

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DIRETORIA DE PESQUISA E PÓS-GRADUAÇÃO
MESTRADO EM TECNOLOGIAS COMPUTACIONAIS PARA O AGRONEGÓCIO

ANDRESSA RUSTICK

**APLICAÇÃO DE MODELOS DE SÉRIES TEMPORAIS NA PREVISÃO
DA PRODUÇÃO, IMPORTAÇÃO E CONSUMO DE FERTILIZANTES
NO BRASIL**

**MEDIANEIRA
2023**

ANDRESSA RUSTICK

**APLICAÇÃO DE MODELOS DE SÉRIES TEMPORAIS NA PREVISÃO
DA PRODUÇÃO, IMPORTAÇÃO E CONSUMO DE FERTILIZANTES
NO BRASIL**

**Application of time series models in forecasting the production, import and
consumption of fertilizers in Brazil.**

Dissertação apresentada como requisito para
obtenção do título de Mestre em Tecnologias
Computacionais para o Agronegócio da Universidade
Tecnológica Federal do Paraná (UTFPR).

Orientador: Prof. Dr. José Ailton Azevedo dos Santos.
Coorientador: Prof. Dr. Cidmar Ortiz

MEDIANEIRA

2023



Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Campus Medianeira



ANDRESSA RUSTICK

APLICAÇÃO DE MODELOS DE SÉRIES TEMPORAIS NA PREVISÃO DA PRODUÇÃO, IMPORTAÇÃO E CONSUMO DE FERTILIZANTES NO BRASIL.

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Tecnologias Computacionais Para O Agronegócio da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Tecnologias Computacionais Aplicadas À Produção Agrícola E Agroindústria.

Data de aprovação: 20 de Outubro de 2023

Dr. Jose Airton Azevedo Dos Santos, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Carlos Aparecido Fernandes, Doutorado - Universidade Tecnológica Federal do Paraná

Dra. Luani Back Silvina, Doutorado - Faculdade Dinâmica das Cataratas (Udc)

Dr. Paulo Cesar Tonin, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 20/10/2023.

RESUMO

RUSTICK, Andressa. **Aplicação de modelos de séries temporais na previsão da produção, importação e consumo de fertilizantes no Brasil**. 2023. Dissertação de Mestrado – Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio, Universidade Tecnológica Federal do Paraná. Medianeira, 2023.

Os fertilizantes, no Brasil, são insumos de grande importância na produtividade agrícola. Neste contexto, este trabalho tem como objetivo comparar modelos, de séries temporais, para previsão da produção, importação e consumo de fertilizantes intermediários no Brasil. Para realizar a comparação, entre os modelos, foram utilizadas séries históricas, da produção, importação e consumo de fertilizantes no Brasil, no período entre 1998 e 2022. Modelos de previsão, baseados em algoritmos de Regressão Linear (LR), Redes Neurais (MLP) e Máquina de Vetores de Suporte para Regressão (SVR), foram desenvolvidos por meio do software WEKA. Resultados obtidos, dos três modelos, 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 o modelo MLP apresentou melhor desempenho.

Palavras-chave: Fertilizantes, Máquina de Vetor de Suporte, Redes Neurais Artificiais, Regressão Linear.

ABSTRACT

RUSTICK, Andressa. **Application of time series models in forecasting production, imports and consumption of fertilizers in Brazil.** 2023. Dissertação de Mestrado – Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio, Universidade Tecnológica Federal do Paraná. Medianeira, 2023.

Fertilizers, in Brazil, are inputs of great importance in agricultural productivity. In this context, this work aims to compare time series models to forecast the production, import and consumption of intermediate fertilizers in Brazil. To carry out the comparison, between the models, historical series of the production, import and consumption of fertilizers in Brazil were used, in the period between 1998 and 2022.. Forecast models, based on Linear Regression algorithms (LR), Neural Networks (MLP) and Support Vector Machine for Regression (SVR), were developed using the WEKA software. Results obtained from the three models were compared using the metrics RSME (Root Mean Squared Error), MAE (Mean Absolute Percent Error) and MAPE (Mean Absolute Percent Error). It was found, for a short-term horizon, that the MLP model performed better.

Key-words: Fertilizers, Support Vector Machine, Artificial Neural Networks, Linear Regression.

LISTA DE ILUSTRAÇÕES

Figura 1– Projeções da produção dos principais produtos agrícolas de 2018 a 2028.	16
Figura 2- Gráfico representativo de insumos necessários no solo.	17
Figura 3– Dependência externa de fertilizantes.	19
Figura 4 – Fertilizantes – Cadeia produtiva.	20
Figura 5 – Estrutura de um neurônio.	22
Figura 6 – Função sigmoide.	23
Figura 7 – Arquitetura de uma rede MLP.	24
Figura 8 – Treinamento <i>Backpropagation</i> .	25
Figura 9 – Classes de dados linearmente separáveis.	26
Figura 10– Classes de dados não linearmente separáveis.	26
Figura 11– Linha de hiperplano junto com linhas de limite definidas por $\pm \epsilon$.	27
Figura 12– Interface do WEKA.	29
Figura 13- Classificação metodológica da pesquisa.	31
Figura 14 - <i>Boxplots</i> – Consumo, Importação e Produção de fertilizantes.	32
Figura 15 - Séries: Consumo, Importação e Produção de fertilizantes.	33
Figura 16– Arquivo no formato ARFF.	35
Figura 17 – Interface <i>Explorer</i> do WEKA.	36
Figura 18 – Aba <i>Basic Configuration</i> .	37
Figura 19 – Aba <i>Advanced Configuration</i> .	37
Figura 20– Janelas de configuração dos algoritmos.	38
Figura 21 – Média mensal do consumo de fertilizantes.	41
Figura 22– Média mensal da produção de fertilizantes.	42
Figura 23 – Média mensal da importação de fertilizantes.	42
Figura 24 – Consumo, produção e importação de fertilizantes no Brasil.	43
Figura 25– Treinamento e Validação – LR (Produção).	45
Figura 26– Treinamento e Validação – LR (Consumo).	46
Figura 27– Treinamento e Validação – LR (Importação).	46
Figura 28– Treinamento e Validação – SVR (Produção).	48
Figura 29– Treinamento e Validação – SVR (Consumo).	48
Figura 30– Treinamento e Validação – SVR (Importação).	49
Figura 31 – Treinamento e Validação – MLP (Produção).	52
Figura 32– Treinamento e Validação – MLP (Consumo).	53
Figura 33– Treinamento e Validação – MLP (Importação).	53
Figura 34– Previsões – Conjunto de Teste (Produção).	55
Figura 35 – Previsões – Conjunto de Teste (Consumo).	56
Figura 36 – Previsões – Conjunto de Teste (Importação).	57
Figura 37 – Previsões para o ano de 2023 (Produção).	57
Figura 38 – Previsões para o ano de 2023 (Consumo).	58
Figura 39– Previsões para o ano de 2023 (Importação).	58

LISTA DE TABELAS

Tabela 1 – Métricas.....	39
Tabela 2 – Análise descritiva.....	41
Tabela 3– Algoritmos que ajustaram os dados.	44
Tabela 4 – RMSE para os métodos de seleção.	44
Tabela 5 – RSME para os parâmetros <i>Ridge</i>	44
Tabela 6 – Configuração para o modelo de Regressão Linear.	45
Tabela 7– RSME para o <i>Kernel</i> da SVR.	47
Tabela 8– RSME para os otimizadores da SVR.....	47
Tabela 9– Configuração para os modelos de Máquina de Vetor de Suporte para Regressão.	47
Tabela 10– Neurônios – RMSE.....	50
Tabela 11– Taxa de Aprendizagem – RMSE.	50
Tabela 12– <i>Momentum</i> – RMSE.	51
Tabela 13– Número de Épocas – RMSE.	51
Tabela 14– Configuração dos modelos de rede neural (MLP).	52
Tabela 15– Dados de Produção Observados e Previstos (LR, MLP e SVR) e Métricas (MAE, RSME e MAPE).	54
Tabela 16– Dados de Consumo Observados e Previstos (LR, MLP e SVR) e Métricas (MAE, RSME e MAPE).	55
Tabela 17 – Dados de Importação Observados e Previstos (LR, MLP e SVR) e Métricas (MAE, RSME e MAPE).	56

LISTA DE QUADROS

Quadro 1 – Tipos de fertilizantes.....	18
Quadro 2– Trabalhos relacionados com a previsão de fertilizantes.....	29
Quadro 3 – Descrição das etapas do <i>Advanced Configuration</i>	38

LISTA DE ABREVIATURAS E SIGLAS

ARIMA	Autorregressivo Integrado de Médias Móveis
BLSTM	<i>Bidirectional Long Short-Term Memory</i>
GRU	<i>Gated Recurrent Unit</i>
IPEA	Instituto de pesquisa econômica aplicada
LR	Regressão Linear
LSTM	<i>Long Short Term Memory</i>
MAE	Erro médio Absoluto
MAPE	Média percentual absoluta do erro
MLP	Redes neurais <i>Multilayer Perceptron</i>
NPK	Nitrogênio, fósforo e potássio.
RNAs	Redes Neurais Artificiais
RMSE	Raiz do erro quadrático médio
SARIMA	Autoregressivo Integrado de Médias Móveis com Sazonalidade
SVM	Máquina de Vetor de Suporte
SVR	Vetor de Suporte para Regressão

SUMÁRIO

1 INTRODUÇÃO	13
1.1 OBJETIVOS	15
1.1.1 Objetivo Geral	15
1.1.2 Objetivos Específicos	15
1.2 JUSTIFICATIVA	15
2 REVISÃO DE LITERATURA	17
2.1 FERTILIZANTES	17
2.2 FERTILIZANTES MINERAIS.....	19
2.3 CADEIA PRODUTIVA	20
2.4 REGRESSÃO LINEAR.....	21
2.5 REDES NEURAIS	22
2.5.1 Neurônio artificial.....	22
2.5.2 Redes neurais <i>Multilayer Perceptron</i> (MLP).....	24
2.5.3 Treinamento <i>Backpropagation</i>	24
2.6 MÁQUINA DE VETOR DE SUPORTE	25
2.7 MINERAÇÃO DE DADOS	27
2.8 TRABALHOS RELACIONADOS	28
2.9 O SOFTWARE WEKA.....	29
3 MATERIAIS E MÉTODOS	31
3.1 CLASSIFICAÇÃO METODOLÓGICA	31
3.2 SÉRIES HISTÓRICAS	32
3.3 PANDEMIA X GUERRA	34
3.4 WEKA.....	35
3.4.1 Interface <i>Explorer</i>	36
3.4.2 <i>Forecast – Basic Configuration</i>	36
3.4.3 <i>Forecast – Advanced Configuration</i>	37
3.5 MÉTRICAS.....	39
3.6 ETAPAS DO TRABALHO.....	39
4 RESULTADOS E DISCUSSÕES	41
4.1 TREINAMENTO E VALIDAÇÃO	43
4.1.1 Ajuste de Variância	43
4.1.2 Regressão Linear (LR)	44
4.1.3 Máquina de Vetor de Suporte para Regressão (SVR)	47
4.1.4 Redes Neurais Artificiais (MLP).....	49
4.1.5 Número de neurônios:	50
4.1.6 Taxa de Aprendizagem:	50
4.1.7 <i>Momentum</i>	51
4.1.8 Número de Épocas:.....	51
4.2 TESTE.....	54
5 CONCLUSÃO	59
REFERÊNCIAS	60

1 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, estão a Regressão Linear (LR), as Redes Neurais Artificiais (RNAs) e a Máquina de Vetor de Suporte para Regressão (SVR). 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. A análise de regressão tem como resultado uma equação matemática que descreve o relacionamento entre variáveis e pode ser utilizada para prever valores futuros (SOUZA, 2001). Já a máquina de vetor de suporte, baseada na teoria de aprendizado estatístico, vêm sendo muito utilizada para realizar previsões de séries temporais (GRANZOTTO; OLIVEIRA, 2014).

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, regressão linear e máquina de vetor de suporte na previsão da produção, importação e consumo de fertilizantes. Geralmente, são utilizados modelos tradicionais, como os modelos ARIMA e SARIMA (ANDRADE et al., 2021).

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

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Este trabalho tem como objetivo comparar modelos, de séries temporais, para previsão da produção, importação e consumo de fertilizantes intermediários no Brasil.

1.1.2 Objetivos Específicos


- a) Obter uma base de dados com séries históricas de produção, importação e consumo de fertilizantes intermediários no Brasil.
- b) Realizar a limpeza e o tratamento dos dados.
- c) Implementar modelos de regressão linear múltipla, máquina de vetor de suporte para Regressão e redes neurais artificiais, no software WEKA, para previsão da produção, importação e consumo de fertilizantes intermediários no Brasil.
- d) Testar e validar os modelos.
- e) Comparar os modelos desenvolvidos e identificar qual deles tem o melhor desempenho.

1.2 JUSTIFICATIVA

O Brasil é uma potência agrícola. Aproximadamente metade das exportações brasileiras são oriundas do agronegócio. Desde 1994 as exportações do

agronegócio vêm crescendo continuamente, no período de 2018 à 2028 a produção agrícola deve continuar a crescer (Figura 1) (BRASIL, 2021).

Figura 1– Projeções da produção dos principais produtos agrícolas de 2018 à 2028.



Fonte: Brasil, 2021.

O crescimento constante, da produção agrícola, gera uma demanda crescente da utilização de fertilizantes no país. Isso ocorre devido à necessidade de restaurar os nutrientes do solo, permitindo que as plantas cresçam de maneira saudável e proporcionem uma alta rentabilidade. É importante ressaltar que toda a cadeia produtiva depende da eficiência da produção agrícola. Portanto, um planejamento eficaz, do consumo de fertilizantes, desempenha um papel fundamental ao ajudar as organizações a evitar desperdícios.

Nesse contexto, a capacidade de realizar previsões precisas sobre o mercado de fertilizantes torna-se um fator crítico tanto para empresas públicas quanto privadas. Esse planejamento estratégico permite que as empresas estejam preparadas para atender às crescentes demandas e, ao mesmo tempo, garantir a gestão eficiente dos recursos necessários para manter a produtividade agrícola em níveis satisfatórios.


2 REVISÃO DE LITERATURA

2.1 FERTILIZANTES

Os fertilizantes, um dos principais insumos agrícolas, contribuem na reposição, devido às colheitas, dos elementos que são retirados do solo. Desempenham um papel de destaque na atividade agrícola, sendo o principal responsável pelo ganho de produtividade das lavouras. Estima-se, no contexto da produção de alimentos, que os fertilizantes são responsáveis por 40 a 60% da produção global de alimentos (TRAGE, 2019).

As plantas, a cada plantio, consomem os nutrientes existentes no solo. Os agricultores, com o avanço da tecnologia e com os aumentos nas safras, dificilmente deixam o solo descansar para recuperar seus nutrientes. Portanto, a cada plantio, é necessário renovar os nutrientes do solo por meio da aplicação de fertilizantes. Porém, deve-se mediar a quantidade utilizada, pois o excesso como a falta acaba prejudicando o desenvolvimento da planta (CAMARGO, 2012) (Figura 2).

Figura 2- Gráfico representativo de insumos necessários no solo.



Fonte: Camargo, 2012.

Os fertilizantes, dependendo do tipo, atuam de várias maneiras nas plantas. Sendo que os resultados obtidos, de suas aplicações, estão relacionados com suas composições, visto que cada um dos nutrientes age em partes específicas do tecido vegetal e possui determinadas funções (GUITARRARA, 2023).

Existem cerca de 17 nutrientes bases para os desenvolvimentos das culturas (REETZ, 2017).

Três deles – carbono (C), hidrogênio (H) e oxigênio (O) – são fornecidos pelo ar e pela água. Os três macronutrientes primários – nitrogênio (N), fósforo (P), e potássio (K) são, principalmente, fornecidos pelo solo, mas deficiências no solo e remoção pelas culturas devem ser repostas via fontes suplementares – principalmente com fertilizantes. Os macronutrientes secundários – enxofre (S), cálcio (Ca), e magnésio (Mg) – não são menos essenciais, mas são usualmente, exigidos em menor quantidade como nutrientes. Finalmente, os micronutrientes – boro (B), ferro (Fe), manganês (Mn), zinco (Zn), cobre (Cu), molibdênio (Mo), cloro (Cl) e níquel (Ni) - são necessários em pequenas quantidades, mas tem funções essenciais como catalizadores nos processos metabólicos para o crescimento e desenvolvimento das culturas ou exercem outras funções chave (REETZ, 2017).

Os fertilizantes são classificados em três tipos (Quadro 1) (GUITARRARA, 2023).


Quadro 1 – Tipos de fertilizantes.

FERTILIZANTES	DESCRIÇÃO
a) Fertilizantes orgânicos	São fertilizantes produzidos com a utilização de materiais orgânicos de origem tanto animal quanto vegetal, como esterco, restos de folhas e frutos, cascas de ovos, resíduos de usinas de açúcar e álcool, entre outras matérias-primas.
b) Fertilizantes Inorgânicos ou Minerais	São fertilizantes produzidos por meio de minerais encontrados na natureza ou sintéticos e que passam por um processo industrial antes de serem destinados ao consumidor final.
c) Fertilizantes organominerais	São fertilizantes produzidos por meio de matéria-prima orgânica e enriquecidos com minerais, o que catalisa a sua ação nos vegetais e fornece um grande aporte de nutrientes ao solo.

Fonte: Guitarrara, 2023.

O Brasil, quarto consumidor mundial de fertilizantes, produz aproximadamente 20% da demanda do país, o que o torna um grande importador de fertilizantes. Portanto, o país, que deixou de ser um exportador de fertilizantes a partir de 1992, importa aproximadamente 80% dos fertilizantes consumidos. A alta dependência das importações causam grandes preocupações ao agronegócio brasileiro, por mais que o Brasil possua grandes reservas de matérias-primas em seu território, como: “gás natural, rochas fosfáticas e potássicas e micronutrientes” ele não consegue manter o mercado interno (ZONTA et al., 2021; BRASIL, 2021).

São apresentadas, na Figura 3, as porcentagens de dependência externa dos principais tipos de fertilizantes nitrogênio, fósforo e potássio (N, P e K).



2.2 FERTILIZANTES MINERAIS

Neste trabalho são estudados a produção, importação e o consumo de fertilizantes minerais, os mais comumente usados na agricultura brasileira.

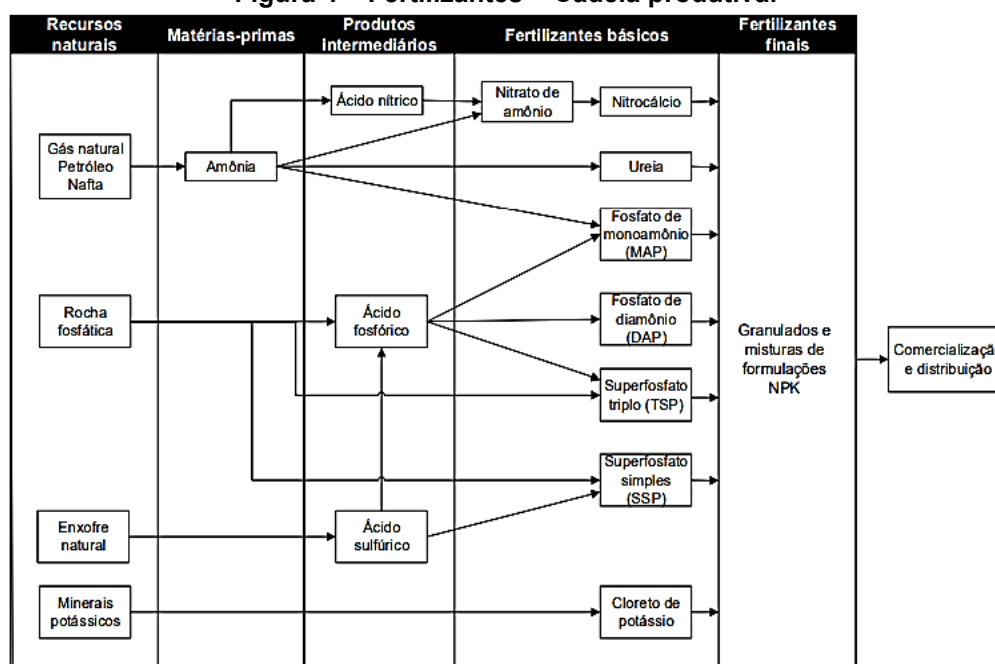
Os fertilizantes minerais são aqueles constituídos por compostos inorgânicos. Segundo Alcarde et al. (1998), os fertilizantes minerais, podem ser divididos, de acordo com sua constituição, em três grupos: simples, mistos e complexos. Os *fertilizantes simples* são compostos por um único composto químico, podendo ter um ou mais nutrientes (sulfato de amônio, superfosfato simples, etc.). Os *fertilizantes mistos* são constituídos por dois ou mais fertilizantes simples (RODELLA; ALCARDE; DIAS, 2000), já os *fertilizantes complexos* são aqueles formados por dois ou mais compostos químicos dentro do mesmo grânulo,

demandando assim maior tecnologia para sua produção. O fertilizante mais utilizado, no Brasil, é o NPK, cujo conteúdo é escrito na sequência N (Nitrogênio), P_2O_5 (Fósforo), e K_2O (Potássio). Este fertilizante demanda menor nível tecnológico e possui preço final menor.

2.3 CADEIA PRODUTIVA

A cadeia produtiva de fertilizantes minerais é apresentada na Figura 4. Nesta cadeia, os recursos naturais básicos para produção de fertilizantes, advindos do setor mineral, são: o gás natural, o petróleo, a nafta, o enxofre e as rochas fosfática e potássica. Na sequência da cadeia, há a fabricação, pela indústria de químicos inorgânicos, das matérias-primas e dos produtos intermediários, utilizando insumos como a amônia e os ácidos nítrico, fosfórico e sulfúrico. Na etapa seguinte, no domínio da indústria de fertilizantes, são produzidos os fertilizantes básicos, como o nitrocálcio, a ureia, entre outros. Os fertilizantes finais, no final da cadeia, são originados dos processos de granulação e mistura dos compostos. Finalmente, são comercializados e distribuídos para a utilização do setor agrícola (TRAGE, 2019).

Figura 4 – Fertilizantes – Cadeia produtiva.



Fonte: Trage, 2019.

2.4 REGRESSÃO LINEAR

Segundo Pereira (2023) um modelo de regressão linear pode ser utilizado para analisar quantitativamente relações entre variáveis. Num modelo de regressão linear o comportamento da variável dependente Y é explicado pela variável independente X . Tem-se um modelo de regressão linear simples quando a variável dependente é explicada somente por uma variável independente (Equação 1). Quando a variável dependente é explicada por mais de uma variável independente tem-se a regressão linear múltipla.

$$Y = f(X) \quad 1$$

Segundo Hoffman (2016) no caso em que exista um conjunto de n pares de valores de duas variáveis ($X_i, Y_i (i=1, \dots, n)$) pode-se estabelecer uma regressão linear simples, onde o modelo estatístico é definido por:

$$Y = \alpha + \beta X + u \quad 2$$

Onde: α representa o coeficiente linear, β o coeficiente angular e u expressa o erro existente entre o valor real da variável Y e do valor estimado pela regressão.

A regressão múltipla busca, através de um modelo estatístico-matemático, conhecer o efeito de cada variável independente e prever a variável dependente. A equação, para regressão múltipla, é expressa por:

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + u \quad 3$$

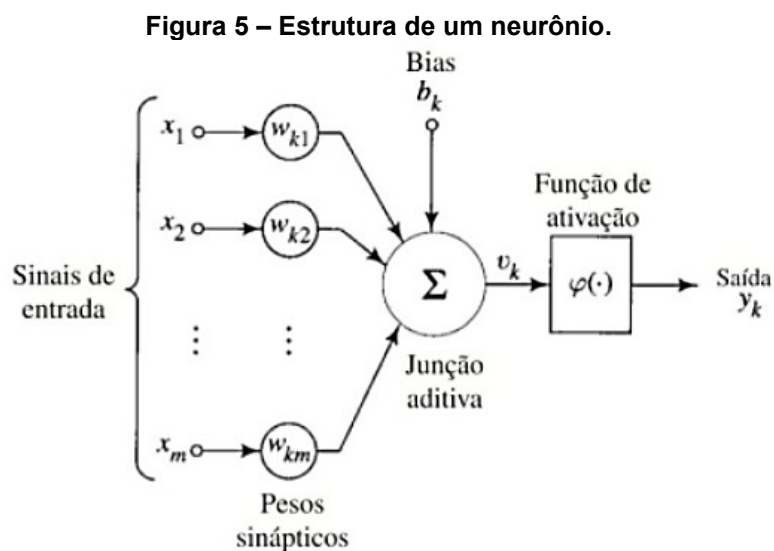
Os coeficientes $\beta_1, \beta_2, \dots, \beta_n$, da Equação 3, podem ser estimados pelo método dos mínimos quadrados. A estimação de parâmetros, por meio do método dos mínimos quadrados, gera, segundo Moreira (2011), um sistema de equações que podem ser resolvidos por meio de softwares computacionais.

2.5 REDES NEURAIS

As Redes Neurais Artificiais (RNAs), com funcionamento inspirado no cérebro humano, são sistemas paralelos distribuídos, composto por unidades simples de processamento, que calculam determinadas funções matemáticas (HAYKIN, 2001).

2.5.1 Neurônio artificial

A Estrutura de um neurônio de uma RNA é apresentada na Figura 5.



Fonte: Antonioli, 2021.

Nesta figura destacam-se os sinais de entrada x_1, x_2, \dots, x_m , os pesos associados as sinapses $w_{k1}, w_{k2}, \dots, w_{km}$, a função de ativação φ , os sinais de saída y_k , a junção aditiva Σ e o bias b_k , que tem o efeito de aumentar ou diminuir a entrada

líquida da função de ativação. Em termos matemáticos o neurônio k pode ser descrito por:


$$u_k = \sum_{j=1}^n w_{kj} x_j \quad 4$$

$$y_k = \varphi(u_k + b_k) \quad 5$$

Identificam-se também, na Figura 5, três elementos básicos de um modelo neural (HAYKIN, 2001).

1. Sinapses (arestas/conexões) – Cada uma das arestas, denominadas sinapses, é constituída por um peso. Onde, na sinapse j do neurônio k , o sinal de entrada x_j é multiplicado pelo peso sináptico w_{kj} .
2. Somador – Faz a soma dos sinais de entrada, ponderados pelos pesos sinápticos dos neurônios, realizando, através de suas operações, uma combinação linear.
3. Função de ativação – É a função que processa o sinal gerado pela combinação linear das entradas e dos pesos das sinapses, para gerar o sinal de saída do neurônio. Neste trabalho a função sigmoide (Figura 6) será utilizada como função de ativação. Esta função é definida como uma função estritamente crescente que exhibe um balanceamento adequado entre o comportamento linear e não linear (PINHEIRO, 2020).

Figura 6 – Função sigmoide.




Fonte: Antonioli, 2021.

2.5.2 Redes neurais *Multilayer Perceptron* (MLP)

As redes MLP (Figura 7) 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. As redes MLP apresentam uma função de ativação para cada neurônio da rede (SILVA, 2015).

Figura 7 – Arquitetura de uma rede MLP.



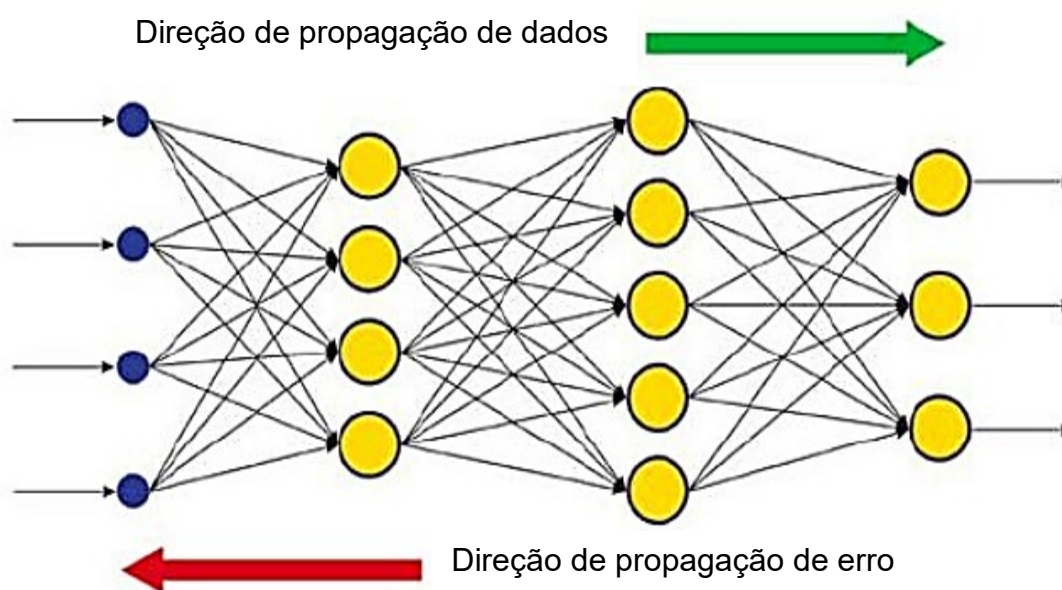
Fonte: Pinheiro, 2020.

2.5.3 Treinamento *Backpropagation*

Backpropagation é um algoritmo utilizado no treinamento de redes neurais supervisionadas. A aprendizagem supervisionada acontece quando é fornecida a resposta desejada e são adaptados os pesos. O passo inicial, deste algoritmo, é a

definição da arquitetura da rede e a inicialização dos pesos. Durante o processo de treinamento um vetor de entrada é aplicado aos neurônios da rede e seu efeito se propaga através da rede, camada por camada, até que seja gerada uma saída por meio da camada de saída (Figura 8). O vetor de saída, produzido pela rede, é comparado com o vetor de saída desejado, resultando num sinal de erro, que é retropropagado através da rede para permitir o ajuste de pesos. Esta saída é comparada com uma saída desejada, e um sinal de erro é calculado para cada neurônio de saída. O processo é repetido até que a rede responda, para cada vetor de entrada, com um vetor de saída com valores muito próximos dos valores desejados (BARCA, 2023; OUYEN et al; 1992).

Figura 8 – Treinamento *Backpropagation*.




Fonte: Adaptado de Pinheiro, 2020.

2.6 MÁQUINA DE VETOR DE SUPORTE

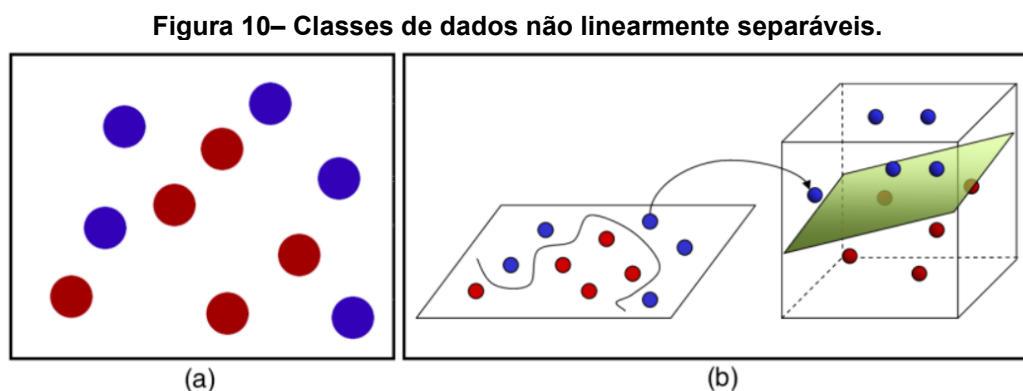
A Máquina de Vetor de Suporte (*Support Vector Machine* - SVM), foi desenvolvida, por Vapnik (1995), com a intenção de resolver problemas de classificação de padrões. A SVM tem por objetivo fazer a separação ótima entre

duas classes (círculos azul e vermelho) (Figura 9.b) (NORONHA; FERNANDES, 2016).



Fonte: Noronha & Fernandes, 2016.

Não é necessário, para obter a linha que separa as classes, todo o conjunto de dados, mas apenas os dados mais próximos da linha de classificação (Figura 9.c) Estes dados, relevantes para a classificação, são chamados de vetores de suporte. Na Figura 10.a apresentam-se conjuntos de dados que não são linearmente separáveis. Necessita-se, para fazer a separação das classes, mapear o conjunto de dados em outra dimensão (*Keelling*). Isto torna possível separar as classes por meio de um hiperplano (Figura 10.b).




Fonte: Noronha & Fernandes, 2016.

As SVMs são muito conhecidas em problemas de classificação. Para problemas de regressão as SVMs são conhecidas por Máquina de Vetor de Suporte para Regressão (*Support Vector Regression (SVR)*). O problema, para o contexto da SVR, consiste em encontrar uma função que minimize o erro de previsão com relação ao conjunto de treinamento. Neste caso, procura-se encontrar uma função

$f(x)$ que aproxima determinado vetor y a menos de um erro de previsão ε (*epsilon*) especificado (ALBUQUERQUE, 2014). O valor de *epsilon* determina a largura do tubo ao redor da função estimada (hiperplano) (Figura 11). Os pontos que caem dentro deste tubo são considerados previsões corretas e não são penalizados pelo algoritmo. Os vetores de suporte, diferente da SVM, são os pontos que ficam fora do tubo e não apenas os que estão na margem (DOBILAS, 2020).

Figura 11– Linha de hiperplano junto com linhas de limite definidas por $\pm \varepsilon$.



Fonte: Dobilas, 2020.

O algoritmo SMOreg, disponível no software WEKA, implementa a máquina de vetores de suporte para regressão (SVR). O objetivo do algoritmo é minimizar o erro, identificando uma função que coloca mais pontos originais dentro do tubo e, ao mesmo tempo, reduz o ε (TEIXEIRA, 2014).

2.7 MINERAÇÃO DE DADOS

Segundo Alves (2018) a Mineração de Dados (*Data Mining*) é um processo de descoberta de padrões significativos e novos, bem como modelos descritivos,

compreensíveis e preditivos a partir de um grande volume de dados. A mineração de dados utiliza métodos de diferentes áreas do conhecimento como: banco de dados, estatística, inteligência artificial, aprendizado de máquina e reconhecimento de padrões.

Diversos softwares podem ser utilizados para realizar o processo de extração da informação, dentre eles pode-se citar o software WEKA.

Etapas da mineração de dados (SPIES, 2015; HOSKEN, 2014):

- **Seleção:** Na etapa inicial se identificam quais dados que serão analisados através da mineração de dados.

- **Pré-processamento e Limpeza:** Nesta etapa se executa processos que farão a eliminação de dados duplicados, incompletos ou que não se enquadrem no que se pretende analisar.

- **Transformação dos dados:** Nesta etapa é realizada a exportação dos registros já pré-processados e limpos, do banco de dados para um arquivo em um formato aceito pelo sistema de mineração de dados.

- **Data Mining:** É a etapa em que se aplica o algoritmo, de uma técnica de mineração de dados, no arquivo com os dados a serem analisados.

- **Interpretação e Avaliação:** Na última etapa se analisa os resultados, apresentados pelo algoritmo de mineração de dados, buscando novas informações sobre os dados analisados.

2.8 TRABALHOS RELACIONADOS

Os artigos, relacionados com o trabalho proposto nesta dissertação, foram obtidos por meio de mapeamento no Google Acadêmico utilizando a *string* “forecast” AND “fertilizer” AND “arima” OR “sarima” OR “neural network” OR “regression”). No Quadro 2 apresentam-se os trabalhos, publicados em periódicos, sobre a previsão de fertilizantes em países ou no mundo, obtidos através do Google Acadêmico.

Quadro 2– Trabalhos relacionados com a previsão de fertilizantes.

Autores	Região	Método
Styhr Petersen (1977)	Dinamarca	Regressão
Deadman et al. (1979)	Mundo	Regressão
Gilland (1993)	Mundo	Regressão
Howarth et al. (2002)	Estados Unidos	Regressão
Dobermann et al. (2005)	Mundo	Regressão
Zhang et al. (2007)	Mundo	Regressão
Tenkorang et al. (2009)	Mundo	Regressão
Ogasawara et al. (2013)	Brasil	ARIMA
Pires et al. (2015)	Brasil	Regressão
Sujjaviriyasup (2021)	Mundo	RNA, ARIMA
Hassan et al. (2022)	Bangladesh	RNA
Pisuyyinusart et al. (2022)	Tailândia	SARIMA
Borkar (2023)	Índia	ARIMA

Fonte: Autoria própria, 2023.

2.9 O SOFTWARE WEKA

O software WEKA, *Waikato Environment for knowledge Analysis*, teve sua origem na Universidade de Waikato, na Nova Zelândia. Este software, de código aberto, fornece várias ferramentas de *Data Mining*. Grande parte de suas ferramentas computacionais foram resultados de teses da universidade de Waikato.

O WEKA suporta várias tarefas de mineração de dados, tarefas como: pré-processamento, agrupamento, classificação, regressão e visualização dos dados. A interface do software WEKA é apresentada na Figura 12.

Figura 12– Interface do WEKA.

Fonte: Autoria própria, 2023.

Existem, segundo Witten et al. (2016), três formas principais de utilização do software WEKA:

1. Comparação de desempenho de diversos métodos de aprendizagem;
2. Utilização dos modelos de aprendizagem para realizar previsões em novos casos;
3. Adoção de métodos de aprendizagem para inspecionar as saídas e coletar informações relevantes.

O WEKA, com sua vasta gama de algoritmos, tem se mostrado uma poderosa ferramenta para a análise e mineração de dados, oferecendo suporte a pesquisadores, cientistas de dados e profissionais que trabalham com aprendizado de máquina e tarefas de mineração de dados em geral.

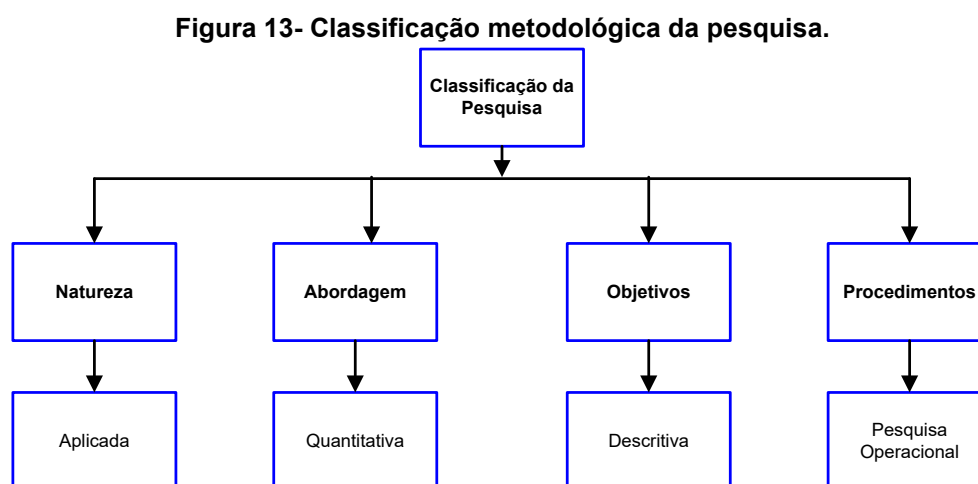
3 MATERIAIS E MÉTODOS

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

3.1 CLASSIFICAÇÃO METODOLÓGICA

A pesquisa, segundo Markoni e Lakatos (2010), é um procedimento formal, que requer um tratamento científico com base em métodos reflexivos, constituindo-se de um meio para conhecer a realidade ou descobrir verdades parciais.

Segundo Gerhardt e Silveira (2009), a pesquisa pode ser classificada quanto a sua natureza, abordagem, objetivos e em relação aos procedimentos técnicos utilizados. Na Figura 13 apresentam-se as formas de classificação que se enquadram nesta pesquisa.



Fonte: Autoria própria, 2023.

A classificação, nesta pesquisa, em relação à:

- Natureza: é do tipo aplicada. Porque esta pesquisa objetiva gerar conhecimentos para uma aplicação prática.
- Abordagem: classifica-se como quantitativa, devido a utilização de dados numéricos, como por exemplo, os dados de produção, importação


e consumo de fertilizantes intermediários no Brasil.

- **Objetivos:** a pesquisa é descritiva, uma vez que é realizada uma descrição de determinada população. Segundo Gil (2010), tem como objetivo identificar relações e associações entre variáveis.
- **Procedimentos técnicos:** é uma pesquisa operacional, porque são utilizados modelos matemáticos, estatística e algoritmos para auxiliar na tomada de decisões (BARBOSA; ZANARDINI, 2010).

3.2 SÉRIES HISTÓRICAS

Para previsão da produção, importação e consumo de fertilizantes do Brasil, foram utilizadas três séries históricas com 300 instâncias cada (Jan/1998 - Dez/2022) (IPEA, 2023a,b,c). 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. Os dados obtidos, das séries históricas, são apresentados na Figura 14, na forma de *boxplot*.


Figura 14 - Boxplots – Consumo, Importação e Produção de fertilizantes.



Fonte: Autoria própria, 2023.

As séries históricas, da produção, importação e consumo de fertilizantes, são apresentadas na Figura 15.

Figura 15 - Séries: Consumo, Importação e Produção de fertilizantes.



Fonte: Autoria própria, 2023.

É possível observar, dos gráficos apresentados na Figura 15, que o Brasil, devido ao aumento da produtividade agrícola, aumentou o consumo de fertilizantes, porém sua produção interna diminuiu. Conseqüentemente, para atender o mercado interno, precisou importar fertilizantes de outros países.

3.3 PANDEMIA X GUERRA

No ano de 2020 o mundo sofreu com a pandemia de COVID-19. Muitas indústrias fecharam ou trabalharam remotamente. Isto se refletiu no setor agrícola. Este setor precisou lidar com a falta de matéria prima e mão de obra, gerando uma baixa produção de fertilizantes em 2020. Por outro lado, as importações no Brasil, no segundo semestre de 2020, fecharam em 29,4 milhões de toneladas de fertilizantes, superando, no mesmo período, a média dos três anos anteriores (GLOBALFERT, 2022).

A pandemia de COVID-19, em 2021, também influenciou no mercado de fertilizantes. Gerando aumento nos fretes dos suprimentos dos fertilizantes, como também a interrupção no fornecimento destes. Tendo como consequência a inflação no preço dos fertilizantes. Muitos países ficaram também receosos com o desabastecimento interno e passaram a estabelecer restrições no fornecimento de fertilizantes (IFA, 2021).

As exportações de fertilizantes pela Rússia, em 2021, foram limitadas devido ao aumento do preço do gás natural (SÁ; KONIG. 2022). No entanto, o governo russo cumpriu os contratos que possuía com o Brasil, trazendo segurança para o setor agrícola. A Rússia é um dos principais fornecedores de fertilizantes para o Brasil (GLOBALFERT, 2022).

A guerra entre a Rússia e a Ucrânia, em 2022, gerou uma grande preocupação, com relação as importações de fertilizantes, já que a Rússia exporta muitos desses produtos. Em 2022 as importações da Rússia recuaram 17,7%. Um dos motivos desta redução foi o aumento do preço dos fertilizantes, devido principalmente ao conflito entre os dois países IFA (2021).

3.4 WEKA

Os modelos utilizados, para o 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 16 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 16– 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: Autoria própria, 2023.

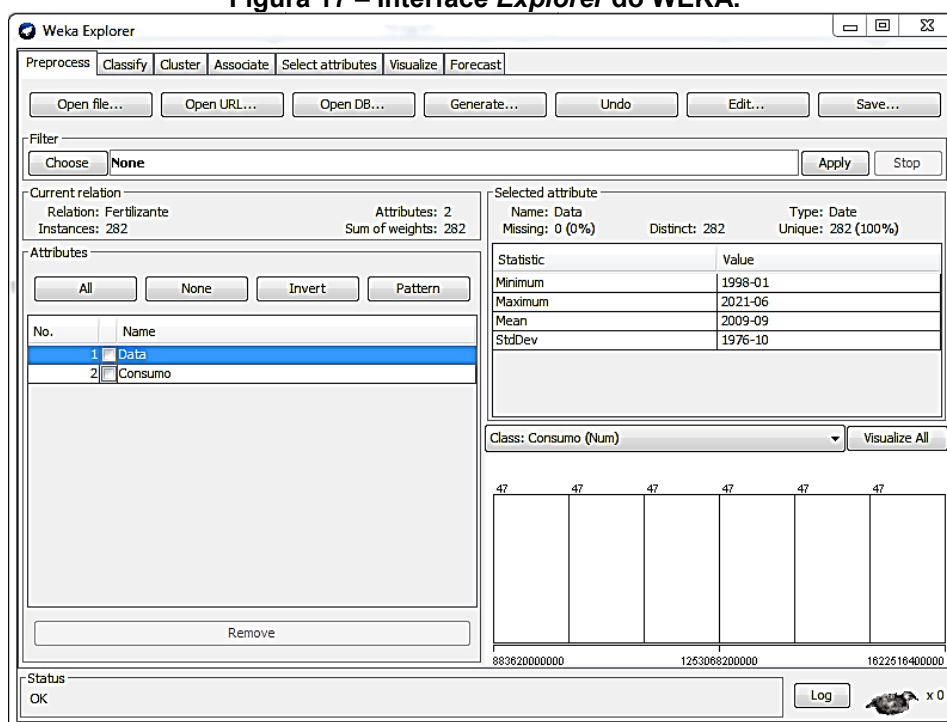
Os tipos podem ser (HOSKEN, 2014):

- *numeric*: usado para número reais e inteiros;
- *<nominal-especificação>*: especifica uma lista pré-definida de valores possíveis separados por vírgula. Exemplo – {amarelo, vermelho, azul};
- *string*: tipo que contém valores textuais;
- *date*: usado para datas.

3.4.1 Interface *Explorer*

A interface *Explorer* do WEKA (Figura 17) fornece algumas medidas de dispersão, como valores de mínimos, máximos, média e desvio padrão. O WEKA também inclui métodos para problemas padrões de mineração de dados como: regressão, classificação, agrupamento, regras de associação e seleção de atributos. Neste trabalho será utilizada a aba *Forecast*. Esta aba é dedicada aos estudos de séries temporais.

Figura 17 – Interface *Explorer* do WEKA.

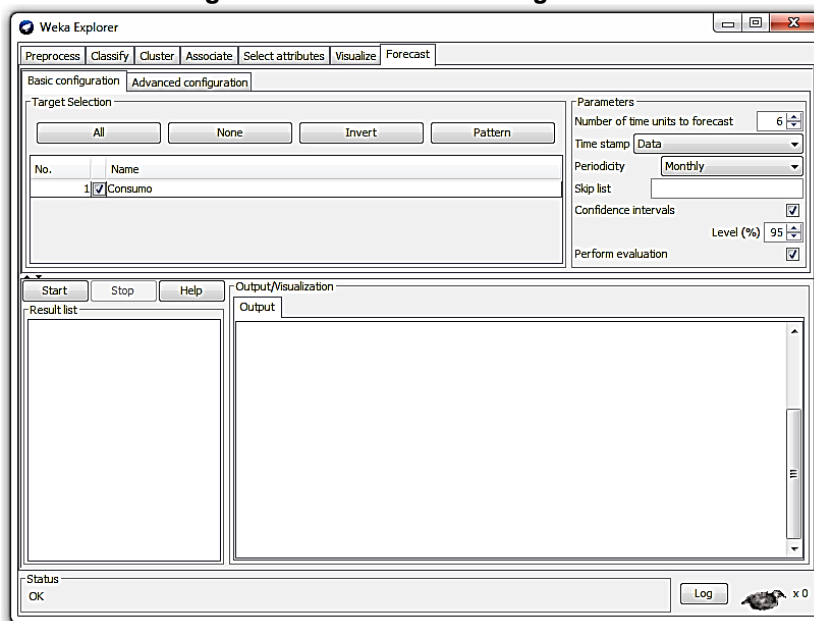


Fonte: Autoria própria, 2023.

3.4.2 *Forecast* – Basic Configuration

As variáveis relacionadas, as unidades de tempo e avaliação da previsão, são configuradas na seção *Parameters* da aba *Basic Configuration* (Figura 18). O horizonte de previsão é controlado pelo *Number of Time Units*, os campos *Time Stamp* e *Periodicity* são cadastrados para *data* e *monthly*, respectivamente. As caixas *Confidences Interval* e *Perform Evaluation* foram acionadas.

Figura 18 – Aba Basic Configuration.




Fonte: Autoria própria, 2023.

3.4.3 Forecast – Advanced Configuration

Na aba *Advanced Configuration* (Figura 19) são fornecidas as opções de configurações avançadas. Na sequência, no Quadro 3, faz-se breves comentários sobre cada uma das abas de *Advanced Configuration* (ANTONIOLLI, 2021).

Figura 19 – Aba Advanced Configuration.



Fonte: Autoria própria, 2023.

Quadro 3 – Descrição das etapas do *Advanced Configuration*.

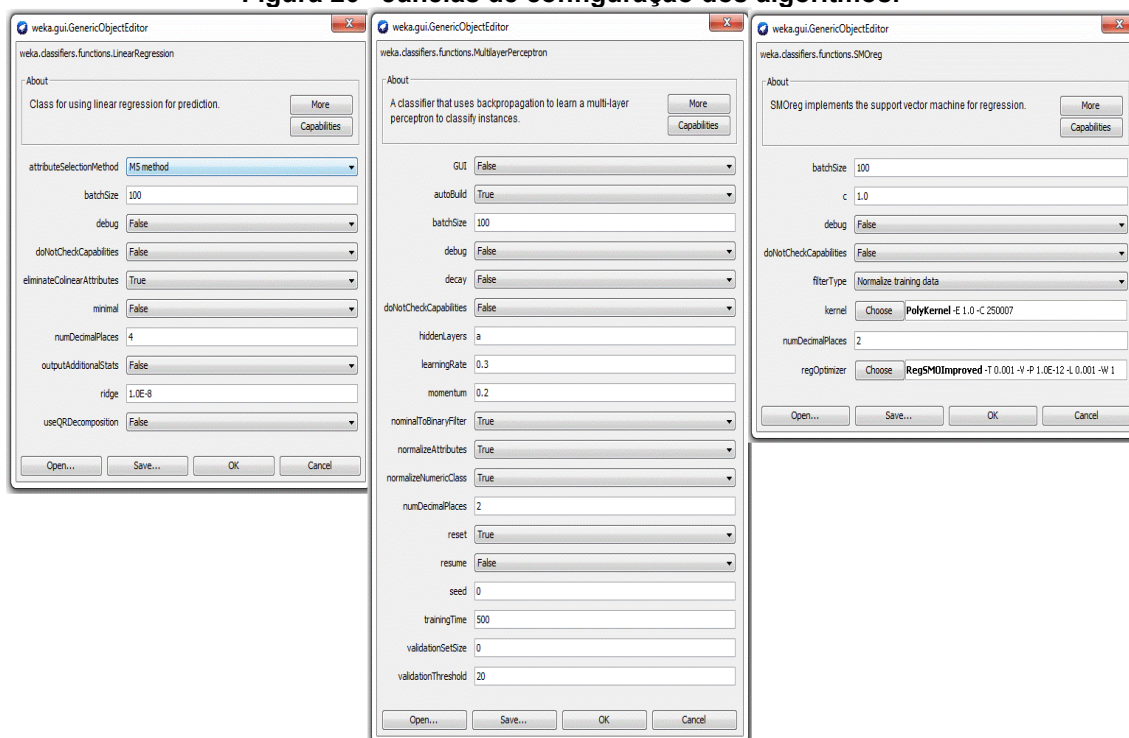
Aba	Descrição
Base learner:	Esta aba fornece diferentes bases de aprendizagem. Neste trabalho utilizou-se as bases de Regressão Linear (LR), Máquina de Vetores de Suporte para Regressão (SVR) e as Redes Neurais Artificiais (MLP) .
Lag creation:	As variáveis defasadas são o principal mecanismo pelo qual o relação entre os valores passados e atuais de uma série pode ser capturados por algoritmos de aprendizado. Ele cria um "janela" ao longo de um período de tempo. Neste trabalho pretende-se utilizar uma janela de 12 meses.
Evaluation:	Nesta aba são selecionadas as métricas de avaliação. Neste estudo será utilizado as métricas MSE (<i>Mean Squared Error</i>), RMSE (<i>Root Mean Squared Error</i>) e MAPE (<i>Mean Absolute Percent Error</i>). Configura-se também, nesta aba, a porção dos dados que será utilizada no conjunto de validação.
Periodic Attributes:	Está aba não é utilizada neste trabalho.
Overlay Data:	Está aba não é utilizada neste trabalho.
Output:	Saída Gráfica.

Fonte: Hosken (2014).

As abas *Periodic Attributes* e *Overlay Data* não serão utilizadas neste trabalho. A primeira customiza a periodicidade dos trabalhos. A segunda restringe os dados que serão usados como entradas.

As telas de configurações dos algoritmos LR, MLP e SVR são apresentadas na Figura 20.

Figura 20– Janelas de configuração dos algoritmos.



Fonte: Autoria própria, 2023.

3.5 MÉTRICAS

Neste trabalho, os modelos obtidos foram avaliados pelas métricas (CANKURT; SUBASI, 2015; ANTONIOLLI, 2021):

- - RSME (*Root Mean Squared Error*): Penaliza mais os erros maiores, permite avaliar a qualidade de um previsor em relação aos dados.
- - MAE (*Mean Absolute Percent Error*): O valor do MAE representa o desvio médio entre o valor observado e o predito. Quanto mais próximo de zero, maior a qualidade dos valores preditos.
- - MAPE (*Mean Absolute Percent Error*): O MAPE mede o tamanho do erro em termos percentuais.

As equações, das métricas MAE, RSME e MAPE, são apresentadas na Tabela 1.

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: Cankurt & Subasi (2015).

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

3.6 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;
- **Treinamento e Validação:** Na segunda etapa, treinamento e validação, foram selecionados, por meio da métrica RMSE, os melhores modelos LR, MLP e SVR;
- **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 confrontadas com valores de produção, importação e consumo reais. A partir desses dados são calculados o MAPE, MAE e o RSME para cada um dos modelos.

4 RESULTADOS E DISCUSSÕES

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados de produção, consumo e importação de fertilizantes (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: Autoria própria, 2023.

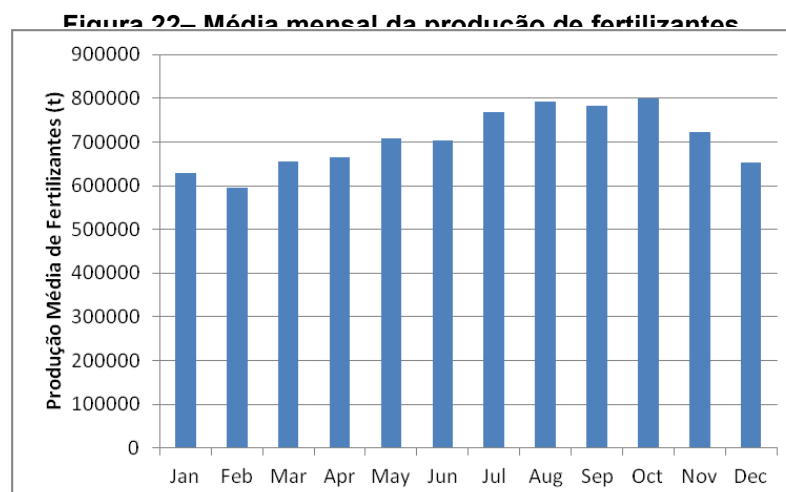
Pode-se observar, dos dados apresentados na Tabela 2, que os valores ficaram, para o período em estudo, em média 706424,2 t para produção, 1596194,1 t para importação e 2263654 t para o consumo. Apresentando, neste período, valores mínimos e máximos para produção de 420945 t e 938839 t, 130805 t e 4263904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

As médias mensais do consumo, importação e produção de fertilizantes, durante o período de janeiro de 1998 à dezembro de 2021, são apresentados nas Figuras 21, 22 e 23.


Figura 21 – Média mensal do consumo de fertilizantes.



Fonte: Autoria própria, 2023.



Fonte: Autoria própria, 2023.




Fonte: Autoria própria, 2023.

Pode-se notar, por meio da Figura 21, que os meses com maiores consumos ocorrem entre julho e novembro. Observou-se também um consumo médio mínimo de 1305397,68 t no mês de Abril e um consumo médio máximo de 3310433,16 t para o mês de Outubro. Para a produção de fertilizantes, Figura 22, tem-se uma produção média mínima de 594095,76 t para o mês de Fevereiro e uma produção média máxima para o mês de Outubro de 800323,76 t. Já para a importação de fertilizantes, Figura 23, tem-se um mínimo de 1049829,36 t para Fevereiro e um máximo de 2026760,96 t em Agosto.

Na Figura 24 apresentam-se o consumo, importação e a produção interna, de 1998 à 2022, de fertilizantes intermediários.

Figura 24 – Consumo, produção e importação de fertilizantes no Brasil.



Fonte: IPEA, 2023a,b,c.

Observa-se, da Figura 24, 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.

4.1 TREINAMENTO E VALIDAÇÃO

Neste trabalho foram utilizados, para previsão dos dados de consumo, importação e produção de fertilizantes, três algoritmos de previsão: Regressão Linear (LR), Redes Neurais Artificiais (MLP) e Máquina de Vetor de Suporte para Regressão (SVR).

Para as etapas de treinamento e validação, dos três algoritmos de previsão, o conjunto de dados foi dividido em 75% para treinamento e 25% para validação.

Observa-se, que as alterações dos parâmetros, de todos os algoritmos do software WEKA, foram feitas sequencialmente, sempre selecionando o resultado com o menor erro para configurar o próximo parâmetro.

4.1.1 Ajuste de Variância

O software WEKA disponibiliza, para compensar as variações nos dados de

entrada, a técnica de ajuste de variância. Na Tabela 3 apresentam-se os algoritmos que utilizaram esta técnica.

Tabela 3– Algoritmos que ajustaram os dados.

Algoritmo	Ajuste de Variância		
	Produção	Consumo	Importação
LR	Com ajuste	Sem ajuste	Sem ajuste
SVR	Com ajuste	Sem ajuste	Sem ajuste
MLP	Sem ajuste	Com ajuste	Com ajuste

Fonte: Autoria própria, 2023.

4.1.2 Regressão Linear (LR)

Inicialmente, testa-se o algoritmo de regressão linear. O WEKA fornece, para o algoritmo LR, os métodos M5 e Greedy de seleção de atributos. Na Tabela 4 são apresentados os resultados da métrica RMSE.

Tabela 4 – RMSE para os métodos de seleção.

Método de Seleção	Produção	Consumo	Importação
	RMSE	RMSE	RMSE
M5	74423	333092	394157
Greedy	61996	328207	394157
Sem Método	71823	325562	387385

Fonte: Autoria própria, 2023.

Observa-se, dos resultados da Tabela 4, que o método de seleção Greedy apresentou melhor resultado para produção. Para importação e consumo, a opção sem método de seleção apresentou o menor RMSE.

Na sequência testou-se o parâmetro *Ridge*. A técnica de regularização de *Ridge* é utilizada para reduzir a complexidade da aprendizagem do modelo (Tabela 5).

Tabela 5 – RSME para os parâmetros *Ridge*.

Ridge	Produção	Consumo	Importação
	RMSE	RMSE	RMSE
1×10^{-12}	86633	325562	387385
1×10^{-8}	85485	325562	387385
1×10^{-5}	85485	328963	387385
1×10^{-3}	85485	328963	387385

Fonte: Autoria própria, 2023.

Da Tabela 5 observa-se que o parâmetro Ridge igual 1×10^{-8} apresentou os menores RMSEs. Portanto, na Tabela 6 apresentam-se, considerando os menores valores de RMSE, a configuração utilizada para o modelo de Regressão Linear.

Tabela 6 – Configuração para o modelo de Regressão Linear.

LR	Produção	Consumo	Importação
	Configuração	Configuração	Configuração
Ridge	1×10^{-8}	1×10^{-8}	1×10^{-8}
Método de Seleção	Greedy	Sem Método	Sem Método

Fonte: Autoria própria, 2023.

Previsões de treinamento e validação do modelo LR, para produção, consumo e importação, são apresentados nas Figuras 25, 26 e 27.

Figura 25– Treinamento e Validação – LR (Produção).




Figura 26– Treinamento e Validação – LR (Consumo).





Figura 27– Treinamento e Validação – LR (Importação).



4.1.3 Máquina de Vetor de Suporte para Regressão (SVR)

Para o modelo de máquina de vetor de suporte foram configurados a função de *kernel* e o algoritmo otimizador. Iniciou-se o processo selecionando a função de *kernel*. Funções de *kernel* são funções utilizadas para realizar regressões não lineares. Alguns dos *kernels* mais utilizados na prática utilizam funções de base polinomial e radial (*Radial Basis Function* (RBF)). Na Tabela 7 apresentam-se os resultados da métrica RMSE para as funções de *kernel* disponibilizadas pelo WEKA.

Tabela 7– RSME para o Kernel da SVR.

Função Kernel	Produção	Consumo	Importação
	RMSE	RMSE	RMSE
Polinomial	66996	302925	360446
Polinomial Normalizada	73191	714040	877981
RBF	81147	383517	482346

Fonte: Autoria própria, 2023.

Observa-se, da Tabela 7, que a configuração de *Kernel* Polinomial obteve os menores RSMEs. Seguindo, com as configurações, escolhe-se o otimizador de aprendizagem. São disponibilizados, pelo software WEKA, o SMOReg e o SMORegImproved. Na Tabela 8 apresentam-se os resultados da métrica RMSE para os dois otimizadores.

Tabela 8– RSME para os otimizadores da SVR.

Otimizador	Produção	Consumo	Importação
	RMSE	RMSE	RMSE
SMORegImproved	66996	302929	360466
SMOReg	67047	310565	357422

Fonte: Autoria própria, 2023.

O otimizador SMORegImproved obteve os menores valores de RMSE para produção e consumo e o otimizador SMOReg apresentou o menor RMSE para importação. Na Tabela 9 apresenta-se, considerando-se os menores valores de RMSE, a configuração utilizada pelos modelos SVR.


Tabela 9– Configuração para os modelos de Máquina de Vetor de Suporte para Regressão.

SVR	Produção	Consumo	Importação
	Configuração	Configuração	Configuração
Kernel	Polinomial	Polinomial	Polinomial
Otimizador	SMORegImproved	SMORegImproved	SMOReg

Fonte: Autoria própria, 2023.


Nas Figuras 28, 29 e 30 apresentam-se as previsões, de treinamento e validação, para produção, consumo e importação dos modelos SVR.

Figura 28– Treinamento e Validação – SVR (Produção).




Fonte: Autoria própria, 2023.

Figura 29– Treinamento e Validação – SVR (Consumo).



Fonte: Autoria própria, 2023.

Figura 30– Treinamento e Validação – SVR (Importação).



Fonte: Autoria própria, 2023.

4.1.4 Redes Neurais Artificiais (MLP)

Foram configurados, para este algoritmo, os seguintes hiperparâmetros:

- - Número de neurônios na camada oculta. O número de neurônios é utilizado para trazer mais ou menos complexidade ao modelo.
- - Taxa de aprendizagem. A taxa de aprendizagem afeta a velocidade em que o algoritmo atinge (converge para) os pesos ideais.
- - *Momentum*. O termo *momentum* tem por objetivo aumentar a velocidade de treinamento da rede neural e reduzir o perigo de instabilidade.
- - Número de épocas. É a quantidade de vezes que o conjunto de treinamento é acessado pelo algoritmo de aprendizado, para atualizar os pesos dos neurônios.

Observa-se que os hiperparâmetros foram alterados nessa sequência, partindo de configurações iniciais e seguindo, com o modelo com o menor erro, para os testes do próximo parâmetro.

4.1.5 Número de neurônios

A primeira configuração foi o número de neurônios da camada oculta. Foram testadas redes com 7, 14, 28 e 56 neurônios. O WEKA, para o conjunto de validação, apresentou os RMSEs para produção, consumo e importação, apresentados na Tabela 10.

Tabela 10– Neurônios – RMSE.

Número de Neurônios	Produção	Consumo	Importação
	RMSE	RMSE	RMSE
7	94136	457123	572628
14	83889	446530	941618
28	94280	489835	1175012
56	91178	507054	676498

Fonte: Autoria própria, 2023

Observa-se, dos resultados da Tabela 10, que a rede com 14 neurônios, na camada oculta, apresentou melhor resultado para produção e consumo. Para importação a rede com 7 neurônios apresentou menor RMSE.

4.1.6 Taxa de Aprendizagem

Definido o número de neurônios da camada oculta, passa-se para o ajuste da taxa de aprendizagem. Os resultados da métrica RMSE, para o conjunto de validação, para as taxas 0,2; 0,1; 0,01 e 0,001 são apresentados na Tabela 11.

Tabela 11– Taxa de Aprendizagem – RMSE.

Taxa de Aprendizagem	Produção	Consumo	Importação
	RMSE	RMSE	RMSE
0,2	83889	446530	572628
0,1	87869	420811	833671
0,01	76444	426749	536000
0,001	88231	366810	618773

Fonte: Autoria própria, 2023.

Pode-se observar, da Tabela 11, que as taxas de aprendizagem para a produção e importação ficaram em 0,01, para o consumo ficou 0,001.

4.1.7 Momentum

Na sequência, analisa-se o próximo hiperparâmetro, o *momentum*, para 0,1, 0,3, 0,5 e 0,7 (Tabela 12). Definiram-se os *momentums* 0,7 e 0,1 como os mais adequados, pelos menores valores do RMSE.

Tabela 12– Momentum – RMSE.

Momentum	Produção	Consumo	Importação
	RMSE	RMSE	RMSE
0,1	76444	366810	536000
0,3	71458	380163	527556
0,5	60193	397528	516953
0,7	55909	425152	498884

Fonte: Autoria própria, 2023

4.1.8 Número de Épocas

Em seguida foram analisados os erros para 500, 1000, 1500 e 2000 épocas. Pode-se observar, desta tabela, que os menores valores do RMSE ficaram para 500 épocas (Tabela 13).

Tabela 13– Número de Épocas – RMSE.

Número de Épocas	Produção	Consumo	Importação
	RMSE	RMSE	RMSE
500	55909	366810	498884
1000	71270	403122	704072
1500	80310	423355	780523
2000	90251	435382	821549

Fonte: Autoria própria, 2023

Assim, concluem-se as configurações da rede neural. A melhor performance, da rede neural artificial, foi obtida com os hiperparâmetros apresentados na Tabela

14.

Tabela 14– Configuração dos modelos de rede neural (MLP).

Parâmetro	Produção	Consumo	Importação
	Configuração	Configuração	Configuração
Número de Neurônios	14	14	7
Taxa de Aprendizagem	0,01	0,001	0,01
Momentum	0,7	0,1	0,7
Número de Épocas	500	500	500

Fonte: Autoria própria, 2023

Nas Figuras 31, 32 e 33 apresentam-se os resultados das previsões de treinamento e validação da rede MLP para a produção, consumo e importação de fertilizantes.

Figura 31 – Treinamento e Validação – MLP (Produção).



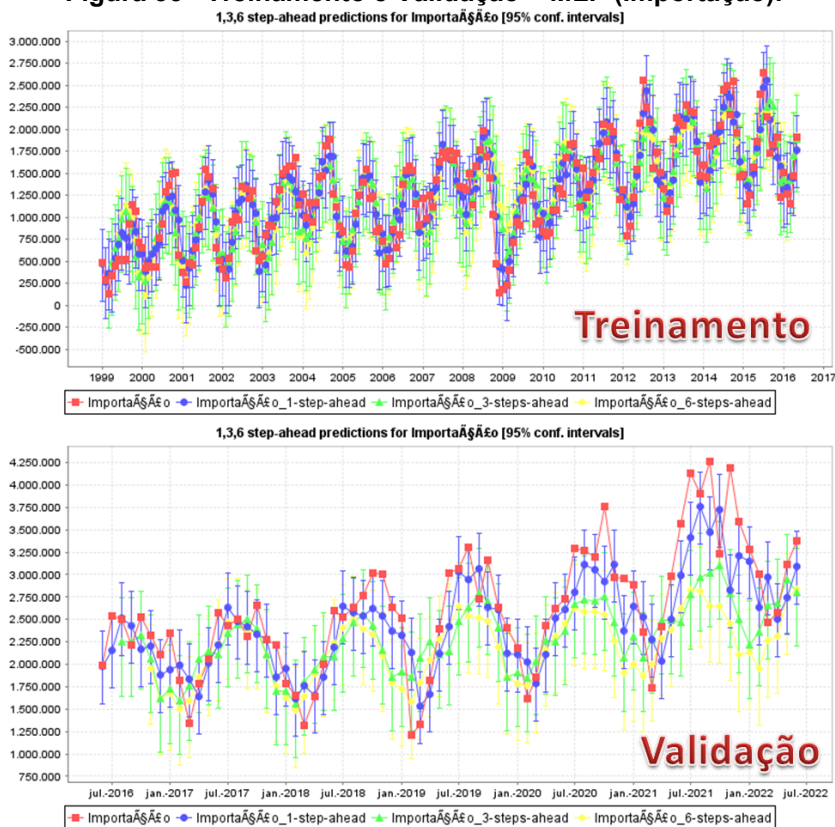


Figura 32– Treinamento e Validação – MLP (Consumo).



Fonte: Autoria própria, 2023.

Figura 33– Treinamento e Validação – MLP (Importação).



Fonte: Autoria própria, 2023

4.2 TESTE

Para comparar o potencial dos modelos de previsão, utilizados neste trabalho, realizou-se uma comparação entre os modelos LR, SVR e MLP. Nas Tabelas 15, 16 e 17 apresentam-se, para estes modelos, os dados observados (reais) e preditos e as métricas MAE, RMSE e MAPE para as 6 instâncias, dos conjuntos de teste de produção, consumo e importação de fertilizantes, que não participaram da etapa de treino e validação.

Por meio dos resultados apresentados, nas Tabelas 15, 16 e 17, conclui-se que o modelo MLP apresentou melhor desempenho, em relação as métricas MAE, RMSE e MAPE, que os modelos SVR e LR, tanto para produção e o consumo quanto para importação de fertilizantes.

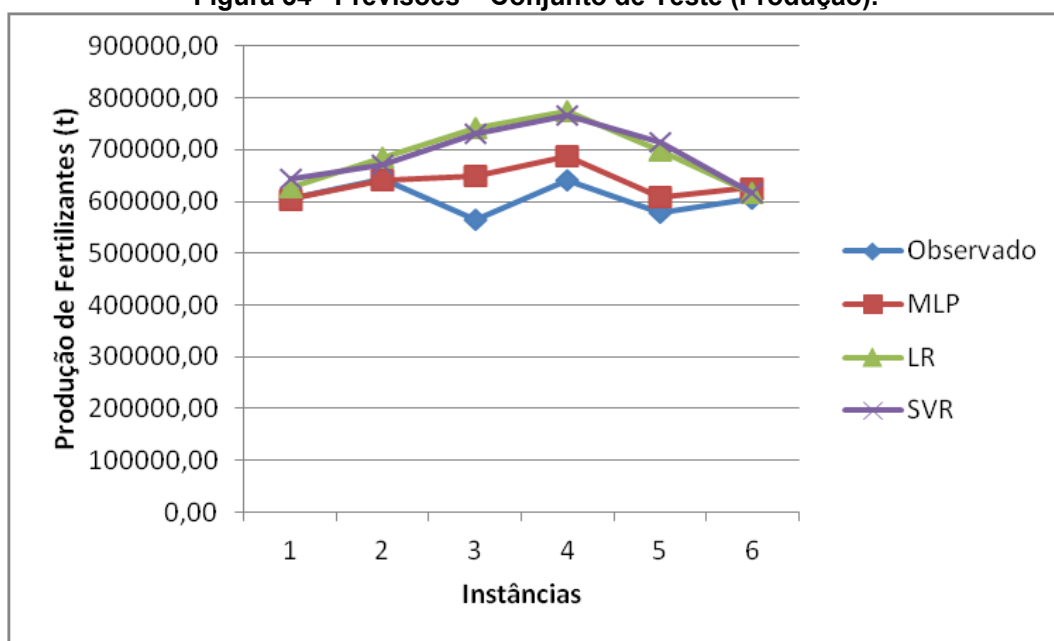
Nas Figuras 34, 35 e 36 apresentam-se, em termos gráficos, os resultados das previsões dos dados de produção, consumo e importação de fertilizantes.

Tabela 15– Dados de Produção Observados e Previstos (LR, MLP e SVR) e Métricas (MAE, RSME e MAPE).

Meses	Observado	MLP	LR		SVR		
jul/22	606932,00	604479,91	0,40	627233,73	3,34	643302,94	5,99
ago/22	642514,00	642016,90	0,08	684389,98	6,52	672103,85	4,61
set/22	564464,00	650115,79	15,17	741387,95	31,34	731523,27	29,60
out/22	640543,00	687697,99	7,36	774807,54	20,96	766160,48	19,61
nov/22	579127,00	609565,94	5,26	697644,45	20,46	715028,81	23,47
dez/22	604918,00	626291,35	3,53	616366,23	1,89	616014,78	1,83
		MAPE= 5,30		MAPE= 14,09		MAPE= 14,18	
Meses	Observado	MLP	LR		SVR		
jul/22	606932,00	604479,91	2452,09	627233,73	20301,73	643302,94	36370,94
ago/22	642514,00	642016,90	497,10	684389,98	41875,98	672103,85	29589,85
set/22	564464,00	650115,79	85651,79	741387,95	176923,95	731523,27	167059,27
out/22	640543,00	687697,99	47154,99	774807,54	134264,54	766160,48	125617,48
nov/22	579127,00	609565,94	30438,94	697644,45	118517,45	715028,81	135901,81
dez/22	604918,00	626291,35	21373,35	616366,23	11448,23	616014,78	11096,78
		MAE= 31261,38		MAE= 83888,65		MAE= 84272,69	
Meses	Observado	MLP	LR		SVR		
jul/22	606932,00	604479,91	6012729,67	627233,73	412160180,09	643302,94	1322845603,82
ago/22	642514,00	642016,90	247112,59	684389,98	1753597960,59	672103,85	875559199,35
set/22	564464,00	650115,79	7336229815,42	741387,95	31302084862,07	731523,27	27908798055,75
out/22	640543,00	687697,99	2223592940,44	774807,54	18026966808,82	766160,48	15779750628,34
nov/22	579127,00	609565,94	926528952,66	697644,45	14046386950,05	715028,81	18469301091,50
dez/22	604918,00	626291,35	456819957,71	616366,23	131061997,61	616014,78	123138530,81
		RSME= 42718,91		RSME= 104620,15		RSME= 103665,64	

Fonte: Autoria própria, 2023

Figura 34– Previsões – Conjunto de Teste (Produção).



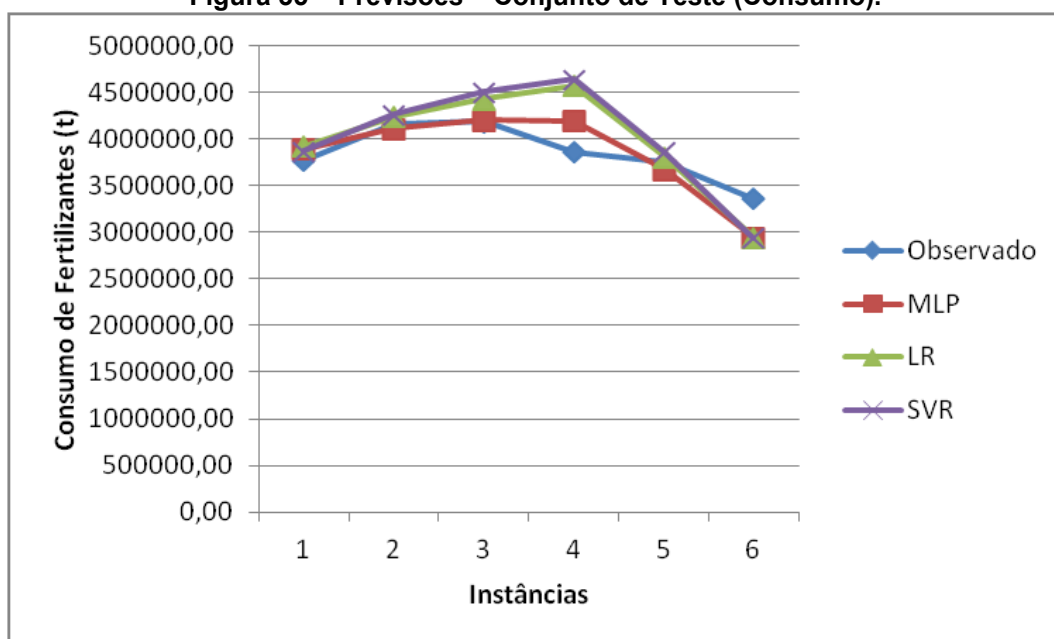
Fonte: Autoria própria, 2023

Tabela 16– Dados de Consumo Observados e Previstos (LR, MLP e SVR) e Métricas (MAE, RSME e MAPE).

Meses	Observado	MLP	LR	SVR
jul/22	3771141,00	3892427,28	3924744,14	3871056,66
ago/22	4157967,00	4116478,46	4241868,63	4266546,95
set/22	4190985,00	4200462,96	4430249,78	4506575,64
out/22	3866288,00	4196948,58	4574476,19	4639617,82
nov/22	3749436,00	3676223,98	3807279,50	3867310,35
dez/22	3360878,00	2944837,63	2950681,08	2937079,63
		MAPE= 4,554011038	MAPE= 7,310798512	MAPE= 8,091081051
Meses	Observado	MLP	LR	SVR
jul/22	3771141,00	3892427,28	3924744,14	3871056,66
ago/22	4157967,00	4116478,46	4241868,63	4266546,95
set/22	4190985,00	4200462,96	4430249,78	4506575,64
out/22	3866288,00	4196948,58	4574476,19	4639617,82
nov/22	3749436,00	3676223,98	3807279,50	3867310,35
dez/22	3360878,00	2944837,63	2950681,08	2937079,63
		MAE= 165360,9573	MAE= 275499,6927	MAE= 306514,7976
Meses	Observado	MLP	LR	SVR
jul/22	3771141,00	3892427,28	3924744,14	3871056,66
ago/22	4157967,00	4116478,46	4241868,63	4266546,95
set/22	4190985,00	4200462,96	4430249,78	4506575,64
out/22	3866288,00	4196948,58	4574476,19	4639617,82
nov/22	3749436,00	3676223,98	3807279,50	3867310,35
dez/22	3360878,00	2944837,63	2950681,08	2937079,63
		RSME= 225206,3874	RSME= 356141,1083	RSME= 390065,941

Fonte: Autoria própria, 2023

Figura 35 – Previsões – Conjunto de Teste (Consumo).



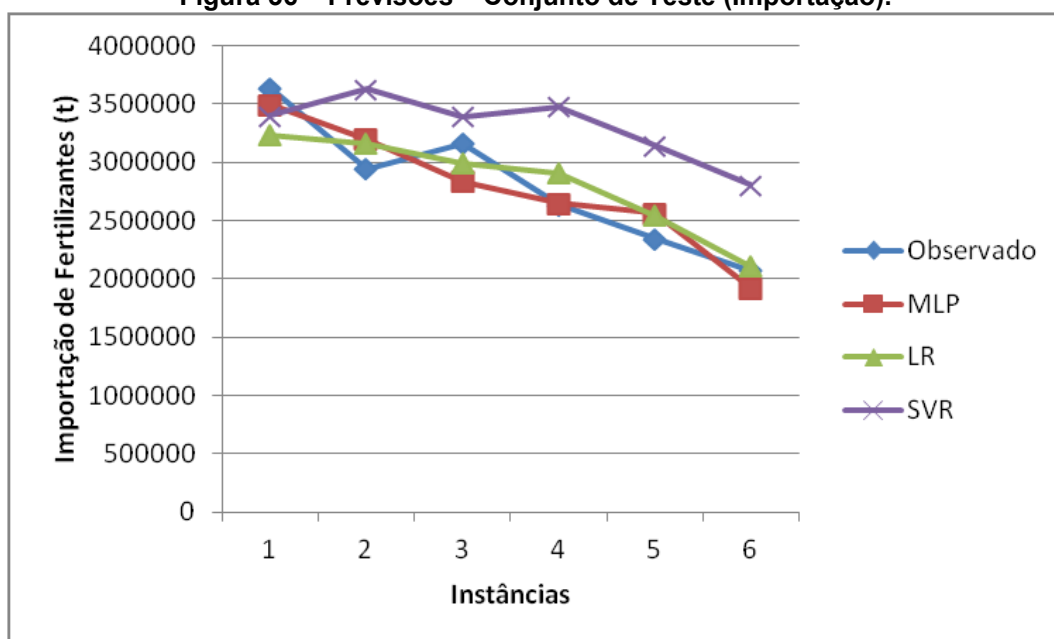
Fonte: Autoria própria, 2023

Tabela 17 – Dados de Importação Observados e Previstos (LR, MLP e SVR) e Métricas (MAE, RSME e MAPE).

Meses	Observado	MLP	LR	SVR
jul/22	3641339	3494144,39	3237192,89	3397329,05
ago/22	2944362	3201583,00	3162376,01	3629342,43
set/22	3160432	2839327,12	2994487,02	3393875,99
out/22	2634273	2650774,54	2910710,26	3479086,68
nov/22	2346175	2566506,64	2544033,50	3147813,48
dez/22	2073149	1924438,02	2110952,47	2805387,95
		MAPE= 6,69	MAPE= 7,42	MAPE= 23,15
Meses	Observado	MLP	LR	SVR
jul/22	3641339	3494144,39	3237192,89	3397329,05
ago/22	2944362	3201583,00	3162376,01	3629342,43
set/22	3160432	2839327,12	2994487,02	3393875,99
out/22	2634273	2650774,54	2910710,26	3479086,68
nov/22	2346175	2566506,64	2544033,50	3147813,48
dez/22	2073149	1924438,02	2110952,47	2805387,95
		MAE= 185177,44	MAE= 216700,72	MAE= 590187,58
Meses	Observado	MLP	LR	SVR
jul/22	3641339	3494144,39	3237192,89	3397329,05
ago/22	2944362	3201583,00	3162376,01	3629342,43
set/22	3160432	2839327,12	2994487,02	3393875,99
out/22	2634273	2650774,54	2910710,26	3479086,68
nov/22	2346175	2566506,64	2544033,50	3147813,48
dez/22	2073149	1924438,02	2110952,47	2805387,95
		RSME= 208914,07	RSME= 243377,82	RSME= 642358,08

Fonte: Autoria própria, 2023

Figura 36 – Previsões – Conjunto de Teste (Importação).




Fonte: Autoria própria, 2023

Nas Figuras 37, 38 e 39 apresentam-se as previsões dos modelos MLP para a produção, consumo e importação de fertilizantes para o ano de 2023.

Figura 37 – Previsões para o ano de 2023 (Produção).

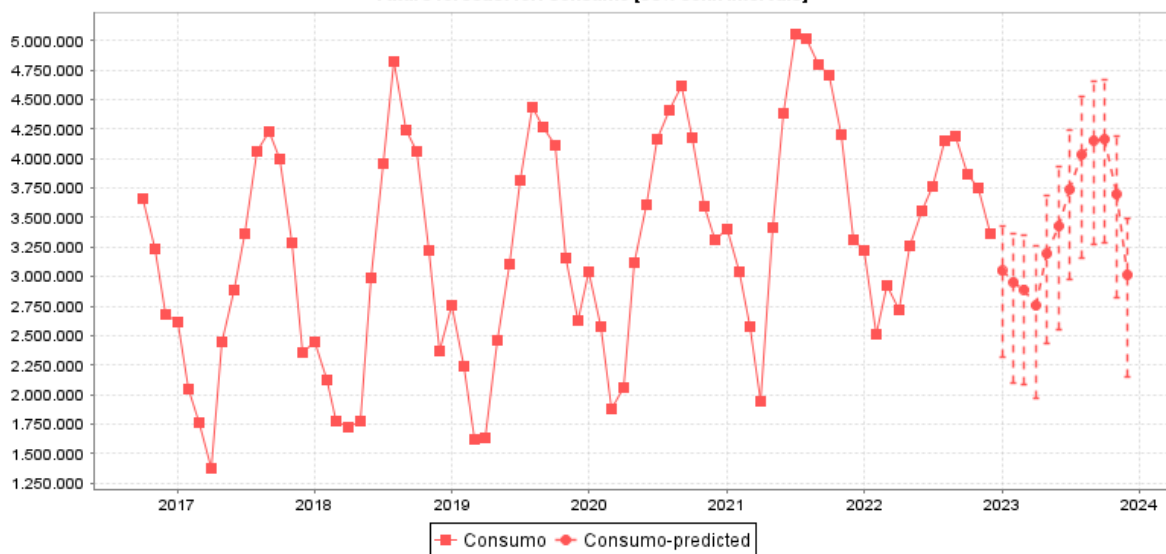
Future forecast for: Produção [95% conf. intervals]



Fonte: Autoria própria, 2023

Figura 38 – Previsões para o ano de 2023 (Consumo).


Future forecast for: Consumo [95% conf. intervals]



Fonte: Autoria própria, 2023

Figura 39– Previsões para o ano de 2023 (Importação).

Future forecast for: Importação [95% conf. intervals]



Fonte: Autoria própria, 2023

Pode-se observar, por meio das Figuras 37, 38 e 39, que as previsões para o consumo tendem a ficar próximas aos valores de 2022. Observou-se também que as previsões das importações de fertilizantes caíram em 2023. Já as previsões da produção aumentaram para 2023.

5 CONCLUSÃO

O presente trabalho teve como objetivo comparar modelos, de séries temporais, para previsão da produção, consumo e importação de fertilizantes intermediários no Brasil. Para tal proposta foram adotados os modelos de Regressão Linear (LR), Máquina de Vetor de Suporte para Regressão (SVR) e Redes Neurais Artificiais (MLP).

Inicialmente, por meio da métrica *Root Mean Squared Error* (RMSE), selecionaram-se os melhores modelos, LR, SVR e MLP, nos conjuntos de treinamento e validação. 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 reais. Observa-se que os valores, dos conjuntos de teste, não participaram dos processos de treinamento e validação.

Observou-se, considerando as métricas MAE, RMSE e MAPE, que os modelos MLPs obtiveram um melhor desempenho, com relação aos modelos LR e SVR, tanto para os dados de produção, importação quanto para os dados de consumo. Os MAPEs (*Mean Absolute Percent Error*), dos três modelos MLP, ficaram próximos a 5%, não se distanciando dos valores reais. Demonstrando uma boa capacidade de generalização dos três modelos MLPs.

Embora, os modelos MLPs tenham apresentados bons resultados, quando comparados com os modelos LR e SVR, sugere-se, para trabalhos futuros, uma comparação dos resultados da rede MLP com resultados obtidos de redes neurais recorrentes simples (LSTM, GRU, BLSTM, BGRU) e híbridas (CNN-LSTM, CNN-BLSTM, CNN-GRU e CNN-BGRU).

REFERÊNCIAS

ALBUQUERQUE, P. H. **Previsão de séries temporais financeiras por meio de máquinas de suporte vetorial e ondaletas**. Relatório Final de Pós-Doutorado. IME-USP, 2014.

ALVES, R. D. **Predição do desempenho da redação do ENEM utilizando técnica de mineração de dados**. Trabalho de Conclusão de Curso. UFSC, 2018.

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/dwload/document.pdf>. Acesso em: 3 de janeiro de 2023.

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.

COPELLI, A. **Previsão e análise dos preços de fertilizantes com formulação NPK para estratégia de compra dos produtores de soja e milho do Paraná**. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná, 2020.

BARBOSA, M. A.; ZANARDINI, R. A. **Iniciação à Pesquisa Operacional no ambiente de gestão**. Curitiba: Ibpex, 2010.

BARCA, M. C. S.; SILVEIRA, T. R. S.; MAGINI, M. **Treinamento de redes neurais artificiais: o algoritmo backpropagation**. Disponível em: https://www.inicepg.univap.br/cd/INIC_2005/inic/IC1%20anais/IC1-17.pdf. Acesso em: 03 de setembro de 2023.

BORKAR, P. Statical modeling for forecasting fertilizer consumption in India. **Plant Science Today**, v. 10, 2023.

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: 5 de janeiro de 2023.

CAMARGO, M. S. (2012). **A importância do uso de fertilizantes para o meio ambiente**. Disponível em: <<http://www.aptaregional.sp.gov.br/acesse-os-artigos-pesquisa-etecnologia/edicao-2012/julho-dezembro-2/1317-a-importancia-do-uso-defertilizantes-para-o-meio-ambiente/file.html>>. Acesso em: 21 de ago de 2023.

CANKURT, S.; SUBASI, A. Comparasion of linear regression and neural network models forecasting tourist arrivals to turkey. **Eurasian Journal of Science & Engineering**. 2015.

CHEN, Y; KANG, Y; WANG, Z. Probabilistic forecasting with temporal convolutional neural network. **Neurocomputing**, v. 399, 2020.

DOBILAS, S. (2020). **Support Vector Regression (SVR) — One of the Most Flexible Yet Robust Prediction Algorithms**. Disponível em: <https://towardsdatascience.com/support-vector-regression-svr-one-of-the-most-flexible-yet-robust-prediction-algorithms-4d25fdbaca60>. Acesso em: 15 de jan. de 2023.

DEADMAN, D.; GHATAK, S. Forecasting fertilizer consumption and production: Long and shor-run models. **Word Development**, v. 7, 1979.

DOBERMANN, A.; CASSMAN, K. Cereal área and nitrogen use efficiency are drivers of future nitrogen fertilizer consumption. *Life Sciences*, v. 48, 2005.

FAO – ORGANIZAÇÃO DAS NAÇÕES UNIDAS PARA ALIMENTAÇÃO E AGRICULTURA. **Base de dados da FAOSTAT. Fertilizantes por nutriente**. Disponível em: <<http://FAO.fao.org/>>. Acesso em: 6 janeiro 2023.

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 janeiro de 2023.

FRIEDRICH, M. **Uma análise da demanda por fertilizantes no Brasil no período de 1970 a 2010**. Dissertação de Mestrado. Pontifica Universidade Católica do Rio Grande do Sul, 2012.

GERHARDT, T. E.; SILVEIRA, D. T. **Métodos de pesquisa**. 5. ed., Porto Alegre: Editora da UFRGS, 2009.

GIL, A. C. **Como elaborar projetos de pesquisa**. 5. ed., São Paulo, Atlas, 2010. 184p.

GILAND, B. Cereals, nitrogen and population: na assessment of the global trends. **Endeavour**, v. 17, 1993.

GLOBALFERT. **Conflito entre Rússia e Ucrânia: Análise do mercado de fertilizantes**. 2022. Disponível em: <<https://globalfert.com.br/analises/conflito-entre-russia-e-ucraniaanalise-do-mercado-de-fertilizantes-globalfert/>>. Acesso em 19 de julho de 2023

GRANZOTTO, M. H.; OLIVEIRA, I. C. **Desenvolvimento de sistema de detecção de falhas baseado em aprendizado estatístico de máquinas de vetor de suporte**. In: XX Congresso Brasileiro de Engenharia Química. Florianópolis, 2014.

GUITARRARA, P. **Fertilizantes; Brasil Escola**. Disponível em: <https://brasilecola.uol.com.br/geografia/fertilizantes.htm>. Acesso em 25 de jan. de 2023.

HASAN M. B.; AKHTER, L. Na artificial neural network method for managing inventory of a fertilizer company in Bangladesh. **Dhaka University Journal of Science**, 2022.

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

HOFFMANN, R. 2016. **Análise de regressão: uma introdução a econometria**. Disponível em: <https://www.esalq.usp.br/biblioteca/sites/default/files/Analise_Regress%C3%A3o.pdf> Acesso em: 03 de setembro 2023.

HOSKEN, L. A. L. **Avaliação do potencial técnico das energias eólica e solar no município de campos dos Goytacazes/RJ através de mineração de dados meteorológicos**. Dissertação de Mestrado. Universidade Candido Mendes, 2014.

HOWARTH, R.; BOYER, E.; PABICH, W.; GALLOWAY, J. Nitrogen use in the United States from 1961-2000 and potential future trends. **Ambio**, v. 31, 2002.

IPEA, Instituto de Pesquisa Econômica Aplicada. **Venda de fertilizantes: quantidade**. 2023a. Disponível em: <http://www.ipeadata.gov.br/Default.aspx>. Acesso em: 22 de agosto de 2023.

IPEA, Instituto de Pesquisa Econômica Aplicada. **Importações de fertilizantes: quantidade**. 2023b. Disponível em: <http://www.ipeadata.gov.br/Default.aspx>. Acesso em: 22 de agosto de 2023.

IPEA, Instituto de Pesquisa Econômica Aplicada. **Produção de fertilizantes: quantidade**. 2023c. Disponível em: <http://www.ipeadata.gov.br/Default.aspx>. Acesso em: 22 de agosto de 2023.

IFA. **Public Summary Short-Term Fertilizer Outlook**. 2021. Disponível em: <<https://api.ifastat.org>> Acesso em 22 de agosto 2023.

JUHIRESHMA, S. R.; ARAVINDHAR, J. Fertilizer estimation using deep learning approach. **NVEO**, v. 8, 2021

MACIEL, Leandro Moreira; DE TUNES, Lilian Vanussa Madruga. **A importância dos fertilizantes para a agricultura** The importance of fertilizers for agriculture. **Brazilian Journal of Development**, v. 7, n. 6, p. 58647-58658, 2021.

MARCONI, M. A.; LAKATOS, E. M. **Fundamentos de metodologia científica**. 5. ed., São Paulo: Editora Atlas, 2010.

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.

MOREIRA, D. A. **Administração da produção e operações**. São Paulo: Cengage Learning, 2011.

NORONHA, D. H.; FERNANDES, M. A. C. (2016). **Implementação em FPGA de Máquina de Vetores de Suporte (SVM) para Classificação e Regressão**. Disponível em: <https://www.researchgate.net/publication/309477255>. Acesso em: 15 de janeiro de 2023.

OGASAWAREA, E.; MARTINEZ, L.; OLIVEIRA, D.; ZIMBRÃO, G.; PAPPA, G.; MATTOSO, M. **A novel data normalization approach for non-stacionary time series**. In: Proceedings of the International Joint Conference on Neural Nteworks, 2010.

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.

OOYEN, A. V.; NIENHUIS, B. **Improving the convergence of the backpropagation algorithm**. New York: Pergamon Press, 1992.

OSAKI, M. **Com forte dependência do mercado externo, setor nacional de fertilizantes enfrenta desafios**. CEPEA – 14/03/2023 <<https://www.cepea.esalq.usp.br/br/opiniao-cepea/com-forte-dependencia-do-mercado-externo-setor-nacional-de-fertilizantes-enfrenta-desafios.aspx>> Acesso em 10 de setembro de 2023.

PEREIRA, S. M. **Previsão climática sazonal para região hidrográfica dos sertões de Crateús utilizando regressão linear múltipla**. Universidade Federal do Ceará, 2023.

PINHEIRO, T. C. **Gestão da produção de frangos de corte por meio de redes neurais artificiais**. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná, 2020.

PIRES, M.; CUNHA, D.; MATOS CARLOS, S.; COSTA, M. **Nitrogen-use efficiency, nitrous oxide emissions, and cereal production in Brazil: current trends and forecast**. *Plos One*, v. 10, 2015.

PISUTTINUSART, C. JATUPORN, C.; SUVANVIHOK, V.; SEERASARN, N. Forecasting the import demand for chemical fertilizer in Thailand. *Euraseans*, v. 3, 2022.

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: 3 de janeiro de 2023.

RICARDO, D. R. B. **Forecasting tourism demand for Lisbon's region**. Dissertação de Mestrado. Universidade Nova de Lisboa, 2017.

SÁ, Camila Dias; KÖNIG, Claudia Cheron; JANK, Marcos S. **A guerra e a dependência externa brasileira no setor de fertilizantes**. Folha de São Paulo, [S. l.], 13 mar. 2022. Mercado. Disponível em: <<https://www1.folha.uol.com.br/mercado/2022/03/a-guerra-e-a-dependencia-externa-brasileira-no-setor-de-fertilizantes.shtml>> Acesso 23 de agosto de 2023.

SANTOS, C. B. **Previsão do índice de desenvolvimento humano e da expectativa de vida na América latina por meio de técnicas de mineração de dados**. Tese de Doutorado. Universidade Tecnológica Federal do Paraná, 2016.

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.

SPIES, P. C. **Mineração na gestão escolar.** Trabalho de Conclusão de Curso. UNIJUI, 2015.

SOUZA, S. G. **Introdução aos modelos de regressão linear e não-linear.** Embrapa, 2001.

STYHR PETERSEN, H, Forecasting Danish Nitrogen Fertilizer consumption. **Industrial Marketing Management**, v. 6, 1977.

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.

TRAGE, D. R.; SCHMIDT, C. A. P.; SANTOS, J. A. A. **Comparação do uso de métodos de previsão no estudo de consumo de fertilizantes NPK do Brasil.** In: Congresso Brasileiro Interdisciplinar em ciência e tecnologia. Evento online, 2020.

TEIXEIRA, S. **Determinação de modelos de estimativa de teores de carbono em solos utilizando máquina de vetor de suporte e refletância espectral.** Dissertação de Mestrado. Universidade Estadual de Ponta Grossa, 2014.

TENKORANG, F.; LOWENBERG-DEBOER, J. Forecasting long-term global fertilizer demand. **Nutrient Cycling in Agroecosystem**, v. 83, 2009

WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data mining: practical machine learning tools and techniques.** 3. ed. [S.l.]: Morgan Kaufmann, 2016.

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 janeiro de 2023.

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

ZONTA, E.; STAFANATO, J. B.; PEREIRA, M. G. **Recomendações de calagem e adubação para abacaxi, acerola, banana, citros, mamão, mandioca, manga e maracujá.** Brasília, DF: Embrapa, 2021. Cap. 14. p. 263 -303.