
Aplicação de modelos de redes neurais artificiais na previsão da produção, importação e consumo de fertilizantes no Brasil

Application of artificial neural network models in forecasting the production, import and consumption of fertilizers in Brazil

Andressa Rustick

ORCID: <https://orcid.org/0000-0003-3918-0830>
Universidade Tecnológica Federal do Paraná, Brasil
E-mail: andressarustick@hotmail.com

José Airton Azevedo dos Santos

ORCID: <https://orcid.org/0000-0002-2568-5734>
Universidade Tecnológica Federal do Paraná, Brasil
E-mail: airton@utfpr.edu.br

Cidmar Ortiz dos Santos

ORCID: <https://orcid.org/0000-0002-1727-3676>
Universidade Tecnológica Federal do Paraná, Brasil
E-mail: cidmar@utfpr.edu.br

RESUMO

Os fertilizantes, no Brasil, são insumos de grande importância na produtividade agrícola. Nesse contexto, este trabalho tem como objetivo implementar modelos, de séries temporais, para previsão da produção, importação e consumo de fertilizantes intermediários no Brasil. A base de dados, disponibilizada pela Associação Nacional para Difusão de Adubos (ANDA), apresenta séries históricas da produção, importação e consumo de fertilizantes no Brasil, no período entre 1998 e 2022. Modelos de previsão, baseados em redes neurais artificiais, foram desenvolvidos por meio do software WEKA. Resultados obtidos, dos modelos de previsão, foram comparados por meio das métricas RSME (*Root Mean Squared Error*), MAE (*Mean Absolute Percent Error*) e MAPE (*Mean Absolute Percent Error*). Verificou-se, para um horizonte de curto prazo, que os modelos de redes neurais, são adequados para prever a produção, importação e o consumo de fertilizantes no Brasil.

Palavras-chave: Horizonte de curto prazo; Modelo; Séries temporais; WEKA.

ABSTRACT

Fertilizers, in Brazil, are inputs of great importance in agricultural productivity. In this context, this work aims to implement time series models to forecast the production, import and consumption of intermediate fertilizers in Brazil. The database, made available by the National Association for the Diffusion of Fertilizers (ANDA), presents historical series of the production, importation and consumption of fertilizers in Brazil, in the period between 1998 and 2022. Forecast models, based on artificial neural networks, were developed through the WEKA software. Results obtained from the forecast models were compared using RSME (*Root Mean Squared Error*), MAE (*Mean Absolute Percent Error*) and MAPE (*Mean Absolute Percent Error*) metrics. It was found, for a short-term horizon, that the neural network models are adequate to predict the production, importation and consumption of fertilizers in Brazil.

Keywords: Short-term horizon; Model; Time series; WEKA.

INTRODUÇÃO

Fertilizantes, definidos como “substâncias minerais ou orgânicas, naturais ou sintéticas, fornecedoras de um ou mais nutrientes vegetais”, são recursos básicos e importantes para produção de culturas agrícolas. Proporcionam retorno rápido sobre a produtividade. Seus nutrientes são essenciais para sobrevivência de plantas, animais e seres humanos (REETZ, 2017; TRAGE et al., 2020).

O Brasil, em relação ao consumo de fertilizantes, se coloca na quarta posição mundial, atrás somente da China, Índia e Estados Unidos, sendo responsável por 8% do consumo global. Aproximadamente 80% dos fertilizantes, consumidos no Brasil, são importados, apesar de existir grandes reservas de matérias-primas em seu território (BRASIL, 2021).

Segundo Woyakoski (2012) (FAO - Organização das Nações Unidas para Alimentação e Agricultura), para cada hectare de utilização correta de fertilizantes, permitindo seu máximo rendimento, a produção terá como equivalência a área de quatro hectares sem a utilização dos mesmos. A grande vantagem da utilização dos fertilizantes é o aumento da produtividade frente à limitação da área agricultável (OGINO et al., 2021).

As projeções do agronegócio brasileiro, devido a demanda por alimentos, apontam para um crescimento da área plantada, da produção e da produtividade, implicando no aumento do consumo de fertilizantes. Quanto maior for a necessidade de produção de alimentos, maior será a quantidade de fertilizantes necessária para o desenvolvimento da atividade agrícola. Portanto, existem quedas e altas no consumo de fertilizantes, tendo em vista que o consumo está atrelado ao desempenho agrícola (FERNANDES et al., 2009). Desse modo, prever, por meio de técnicas de análise de séries temporais, o consumo de fertilizantes, necessário para sustentar a produção agrícola futura, é muito importante para organizações públicas e privadas (OGINO et al., 2021; TRAGE et al., 2020; ANDRADE et al., 2021).

Dentre as técnicas utilizadas, para previsão de séries temporais, está a Rede Neural Artificial (RNA). A RNA, segundo Haykin (2001), é um sistema de processamento paralelo, composto por unidades simples, que possuem a capacidade de armazenar conhecimento experimental e torná-lo disponível para o uso.

Diversos trabalhos utilizaram métodos de previsão, de séries temporais, na análise do consumo, importação e produção de fertilizantes. Mishra et al. (2014)

aplicaram a técnica, de modelagem ARIMA, na análise e previsão do consumo de fertilizantes, no período entre 1961 e 2002, na Índia. OGINO et al. (2021) empregaram o modelo autorregressivo vetorial estrutural (SVAR) para previsão do consumo e do preço, de fertilizantes minerais, no centro-oeste brasileiro. Andrade (2021) explorou abordagens de ciência de dados, através da otimização da construção de modelos, para capacitar a predição do consumo de fertilizantes. Zangh e Zangh (2007) utilizaram a técnica de regressão para previsão do consumo de fertilizantes no mundo. Já Trage (2019) estudou a produção, o consumo e as importações nacionais de fertilizantes por meio de previsões estatísticas.

Apesar da importância da previsão da produção, importação e consumo de fertilizantes, para a agricultura brasileira, muito poucos são os trabalhos que utilizaram redes neurais artificiais na previsão da produção, importação e consumo de fertilizantes. Geralmente, são utilizados modelos tradicionais, como os modelos ARIMA e SARIMA (ANDRADE et al., 2021).

Nesse contexto, este trabalho tem como objetivo implementar modelos, de séries temporais, para previsão da produção, importação e consumo de fertilizantes intermediários no Brasil.

METODOLOGIA

Nesse capítulo abordam-se a metodologia e as tecnologias utilizadas na pesquisa e no desenvolvimento do trabalho.

Redes Neurais *Multilayer Perception* (MLP)

As redes MLP são utilizadas para resolver diversos tipos de problemas através de seu treinamento *backpropagation*. Estruturalmente, são constituídas por uma camada entrada, uma ou mais camadas escondidas e uma camada de saída. São consideradas redes progressivas (*feedforward*). Nestas redes as saídas dos neurônios de uma determinada camada se conectam apenas às entradas dos neurônios da camada seguinte (SILVA, 2015).

Etapas do trabalho

Neste trabalho, para realizar a previsão da produção, importação e consumo de fertilizantes, foram realizadas as etapas apresentadas a seguir:

Análise de dados: Inicialmente, na primeira etapa, foi realizada uma análise exploratória dos dados obtidos da Associação Nacional para Difusão de Adubos (ANDA);

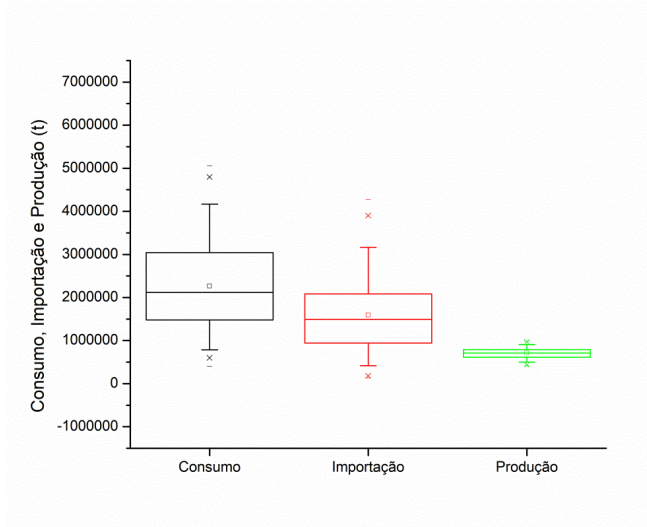
Treinamento e Validação: Na segunda etapa, treinamento e validação, foram selecionados, por meio da métrica RMSE, os melhores modelos MLP;

Teste: Na última etapa, etapa de teste, os modelos foram testados para dados que não participaram da etapa de treinamento e validação (Julho, Agosto, Setembro, Outubro, Novembro e Dezembro de 2022). Nesta etapa as previsões dos três modelos são confrontados com valores de produção, importação e consumo observados pela ANDA. A partir desses dados são calculados o MAPE, MAE e o RSME para cada um dos modelos.

Base de dados

Para previsão da produção, importação e consumo de fertilizantes foram utilizadas três séries históricas com 300 instâncias cada (Jan/1998 - Dez/2022) obtidas da Associação Nacional para Difusão de Adubos (ANDA). Os dados referem-se aos fertilizantes intermediários produzidos e entregues ao consumidor final desta cadeia. Para fertilizantes intermediários são considerados, do tipo simples, os que são utilizados em misturas NPK (Nitrogênio, Fósforo e Potássio) ou em aplicação direta ao solo (IPEA, 2023). Os dados obtidos, das séries históricas, são apresentados na Figura 1 na forma de *boxplot*.

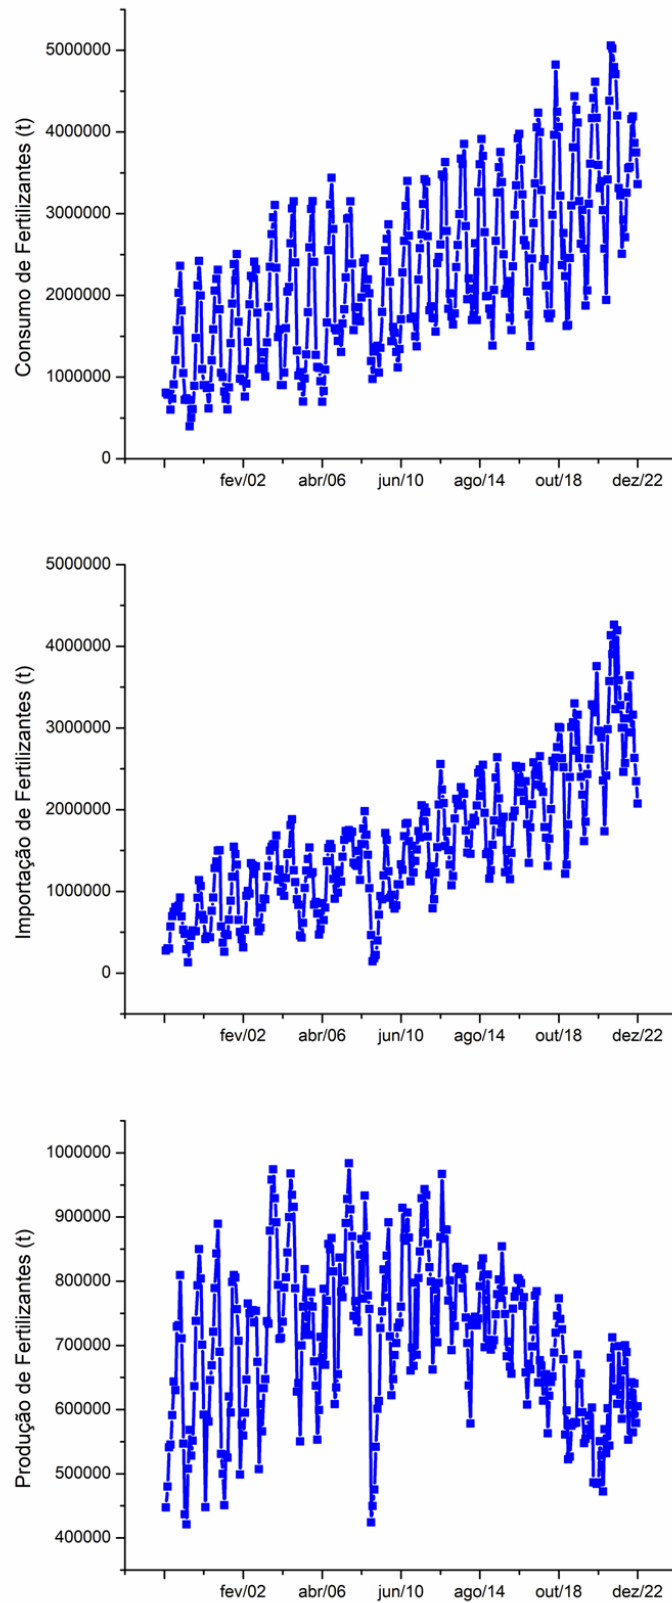
Figura 1 – *Boxplots* – consumo, importação e produção de fertilizantes.



Fonte: Os Autores (2023)

As séries históricas, da produção, importação e consumo de fertilizantes, são apresentadas na Figura 2.

Figura 2 – Séries: produção, importação e consumo de fertilizantes.



Fonte: Os Autores (2023)

Weka

Os modelos utilizados, no desenvolvimento deste trabalho, foram implementados no software WEKA. Este software foi escolhido por ser disponibilizado gratuitamente na internet e, também, por manter atualizados diversos algoritmos de mineração de dados.

O WEKA utiliza, para inserção dos dados, o formato ARFF, um tipo de arquivo de atributo e relação (ANTONIOLLI, 2021). Na Figura 3 apresenta-se, como exemplo, o arquivo ARFF com os dados de consumo de fertilizantes. Observa-se, deste arquivo, que os requisitos são escritos por linha e os valores dos atributos separados por vírgula.

Figura 3 – Arquivo no formato ARFF.

```
@relation 'Fertilizante'
@attribute Data date "yyyy-MM"
@attribute Consumo numeric

@data
1998-01,808248
1998-02,783732
1998-03,793043
1998-04,600047
1998-05,736615
1998-06,911410
1998-07,1207152
1998-08,1575375
```

Fonte: Os Autores (2023)

Métricas

O desempenho dos modelos de redes neurais foram avaliados por meio das métricas RSME (*Root Mean Squared Error*), MAE (*Mean Absolute Percent Error*) e MAPE (*Mean Absolute Percent Error*). As equações das métricas RMSE, MAE e MAPE são apresentadas na Tabela 1 (SANTOS, 2022).

Tabela 1 – Métricas.

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

Fonte: Santos (2022)

RESULTADOS E DISCUSSÕES

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

Tabela 2 – Análise descritiva.


Parâmetro analisado	Produção	Consumo	Importação
Instâncias	300	300	300
Média (t)	706414,2	2263654	1596194,1
Mínimo (t)	420945	3967180	130805
Máximo (t)	983839	5058905	4263904
Desvio Padrão (t)	121979,4	1038655	849460,1
Coefficiente de Variação (%)	17,2	45,9	53,2

Fonte: Os Autores (2023)

Pode-se observar, dos dados apresentados na Tabela 2, que os valores ficaram, para o período em estudo, em média 706424,2 t para produção, 1596194,1 t para importação e 2263654 t para o consumo. Apresentando, neste período, valores mínimos e máximos para produção de 420945 t e 938839 t, 130805 t e 4263904 t para a importação e de 3967180 t e 5058905 t para o consumo. Observam-se também altos coeficientes de variação (17,2%, 45,9% e 53,2%), o que indica variabilidade dos dados.

Na Figura 4 apresentam-se o consumo, importação e a produção interna, de 1998 a 2022, de fertilizantes intermediários.

Figura 4 – Consumo, produção e importação de fertilizantes no Brasil.



Fonte: Os Autores (2023)

Observa-se, da Figura 4, que a produção nacional de fertilizantes intermediários tem se mantido constante durante este período. Enquanto que o consumo e as importações seguem em ritmo crescente. Em 2022 o consumo e as importações alcançaram aproximadamente 41 e 34 milhões de toneladas respectivamente, enquanto a produção nacional se manteve em 7 milhões de toneladas.

Treinamento e validação

Explorou-se neste trabalho, para obter a melhor modelagem possível da produção, importação e do consumo de fertilizantes, diferentes arquiteturas e hiperparâmetros das redes neurais. Para as etapas de treinamento e validação, dos modelos de previsão, o conjunto de dados foi dividido em 75% para treinamento e 25% para validação.

A Tabela 3 descreve as combinações dos parâmetros avaliados, na busca pelas melhores métricas, para os modelos MLPs.

Tabela 3 – Combinações das configurações para o modelo MLP.

Neurons	[7,14,28,56]
Layer Sizes	[1,2,3]
Activation	Sigmoid
Learning Rate	[0.2,0.1,0.01,0.001]
Momentum	[0.1,0.3,0.5,0.7]
Epochs	[500,1000,1500,2000]

Fonte: Os Autores (2023)

As melhores combinações de parâmetros, definidas por meio da métrica RMSE para os modelos MLPs, são mostradas na Tabela 4.

Tabela 4 – Melhores combinações para os modelos MLP.

<i>Parâmetros</i>	<i>Produção</i>	<i>Importação</i>	<i>Consumo</i>
<i>Neurons</i>	14	7	14
<i>Layer Sizes</i>	1	1	1
<i>Activation</i>	Sigmoid	Sigmoid	Sigmoid
<i>Learning Rate</i>	0.01	0.01	0.001
<i>Momentum</i>	0.7	0.7	0.1
<i>Epochs</i>	500	500	500

Fonte: Os Autores (2023)

Os resultados das métricas, para estas combinações de parâmetros, são apresentados na Tabela 5.

Tabela 5 – Resultados – Métricas (MAE, MAPE e RMSE).

<i>Métricas</i>	<i>Produção</i>	<i>Importação</i>	<i>Consumo</i>
<i>MAE (t)</i>	42766,47	371154,15	322188,6
<i>MAPE (%)</i>	7,03	13,85	10,16
<i>RSME (t)</i>	55909,6	482737,37	416217,8

Fonte: Os Autores (2023)

Teste

A Tabela 6 apresenta os dados observados (Produção, Importação e Consumo) e preditos (MLP-Produção, MLP-Importação e MLP-Consumo) para os seis meses que não participaram da etapa de treino e teste.

Tabela 6 – Dados observados e previstos de produção, importação e consumo de fertilizantes.

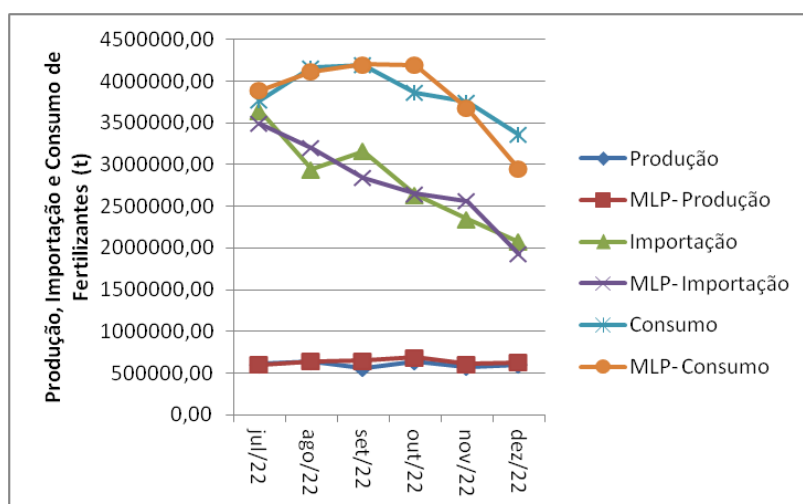
<i>Meses</i>	<i>Produção</i>	<i>MLP- Produção</i>
jul/22	606932,00	604479,91
ago/22	642514,00	642016,90
set/22	564464,00	650115,79
out/22	640543,00	687697,99
nov/22	579127,00	609565,94
dez/22	604918,00	626291,35
<i>Meses</i>	<i>Importação</i>	<i>MLP- Importação</i>
jul/22	3641339	3494144,39
ago/22	2944362	3201583,00

set/22	3160432	2839327,12
out/22	2634273	2650774,54
nov/22	2346175	2566506,64
dez/22	2073149	1924438,02
Meses	Consumo	MLP- Consumo
jul/22	3771141,00	3892427,28
ago/22	4157967,00	4116478,46
set/22	4190985,00	4200462,96
out/22	3866288,00	4196948,58
nov/22	3749436,00	3676223,98
dez/22	3360878,00	2944837,63

Fonte: Os Autores (2023)

Na Figura 5 apresentam-se, na forma gráfica, os resultados das previsões da produção, importação e consumo de fertilizantes.

Figura 5 – Previsões do consumo, produção e importação de fertilizantes – Conjunto de Teste.



Fonte: Os Autores (2023)

Na Tabela 7 apresentam-se os resultados das métricas, MAE, RSME e MAPE, para o conjunto de teste.

Tabela 7 – Métricas – Conjunto de Teste.

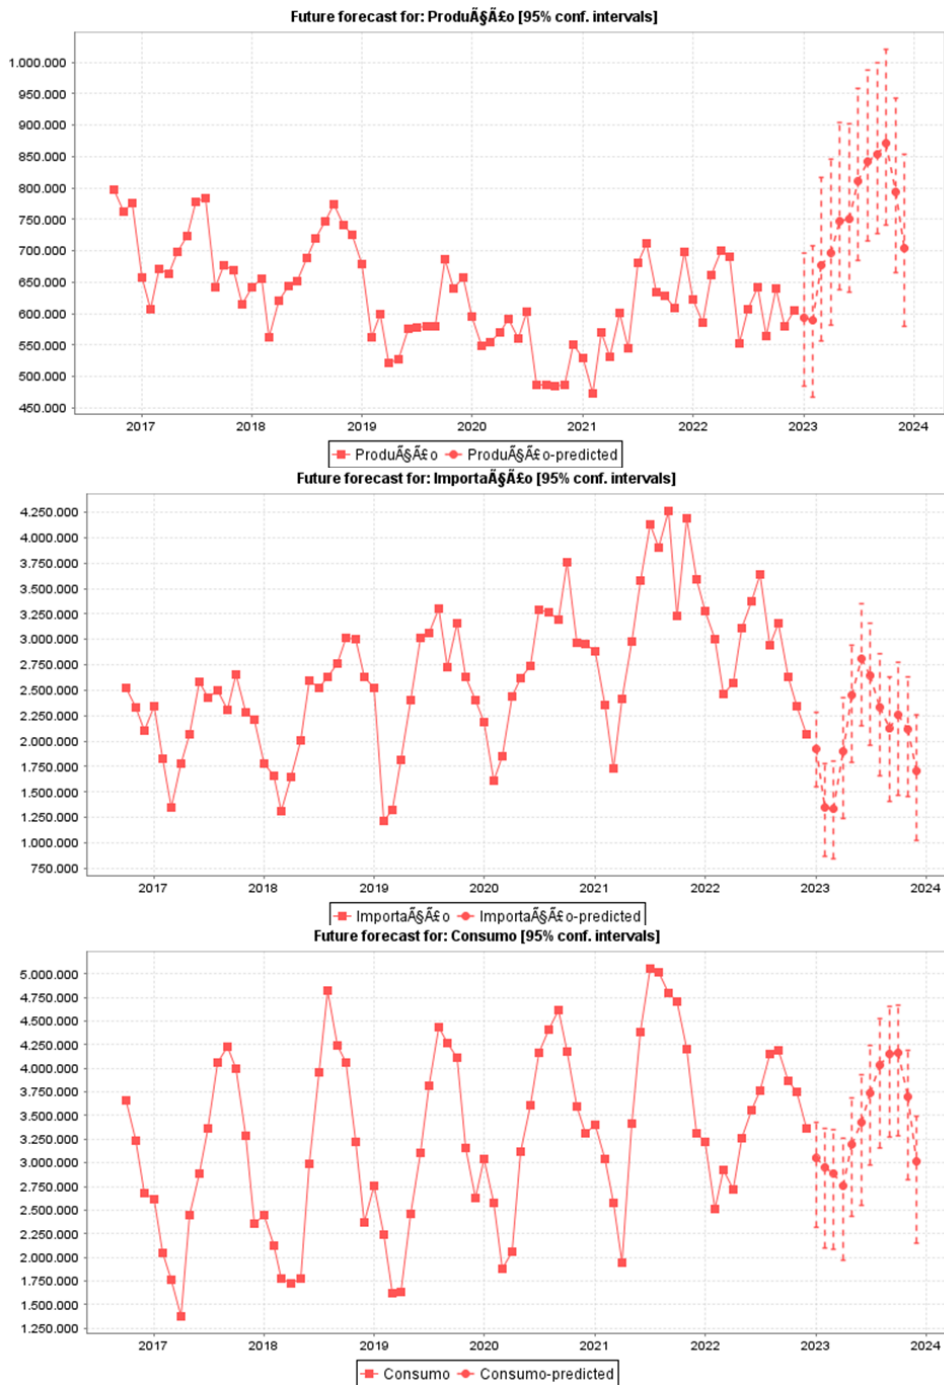
	MAE (t)	RMSE (t)	MAPE (%)
Produção	31261,38	42718,91	5,3
Importação	185177,44	208914,07	6,65
Consumo	105360,95	222206,38	4,55

Fonte: Os Autores (2023)

Pode-se observar, dos resultados apresentados na Tabela 7, que os MAPEs, que medem o tamanho do erro em termos percentuais, ficaram próximos a 5% para os modelos de produção, importação e consumo de fertilizantes no Brasil.

Na Figura 6 apresentam-se as previsões, do ano de 2023, para os modelos de produção, importação e consumo de fertilizantes.

Figura 6 – Previsões para o ano de 2023 – produção, importação e consumo de fertilizantes.



Fonte: Os Autores (2023)

CONCLUSÃO

O presente trabalho teve como objetivo implementar modelos, de séries temporais, para previsão da produção, consumo e importação de fertilizantes intermediários no Brasil. Para tal proposta foram implementados modelos de Redes Neurais *Multilayer Perception* (MLP).

Inicialmente, por meio da métrica *Root Mean Squared Error* (RMSE), selecionaram-se, nos conjuntos de treinamento e validação, os melhores modelos MLPs. Na sequência, estimaram-se os valores referentes aos conjuntos de teste (Julho/22, Agosto/22, Setembro/22, Outubro/22, Novembro/22 e Dezembro/22). Valores estes que foram confrontados com os valores disponibilizados pela ANDA. Observa-se que os valores disponibilizados pela ANDA, dos conjuntos de teste, não participaram do processo de treinamento e validação.

Observou-se, para os conjuntos de teste de produção, importação e consumo, que os MAPEs (*Mean Absolute Percent Error*), dos modelos MLPs, ficaram próximos a 5%, não se distanciando dos valores observados pela ANDA. Demonstrando uma boa capacidade de generalização dos três modelos.

Embora, os modelos MLPs tenham apresentado bons resultados sugere-se, para trabalhos futuros, uma comparação dos resultados das redes MLPs com resultados obtidos de redes neurais recorrentes simples (LSTM, GRU, BLSTM, BGRU) e híbridas (CNN-LSTM, CNN-BLSTM, CNN-GRU e CNN-BGRU).

REFERÊNCIAS

ANDRADE, A.; SALLES, A.; CARVALHO, F. (2021) **Uso de ciência de dados para predição do consumo de fertilizantes no Brasil**. Disponível em: <file:///mnt/bfa0f185-4a3e-437d-a457-33464aa8e85c/download/document.pdf>. Acesso em: 3 de julho de 2021.

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

BRASIL, **Secretaria Especial de Assuntos Estratégicos. Produção nacional de fertilizantes**. Disponível em: https://www.gov.br/planalto/pt-br/assuntos/assuntos-estrategicos/documentos/estudos-estrategicos/sae_publicacao_fertilizantes_v10.pdf. Acesso em: 3 de setembro 2021.

FERNANDES, E; GUIMARÃES, B. A.; MATHEUS, R. R. (2009) **Principais empresas e grupos brasileiros do setor de fertilizantes**. Disponível em: https://www.bndes.gov.br/SiteBNDES/export/sites/default/bndes_pt/Galerias/Arquivos/conhecimento/bnset/Set2906.pdf. Acesso em: 15 de ago. de 2021.

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

MISHRA, P.; SAHU, P. K.; UDAY, J. P. S. ARIMA modeling technique in analyzing and forecasting fertilizer statistics in India. **Trends in Biosciences**, v. 7, 2014.

OGINO, C. M.; COSTA JUNIOR, G.; POPOVA, N. D., MARTINEZ FILHO, J. G. Poder de compra, preço e consumo de fertilizantes minerais: uma análise para o centro-oeste brasileiro. **Revista de Economia e Sociologia Rural**, v. 59, 2021.

REETZ, M. F. **Fertilizantes e seu uso eficiente**. (2017). Disponível em: <https://www.ufla.br/dcom/wp-content/uploads/2018/03/Fertilizantes-e-seu-uso-eficiente-WEB-Word-Ouubro-2017x-1.pdf>. Acesso em: 8 de setembro de 2021.

SANTOS, J. A. A. Arabica coffee price forecast: a neural network application CNN-BLSTM. **Research, Society and Development**, v. 11, 2022.

SILVA, R. A. **Estudo preliminar da aplicação de redes neurais no sistema de controle de temperatura em uma planta didática**. Trabalho de Conclusão de Curso. Universidade Federal Fluminense; 2015.

TRAGE, D. R. **Estudo do mercado de fertilizantes no Brasil por meio de previsões estatísticas**. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná, 2019.

WOYAKOSKI, J. F. G. (2012) **Análise da demanda de fertilizantes no Brasil: Um estudo econométrico através da modelagem ARIMA**. Disponível em: https://repositorio.unesp.br/bitstream/handle/11449/121766/woyakoski_jfg_tcc_arafcl.pdf?sequence=1&isAllowed=y>. Acesso em: 10 de julho 2021.

ZANGH, W.; ZANGH, X. A forecast analysis on fertilizers consumption worldwide. **Environmental Monitoring and Assessment**, v. 133, 2007.