



University of  
Texas Libraries



e-revist@s



Centro Universitário Santo Agostinho

# revistafsa

[www4.fsnet.com.br/revista](http://www4.fsnet.com.br/revista)

Rev. FSA, Teresina, v. 20, n. 2, art. 10, p. 187-202, fev. 2023

ISSN Impresso: 1806-6356 ISSN Eletrônico: 2317-2983

<http://dx.doi.org/10.12819/2023.20.2.10>

DOAJ DIRECTORY OF  
OPEN ACCESS  
JOURNALS

WZB  
Wissenschaftszentrum Berlin  
für Sozialforschung



Zeitschriftendatenbank



## Previsão do Abate de Frangos: Uma Investigação Comparativa da Aplicação de Redes Neurais

### Broiler Slaughter Prediction: A Comparative Investigation of the Application of Neural Networks

#### Leandro de Oliveira

Mestrado do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio (PPGTCA)  
Bacharel em Engenharia Elétrica pela Universidade Tecnológica Federal do Paraná  
E-mail: leandro-smi@hotmail.com

#### Andressa Rustick

Mestrado do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio (PPGTCA)  
Graduação em Licenciatura em Matemática pela Universidade Tecnológica Federal do Paraná  
E-mail: andressarustick@hotmail.com

#### José Airton Azevedo dos Santos

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

#### Endereço: Leandro de Oliveira

CAMPUS MEDIANEIRA Avenida Brasil, 4232 CEP  
85884-000 – Caixa, Postal 271 - Medianeira - PR, Brasil.

#### Endereço: Andressa Rustick

CAMPUS MEDIANEIRA Avenida Brasil, 4232 CEP  
85884-000 – Caixa, Postal 271 - Medianeira - PR, Brasil.

#### Endereço: José Airton Azevedo dos Santos

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 25/12/2022. Última versão  
recebida em 17/01/2023. Aprovado em 18/01/2023.

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

O presente trabalho tem como objetivo comparar modelos, baseados em redes neurais recorrentes, para a previsão da quantidade de frangos abatidos no Brasil. A base de dados, disponibilizada pelo Instituto de Pesquisa Econômica Aplicada (IPEA), apresenta uma série histórica do abate de frangos, no período entre 2005 e 2022. Modelos de previsão, baseados em Redes Neurais LSTM (*Long Short-Term Memory*) e GRU (*Gated Recurrent Unit*), foram implementados, na linguagem Python, utilizando a biblioteca PyTorch. Resultados obtidos, dos dois modelos, foram comparados por meio da métrica MAPE (*Mean Absolute Percent Error*). Verificou-se, para um horizonte de cinco meses, que o modelo GRU apresentou um melhor desempenho que o modelo LSTM.

**Palavras-chave:** MAPE. Python. Redes LSTM. Redes GRU.

## ABSTRACT

The present work aims to evaluate models, based on recurrent neural networks, to predict the amount of broiler slaughtered in Brazil. The database, made available by the Institute for Applied Economic Research (IPEA), presents a historical series of broiler slaughter, in the period between 2005 and 2022. Forecast models, based on LSTM Neural Networks (Long Short-Term Memory) and GRU (Gated Recurrent Unit), were implemented, in the Python language, using the PyTorch library. Results obtained from the two models were compared using the MAPE (Mean Absolute Percent Error) metric. It was verified, for a horizon of five months, that the GRU model presented a better performance than the LSTM model.

**Keywords:** MAPE. Python. LSTM networks. GRU networks.

## 1 INTRODUÇÃO

A avicultura de corte no Brasil, ao longo das últimas décadas, consolidou-se como um dos segmentos mais dinâmicos e importantes da economia nacional. Seu desenvolvimento pode ser considerado como o símbolo do crescimento e modernização do setor (ABPA, 2020; PINHEIRO *et al.*, 2020; SOBRINHO, 2010).

Diversos fatores contribuíram para que o setor avícola alcançasse o patamar atual. Dentre eles podem-se citar as inovações tecnológicas, nas áreas de genética, nutrição, sanidade e no processo produtivo (PROCÓPIO *et al.*, 2020; JÚNIOR *et al.*, 2009).

A avicultura de corte brasileira se destaca no agronegócio como uma das mais competitivas do mundo. A quantidade de frangos abatidos, no primeiro trimestre de 2021, teve o melhor trimestre, de sua série histórica, com 1,57 bilhão de cabeças abatidas. A região Sul ficou com 60,4% do abate nacional, seguido pelo Sudeste (19,2%), Centro-Oeste (14,6%), Nordeste (4,2%) e Norte (1,76%) (IBGE, 2021).

Técnicas de previsão de séries temporais podem ser utilizadas por produtores e compradores, como instrumentos para avaliar, em termos de abate, o setor avícola. As séries temporais, coleções de observações realizadas ao longo do tempo, existem em diversas atividades, como: economia, demografia, finanças, energia, entre outras (PAIVA *et al.*, 2019). Dentre as técnicas utilizadas, para previsão de séries temporais, estão as Redes Neurais Artificiais (RNAs). Segundo Haykin (2001), a Rede Neural Artificial é uma técnica de inteligência artificial, inspirada na arquitetura do cérebro humano. São capazes de memorizar, analisar e processar um grande número de dados obtidos de um experimento (BASTIANI, *et al.*, 2018; PINHEIRO *et al.*, 2020; SANTOS; CHAUKOSKI, 2020; SPANCERSKI; SANTOS, 2021).

Diversos trabalhos utilizaram métodos de previsão de séries temporais na avicultura de corte. Dentre eles, podem-se citar os trabalhos de Pinheiro *et al.* (2020) que aplicaram Redes LSTMs na previsão do preço do quilo de frango congelado e resfriado, Bastiani *et al.* (2018) aplicaram Redes MLPs para predição e classificação de variáveis produtivas das aves produzidas por uma cooperativa localizada na região oeste paranaense. Piacenti *et al.* (2007) aplicaram modelos ARIMA na previsão dos preços futuros do frango de corte. Magagnin (2008) utilizou, para predição do preço do frango de corte, Suavização Exponencial, ARIMA, Regressão Dinâmica e a combinação dessas metodologias. Já Paiva *et al.* (2019)

analisaram a produção de frangos no Brasil por meio de modelos SARIMA (ARIMA sazonal).

Embora o estudo da quantidade de frangos abatidos no Brasil tenha grande importância, principalmente por estar relacionada às práticas de consumo e alimentação da população, poucos são os trabalhos que utilizam redes neurais LSTM e GRU na previsão do abate. Geralmente, são utilizados modelos tradicionais como os modelos ARIMA.

Neste contexto, este trabalho tem como objetivo comparar modelos, baseados em redes neurais recorrentes LSTM e GRU, para a previsão da quantidade de frangos abatidos no Brasil.


O artigo é organizado da seguinte maneira. Na seção 2 são apresentadas as redes recorrentes LSTM e GRU. Na Seção 3 é apresentada a metodologia utilizada na previsão da quantidade de frangos abatidos no Brasil. Na Seção 4 são apresentados os resultados obtidos da aplicação desta metodologia. Comentários finais e conclusões, na Seção 5, finalizam o artigo.

## 2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção apresentam-se os algoritmos de previsão, utilizados nesta pesquisa, bem como as métricas utilizadas.

### 2.1 Redes Neurais Recorrentes

Uma Rede Neural Recorrente (RNN) é um tipo especial de Rede Neural Artificial projetada para apreender a partir de dados sequenciais. Nestas redes existe um tipo de retroalimentação em que o sinal retorna para uma camada anterior. As redes neurais recebem entradas de duas fontes: uma do presente e outra de um ponto passado, por meio de um tipo de retroalimentação (Figura 1) (VASCO, 2020).

**Figura 1 – Rede neural recorrente**

Fonte: Vasco (2020).

## 2.2 Redes LSTM

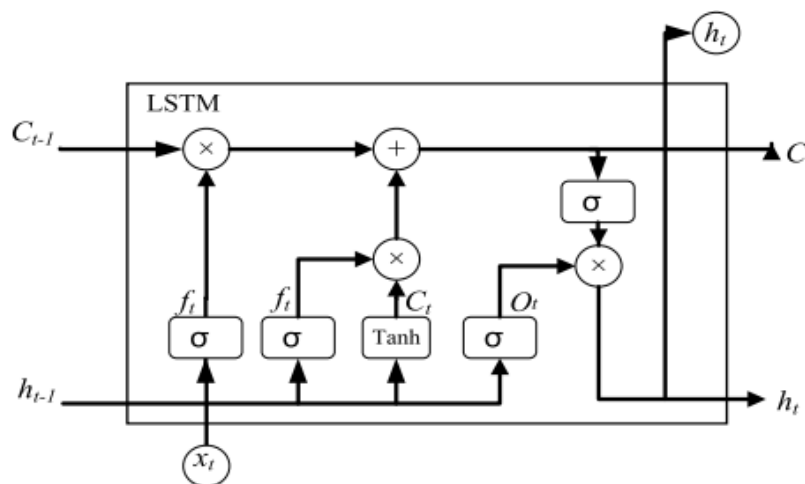
A rede Recorrente LSTM é um tipo de Rede Neural Artificial projetada para modelar sequências de longo prazo. Sendo muito utilizada em tarefas que envolvam dados sequenciais, como as séries temporais.

Um neurônio LSTM (célula) trabalha com uma sequência de entrada  $x_t$  (Figura 2) e cada porta (*gate*), dentro de uma célula, usa unidades de ativação 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 instante de tempos passados. Cada célula contém 3 portas (SPANCERSKI; SANTOS, 2021):

- Porta de Esquecimento  $f_t$  (*Forget Gate*): Permite eliminar elementos da memória;
- Porta de Saída  $O_t$  (*Output Gate*): Permite atualizar o estado oculto, com base na entrada e na memória da célula;
- Porta de Entrada  $i_t$  (*Update Gate*): Permite adicionar novos elementos à memória.

Todos esses valores acabam sendo concatenados, multiplicados ou somados, conforme mostra o circuito apresentado na Figura 2 (GRAVES, 2014, JIA; WANG, 2020).

Figura 2 – Célula LSTM



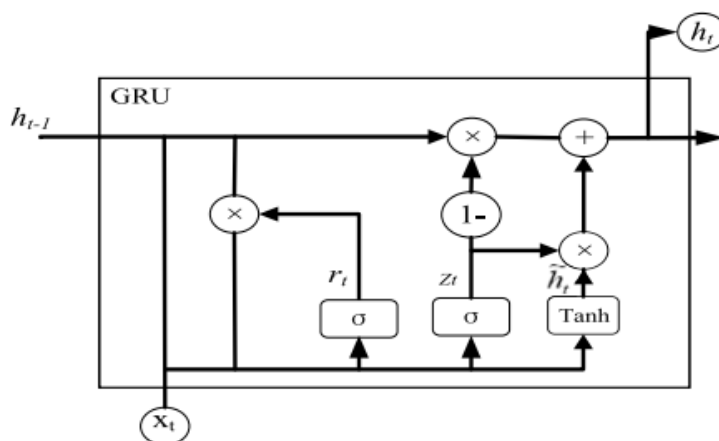
Fonte: Jia e Wang (2020).

• REDES GRU

A rede recorrente GRU é uma rede similar à rede LSTM, mas com uma estrutura mais simplificada, porém sem perda de desempenho. Esta rede, por possuir somente dois tipos de portas de controle, é treinada mais rapidamente que uma rede LSTM.

A topologia de um neurônio, de uma rede GRU, é apresentada na Figura 3. Cada neurônio contém duas portas, uma porta de redefinição  $z_t$  (*reset gate*) e um portão de atualização  $r_t$  (*update gate*). Basicamente estas portas regulam o fluxo de informações de entrada e decidem quais informações devem ser repassadas para saída.

Figura 3 – Célula GRU



Fonte: Jia e Wang (2020).

• MÉTRICAS

Neste trabalho, os modelos obtidos foram avaliados por (CANKURT; SUBASI, 2015; SANTOS, 2021; SPANCERSKI; SANTOS, 2021):

- $r^2$  (*Coefficient of Determination*): O coeficiente de determinação indica quanto o modelo foicapaz de explicar os dados coletados. Valor perfeito –  $r^2= 1$ .
- RSME (*Root Mean Squared Error*): Penaliza mais os erros maiores, permite avaliar aqualidade de um previsor em relação aos dados. Valor perfeito – RMSE= 0.
- MAE (*Mean Absolute Percent Error*): O valor do MAE representa o desvio médio entre ovalor observado e o predito. Valor perfeito – MAE= 0.
- MAPE (*Mean Absolute Percent Error*): O MAPE mede o tamanho do erro em termospercentuais. Valor perfeito – MAPE= 0%.

Na Tabela 1 apresentam-se as equações das métricas RMSE, MAE e MAPE.

**Tabela 1 – Equações MAE, RMSE e MAPE**

| Sigla   | MAE   | RMSE  | MAPE   |
|---------|---|---|--|
| Equação | $-\frac{1}{n} \sum_{i=1}^n  y_i - \hat{y}_i $ | $\sqrt{\frac{1}{n} \sum_{i=1}^n ((y_i - \hat{y}_i)^2)}$ | $-\frac{1}{n} \sum_{i=1}^n  (y_i - \hat{y}_i)/y_i  \times 100 = -\frac{1}{n} \sum_{i=1}^n ERP_i$ |

Fonte: Santos (2021).

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

### 3 MATERIAIS E MÉTODOS


#### 3.1 Etapas do Trabalho

Inicialmente, realizou-se neste trabalho a coleta dos dados. Na sequência, na etapa de Modelagem, foram implementados os modelos de redes neurais LSTM e GRU. Em seguida, na etapa de Treinamento e Validação, foram selecionados os melhores modelos de redes

neurais LSTM e GRU. Na sequência, na etapa de Teste, testaram-se os modelos para dados que não participaram da etapa de Treinamento e Validação.

Na Figura 4 apresentam-se as etapas realizadas para previsão da quantidade de frangos abatidos no Brasil.


**Figura 4 – Etapas do trabalho**



### 3.2 BASE DE DADOS

Para previsão da quantidade de frangos abatidos, em (Cabeça (mil)), utilizou-se uma base de dados com 214 meses (Jan/2005 - Set/2022) obtida do Instituto de Pesquisa Econômica Aplicada (IPEA) (IPEA, 2022). Os abates de frango para os meses de Maio/22, Junho/22, Julho/22, Agosto/20 e Setembro/22 foram retirados do conjunto de dados, para serem utilizados posteriormente para testes dos modelos (Conjunto de teste). Na Figura 5 apresenta-se o *boxplot* dos dados.

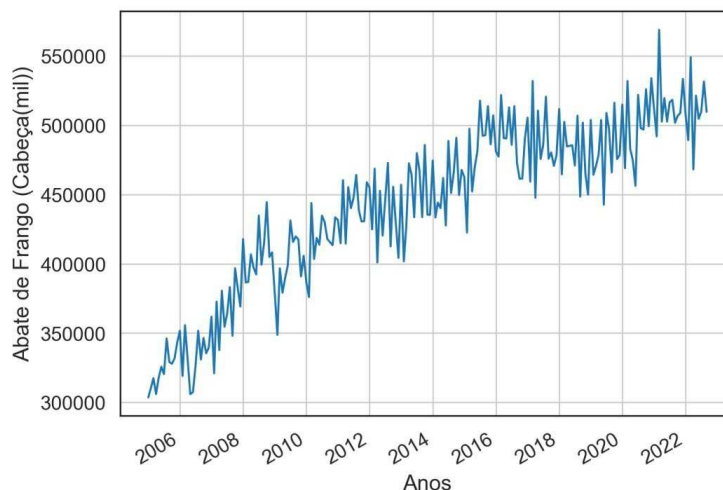
**Figura 5 – Boxplot dos dados**





A série histórica, obtida do IPEA, é apresentada na Figura 6.

**Figura 6 – Série: quantidade de frangos abatidos (período Jan/2005 - Set/2022)**



### 3.3 RECURSOS

Neste trabalho, utilizou-se para criar e executar os modelos o ambiente de computação Jupyter Notebook. Os modelos foram implementados por meio da biblioteca Pytorch. PyTorch é uma biblioteca de aprendizado de máquina, de código aberto, desenvolvida pelo laboratório de inteligência artificial do Facebook (SANTOS; SPANCERSKI, 2021). Foram também utilizadas, neste trabalho, as bibliotecas Scikit-learn, Pandas e Matplotlib. Scikit-learn é uma biblioteca que fornece uma seleção de ferramentas eficientes para aprendizado de máquina e modelagem estatística. Matplotlib é a mais famosa biblioteca de visualização de dados do Python. A biblioteca Pandas fornece ferramentas de análise de dados e estrutura de dados de alta performance (OLIVEIRA; SANTOS, 2019).

Um *desktop* com o sistema *Windows 10* foi utilizado para executar os modelos.

O *desktop* conta com um processador AMD Ryzen 5 e 32GB de memória RAM.

## 4 RESULTADOS E DISCUSSÕES


Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados (Tabela 2).

**Tabela 2 – Análise descritiva de dados**

|                              |           |
|------------------------------|-----------|
| Média (Cabeça (mil))         | 435382,63 |
| Mínimo (Cabeça (mil))        | 303633,31 |
| Máximo (Cabeça(mil))         | 566217,49 |
| Desvio Padrão (Cabeça (mil)) | 59128,03  |
| Coefficiente de Variação (%) | 13,5      |

Pode-se observar, dos dados apresentados na Tabela 2, que a quantidade de frangos abatidos ficou, para o período em estudo, em média de 435382,63 Cabeça (mil). Apresentando, neste período, quantidade mínima e máxima de 303633,31 e 566217,49 Cabeça (mil), respectivamente. Observa-se também um médio coeficiente de variação dos dados (13,5%).

A quantidade média de frangos abatidos, durante o período de Jan/2005 - Dez/2021, é apresentado na Figura 7. Pode-se notar, por meio desta figura, uma quantidade média abatida mínima de 410959,7952 (Cabeça (mil)) no mês de Fevereiro e uma quantidade média máxima de 454033,8108 (Cabeça (mil)) para o mês de Outubro.

**Figura 7 – Média de abate mensal de frango**

#### 4.1 Treinamento e Validação

Para escolha do melhor modelo, para previsão do abate de frangos, vários modelos LSTMs e GRUs foram treinados por meio da biblioteca Pytorch. Com base nos resultados das métricas RMSE e MAPE, os modelos com melhor desempenho, no conjunto de validação, foram selecionados. Estes modelos, obtidos por meio das métricas, utilizam o algoritmo de otimização Adam (*Adaptive moment*) com os hiperparâmetros apresentados na Tabela 3. Na Tabela 4 apresentam-se os resultados obtidos dos modelos.

**Tabela 3 – Hiperparâmetros do modelo**

| Hiperparâmetro                                 | Valor do Hiperparâmetro |
|--|-------------------------|
| <i>Activation function of the hidden layer</i> | tanh                    |
| <i>Epochs</i>                                  | 1100                    |
| <i>Hidden layer dimension</i>                  | 7                       |
| <i>Number de network layers</i>                | 2                       |
| <i>Learning rate</i>                           | 0,16                    |

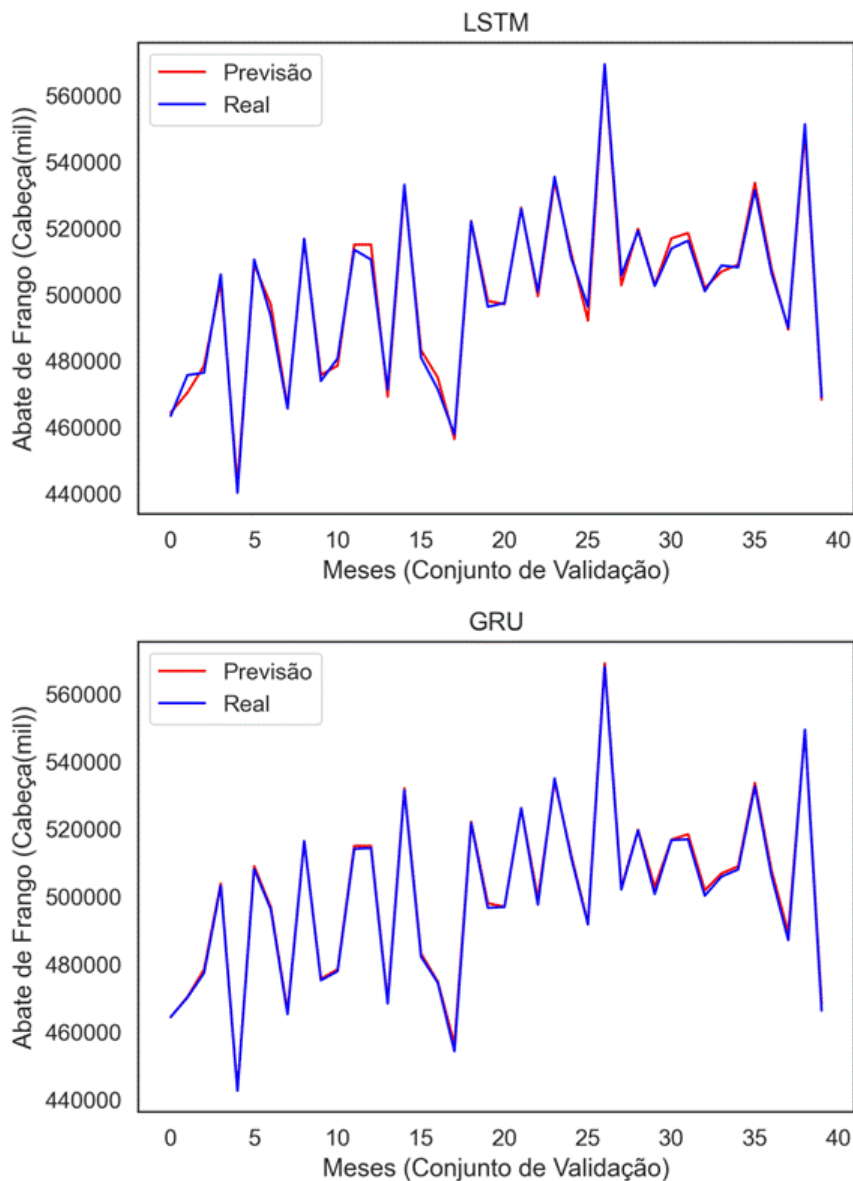
**Tabela 4 – Resultados das métricas – Conjunto de validação**

| Cenário     | Validação      |         |         |
|-------------|----------------|---------|---------|
|             | r <sup>2</sup> | RMSE    | MAE     |
| <b>LSTM</b> | 0,993          | 2132,74 | 1757,82 |
| <b>GRU</b>  | 0,998          | 1020,02 | 820,02  |

Pode-se observar, dos dados apresentados na Tabela 4, que os indicadores, r<sup>2</sup>, RMSE e MAE obtidos pelos modelos, mostram que a rede neural GRU teve um desempenho melhor.

Neste trabalho utilizou-se o método de fragmentação de *Houldout*, cuja base de dados foi dividida com 80% dos dados para treinamento dos algoritmos e 20% para validação. Na Figura 8 apresentam-se os resultados de predição, conjunto de validação, para os dois modelos. Pode-se notar, por meio das figuras, que o modelo GRU obteve melhor aderência dos dados previstos com os dados reais.

**Figura 8 – Previsão conjunto de validação – LSTM e GRU**




### 4.2 Teste

Na Tabela 5 apresentam-se, para os meses de Maio/22, Junho/22, Julho/22, Agosto/22 e Setembro/22, os dados observados e preditos, o Erro Percentual (ERP) e o Erro Absoluto Médio Percentual (MAPE).

**Tabela 5 – Previsão do abate de frangos (Cabeças(mil)), ERP e MAPE (%).**

| Mês    | IPEDATA  | LSTM     | GRU             | ERP (LSTM)      | ERP (GRU)       |
|--------|----------|----------|-----------------|-----------------|-----------------|
| mai/22 | 521439,1 | 522414,1 | 550610,8        | 5,594459        | 0,186986        |
| jun/22 | 504681,6 | 464708,3 | 507409,6        | 0,540537        | 7,920496        |
| jul/22 | 509944,8 | 522414,1 | 507409,6        | 0,497158        | 2,445225        |
| ago/22 | 531562,1 | 522414,1 | 550610,8        | 3,583544        | 1,720951        |
| set/22 | 509715   | 527799,6 | 507409,6        | 0,452284        | 3,547985        |
|        |          |          | <b>MAPE (%)</b> | <b>2,133596</b> | <b>3,164329</b> |

Por meio dos resultados apresentados, na Tabela 4, conclui-se que os resultados das previsões, dos dois modelos, estão próximos aos fornecidos pelo IPEA. Contudo, o modelo GRU, para o conjunto de teste, apresentou um Erro Absoluto Médio Percentual (MAPE) menor que o modelo LSTM (MAPE (LSTM)= 3,16% e MAPE (GRU)= 2,13%) (Figura 9).

**Figura 9 – Erro Percentual Médio Absolut(MAPE)**

## 5 CONSIDERAÇÕES FINAIS

Neste trabalho apresentou-se uma aplicação de modelos de séries temporais para previsão da quantidade de frangos abatidos no Brasil, utilizando os modelos LSTM (*Long*

*Short-Term Memory*) e GRU (*Gated Recurrent Unit*), implementados por meio da biblioteca PyTorch. Buscou-se, por meio deste estudo, determinar o comportamento futuro, da quantidade de frangos abatidos, a partir da dinâmica do passado. Os modelos foram construídos baseados nos dados disponibilizados pelo Instituto de Pesquisa Econômica Aplicada- IPEA.

Inicialmente, por meio das métricas, selecionaram-se os melhores modelos, GRU e LSTM, no conjunto de treinamento e validação. Na sequência, estimaram-se os valores referentes aos meses Maio/22, Junho/22, Julho/22, Agosto/22 e Setembro/22, que não participaram do processo de treinamento e validação. Observou-se, dos dados previstos, que os modelos apresentaram resultados próximos ao do Instituto de Pesquisa Econômica Aplicada- IPEA. Portanto, a proximidade entre valores preditos e reais demonstram a boa capacidade de generalização, para um horizonte de cinco meses, dos modelos implementados neste trabalho. Contudo, o modelo GRU, para o conjunto de teste, apresentou Erro Absoluto Médio Percentual (MAPE) menor que o modelo LSTM.

Finalmente, observa-se que as previsões do comportamento da quantidade de frangos abatidos podem auxiliar produtores e compradores na avaliação do setor avícola, em termos de abate.

## REFERÊNCIAS

ABPA (Associação Brasileira de Proteína Animal). **Relatório anual 2020**. Disponível em: < content/uploads/2020/05/abpa\_relatorio\_anual\_2020\_portugues\_web.pdf>. Acesso em: 26 de jun. 2020.

BASTIANI, M *et al.* Application of data mining algorithms in the management of the broiler production. **Geintec**, vol. 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.

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

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

IBGE - Instituto Brasileiro de Geografia e Estatística. **Abate de bovinos cai e de frangos é recorde no primeiro trimestre**. Disponível em:<

<https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012agenciadenoticias/noticias/30872-abate-de-bovinos-cai-e-de-frangos-e-recorde-no-primeiro-trimestre>>. Acesso em: 17 jul. de 2021.

IPEA - Instituto de Pesquisa Econômica Aplicada. **Abate de frango**. Disponível em: <http://www.ipeadata.gov.br/Default.aspx>. Acesso em: 22 de des. 2022.

JIA, P.; LIU, H.; WANG, P. Research on a Mine Gas Concentration Forecasting Model Based on a GRU Network. **IEEE Access**, 2020.

JÚNIOR, J. G.; BENTO, E. F.; SOUZA, A. F. Diagnóstico da realidade dos criatórios de aves na comunidade base física - Ipangaçu/RN. **Revista Holos**, vol. 4, 2009.

MAGAGNIN, G. **Modelo para a previsão da demanda internacional de carne de frango produzida no Brasil**. Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Florianópolis, 2008.

OLIVEIRA, L.; SANTOS, J. A. A. As Redes Neurais Aplicadas à Previsão de Corrente Elétrica de um Sistema Fotovoltaico. **Revista FSA**, vol. 19, 2022.

PAIVA, D. A.; HERVAL, A. C. F.; SÁFADI, T. Metodologia de Séries Temporais como ferramenta de análise na produção de frangos no Brasil. **Sigmae**, vol. 8, 2019.

PIACENTI, A. A.; LIMA, J. F.; ALVES, L. R.; PIFFER, M. O preço do frango de corte: evolução e tendências no Brasil. **Cadernos de Economia**, vol. 11, 2007.

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**, vol. 2, 2020.

PROCÓPIO, D. P.; LIMA, H. J. Avaliação conjuntural da avicultura no Brasil. **Research, Society and Development**, vol. 9, 2020.

SANTOS, J. A. A. Aplicação de Redes Neurais na Previsão de Custos de Produção de Frangos de Corte no Estado do Paraná. **Revista FSA**, vol. 18, 2021.

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. 12, 2020.

SANTOS, J. A. A.; SPANCERSKI, J. S. Previsão da produtividade de arroz: uma aplicação de redes neurais LSTM. **Revista CEREUS**, v. 13, n. 1, 2021.

SPANCERSKI, J. S.; SANTOS, J. A. A. Redes neurais aplicadas na predição do preço da soja no estado do Paraná. **Revista Perspectivas Online: Exatas & Engenharia**, vol. 11, 2021.

VASCO, L. P. **Um Estudo de Redes Neurais Recorrentes no Contexto de Previsões no Mercado Financeiro**. Dissertação (Mestrado) - Universidade Federal de São Carlos, São Carlos, 2020.

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

OLIVEIRA, L; RUSTICK, A; SANTOS, J. A. A. Previsão do Abate de Frangos: Uma Investigação Comparativa da Aplicação de Redes Neurais. **Rev. FSA**, Teresina, v. 20, n. 2, art. 10, p. 187-202, fev. 2023.

| <b>Contribuição dos Autores</b>                              | <b>L. Oliveira</b> | <b>A. Rustick</b> | <b>J. A. A. Santos</b> |
|--|--------------------|-------------------|------------------------|
| 1) concepção e planejamento.                                 | X                  | X                 | X                      |
| 2) análise e interpretação dos dados.                        | X                  | X                 | X                      |
| 3) elaboração do rascunho ou na revisão crítica do conteúdo. | X                  | X                 | X                      |
| 4) participação na aprovação da versão final do manuscrito.  | X                  | X                 | X                      |