para treinamento, validação e teste, disponibilizados pela EMBRAPA e pelo IPEA.

Resultados de previsão, do modelo proposto CNN-LSTM no Conjunto de Teste, foram comparados, por meio das métricas MAE, RMSE e MAPE, com resultados obtidos dos modelos LSTM multivariado, LSTM univariado e CNN-LSTM univariado. Observou-se, por meio desta comparação, que o modelo CNN-LSTM multivariado, em relação aos outros três modelos, apresentou um melhor desempenho preditivo (menores valores de MAE, RMSE e MAPE).

Por fim, conclui-se que o modelo CNN-LSTM multivariado apresentou resultados promissores e pode contribuir como apoio em processos de tomada de decisão e planejamentos futuros na suinocultura. No entanto, é importante destacar que o estudo foi conduzido apenas com dados do estado do Paraná e considerando um único horizonte de previsão. Assim, recomenda-se cautela quanto à generalização dos resultados, sendo necessária, para confirmar sua aplicabilidade como ferramenta de gestão, a validação do modelo em diferentes regiões e cenários produtivos.

REFERÊNCIAS

ABPA, Associação Brasileira de Proteína Animal. **Relatório anual**. Disponível em: < https://abpa-br.org/wp-content/uploads/2024/04/ABPA-Relatorio-Anual-2024_capa_frango.pdf>. Acesso em: 11 jul. 2024.

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.
<https://doi.org/10.1016/j.aej.2022.01.011>

BRANDT, G. **Produção Brasileira de Suínos: Como se formam os custos de produção?** 2023. Disponível em: < https://www.3tres3.com.br/artigos/producao-brasileira-de-suinos-como-se-formam-os-custos-de-producao_3367/>. Acesso em: 10 mai. 2024.

EMBRAPA. **Custos de produção de suínos por estado**. Disponível em: < <https://www.embrapa.br/suinos-e-aves/cias/custos/icpsuino>>. Acesso em: 10 mai. 2024.

FURTUOSO, G. D. V.; SANTOS, M.; QUINTAL, R. S. Aplicação de redes neurais recorrentes na previsão de séries temporais: um estudo de preços de ações na bolsa de valores. **Revista Gestão em Análise**, 2022.
<https://doi.org/10.12662/2359-618xregea.v11i2.p25-36.2022>

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural Computation**, v. 9, n. 8, p. 1735-1780, 1997. <https://doi.org/10.1162/neco.1997.9.8.1735>.

KHORRAM, S.; JEHBEZ, N. A hybrid CNN-LSTM approach for monthly reservoir inflow forecasting. **Water Resources Management**, 2023.
<https://doi.org/10.1007/s11269-023-03541-w>

IPEA. **Preço médio no atacado: soja em farelo**. Disponível em: < <https://www.ipeadata.gov.br/Default.aspx>. Acesso em: 10 mai. 2024a.

IPEA. **Preço médio no atacado: milho**. Disponível em: < <https://www.ipeadata.gov.br/Default.aspx>. Acesso em: 10 mai. 2024b.

JIA, P.; LIU, H.; WANG, P. Research on a Mine Gas Concentration Forecasting Model Based on a GRU Network. **IEEE Access**, 2020.
<https://doi.org/10.1109/ACCESS.2020.2975257>

KIM, T. Y.; CHO, S. B. Predicting residential energy consumption using CNN-LSTM neural networks. **Energy**, v. 182, 2019.
<https://doi.org/10.1016/j.energy.2019.05.230>

LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFENR, P. Gradient-Based Learning Applied to Document Recognition. **Proceedings of the IEEE**, v. 86, 1998.
<https://doi.org/10.1109/5.726791>

LI, T.; HUA, M.; WU, X. A Hybrid CNN-LSTM Model for Forecasting Particulate Matter (PM2.5). **IEEE Access**, v. 8, 2020.
<https://doi.org/10.1109/ACCESS.2020.2971348>

LIVIERIS, I. E.; PINTELAS, E.; PINTELAS, P. A CNN-LSTM model for gold price time-series forecasting. **Neural Computing and Applications**, 2020.
<https://doi.org/10.1007/s00521-020-04867-x>

LU, W.; LI, J.; SUN, A. A CNN-LSTM-based model to forecast stock prices. Complexity, 2020. <https://doi.org/10.1155/2020/6622927>

OLIVEIRA, L.; SANTOS, J. A. A. Previsão do preço futuro do óleo de girassol: uma abordagem baseada no modelo CNN-Attention. **Revista Cereus**, 2024. <https://doi.org/10.18605/2175-7275/cereus.v16n2p70-82>

OLIVEIRA, L.; RUSTICK, A.; SANTOS, J. A. A. Previsão do Abate de Frangos: Uma Investigação Comparativa da Aplicação de Redes Neurais. **Revista FSA**, v. 20, 2023.
<http://dx.doi.org/10.12819/2023.20.2.10>

PORTES, J. V.; LACERD, V. V.; NETO, J. B.; SOUZA, A. R. L. Análise dos custos da cadeia produtiva de suínos no Sul do Brasil. **Custos e @gronegócio on line**, 2019.

SANTOS, J. A. A. Previsão do preço do café arábica: uma aplicação de redes neurais CNN-BLSTM. **Research, Society and Development**, v. 11, 2022.
<http://dx.doi.org/10.33448/rsd-v11i3.26101>

SANTOS, J. A. A., ANTONIOLLI, E. A.; GUEDES, A. L. PASA, L. A. Previsão do consumo de energia elétrica em uma agroindústria: um estudo de caso usando redes LSTM e CNN-LSTM. **Revista Cereus**, v. 14, 2022.
<http://dx.doi.org/10.18605/2175-7275/cereus.v14n1p63-76>

SHEWALKAR, A.; NYAVANANDI, D.; LUDWIG, S. A. Performance evaluation of deep neural networks applied to speech recognition; RNN, LSTM and GRU. **JAICR**, 2019. <http://dx.doi.org/10.2478/jaiscr-2019-0006>

SUMMIT AGRO. **Qual é o impacto dos preços do milho e da soja na criação de aves e suínos?** 2021. Disponível em:
<<https://summitagro.estadao.com.br/noticias-do-campo/qual-e-o-impacto-dos-precos-do-milho-e-da-soja-na-criacao-de-aves-e-suinos/>>. Acesso em: 10 mai. 2024.

XU, W.; JIANG, Y.; ZHANG, X.; ZHANG, R. Using long short-term memory networks for river flow prediction. **Hydrology Research**. v. 51, 2020.
<https://doi.org/10.2166/nh.2020.026>

YAO, H. et al. Convolutional neural networks for time series classification. **Journal of System Engineering and Electronics**. v. 29, 2018.
ZHA, W. et al. Forecasting monthly gas field production based on the CNN-LSTM model. **Energy**, 2022. <http://dx.doi.org/10.1016/j.energy.2022.124889>