

Previsão de preço de frango e de suíno vivo: uma comparação entre os modelos Prophet e NeuralProphet

Broiler and swine price forecasting: a comparison of the prophet and NeuralProphet models

Aldino Norbelio Brun Polo¹

José Airtton Azevedo dos Santos²

Laércio Mantovani Frare³

Dalila Natália Costa da Luz⁴

RESUMO

Prever os movimentos de preços de frangos e suínos vivos, devido a todas as indeterminações envolvidas, é um desafio muito complexo. Neste contexto, este trabalho tem como objetivo comparar o desempenho de modelos univariados e multivariados, baseados nas ferramentas Prophet e NeuralProphet, na previsão, no estado do Paraná, de preços médios de frangos e suínos vivos. A base de dados apresenta, no período entre janeiro/2007 e junho/2024, cinco séries históricas: preço médio do frango vivo, preço médio do suíno vivo, precipitação acumulada mensal, temperatura média mensal e duração da pandemia Covid. Modelos de previsão, baseados nas ferramentas Prophet e NeuralProphet, foram implementados na linguagem Python. Resultados obtidos, dos dois modelos de previsão, foram comparados por meio do Erro Médio Absoluto Percentual (MAPE), da Raiz Quadrada do Erro Médio Quadrático (RMSE) e do Erro Médio Absoluto (MAE). Verificou-se, para um horizonte de 12 meses, que o modelo NeuralProphet multivariado obteve, na previsão dos preços médios de frangos e de suínos vivos, o melhor desempenho de previsão.

Palavras-chave: Avicultura; Suinocultura; Série temporal; Ciência de dados.

ABSTRACT

Forecasting the price movements of broilers and swine, due to all the uncertainties involved, is a very complex challenge. In this context, this work aims to compare the performance of models, based on the Prophet and NeuralProphet tools, in forecasting, in the state of Paraná, average prices of broilers and swine. The database presents, for the period between January/2007 and June/2024, five historical series: average price of live broiler, average price of live swine, accumulated monthly precipitation, average monthly temperature, and duration of the Covid pandemic. Forecasting models, based on the Prophet and NeuralProphet tools, were implemented in the Python language. The results obtained from the two forecasting models were compared using the Mean Absolute Percentage Error (MAPE), the Root Mean Square Error (RMSE) and the Mean Absolute Error (MAE). It was found that, for a 12-month horizon, the multivariate NeuralProphet model obtained the best forecasting performance in predicting the average prices of broilers and live swine.

Keywords: Poultry farming; Swine farming; Time series; Data science.

¹ Mestre em Tecnologias Computacionais para o Agronegócio, Universidade Tecnológica Federal do Paraná – UTFPR. Orcid: <https://orcid.org/0009-0000-2969-274X> E-mail: aldinonbpolo@gmail.com

² Acadêmico do Programa de Pós-graduação em tecnologias Computacionais para o Agronegócio (PPGTCA), Universidade Tecnológica Federal do Paraná. Orcid: <https://orcid.org/0000-0002-2568-5734> E-mail: airton@utfpr.edu.br

³ Doutor em Engenharia Química, professor do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio, Universidade Tecnológica Federal do Paraná – UTFPR. Orcid: <https://orcid.org/0000-0002-6367-0023> E-mail: laercio@utfpr.edu.br

⁴ Engenheira de Produção, mestranda do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio, Universidade Tecnológica Federal do Paraná – UTFPR. Orcid: <https://orcid.org/0009-0009-4701-0875> E-mail: dalilanataliacostadaluz@gmail.com

1. INTRODUÇÃO

Os setores avícola e suinícola brasileiros não somente impulsionam a economia brasileira como um todo, como também geram mais de 4 milhões de empregos diretos e indiretos. Sendo mais de 500 mil empregos apenas nos frigoríficos e mais de 50 mil famílias de produtores nos campos, auxiliando na geração de renda e de sustentabilidade econômica (ABPA, 2024)

Atualmente, a avicultura é uma atividade econômica internacionalizada e uniforme, sem fronteiras geográficas de tecnologia. No Brasil, está presente em todas as regiões e tem gerado um efeito positivo na economia da maioria dos estados (PINHEIRO, 2020). Já a produção de suínos no Brasil vem crescendo devido a expansão dos investimentos e a aumentos substanciais na produtividade agrícola (PAGGIOLI, 2023).

Os preços nos mercados, do frango e do suíno vivo, apresentam flutuações durante o ano, dificultando na organização, programação e comercialização da produção. Além disso, com a Pandemia de COVID-19, ambos os mercados sofreram impactos negativos, em especial, os pequenos produtores que observaram esses impactos em diferentes dimensões da produção (FUTEMMA et al., 2021; MIELE et al., 2020). Portanto, uma estimativa futura destes preços, por meio de modelos de previsão de séries temporais, pode ser útil para produtores e compradores no momento de organizar, produzir e negociar.

Técnicas de análise, de séries temporais, estão sendo muito utilizadas para realizar análise de mercado e formular planos e estratégias. Dentre estas técnicas tem-se as ferramentas Prophet e NeuralProphet. O Prophet, desenvolvido pelo Facebook, implementa modelos, de séries temporais, utilizando ferramentas de previsão avançadas (TAYLOR; LETHAM, 2017). Já o modelo NeuralProphet é uma extensão do Prophet que utiliza modelos de aprendizado profundo (*deep learning*) para previsão de séries temporais (CHIKKAKRISHNA; RACHAKONDA; TALLAM, 2022).

Diversos trabalhos utilizaram métodos de previsão, de séries temporais, em previsões relacionadas com frangos e suínos. Dentre estes trabalhos, podem-se citar os trabalhos de: Du (2024) que utilizou modelos ARIMA (*Autoregressive Integrated Moving Average*) para previsão, de agosto de 2023 a fevereiro de 2024, de preços de suínos (Yuan/kg), na China. Pinheiro et al. (2020) utilizaram redes neurais recorrentes para prever o preço do frango, congelado e resfriado (R\$/kg), usando duas bases de dados de 11 anos (2008-2019). Sabroso & Bugarin (2023) utilizaram modelos ARIMA para previsão do preço do frango, nas

Filipinas, de janeiro de 1990 a janeiro de 2021. YANG et al. (2022) utilizaram modelos ARIMA e LSTM para previsão, na China, do preço da carne suína. Concluíram que o modelo LSTM apresentou melhor desempenho de previsão tanto para curto quanto para longo prazo. Molina et al. (2017) analisaram os efeitos da sazonalidade, no preço dos suínos, nas Filipinas. Xiaohui & Chuang (2022) utilizaram o modelo CNN-LSTM para previsão do preço do suíno no curto prazo. Observaram que o modelo CNN-LSTM, com relação ao modelo LSTM, apresentou o melhor desempenho. Já Zielinska-Sitkiewicz & Chrzanowska (2021) utilizaram modelos ARIMA para prever o preço da carne suína na Polônia.

Apesar da importância da avicultura e da suinocultura na economia brasileira, existem poucos trabalhos que utilizam as ferramentas Prophet e NeuralProphet na previsão dos preços de frangos e suínos vivos. Geralmente, são utilizados modelos tradicionais como os modelos ARIMA e SARIMA.

Neste contexto, este trabalho tem como objetivo aplicar modelos, baseados nas ferramentas Prophet e NeuralProphet, para previsão, no estado do Paraná, dos preços médios de frangos e suínos vivos (R\$/kg), no período entre janeiro/2007 e maio/2024.


2. MATERIAIS E MÉTODOS

- Nesta seção, apresenta-se a base de dados, uma breve descrição dos algoritmos utilizados neste trabalho, bem como as métricas utilizadas.
- Base de dados:
- A base de dados apresenta, no período entre janeiro/2007 e junho/2024, cinco séries históricas: precipitação acumulada mensal, temperatura média mensal, duração da pandemia Covid, preço médio do frango vivo e preço médio do suíno vivo,
- Precipitação acumulada mensal e temperatura média mensal: As bases de dados de precipitação acumulada mensal (mm) e temperatura média mensal (°C), no estado Paraná (janeiro/2007 – junho/2024), utilizadas como variáveis explicativas para o modelo de previsão de preço, são disponibilizadas pelo Instituto Nacional de Meteorologia (INMET, 2024).
- Duração da pandemia de COVID-19: A base de dados, de duração da COVID-19, foi montada, com base em informações fornecidas pela Organização Pan-Americana da Saúde, da seguinte forma: para os meses de vigência da pandemia que foi entre 11 de março de 2020 até 05 de maio de 2023 foram adicionados o valor 1 (um) e para o restante o valor 0 (zero), ou seja, sem vigência da pandemia (OPAS, 2023). A base

de dados de duração da COVID-19 foi utilizada como variável explicativa para os modelos de previsão.

- Preços de Frangos e Suínos: Para previsão dos preços de frangos e suínos vivos, no estado do Paraná, em R\$/kg, foram utilizadas duas séries históricas, com 210 meses (janeiro/2007 e junho/2024), que são disponibilizadas pela Secretaria da Agricultura e do Abastecimento do Estado do Paraná (SEAB-PR) e pelo Instituto de Pesquisa Econômica Aplicada (IPEA) (SEAB-PR, 2024a, 2024b). Na Figura 1, são apresentadas as duas séries históricas.

-



-

- **Figura 1.** Séries históricas dos preços médios de frangos e suínos vivos.

- Prophet:
- O Prophet é uma ferramenta de previsão desenvolvida pelo Facebook. É uma ferramenta, de código aberto, que utiliza parâmetros indutivos fáceis de ajustar. O Prophet usa modelos de séries temporais compostos por três componentes principais: tendência, sazonalidade e feriados. Estas componentes são combinadas na seguinte equação (PINTO, 2020; SANTOS; CHAUCOSKI, 2022; TAYLOR; LETHAM, 2017; XIE et al., 2021).

-

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad 1$$

-

- Onde:
- $g(t)$ - representa a tendência dos modelos, preocupa-se com as mudanças não periódicas nos valores;
- $s(t)$ - representa a sazonalidade, descreve como os dados são afetados por fatores sazonais, como a época do ano;

- $h(t)$ - representa os feriados, modela os efeitos dos feriados, ou grandes eventos, que afetam as séries temporais;
- ε_t - representa o erro, quaisquer alterações incomuns são acomodadas pelo modelo.
- NeuralProphet:
- O NeuralProphet adiciona ao modelo original Prophet três componentes, conforme apresentado na Equação 2:
-

$$y(t) = g(t) + s(t) + h(t) + f(t) + a(t) + l(t) \quad 2$$

-
- Onde:
- $f(t)$ - representa efeitos de regressão, no tempo t , para variáveis exógenas conhecidas no futuro;
- $a(t)$ - representa os efeitos da autorregressão, no tempo t , com base em observações passadas;
- $l(t)$ - representa os efeitos da regressão, no tempo t , para observações defasadas de variáveis exógenas.
- Construção dos modelos de previsão:
- A base de dados, para a construção dos modelos, foi separada em treinamento e teste. Os dados de testes foram os últimos 12 meses, sendo utilizados apenas para avaliar os modelos finais, após a definição dos hiperparâmetros, não sendo utilizados em nenhum momento durante o treinamento dos modelos.
- Os algoritmos selecionados, para realizar as previsões de preços médios do frango e do suíno vivos, foram o Prophet e o NeuralProphet. Neste estudo treinaram-se cinco modelos para cada variável objetivo (preço do frango e preço do suíno): modelo univariado; modelo multivariado utilizando a precipitação acumulada mensal como variável explicativa; modelo multivariado utilizando a temperatura média mensal como variável explicativa; modelo multivariado utilizando a duração da pandemia de COVID como variável explicativa; modelo multivariado utilizando a precipitação acumulada mensal, temperatura média mensal e a duração da pandemia de COVID como variáveis explicativas.
- Para definir os hiperparâmetros, de cada modelo de previsão, foi utilizado o método de otimização Bayesiana (FRAZIER, 2018).
- Avaliação de desempenho dos modelos:

- A avaliação de desempenho, dos modelos de previsão Prophet e NeuralProphet, foram realizadas por meio das métricas apresentadas na Tabela 1 (ANTONIOLLI, 2021).

•

• **Tabela 1. Equações - Métricas**

	Valor Perfeito	Observações
RMSE - Root Mean Squared Error	RMSE = 0	$\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) $
MAE - Mean Absolute Error	MAE = 0	$\sqrt{\frac{1}{n} \sum_{i=1}^n ((y_i - \hat{y}_i)^2)}$
MAPE - Mean Absolute Percentage Error	MAPE = 0	$100 \frac{1}{n} \sum_{i=1}^n \left \frac{(y_i - \hat{y}_i)}{y_i} \right $

•

- 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.

•

3. RESULTADOS E DISCUSSÃO

Na Tabela 2 apresentam-se uma análise descritiva dos conjuntos de dados dos preços médios do frango e do suíno vivo.

Tabela 2. Análise descritiva.

Parâmetro analisado	Frango vivo	Suíno Vivo
Contagem	210	210
Média (R\$/kg)	2,80	3,45
Desvio padrão (R\$/kg)	1,27	1,77
Valor mínimo (R\$/kg)	1,26	1,08
Valor máximo (R\$/kg)	5,91	7,17
Coeficiente de variação (%)	45,35	51,30

Os dados, apresentados na Tabela 2, mostram que o suíno vivo apresenta preço médio superior ao do frango (2,80 (R\$/kg) para o frango vivo e 3,45 (R\$/kg) para o suíno vivo). Apresentando também maior dispersão dos valores e maior volatilidade, traduzida por um desvio padrão e coeficiente de variação mais elevados. Isto reflete um mercado

mais instável para o suíno, sujeito a oscilações relacionadas sobretudo aos custos de produção, insumos como milho e variações de demanda. Em contrapartida, o frango vivo, apesar de também apresentar volatilidade significativa, tem menor amplitude entre os valores mínimos e máximos, sinalizando uma precificação mais previsível e menos sensível a choques externos, o que impacta diretamente a gestão de risco e o planejamento dos produtores em ambos os setores.

Análise do comportamento das séries históricas:

Inicialmente, para identificar o comportamento das variáveis objetivo (preços médios do frango e do suíno vivos) com relação as variáveis explicativas (duração da pandemia de COVID, precipitação acumulada mensal e temperatura média mensal), construíram-se gráficos de correlação destas variáveis (Figura 2). Observa-se, dos coeficientes de correlação apresentados na figura, que a variável duração da pandemia de Covid tem maior impacto sobre as variáveis objetivo (0,88 e 0,87).




Figura 2. Correlações entre as variáveis objetivo e explicativas.

Neste trabalho, para também comparar o comportamento de cada variável explicativa em relação as variáveis objetivo, foram normalizadas todas as variáveis e, então, foram feitos gráficos dos valores normalizados das variáveis (Figura 3). Observa-se, por

meio da Figura 3, comportamentos das variáveis objetivas preços do frango e suíno vivos, no período entre 2020 e 2023, um padrão de crescimento anormal, que acompanha a variável explicativa duração da pandemia de COVID. Por outro lado, não é perceptível nenhum tipo de relação entre as variáveis objetivo e as variáveis explicativas precipitação acumulada mensal e temperatura média mensal.




Figura 3. Gráficos comparativos entre as variáveis objetivo e explicativas.

Seleção de hiperparâmetros:

Hiperparâmetros são variáveis utilizadas para gerenciar o treinamento de modelos de *machine learning*. Estas variáveis afetam o desempenho dos algoritmos de aprendizado de máquina. É necessário, para definir os melhores hiperparâmetros dos modelos de previsão, testar diferentes valores para esses hiperparâmetros e verificar qual combinação oferece os melhores resultados. Neste trabalho utilizou-se, para encontrar os melhores hiperparâmetros dos modelos, o método de otimização bayesiana. A otimização bayesiana é um método utilizado para ajustar, por meio de técnicas estatísticas, os hiperparâmetros de algoritmos de aprendizado de máquina (FRAZIER, 2024).

Para o modelo Prophet foram testados os seguintes hiperparâmetros: *growth*, que representa a forma da tendência da série histórica e *changepoint_prior_scale*, que determina a flexibilidade da tendência e, em particular, o quanto a tendência muda.

Para o modelo NeuralProphet foram testados os seguintes hiperparâmetros: *growth*, que define o tipo de crescimento da tendência; *n_forecasts*, que indica o número de passos à frente do tempo de previsão; *learning_rate*, que determina o tamanho do passo em cada

iteração; *n_changepoints*, que define o número de potenciais pontos de mudança de tendência e *changepoints_range*, que representa a proporção do histórico em que os pontos de mudança de tendência serão estimados.

Nas Tabelas 3 e 4, apresentam-se os melhores hiperparâmetros para os modelos Prophet e NeuralProphet. Observa-se que para a convergência da otimização bayesiana utilizou-se a métrica MAPE.

Tabela 3. Melhores hiperparâmetros para os modelos Prophet.

PROPHET		
Frango vivo		
Modelo	growth	changepoint_prior_scale
Univariado	'logistic'	0,0512
Multivariado: precipitação	'logistic'	0,0542
Multivariado: temperatura	'logistic'	0,0491
Multivariado: pandemia de COVID	'logistic'	0,0086
Multivariado: precipitação, temperatura, pandemia de COVID	'logistic'	0,0056
Suíno vivo		
Modelo	growth	changepoint_prior_scale
Univariado	'linear'	0,8888
Multivariado: precipitação	'logistic'	0,0965
Multivariado: temperatura	'linear'	0,8963
Multivariado: pandemia de COVID	'logistic'	0,3790
Multivariado: precipitação, temperatura, pandemia de COVID	'logistic'	0,3223

Tabela 4. Melhores hiperparâmetros para os modelos NeuralProphet.

NEURALPROPHET					
Frango vivo					
Modelo	growth	n_forecasts	learning_rate	n_changepoints	changepoints_range
Univariado	'linear'	2	0,2487	10	0,5046
Multivariado: precipitação	'linear'	4	0,1966	17	0,5264
Multivariado: temperatura	'linear'	2	0,2487	10	0,5046
Multivariado: pandemia de COVID	'discontinuous'	6	0,4556	40	0,5471

Multivariado: precipitação, temperatura, 'discontinuous' pandemia de COVID					
		3	0,0708	22	0,5012
Suíno Vivo					
Modelo	growth	n_forecasts	learning_rate	n_changepoints	changepoints_range
Univariado	'linear'	2	0,5214	32	0,5025
Multivariado: precipitação	'linear'	2	0,5914	34	0,6000
Multivariado: temperatura	'linear'	4	0,0776	15	0,5191
Multivariado: pandemia de COVID	'linear'	2	0,4782	10	0,6283
Multivariado: precipitação, temperatura, pandemia de COVID	'linear'	2	0,3828	20	0,6911

Conjuntos de teste:

Nas Figuras 4 e 5 apresentam-se, para os conjuntos de testes das variáveis objetivo (jul/23 a jun/24), os dados observados (reais) e preditos pelos modelos de previsão Prophet e NeuralProphet.




Figura 4. Previsões dos modelos Prophet para o preço médio do frango e do suíno vivo - Conjunto de Teste (R\$/kg).

Percebe-se, por meio da Figura 4, que o modelo Prophet multivariado utilizando duração da pandemia de COVID como variável explicativa e o modelo Prophet multivariado utilizando a precipitação acumulada mensal, temperatura média mensal e a duração da pandemia de COVID, como variáveis explicativas, foram os que obtiveram resultados mais próximos aos valores reais.




Figura 5. Previsões dos modelos NeuralProphet para o preço médio do frango e do suíno vivo - Conjunto de Teste (R\$/kg).

Observa-se, por meio da Figura 5, que o modelo NeuralProphet multivariado utilizando duração da pandemia de COVID como variável explicativa e o modelo NeuralProphet multivariado utilizando a precipitação acumulada mensal, temperatura média mensal e a duração da pandemia de COVID, como variáveis explicativas, foram os que obtiveram resultados mais próximos aos valores reais.

Nas Figuras 5 e 6 apresentam-se, para os conjuntos de teste do preço médio do frango vivo e do suíno vivo, os resultados das métricas MAE, RMSE e MAPE.

Tabela 5. Métricas para os modelos de previsão do preço médio do frango vivo - Conjunto de Teste.

Prophet			
Modelo	RMSE (R\$/kg)	MAE (R\$/kg)	MAPE (%)
Univariado	0,96	0,95	21,26
Multivariado: Precipitação	0,93	0,91	20,37
Multivariado: Temperatura	0,82	0,82	18,23
Multivariado: COVID	0,19	0,18	3,99
Multivariado: Precipitação, Temperatura, COVID	0,21	0,20	4,48

NeuralProphet			
Modelo	RMSE (R\$/kg)	MAE (R\$/kg)	MAPE (%)
Univariado	1,08	1,07	23,96
Multivariado: Precipitação	1,05	1,04	23,10
Multivariado: Temperatura	0,99	0,98	21,95
Multivariado: COVID	0,14	0,12	2,76
Multivariado: Precipitação, Temperatura, COVID	0,30	0,28	6,33

Tabela 6. Métricas para os modelos de previsão do preço médio do suíno vivo - Conjunto de Teste.

Prophet			
Modelo	RMSE (R\$/kg)	MAE (R\$/kg)	MAPE (%)
Univariado	1,25	1,25	20,58
Multivariado: Precipitação	1,13	1,11	18,32
Multivariado: Temperatura	1,22	1,21	20,01
Multivariado: COVID	0,32	0,30	4,88
Multivariado: Precipitação, Temperatura, COVID	0,37	0,34	5,52

NeuralProphet			
Modelo	RMSE (R\$/kg)	MAE (R\$/kg)	MAPE (%)
Univariado	1,13	1,12	18,54
Multivariado: Precipitação	1,18	1,15	19,08
Multivariado: Temperatura	1,07	1,06	17,53
Multivariado: COVID	0,65	0,64	10,50
Multivariado: Precipitação, Temperatura, COVID	0,19	0,15	2,53

Para a previsão do preço médio do frango vivo, no estado do Paraná, percebe-se que o modelo NeuralProphet multivariado, utilizando a duração da pandemia de COVID como variável explicativa, apresentou erros menores (RMSE, MAE e MAPE) (Tabela 5), além disso esse modelo teve um ajuste melhor aos valores observados (Figura 6).

Para a previsão do preço médio do suíno vivo, no estado do Paraná, percebe-se que o modelo NeuralProphet multivariado, utilizando a precipitação acumulada mensal, temperatura média mensal e a duração da pandemia de COVID como variáveis explicativas, apresentou erros menores (RMSE, MAE e MAPE) (Tabela 6), além disso esse modelo teve um ajuste melhor aos valores observados (Figura 6).

5. CONSIDERAÇÕES FINAIS

Este trabalho teve por objetivo aplicar os modelos de séries temporais Prophet e NeuralProphet, nas suas formas univariada e multivariada, para realizar a previsão do preço médio do suíno vivo e do frango vivo no estado do Paraná.

Inicialmente, realizou-se a coleta dos dados, sendo que os dados do preço médio do suíno vivo e do frango vivo foram disponibilizados pela Secretaria da Agricultura e do Abastecimento do Estado do Paraná (SEAB-PR) e pelo Instituto de Pesquisa Econômica Aplicada (IPEA). Os dados de precipitação acumulada mensal e de temperatura média mensal foram disponibilizados pelo Instituto Nacional de Meteorologia (INMET). Já os dados de duração da pandemia de COVID foram montados com base em informações disponibilizadas pela Organização Pan-Americana da Saúde.

Na sequência, foi realizada uma análise exploratória dos dados em estudo. Nesta análise, realizada para avaliar o comportamento de cada um dos conjuntos de dados, foi possível obter informações, sobre os conjuntos de dados, através de um resumo estatístico e gráficos comparativos.

Posteriormente, os modelos Prophet e NeuralProphet foram construídos. Inicialmente, nesta etapa, realizou-se, com o objetivo de definir os melhores hiperparâmetros de cada modelo, uma otimização bayesiana. Por fim, os modelos, com hiperparâmetros otimizados, foram construídos e testados com os respectivos conjuntos de teste.

Observou-se, para a previsão do preço médio do frango vivo, que o modelo que obteve melhor generalização, do Conjunto de Teste (julho/2023 a junho/2024), foi o modelo NeuralProphet multivariado, utilizando a duração da pandemia de COVID como variável explicativa. Este modelo obteve menores valores das métricas RMSE, MAE e MAPE (RMSE = 0,14 R\$/kg; MAE = 0,12 R\$/kg; MAPE = 2,76%).

Observou-se também, para a previsão do preço médio do suíno vivo, que o modelo que obteve uma melhor generalização, do Conjunto de Teste (julho/2023 a junho/2024), foi o modelo NeuralProphet multivariado, utilizando a precipitação acumulada mensal, temperatura média mensal e a duração da pandemia de COVID como variáveis explicativas. Este modelo obteve menores valores das métricas RMSE, MAE e MAPE (RMSE = 0,19 R\$/kg; MAE = 0,15 R\$/kg; MAPE = 2,53%).

Por fim, considerando os resultados obtidos neste estudo, pode-se observar que os modelos Prophet e NeuralProphet são modelos válidos e podem ser utilizados no auxílio a

produtores em processos de tomada de decisão, na organização, programação e comercialização da produção.

Para trabalhos futuros, sugere-se testar, na previsão do preço médio do suíno e do frango vivo, outros modelos de previsão de séries temporais, bem como outras variáveis explicativas.

REFERÊNCIAS

ABPA. **Relatório Anual 2024**. São Paulo: Associação Brasileira de Proteína Animal (ABPA), 2024.

ANTONIOLLI, E. A. **Previsão do consumo de energia elétrica em um frigorífico: um estudo de caso utilizando regressão linear, redes neurais e máquinas de vetores de suporte**. Dissertação—Medianeira: Universidade Tecnológica Federal do Paraná, 2021.

CHIKKAKRISHNA, N. K.; RACHAKONDA, P.; TALLAM, T. **Short - Term Traffic Prediction Using Fb-PROPHET and Neural-PROPHET**. 2022. Disponível em: <<https://ieeexplore.ieee.org/document/9753459/>>. Acesso em: 1 abr. 2024.

DU, Z. Short-Term Forecasting of Pork Price Based on The ARIMA Model. **Highlights in Business, Economics and Management**, v. 25, 2024.

FRAZIER, P. I. **A Tutorial on Bayesian Optimization**. arXiv, 2018. Disponível em: <<http://arxiv.org/abs/1807.02811>>. Acesso em: 18 ago. 2024

FUTEMMA, C. et al. A pandemia da Covid-19 e os pequenos produtores rurais: superar ou sucumbir? **Ciências Humanas**, v. 16, 2021.

INMET, I. N. DE M. **Dados Históricos Anuais**. 2024. Disponível em: <<https://portal.inmet.gov.br/dadoshistoricos>>. Acesso em: 18 ago. 2024

MIELE, M. et al. **Impacto da COVID-19 sobre as cadeias produtivas de frangos de corte, ovos e suínos**. Concórdia: Embrapa Suínos e Aves, 7 maio 2020.

MOLINA, I. R.; REYES, J. A. D.; GORDONCILLO, P. U. Analysis of seasonality in monthly pork prices in the philippines based on X-12 ARIMA. **Journal of the International Society for Southeast Asian Agricultural**, v. 23, n. 2, 2017.

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

PAGGIOLI, C. **Cenário econômico da suinocultura brasileira: uma breve análise**. 2023. Disponível em: <<https://repositorio.unesp.br/items/22e432e7-d46e-4390-aa7d-e90ed160100b>>. Acesso em: 15 jan. 2024.

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**. v. 2, 2020.

PINTO, C. T. **Análise e projeção comportamental de clientes na área de venda de cimento e derivados**. Dissertação—Porto: Universidade do Porto, 2020.

SABROSO, L. M.; BUGARIN J. B. Price forecasting of fully dressed chicken in the Philippines. **European Journal of Economic and Financial Research**, v. 7, n. 2, 2023.

SANTOS, J. A. A.; CHAUCOSKI, Y. Previsão de preço de ovos, no estado do Paraná, por meio de modelos SARIMA e PROPHET. **Revista Cereus**, v. 14, n. 1, 2022.

SEAB-PR. **Preço médio recebido pelo agricultor: frango vivo (kg - Paraná) (DERAL12_PRFRV12)**. 2024a. Disponível em: <<http://ipeadata.gov.br/>>. Acesso em: 16 ago. 2024

SEAB-PR. **Preço médio recebido pelo agricultor: suínos comuns (kg - Paraná) (DERAL12_PRSUC12)**. , 2024b. Disponível em: <<http://ipeadata.gov.br/>>. Acesso em: 16 ago. 2024

TAYLOR, S. J.; LETHAM, B. Forecasting at scale. [s.l.] **PeerJ Preprints**, 2017. Disponível em: <<https://peerj.com/preprints/3190v2>>. Acesso em: 6 set. 2023.

XIE, C. et al. Trend analysis and forecast of daily reported incidence of hand, foot and mouth disease in Hubei, China by Prophet model. **Scientific Reports**, v. 11, n. 1, p. 1445, 2021.

XIAOHUI, G. CHUANG, C. An Improved Prediction Model of Pig Price. **Asian Journal of Advances in Agricultural Research**, v. 20, 2022.

YANG, Z.; ZHANG, R.; YIN, Z.; ZU, Y. Pork Price Prediction using LSTM Model: Based on a New Dataset. *In*: ICPDI 2022 - International Conference on Public Management, Digital Economy and Internet Technology. Changsha, China, 2022.

ZIELINSKA-SITKIEWICZ, M.; CHRZANOWSKA, M. Prediction of pork meat prices by selected methods as an element supporting the decision-making process. **Operations Research and Decisions**, v. 31, n. 3, 2021.