

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

GUSTAVO BEZERRA DA SILVA

**APLICAÇÃO DE TÉCNICAS DE REGRESSÃO LINEAR, REGRESSÃO DO
PROCESSO GAUSSIANO E DE REDES NEURAS ARTIFICIAIS PARA
PREVISÃO DO CONSUMO DE ENERGIA DE UMA AGROINDÚSTRIA**

MEDIANEIRA

2022

GUSTAVO BEZERRA DA SILVA

**APLICAÇÃO DE TÉCNICAS DE REGRESSÃO LINEAR, REGRESSÃO DO
PROCESSO GAUSSIANO E DE REDES NEURAIAS ARTIFICIAIS PARA
PREVISÃO DO CONSUMO DE ENERGIA DE UMA AGROINDÚSTRIA**

**Application of linear regression, gaussian process regression and artificial
neural network techniques to predict electricity consumption of an
agroindustry**

Trabalho de conclusão de curso de graduação
apresentado como requisito para obtenção do título de
Bacharel em Engenharia Elétrica da Universidade
Tecnológica Federal do Paraná (UTFPR).
Orientador: José Airton Azevedo dos Santos.

MEDIANEIRA

2022



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

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

GUSTAVO BEZERRA DA SILVA

**APLICAÇÃO DE TÉCNICAS DE REGRESSÃO LINEAR, REGRESSÃO DO
PROCESSO GAUSSIANO E DE REDES NEURAS ARTIFICIAIS PARA
PREVISÃO DO CONSUMO DE ENERGIA DE UMA AGROINDÚSTRIA**

Trabalho de Conclusão de Curso de Graduação
apresentado como requisito para obtenção do título
de Bacharel em Engenharia Elétrica da
Universidade Tecnológica Federal do Paraná
(UTFPR).

Data de aprovação: 16/novembro/2022

José Airton Azevedo dos Santos
Doutorado
Universidade Tecnológica Federal do Paraná

Carlos Aparecido Fernandes
Doutorado
Universidade Tecnológica Federal do Paraná

Leandro Antonio Pasa
Doutorado
Universidade Tecnológica Federal do Paraná

MEDIANEIRA

2022

RESUMO

Este trabalho busca comparar técnicas de análise, de séries temporais, para previsão do consumo de energia elétrica de uma agroindústria, localizada no sudoeste do estado de Goiás. A base de dados apresenta uma série histórica do consumo mensal de energia no período entre janeiro/2016 e dezembro/2021, totalizando 72 observações. Modelos de previsão, de Regressão Linear (LR), Regressão do Processo Gaussiano (GPR) e Redes Neurais *Multilayer Perception* (MLP), fornecidos pelo software WEKA, foram utilizados na previsão do consumo de energia. Resultados, obtidos dos três modelos, foram comparados por meio do Erro Médio Absoluto Percentual (MAPE). Verificou-se, para um horizonte de quatro meses, que o modelo MLP apresentou, com relação aos modelos LR e GPR, um melhor desempenho.

Palavras-chave: consumo de energia; análise de séries temporais; aprendizado de máquinas; inteligência artificial.

ABSTRACT

This work seeks to compare time series analysis techniques to predict the electricity consumption of an agroindustry, located in the southwest of the state of Goiás. The database presents a historical series of monthly energy consumption in the period between January/2016 and December/2021, totaling 72 observations. Forecast models, Linear Regression (LR), Gaussian Process Regression (GPR) and Multilayer Perception Neural Networks (MLP), provided by WEKA software, were used to predict energy consumption. Results, obtained from the three models, were compared using the Mean Absolute Percentage Error (MAPE). It was verified, for a horizon of four months, that the MLP model presented, in relation to the LR and GPR models, a better performance.

Keyword: energy consumption; analysis of time series; machine learning, artificial intelligence.

LISTA DE ILUSTRAÇÕES

Figura 1 – Hierarquia do aprendizado	15
Figura 2 – Paralelo entre neurônio biológico e artificial	16
Figura 3 – Rede MLP	18
Figura 4 – Interface do software WEKA	20
Figura 5 – Boxplot dos dados de consumo	22
Figura 6 – Série histórica do consumo de energia	23
Figura 7 – Arquivo ARFF	24
Figura 8 – Interface Basic Configuraton	24
Figura 9 – Interface Advanced Configuraton	25
Figura 10 – Exemplo da fase de testes	26
Figura 11 – Exemplo de métricas na fase de testes	26
Figura 12 – Exemplo de gráfico de previsão na fase de testes	27
Figura 13 – Adjust for variance	27
Figura 14 – Consumo anual de 2016 a 2021	30
Figura 15 – Média mensal do consumo de energia	30
Figura 16 – Parâmetros – Rede Neural MLP	32
Figura 17 – Consumo (kWh) – Conjunto de validação (MLP)	33
Figura 18 – Parâmetros - Regressão Linear	34
Figura 19 – Consumo (kWh) LR – Conjunto de validação	35
Figura 20 – Parâmetros - Regressão do Processo Gaussiano	35
Figura 21 – Consumo (kWh) LR – Conjunto de validação	36
Figura 22 – Previsões MLP – Conjunto de teste	37
Figura 23 – Previsões LR – Conjunto de teste	37
Figura 24 – Previsões GPR – Conjunto de teste	38

LISTA DE TABELAS

Tabela 1 – Equações: RMSE, MAE e MAPE	28
Tabela 2 – Análise descritiva dos dados	29
Tabela 3 – Combinações das configurações para o modelo MLP	31
Tabela 4 – Melhores Combinações para o modelo MLP	32
Tabela 5 – Resultados – Métricas (MLP)	33
Tabela 6 – Resultados – Métricas (LR)	34
Tabela 7 – Resultados – Métricas (GPR)	36
Tabela 8 – Previsões do consumo (kWh), ERP (%) e MAPE (%)	37

LISTA DE ABREVIATURAS E SIGLAS

ARFF	<i>Attribute-Relation File Format</i>
CCEE	Câmara de Comercialização de Energia Elétrica
GPL	<i>General Public License</i>
GPR	A Regressão do Processo Gaussiano
LR	Regressão Linear
MAE	Erro Absoluto Médio
MAPE	Erro absoluto Médio Percentual
MLP	Redes <i>Perceptrons</i> Multicamadas
RSME	Raiz quadrada do Erro Médio
TUSD	Tarifa do Uso do Sistema de Distribuição/Transmissão
WEKA	<i>Waikato Environment for Knowledge Analysis</i>

SUMÁRIO

1	INTRODUÇÃO	10
2	OBJETIVO	12
2.1	Objetivos específicos.....	12
3	FUNDAMENTAÇÃO TEÓRICA	13
3.1	Mercado livre de energia elétrica	13
3.2	Aprendizado de máquina	14
3.3	Redes neurais	15
3.3.1	Neurônio	15
<u>3.3.1.1</u>	<u>Topologia.....</u>	<u>17</u>
<u>3.3.1.2</u>	<u>Redes <i>perceptrons</i> de multicamadas</u>	<u>17</u>
<u>3.3.1.3</u>	<u>Treinamento</u>	<u>18</u>
3.4	Regressão linear (LR)	18
3.5	Regressão do processo gaussiano (GPR)	19
3.6	WEKA	19
4	METODOLOGIA	21
4.1	A empresa	21
4.2	Base de dados	21
4.3	Etapas do trabalho	23
4.4	Arquivo de dados	23
4.5	Aba <i>forecast</i>	24
4.6	Ajustar variações nos dados de entrada.....	27
4.7	Métricas	28
5	RESULTADOS E DISCUSSÃO	29
5.1	Análise descritiva de dados	29
5.2	Redes neurais (MLP)	31
5.3	Regressão linear (LR)	33
5.4	Regressão do processo gaussiano (GPR)	35
5.5	Conjunto de teste	36
6	CONCLUSÕES	39
	REFERÊNCIAS.....	40

1 INTRODUÇÃO

Previsões, baseadas na avaliação do histórico de consumo de energia elétrica, podem servir como base para o contrato de demanda de energia elétrica e trazer vários benefícios como: alinhar as necessidades reais de consumo a demanda contratada, evitar a cobrança de penalidades e multas por ultrapassagem do consumo demandado e manter a confiabilidade do sistema de distribuição de energia elétrica. Toda a construção do sistema de distribuição elétrica, os planos de gastos das indústrias e sua capacidade de produção são dependentes do consumo de energia (CASTRO; FERARI, 2016).

As previsões, para os consumidores do mercado livre de energia, se tornam mais importantes por se tratarem de negociações bilaterais, em que a unidade consumidora e a comercializadora de energia acordam a potência a ser contratada, o preço e os prazos (BARROS et al., 2020; PINTO, 2018).

O superdimensionamento, de um contrato de demanda de energia elétrica, pode causar desde o desprendimento de recursos em gastos desnecessários até o estouro do orçamento. Já um contrato subdimensionado pode levar a cobrança de multas e paradas do processo fabril por falta de energia. Sendo assim, projeções são um meio de fornecer informações, para tomadas de decisões, que contribuem para a continuidade do processo, garantindo tanto vantagens financeiras quanto operacionais (KAYTEZ et al., 2015). Neste sentido, os modelos de séries temporais podem ser utilizados como ferramentas de apoio no processo de tomada de decisão. Tais ferramentas são de grande importância em um sistema de planejamento, pois direcionam a melhor forma de aproveitar todos os recursos disponíveis pela empresa (PINHEIRO et al., 2020).

Diversos trabalhos utilizaram métodos de previsão, de séries temporais, para previsão do consumo de energia elétrica. Nichiforov et al. (2017) realizaram previsões do consumo de energia elétrica usando modelos ARIMA e de Redes Neurais. Wang & Meng (2012) utilizaram modelos ARIMA e de Redes Neurais Híbridas para previsão do consumo de energia elétrica da província de Hebei na China. Santos (2020), realizou previsões do consumo de energia elétrica na região Sudeste utilizando SARIMA e LSTM. Chou & Tran (2018) realizaram, por meio de técnicas de aprendizagem de máquina, previsões do consumo de energia de um prédio residencial. Já Jeihoonian et al. (2010) apresentaram uma abordagem, baseada em

Redes Neurais Artificiais, para previsão do consumo anual de energia nas indústrias de metais básicos do Irã.

Neste contexto, este trabalho tem como objetivo comparar três técnicas de análise de séries temporais, disponibilizadas pelo software WEKA, Regressão Linear, Regressão do Processo Gaussiano e Redes *Perceptron* Multicamada, para previsão do consumo de energia elétrica de uma agroindústria localizada no sudoeste do estado de Goiás.

2 OBJETIVO

O objetivo deste trabalho é comparar técnicas de análise de séries temporais, disponibilizadas pelo software WEKA, para previsão do consumo de energia elétrica de uma agroindústria localizada no sudoeste do estado de Goiás.

2.1 Objetivos específicos

Os objetivos específicos, descritos abaixo, são propostos para que o objetivo geral possa ser alcançado.

- Obter e tratar os dados históricos de consumo de energia elétrica da agroindústria;
- Conhecer e trabalhar com o software WEKA, utilizando a ferramenta de previsão e os algoritmos de aprendizagem;
- Desenvolver modelos de previsão com base em Regressão Linear, Regressão do Processo Gaussiano e Redes Neurais Artificiais;
- Validar os modelos gerados através da avaliação do erro médio absoluto, da raiz do erro quadrático médio e do erro absoluto médio percentual;
- Comparar os modelos desenvolvidos e identificar, por meio do erro absoluto médio percentual, qual deles tem melhor desempenho.

3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, para uma melhor compreensão, do mercado livre de energia elétrica e das ferramentas de previsão, serão apresentados os conceitos mais importantes relacionados a esses temas.

3.1 Mercado livre de energia elétrica

Majoritariamente o fornecimento de energia elétrica é feito pelas distribuidoras de energia. Entretanto, o mercado atual permite que sejam parcialmente desvinculados os aspectos técnicos dos comerciais. O resultado dessa possibilidade é que, apesar da unidade consumidora estar fisicamente conectada à rede concessionada pela distribuidora, o contrato de energia pode ser realizado por outra empresa (BARROS et al., 2020).

As comercializadoras foram criadas, em detrimento da mudança ocorrida no setor elétrico, na década de 90. Onde, em conjunto com as empresas de geração de energia elétrica, passaram a atuar, no mercado livre, baseado na oferta e demanda de consumo (BARROS et al., 2020; PINTO, 2018).

Desde 2004, a Câmara de Comercialização de Energia Elétrica (CCEE) cumpre o papel de controle e viabilização das transações ocorridas no mercado livre de energia. As funções da CCEE vão desde: manter e registrar contratos de fornecimento de energia, medir e registrar a potência gerada, a transmissão e o consumo, até a investigação de possíveis descumprimentos de contrato, sendo de sua responsabilidade aplicar as penalidades cabíveis (BARROS et al., 2020).

É estabelecido pela Lei nº 9.704 que as unidades consumidoras com demanda contratada acima de 500 kW podem optar pela compra de energia no mercado livre. Ao fazer isso, a unidade poderá adquirir a energia diretamente com um gerador, ou através de uma comercializadora. Mesmo não sendo responsável pela entrega da potência contratada pela unidade consumidora, a distribuidora tem a responsabilidade de manter a integridade da rede, ou seja, mantê-la em condições para que o fornecimento de energia seja garantido para o consumidor. Por esse motivo, as distribuidoras continuam a ser remuneradas pela Tarifa do Uso do Sistema de Distribuição/Transmissão (TUSD) (BARROS et al., 2020; ANTONIOLLI, 2021).

Por sofrer alterações, baseadas na oferta e demanda de energia elétrica, o custo pode ter variações à curto prazo. Uma forma da unidade consumidora se proteger destas variações é realizar um contrato de longo prazo com a comercializadora, firmando o valor a ser pago durante o intervalo definido (BARROS et al., 2020).

A definição do sistema de medição, feito pela concessionária local, deve seguir a padronização da CCEE e do Operador Nacional do Sistema Elétrico. A CCEE define que o medidor de energia deve conter um acesso exclusivo de telecomunicação para que possa acessar remotamente os dados, e, assim, compará-los com a demanda contratada. Para a diferença entre valor da demanda contratada e da demanda real, a CCEE define que a unidade execute a venda no mercado de curto prazo, caso o montante seja maior que o contratado, ou a compra, quando se ultrapassa o valor do montante contratado. O preço da energia no mercado de curto prazo é definido pela CCEE, sendo denominado de Preço de liquidação das Diferenças (BARROS et al., 2020).

3.2 Aprendizado de máquina

O Aprendizado de Máquina, subárea da Mineração de Dados, concentra-se no desenvolvimento de modelos que possam “aprender” por meio de experiências. Nesta subárea são introduzidos algoritmos dedutivos que extraem regras e padrões em grandes quantidades de dados.

Os algoritmos de aprendizagem de máquina dividem-se de acordo com o problema que buscam resolver. Dentre eles, pode-se destacar:

Classificação: o objetivo, na classificação, é identificar a qual categoria determinada imagem ou conjunto de dados pertence.

Regressão: neste caso, procura-se estimar um valor numérico e não uma categoria ou rótulo.

O aprendizado pode ser dividido em duas categorias, o aprendizado supervisionado e não supervisionado. Neste trabalho foi utilizado o aprendizado supervisionado. Na abordagem supervisionada, o algoritmo aprende a executar determinada tarefa a partir de resultados conhecidos (SCARAVONATTI, 2015).

A Figura 1 apresenta a hierarquia do aprendizado. Nela pode ser observado que, partindo do Aprendizado Indutivo, há duas ramificações, Aprendizado

Supervisionado e Aprendizado Não-Supervisionado. Tanto a Classificação, quanto a Regressão são oriundas do Aprendizado Supervisionado.

Figura 1 – Hierarquia do aprendizado



Fonte: Scaravonatti (2015)

3.3 Redes neurais


Modelos computacionais baseados no sistema biológico de aprendizado, são chamadas de Redes Neurais Artificiais. Replicam o funcionamento do cérebro humano, onde várias células simples conectadas têm a capacidade memorizar, entender e assimilar informações (PINHEIRO et al., 2020; BASTIANI et al., 2018).

3.3.1 Neurônio

Comumente os neurônios apresentam três partes: o corpo celular, dendritos e axônio. Os dendritos são extensões do neurônio que cumprem o papel de receptores de estímulos, eles levam os impulsos nervosos até o corpo celular. Um pulso elétrico, para sinais significativos, é transmitido ao axônio e por sinapse esse sinal é repassado para outros neurônios (COPPIN, 2010).

O neurônio artificial é composto por entradas, que simulam os dendritos, unidades de processamento, que agem como o corpo celular, e saídas que desempenham o papel do axônio. O paralelo entre os modelos biológico e artificial estão representados na Figura 2.

Figura 2 – Paralelo entre neurônio biológico e artificial



Fonte: Adaptado de JavaTpoint (2020)

As diversas entradas são recebidas pelo neurônio, e cada entrada é recebida por uma conexão, chamada de peso. Para se constituir a função de ativação do neurônio é realizada a soma ponderada das entradas (x_n). Sendo que cada uma das entradas é multiplicada pelo seu respectivo peso (W_n) (SILVA, 2015). Na Equação 1 representa-se a configuração da função de ativação.

$$f = W_1x_1 + W_2x_2 + \dots + W_nx_n \quad (1)$$

Pode-se utilizar, como função de ativação, várias funções matemáticas. Dentre elas pode-se citar a: Identidade, Logística, Sigmoides, Exponencial, Tangente hiperbólica, entre outras.

3.3.1.1 Topologia

As características de uma rede neural influenciarão no sucesso dos resultados obtidos. Podem ser variados a quantidade de neurônios, o número de camadas, as funções de ativação, os pesos iniciais, o número de iterações que serão realizadas e qual será o algoritmo de aprendizado (OGCU et al., 2012).

O direcionamento das conexões sinápticas definirá a forma em que os neurônios serão dispostos, formando a arquitetura da rede neural. Dada uma arquitetura, diferentes composições da estrutura formarão a topologia da rede. Três classes, fundamentalmente distintas de arquitetura, de acordo com Haykin (2001), são:

- Redes de camada única, alimentadas adiante;
- Redes de camadas múltiplas alimentadas adiante;
- Redes cíclicas.

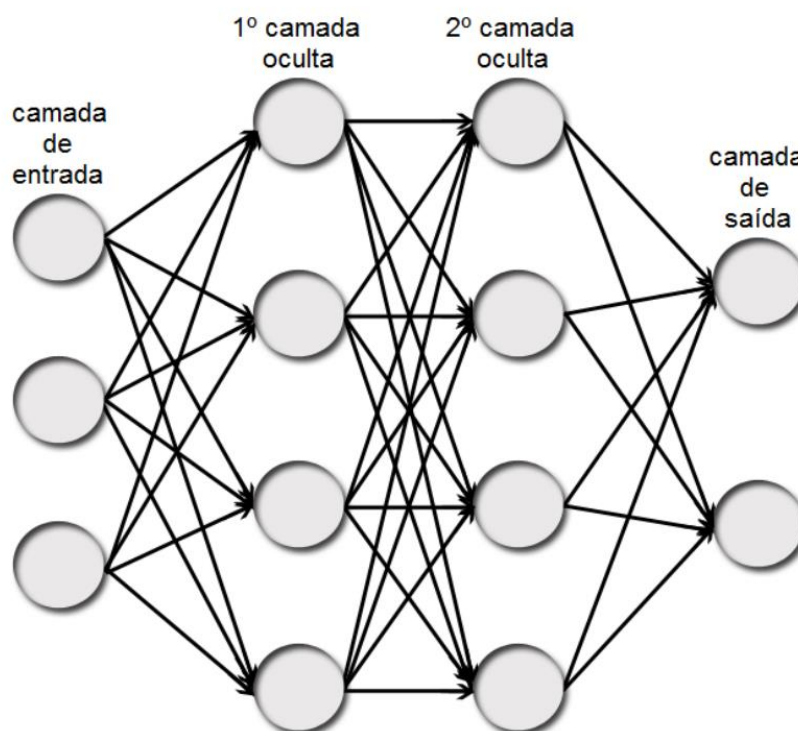
A definição da topologia da rede deve levar em consideração a complexidade do caso a ser mapeado e a qualidade e quantidade de dados disponíveis. No caso das redes de camadas múltiplas alimentadas adiante, pode ser definido o número de camadas escondidas, podendo ser uma ou mais, e a quantidade de neurônios de cada camada (HAYKIN, 2001; SILVA et al., 2010).

3.3.1.2 Redes *Perceptrons* de Multicamadas

As redes *Perceptrons* multicamadas (*multilayer perceptron* – MLP) são principalmente utilizadas em casos que envolvem aproximação funcional e sistemas variáveis no tempo. 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 (HAYKIN, 2001; SILVA et al., 2010).

A rede MLP, apresentada na Figura 3, é composta de três entradas e duas saídas. Também há duas camadas ocultas com quatro neurônios cada. Nas camadas ocultas realizam-se combinações não-lineares em relação às entradas e seus pesos. Servem também para transmitir a informação para a camada de saída. Para casos mais complexos é comum utilizarem-se um número maior de camadas ocultas com vários neurônios em cada uma delas.

Figura 3 – Rede MLP



Fonte: Pinheiro (2020)

3.3.1.3 Treinamento

A aprendizagem por retropropagação (*backpropagation*) é o algoritmo de treinamento mais comum no caso da MLP. A ideia do algoritmo *backpropagation* é, com base no cálculo do erro ocorrido na camada de saída da rede neural, recalculando o valor dos pesos da última camada de neurônios e assim proceder para as camadas anteriores, de trás para frente, ou seja, atualizar todos os pesos W , até o erro diminuir e chegar abaixo de algum limiar preestabelecido, ou o número de iterações atingirem um valor máximo, quando enfim o algoritmo termina e a rede está treinada (HAYKIN, 2009).

3.4 Regressão linear (LR)

A modelagem matemática da regressão linear consiste em representar uma saída como combinação linear de parâmetros com pesos pré-definidos. Na Equação 2 a classe é representada por y ; os parâmetros são representados por a_1, a_2, \dots, a_n ; e os pesos são representados por w_0, w_1, \dots, w_n . O cálculo dos valores que serão

atribuídos aos pesos é feito a partir dos dados de treinamento (WITTEN et al., 2016; CASTRO, FERRARI 2016; CURRAL, 1994; HOFFMANN, 2006).

$$y = W_1a_1 + W_2a_2 + \dots + W_na_n \quad (2)$$

3.5 Regressão do processo gaussiano (GPR)

Parte dos modelos e métodos estatísticos são fundamentados na distribuição normal. Isto porque, em problemas reais, é matematicamente simples de aplicar. E quando existir, no problema em estudo, um grande número de variáveis o método de distribuição pode ser estendido. A Regressão do Processo Gaussiano (GPR) é um método Bayesiano de regressão, constituído pela extensão da distribuição Gaussiana multivariada (RASMUSSEN, WILLIAMS, 2006).

Em *machine learning*, a GPR é um dos métodos que pode ser utilizado para se modelar matematicamente uma função a partir de variáveis reais. Esta técnica vem aumentando de popularidade nos últimos anos e está sendo bastante utilizada para previsões de séries temporais. Baseia-se no ajuste de funções aos dados (Regressão). Segundo Acosta & Amoroso (2020) a GPR consiste em estimar uma função para entradas arbitrárias, dada um conjunto *a priori* de treinamento.

Segundo Rasmussen e Williams (2006), é desejável que tenhamos informação prévia detalhada da base de dados para que seja possível especificar as funções de covariância. Cabral (2021), complementa que escolher a função de covariância do processo gaussiano ditará as propriedades do processo em si, e a relevância que terão para a modelagem da GPR. Contudo, não é comum que exista uma informação tão detalhada para os casos de aplicação em aprendizagem de máquina, sendo assim, é necessário que sejam escolhidas entre diferentes funções de covariância de acordo com os dados. Esse processo pode ser chamado de treinamento do modelo GPR (RASMUSSEN, 2004).

3.6 WEKA

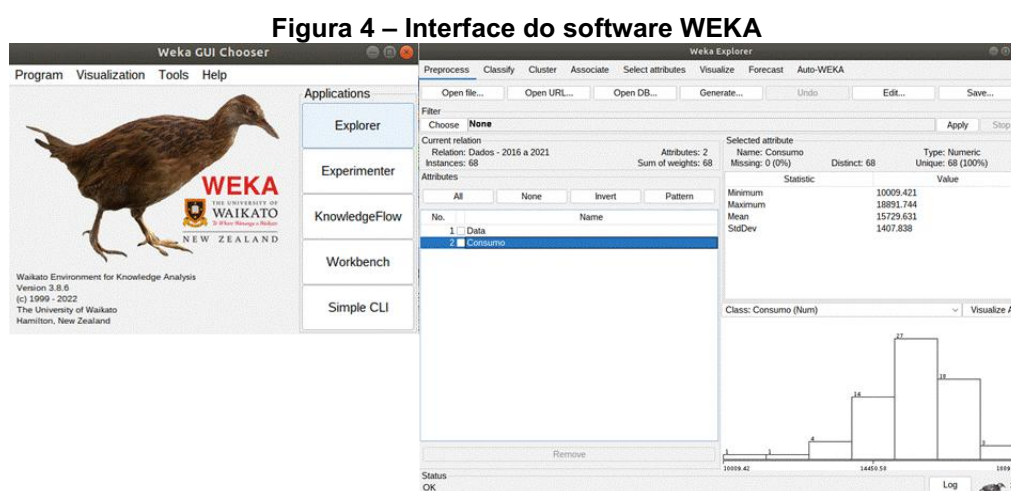
O WEKA (*Waikato Environment for Knowledge Analysis* – Ambiente para Análise de Conhecimento Waikato, em tradução livre) é um *software* livre que consta com diversos algoritmos de aprendizado de máquina e ferramentas de processamento

de dados (WEKA3, 2016). O software foi desenvolvido pela universidade de Waikato (Nova Zelândia). Foi implementado por meio da linguagem Java, sendo distribuído sob os termos da *General Public License* (GPL) e pode ser implementado nos sistemas operacionais Linux, Windows ou Macintosh.

Das diversas funcionalidades que o WEKA possui, Witten et al. (2016) aponta as três principais formas em que pode ser utilizado:

- Para aplicar métodos de aprendizagem, analisar as saídas e coletar informações;
- Para utilizar modelos de aprendizagem para prever casos novos;
- Para comparar a performance entre diferentes métodos de aprendizagem.

A Figura 4 apresenta a página inicial e a interface de trabalho do programa. O software possui uma interface simples, em que o usuário pode comparar e escolher diferentes tipos de métodos e escolher o mais adequado para solução do seu problema (BANDEIRA, 2015).



Fonte: Autoria Própria (2022)

4 METODOLOGIA

A metodologia utilizada, neste estudo, pode ser considerada como (GIL, 2010, ANTONIOLLI, 2021):

Aplicada - uma vez que busca soluções a problemas específicos, gerando conhecimentos para aplicação prática;

Descritiva - pois descreve as características de uma determinada população, procurando detectar potenciais relações entre as variáveis;

Quantitativa - quanto a forma de abordar o problema, por que enfatiza o raciocínio dedutivo, lógico e argumentos mensuráveis.

4.1 A Empresa

A empresa localizada na região sudoeste do Estado de Goiás, atua no ramo alimentício. Constatou-se, com base em dados coletados junto com a empresa, que a segunda maior despesa da unidade está relacionada à contratação de energia elétrica, atrás somente das despesas com o quadro de funcionários.

Os processos, do frigorífico da unidade, consistem no recebimento de aves e suínos, abate, congelamento e armazenamento. A unidade produz cortes de frango, cortes de suínos, também alimentos embutidos, empanados e linguiças.

Existem no mesmo parque fabril uma fábrica de farinha e gordura animal, fábrica de rações e um centro de distribuição.

Observou-se, da mesma maneira que o trabalho de Frozza (2013), que a geração de frio, composta pelos compressores, torres de resfriamento e túneis de congelamento, são os maiores consumidores de energia elétrica.


O atendimento de energia elétrica da unidade é feito em 138kV, devido à dimensão do parque fabril e seus diversos processos. Este modelo de alimentação se faz vantajoso, pois a tarifa da distribuidora é menor tanto para demanda como para o consumo (BARROS et al, 2020).

4.2 Base de dados

Utilizou-se, para previsão do consumo de energia elétrica, uma base de dados com 72 meses (Jan/2016 - Dez/2021), obtida da agroindústria em estudo. Os dados obtidos, da base de dados, são apresentados, na Figura 5, na forma de *boxplot*.

No *boxplot* pode ser observado que há uma variabilidade entre 475.000kwh e 575.000kwh no consumo diário de energia. Há pontos discrepantes abaixo do mínimo, que podem indicar finais de semana e dias não produtivos, e pontos discrepantes acima do máximo, que podem indicar dias atipicamente quentes, onde há demanda de maior consumo de energia para geração de frio. Estes pontos discrepantes são chamados *outliers*. Também é possível observar a mediana, representada pela linha no interior do retângulo, de consumo de energia diário na faixa de 520.000kwh.


Figura 5 – Boxplot dos dados de consumo



Fonte: Aatoria Própria (2022)

A série histórica obtida da agroindústria é apresentada na Figura 4. Os pontos de maior consumo evidenciam a sazonalidade de consumo de energia elétrica, que, em função da variação de temperatura na região, se torna maior em épocas quentes. E pontos de menor consumo, que são resultado do consumo menor de energia em estações mais frias. Também pode ser observado, na Figura 4, uma discrepância no mês de março de 2020, causado pela parada da fábrica devido ao início da pandemia de Covid-19.

Figura 6 – Série histórica do consumo de energia



Fonte: Autoria Própria (2022)

4.3 Etapas do trabalho

Para comparar os modelos de Regressão Linear (LR), Regressão do Processo Gaussiano (GPR) e Redes Neurais (MLP) foram realizadas, neste trabalho, três etapas:

1. Coleta e análise de dados: Inicialmente, na primeira etapa, foi realizada uma análise exploratória dos dados obtidos da agroindústria;
2. Treinamento e Validação: Na segunda etapa, treinamento e validação, foram selecionados, por meio de métricas, os melhores modelos MLP, GPR e LR;
3. Teste: Na última etapa, etapa de teste, foram testados os modelos para dados que não participaram da etapa de treinamento e validação (Setembro, Outubro, Novembro e Dezembro de 2021).

4.4 Arquivo de dados

O WEKA trabalha com arquivos no formato ARFF (*Attribute-Relation File Format*). O ARFF é um arquivo texto contendo um conjunto de observações, precedido por um pequeno cabeçalho (Figura 7). O cabeçalho é utilizado para fornecer informações a respeito dos campos que compõem o conjunto de observações. Neste cabeçalho os atributos são declarados, que podem ser *numeric*, *date* ou *string*. Na segunda parte do arquivo se localizam os dados, que são estruturados de acordo com as declarações da primeira seção e são separados por vírgula (SOUZA, 2021).

Figura 7 – Arquivo ARFF

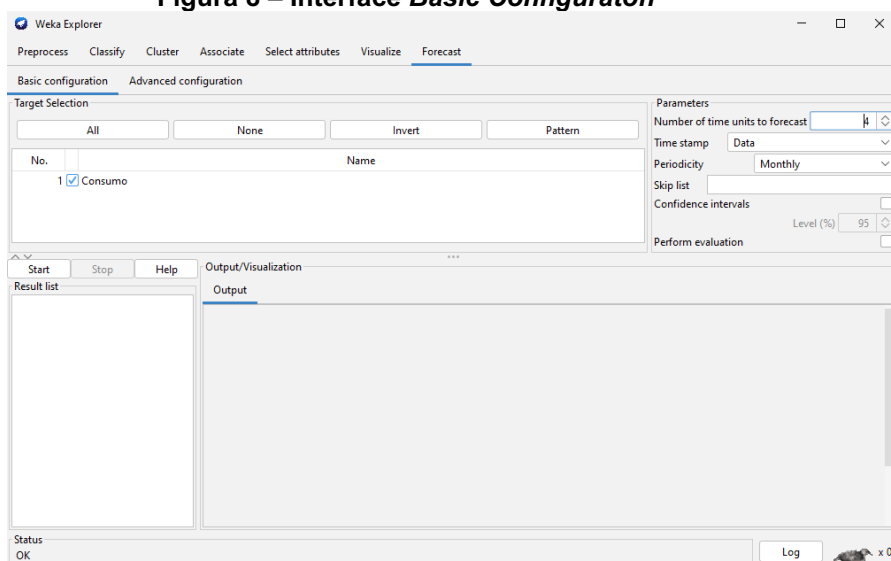
```
@relation 'Dados - 2016 a 2021'
@attribute Data date "MM-yyyy"
@attribute Consumo numeric

@data
1-2016,508970.3452
2-2016,520071.9117
3-2016,519863.6265
4-2016,392082.7157
5-2016,430716.5671
6-2016,529070.1017
7-2016,481809.5871
8-2016,485678.2626
9-2016,452098.5243
```

Fonte: Aatoria Própria (2022)

4.5. Aba *forecast*

Ao entrar na aba *Forecast* do WEKA, são disponibilizadas as áreas *Basic Configuration* e *Advanced Configuration*. Na área *Basic Configuration* (Figura 8), na seção *Parameters*, conforme Antonioli (2021), podem ser configuradas as variáveis relacionadas às unidades de tempo e avaliação da previsão. O *Number of time units to forecast* controla o horizonte de previsão, que no caso deste trabalho será de 4 meses. O *Time stamp* deve ser configurado para que os dados tenham rótulo do tipo *datas*. Para o campo *Periodicity* será cadastrado mensal. Sendo, que neste estudo, as caixas *Confidence intervals* e *Performe evaluation* não devem ser acionadas.

Figura 8 – Interface *Basic Configuraton*

Fonte: Aatoria Própria (2022)

Na área *Advanced Configuration* foram utilizadas as seguintes abas (Figura 9):

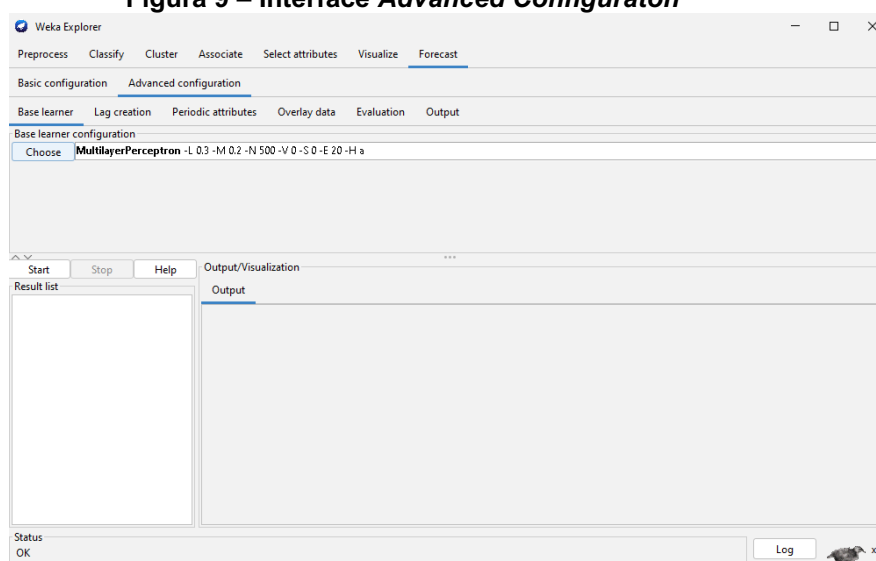
Base learner: Esta aba fornece diferentes bases de aprendizagem. Neste trabalho foram utilizados as bases de Regressão Linear (LR), Regressão do Processo Gaussiano (GPR) e Redes Neurais Artificiais (MLP).

Lag creation: As variáveis defasadas são o principal mecanismo pelo qual a relação entre os valores passados e atuais de uma série pode ser capturada por algoritmos de aprendizado. Ele cria uma "janela" ao longo de um período. Neste trabalho foi utilizada uma janela de 12 meses.

Evaluation: Nesta aba são selecionadas as métricas de avaliação. Neste estudo serão utilizadas as métricas MAE (*Mean Absolute Error*), RSME (*Root Mean Squared Error*) e MAPE (*Mean Absolute Percent Error*). Configura-se também, nesta aba, a porção dos dados que foi utilizada no conjunto de validação.

Observa-se que, neste trabalho, não serão utilizadas as abas *Periodic attributes* e *Overlay data*.

Figura 9 – Interface *Advanced Configuration*



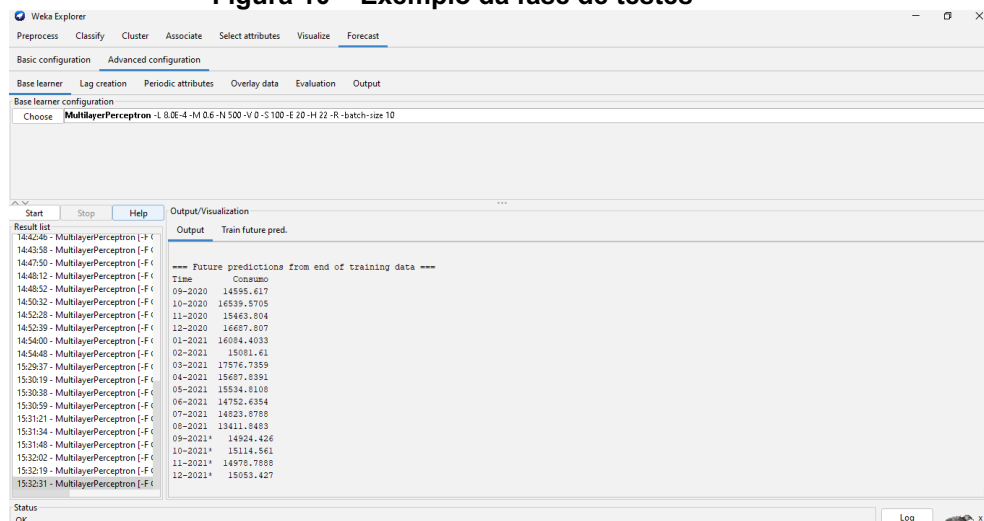
Fonte: Autoria Própria (2022)

Na fase de testes é possível se realizar a configuração e ajuste dos parâmetros. Definidos os parâmetros, os resultados dos testes são exibidos na janela *Output/Visualization* após ser pressionado o *Start*.

Na Figura 10 é exemplificado um teste para a rede MLP, utilizando-se um período de 12 meses. Os últimos 4 meses, evidenciados por asterisco, consta o resultado da previsão obtida através dos parâmetros utilizados na fase de testes. Os

resultados realizados nos testes anteriores podem ser vistos na janela *Result list* mostrada ao lado esquerdo, e comparados ao resultado mais recente com o intuito de se encontrar o melhor modelo.

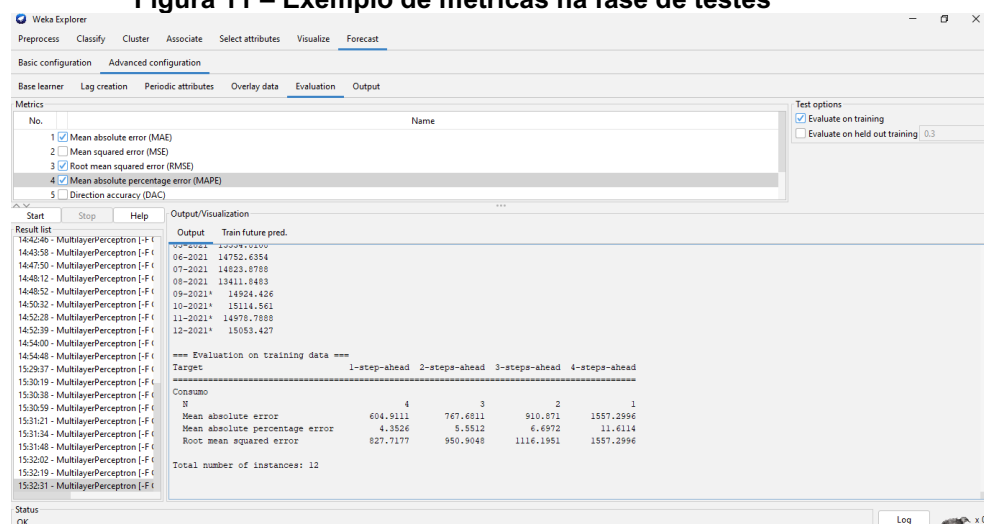
Figura 10 – Exemplo da fase de testes



Fonte: Autoria própria (2022)

As métricas definidas na aba *Evaluation* também podem ser observadas na janela *Output*, desde que na aba seja marcada a caixa *Evaluate on training*. Estas métricas ficam disponíveis abaixo do resultado da previsão, como mostra a Figura 11.

Figura 11 – Exemplo de métricas na fase de testes




Fonte: Autoria própria (2022)

Também na janela *Output/Visualization* pode observar-se um gráfico contendo os valores utilizados para treinamento, e a previsão realizada com o método escolhido.

Para se visualizar o gráfico, seleciona-se a opção *Train future pred.* Um dos gráficos obtidos na utilização do conjunto de testes pode ser contemplado na Figura 12.

Figura 12 – Exemplo de gráfico de previsão na fase de testes



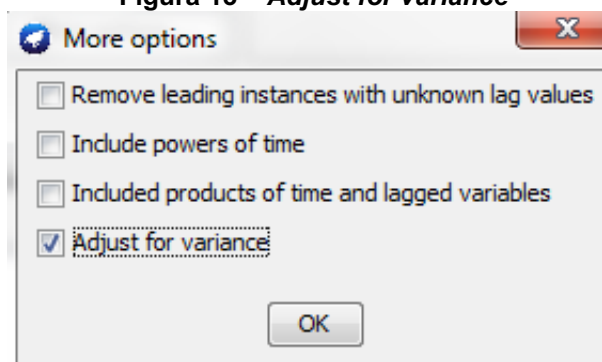
Fonte: Autoria própria (2022)

4.6 Ajustar variações nos dados de entrada

Na janela *More options*, mostrada na Figura 13, do menu *Lag creation* existem caixas de seleção para ajustar a variação nos dados de entrada. A opção *Ajustar para variação (Adjust for variance)* permite ao usuário optar por fazer com que o sistema compense a variação nos dados.

Segundo Santos et al. (2019) o ajuste de variância, para o conjunto de dados de entrada, pode, ou não, melhorar o desempenho dos algoritmos. No caso específico do modelo LR, verificou-se que o ajuste diminui os resultados das métricas, então decidiu-se adotá-lo.

Figura 13 – Adjust for variance



Fonte: Autoria Própria (2022)

4.7 Métricas

Os modelos de Redes Neurais Artificiais, Regressão do Processo Gaussiano (GPR) e Regressão Linear serão avaliados por meio das métricas (CANKURT; SUBASI, 2015; BASTIANI et al., 2018; PINHEIRO et al., 2020):

- **RSME (Root Mean Squared Error):** A métrica RMSE penaliza mais os erros maiores, permite avaliar a qualidade de um previsor em relação aos dados.
- **MAE (Mean Absolute Error):** Como o RMSE, o MAE possui dimensão igual à dimensão dos valores observados e preditos. Seu valor representa o desvio médio entre observado e predito.
- **MAPE (Mean Absolute Percent Error):** O MAPE mede o tamanho do erro em termos percentuais.

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

Tabela 1 – Equações: RMSE, MAE e MAPE

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

Fonte: Santos (2021)

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

5 RESULTADOS E DISCUSSÃO

Este capítulo tem como objetivo apresentar os resultados obtidos ao longo deste trabalho. Inicialmente, fez-se uma breve análise dos dados obtidos da agroindústria. Na sequência foram realizados testes empregando algoritmos, fornecidos pelo software WEKA, de Regressão Linear, Regressão do Processo Gaussiano (GPR) e Redes Neurais *Multilayer Perception* (MLP).

5.1 Análise descritiva de dados

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


Tabela 2 – Análise descritiva dos dados

Resumo Descritivo	Consumo
Quantidade	72
Média (kWh)	516.070,96
Mínimo (kWh)	333.647,37
Máximo (kWh)	609.411,11
Desvio Padrão (kWh)	43.939,94
Coefficiente de Variação (%)	8,5

Fonte: Autoria Própria (2022)


Pode-se observar, dos dados apresentados na Tabela 2, que o consumo ficou, para o período em estudo, em média de 516.070,96 kWh. Apresentando, neste período, consumo mínimo e máximo de 333.647,37 kWh e 609.411,11 kWh. Nota-se também, da tabela, um coeficiente de variação dos dados de 8,5%, considerado baixo de acordo com Pimentel (2009). Observa-se que quanto maior o coeficiente de variação maior a variação nos dados.

Na Figura 14 apresenta-se o consumo de energia da agroindústria, de 2016 a 2021, com indicativos de crescimento do consumo até 2020. Tendo na sequência, em 2021, um decréscimo do consumo.

Figura 14 – Consumo anual de 2016 a 2021

Fonte: Aatoria Própria (2022)

A média mensal do consumo de energia, durante o período estudado, é apresentada na Figura 15. Pode-se notar, por meio desta figura, que os meses, com menor consumo, ocorrem entre abril e setembro. Observou-se também um consumo médio mínimo de 488.771,5 kWh no mês junho e um consumo médio máximo de 553.676 kWh para o mês de Março.

Figura 15 – Média mensal do consumo de energia

Fonte: Aatoria Própria (2022)

5.2 Redes neurais (MLP)

A construção dos modelos, implementados neste trabalho, explorou diferentes camadas de arquiteturas e o ajuste dos hiperparâmetros, para a rede MLP, com o objetivo de obter a melhor modelagem possível do consumo de energia da agroindústria. Assim, diferentes camadas de arquiteturas e hiperparâmetros foram avaliados. As redes neurais foram treinadas com 56 amostras e validadas com 12 amostras.

A Tabela 3 descreve as combinações, dos parâmetros avaliados, na busca pelas melhores métricas para o modelo MLP.

Tabela 3 – Combinações das configurações para o modelo MLP

Parâmetros	
Neurons	[11,22,33,66]
Layer Sizes	[1,2,3]
Batch	[5,10,15,20]
Activation	Sigmoid
Learning Rate	[0.1,0.01,0.001]
Momentum	[0.1,0.3,0.5,0.6]
Epochs	[500,1000,1500,2000]

Fonte: Autoria Própria (2022)

Onde:

Learning Rate: Indica o ritmo que os pesos são atualizados.

Epochs: É a quantidade de vezes que o conjunto de treinamento é acessado pelo algoritmo de aprendizado, para atualizar os pesos dos neurônios.

Neurons: Para trazer mais ou menos complexidade ao modelo pode-se adicionar ou remover neurônios.

Activation: A função de ativação utilizada pelos neurônios artificiais é a Sigmoid.

Batch: corresponde ao número de casos de treino que são utilizados em cada época.

Momentum: O termo *Momentum* é utilizado para ajustes nos pesos da rede. Seu valor varia entre 0 e 1.

As melhores combinações de parâmetros, definidas para o modelo MLP, são mostradas na Tabela 4.

Tabela 4 – Melhores Combinações para o modelo MLP

Parâmetros	
Neurons	22
Layer Sizes	1
Batch	10
Activation	Sigmoid
Learning Rate	0.001
Momentum	0.5
Epochs	500

Fonte: Autoria Própria (2022)

Na Figura 16 apresentam-se os parâmetros de entrada do modelo MLP do WEKA.

Figura 16 – Parâmetros – Rede Neural MLP

weka.classifiers.functions.MultilayerPerceptron

About

A classifier that uses backpropagation to learn a multi-layer perceptron to classify instances. [More](#) [Capabilities](#)

GUI

autoBuild

batchSize 10

debug

decay

doNotCheckCapabilities

hiddenLayers a

learningRate 0.001

momentum 0.5

nominalToBinaryFilter

normalizeAttributes

normalizeNumericClass

numDecimalPlaces 2

reset

resume

seed 0

trainingTime 500

validationSetSize 0

validationThreshold 20

Open... Save... OK Cancel

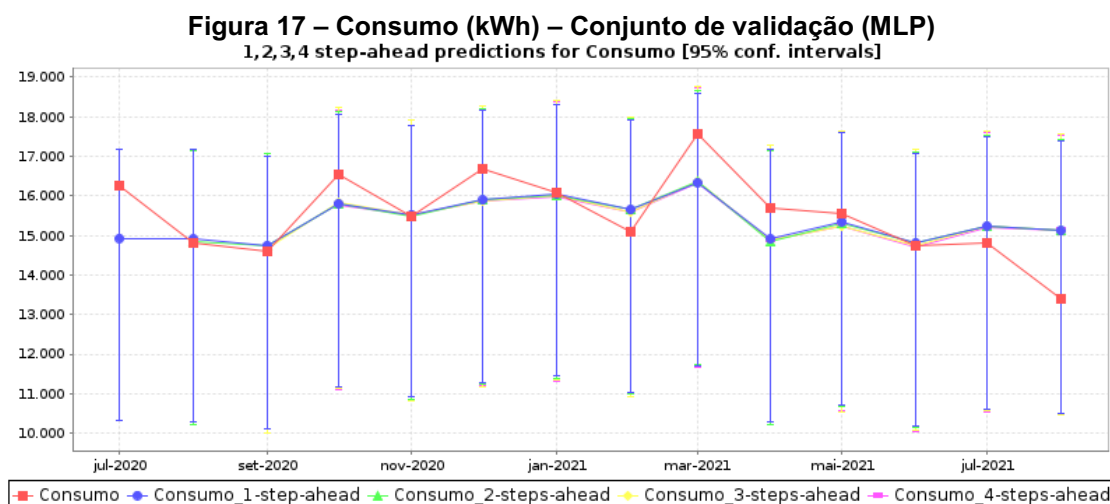
Fonte: Autoria Própria (2022)

Os resultados das métricas, para esta combinação de parâmetros, são apresentados na Tabela 5.

Métricas	MLP
MAE (kWh)	574,387575
MAPE (%)	3,77235
RSME (kWh)	766,5113

Fonte: Autoria Própria (2022)

A Figura 17 apresenta os resultados obtidos, pela rede MLP, para o conjunto de validação, considerando um intervalo de confiança de 95%.

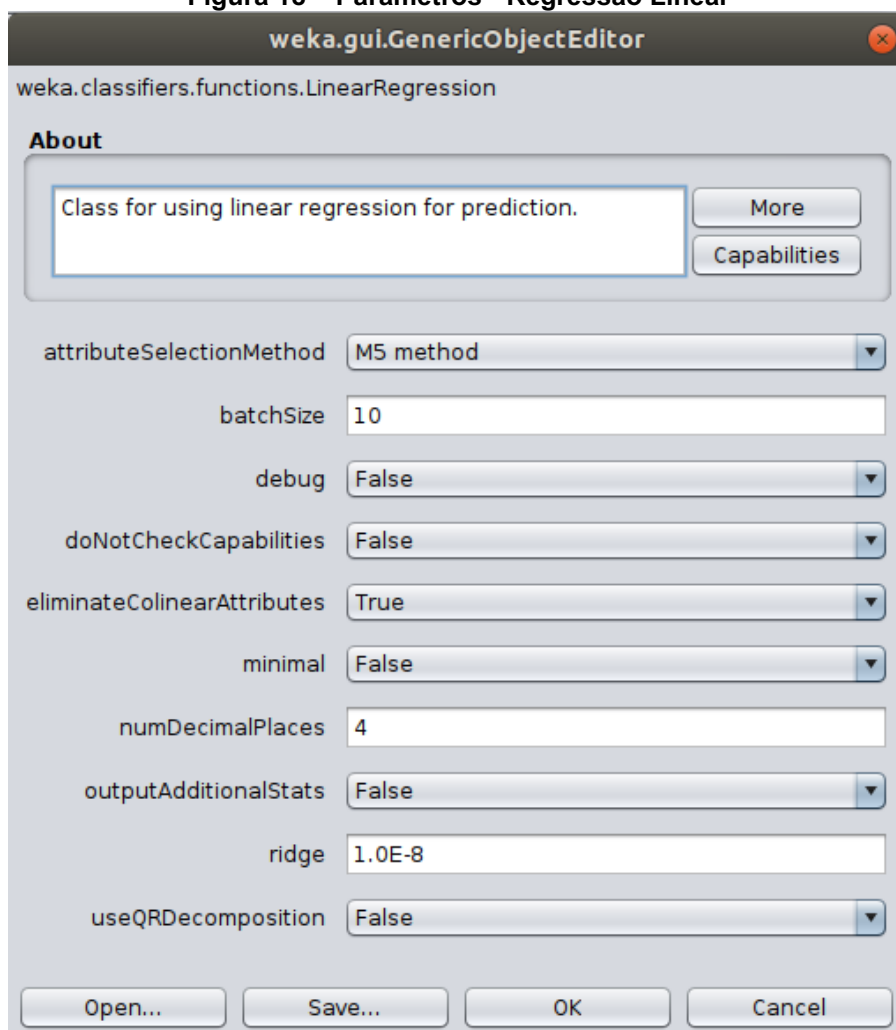


Fonte: Autoria Própria (2022)

5.3 Regressão linear (LR)

O WEKA utiliza, para o modelo de Regressão Linear, a técnica de regularização de *Ridge*. Esta técnica é utilizada para reduzir a complexidade da aprendizagem do modelo. Neste trabalho foram avaliados os parâmetros de *Ridge* 1×10^{-12} , 1×10^{-8} e 1×10^{-4} . As métricas MAE, MAPE e RSME, para estes valores, apresentaram, no conjunto de validação, resultados muito próximos. Portanto, utilizou-se, para o modelo de regressão linear, os seguintes parâmetros (Figura 18):

Figura 18 – Parâmetros - Regressão Linear



Fonte: Autoria Própria (2022)

Os resultados das métricas, para esta combinação de parâmetros, são apresentados na Tabela 6. Observa-se que para o modelo LR utilizou-se do ajuste de variância para o conjunto de dados de entrada.


Tabela 6 – Resultados – Métricas (LR)

Métricas	Validação
MAE (kWh)	25453,2
MAPE (%)	5,2
RSME (kWh)	35284,6

Fonte: Autoria Própria (2022)

A Figura 19 apresenta os resultados obtidos, pela regressão linear (LR), para o conjunto de validação, considerando um intervalo de confiança de 95%.

Figura 19 – Consumo (kWh) LR – Conjunto de validação
1,2,3,4 step-ahead predictions for Consumo [95% conf. intervals]

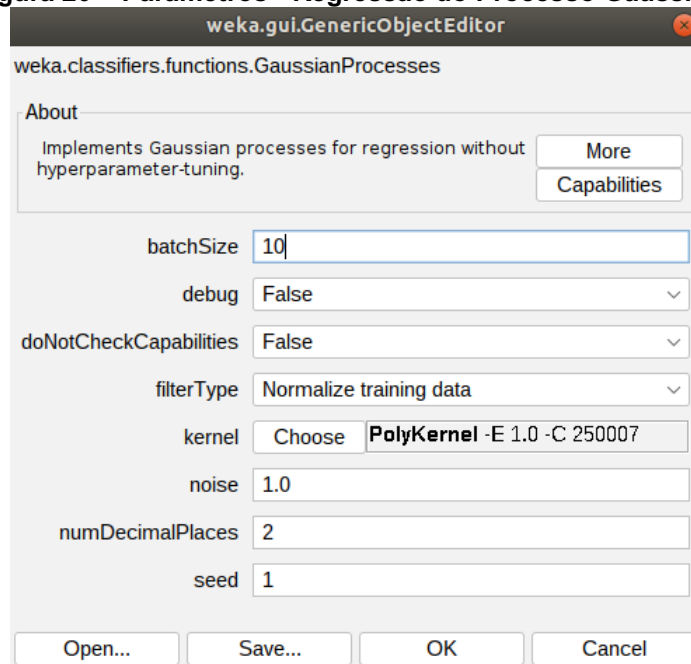


Fonte: Autoria Própria (2022)

5.4 Regressão do processo gaussiano (GPR)


Para Regressão de Processo gaussiano utilizou-se, neste trabalho, os parâmetros apresentados na Figura 20.

Figura 20 – Parâmetros - Regressão do Processo Gaussiano



Fonte: Autoria Própria (2022)

A Figura 21 apresenta os resultados obtidos, pela regressão do processo gaussiano para o conjunto de validação, considerando um intervalo de confiança de 95%.



Os resultados das métricas, para esta combinação de parâmetros, são apresentados na Tabela 7.

Tabela 7 – Resultados – Métricas (GPR)

Métricas	Validação
MAE (kWh)	629,46
MAPE (%)	4,08
RSME (kWh)	770,2

Fonte: Autoria Própria (2022)

5.5 Conjunto de teste

Na Tabela 8 apresentam-se os dados, observados, preditos, os Erros Relativos Percentuais (ERP) e o MAPE, para os quatro meses que não participaram da etapa de treino e teste. O ERP é obtido por meio da equação 3:

$$ERP = \left| \frac{Observado - Predito}{Observado} \right| \times 100 \quad (3)$$

Tabela 8 – Previsões do consumo (kWh), ERP (%) e MAPE (%)


Real	MLP	EPR-MLP	LR	ERP-LR	GPR	ERP-GPR
14937,45	14677,302	1,7415734	13835,09	7,379859	14014,72	6,177284
15473,02	15569,966	0,6265207	14924,21	3,546901	15415,67	0,370642
14956,36	15313,146	2,3854955	14945,82	0,070471	14950,09	0,041973
15579,22	15434,878	0,926526	14884,33	4,460392	15137,43	2,835772
	MAPE=	1,4200289	MAPE=	3,864406	MAPE=	2,356418

Fonte: Autoria Própria (2022)

Nas Figuras 22, 23 e 24 apresentam-se, para as três técnicas, as previsões para os meses de setembro, outubro, novembro e dezembro de 2021.

Figura 22 – Previsões MLP – Conjunto de teste


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



Fonte: Autoria Própria (2022)

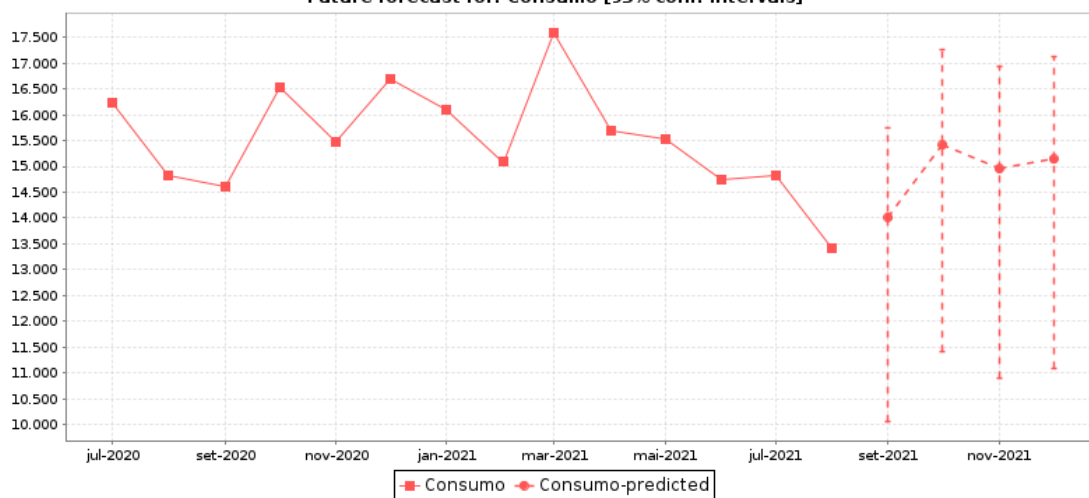
Figura 23 – Previsões LR – Conjunto de teste

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



Fonte: Autoria Própria (2022)

Figura 24 – Previsões GPR – Conjunto de teste
 Future forecast for: Consumo [95% conf. intervals]



Fonte: Autoria Própria (2022)

Por meio dos resultados apresentados, na Tabela 8, conclui-se que os resultados das previsões, dos três modelos, estão próximos aos fornecidos pela agroindústria. Contudo, o modelo MLP apresenta um MAPE menor que os modelos LR e GPR (MAPE-MLP= 1,42%%, MAPE-LR= 3,86% e MAPE-GPR=2,35%).

6 CONCLUSÕES

Neste trabalho abordou-se a aplicação de três algoritmos, de previsão de séries temporais do software WEKA, na previsão futura do consumo de energia elétrica em uma agroindústria, localizada no estado de Goiás. Os modelos passaram pelas fases de: preparação de dados, definição das estruturas, estimativas, avaliação dos resultados e validação.

Inicialmente, realizou-se a validação dos modelos MLP, GPR e LR. Na sequência, observou-se, para os meses que não participaram do treinamento da rede (setembro, outubro, novembro e dezembro de 2021), que as previsões foram bem precisas e as diferenças entre valores reais e preditos foram pequenas. Portanto, a proximidade entre valores preditos e reais demonstram a boa capacidade de generalização, para um horizonte de curto prazo, dos modelos utilizados neste trabalho. Não obstante, observou-se uma superioridade na qualidade do ajuste do modelo MLP.

Por fim, pode-se observar que os três modelos são válidos e podem auxiliar, os gerentes da agroindústria, no processo de tomada de decisão.

Para trabalhos futuros, sugere-se a aplicação, para previsão do consumo de energia elétrica da agroindústria, de redes neurais híbridas, tais como a LSTM-CNN e a CNN-GRU, que são amplamente aplicadas no reconhecimento de imagens, com o intuito de comparar os desempenhos destes métodos de previsão.

REFERÊNCIAS

- ANTONIOELLI, E. A. **Previsão do consumo de energia elétrica em um frigorífico: um estudo de caso utilizando regressão linear, redes neurais e máquinas de vetores de suporte**. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná. Medianeira, 2021.
- BANDEIRA, A. P. F. **Aplicação de rede neural artificial para o reconhecimento do diabetes mellitus gestacional com marcadores não-glicêmicos**. Dissertação de Mestrado. Universidade Federal do Paraná, Curitiba, 2015.
- BARROS, B. F.; BORELLI, R.; GEDRA, R. L. **Gerenciamento de energia: ações administrativas e técnicas de uso adequado da energia elétrica**. 3. ed. São Paulo: Editora Érica, 2020. ISBN 978-85-365-3306-3.
- BASTIANI, M.; SANTOS, J. A. A.; SCHMIDT, C. A. P.; SEPULVEDA, G. P. L. **Application of data mining algorithms in the management of the broiler production**. Geintec. v. 8, 2018.
- CABRAL, B. R. **Processos Gaussianos para Aprendizado Supervisionado**. Trabalho de Conclusão de Curso. Universidade Federal de Santa Catarina. Florianópolis, 2021.
- CANKURT, S.; SUBASI, A. **Comparasion of linear regression and neural network models forecasting tourist arrivals to turkey**. Eurasian Journal of Science & Engineering, 2015.
- CASTRO, L. N.; FERRARI, D. G. **Introdução a mineração de dados: conceitos básicos, algoritmos e aplicações**. São Paulo: Editora Saraiva, 2016.
- CHOU, J. S.; TRAN, D. S. **Forecasting energy consumption time series using machine learning techniques based on usage patterns of residential householders**. Energy, v. 165, 2018.
- COPPIN, B. **Inteligência Artificial**. 2. ed. Rio de Janeiro: ROTAPLAN - Gráfica e Editora LTDA, 2010. 253-256 p.
- CURRAL, J. **Statistics Packages: A General Overview**. Universidade de Glasglow: [s. n.], 1994.
- FROZZA, J. F. **Eficiência energética em uma indústria frigorífica: desafios da implantação**. Monografia (Dissertação de mestrado) — Universidade Tecnológica Federal do Paraná, 2013.
- GIL, A. C. **Como Elaborar Projetos de Pesquisa**. São Paulo: Atlas, 2010.
- HOFFMANN, R. **Análise de Regressão: Uma Introdução a Econometria**. Editora Hucitec, 2006.

JAVATPOINT (ed.). Artificial Neural Network. *In: Artificial Neural Network*. Noida, India: JavaTpoint, 2020. Disponível em: <https://www.javatpoint.com/artificial-neural-network>. Acesso em: 23 abr. 2022.

JEIHOONIAN, S. F.; GHADERI, S. F.; PILTAN, M. **Modeling and comparing energy consumption in basic metal industries by neural networks and ARIMA**. *In: International Conference on Computer Information Systems and Industrial Management Applications (CISIM)*. Krakow, Poland, 2010.

KAYTEZ, F. et al. **Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines**. *International Journal of Electrical Power Energy Systems*, v. 67, p. 431–438, 2015.

MACKAY, D. J. C. **Introduction to gaussian processes**. *In: Bishop, Christopher M. (Org.)*. *Neural Networks and Machine Learning*. Springer-Verlag, 1998.

MORDJAOUI, M. et al. **Electric load forecasting by using dynamic neural network**. *International Journal of Hydrogen Energy*, v. 42, n. 28, p. 17655–17663, 2017.

NICHIFOROV, C. et al. **Energy consumption forecasting using ARIMA and neural network models**. *In: International Symposium on Electrical and Electronics Engineering (ISEEE)*, Galati, Romania, 2017.

OGCU, G.; DEMIREL, O. F.; ZAIM, S. **Forecasting electricity consumption with neural networks and support vector regression**. *Procedia - Social and Behavioral Sciences*, v. 58, p. 1576–1585, 2012.

OZTURK, S.; OZTURK, F. **Forecasting Energy Consumption of Turkey by Arima Model**. *Journal of Asian Scientific Research*, v. 8, 2018.

PIMENTEL, F. **Curso de estatística experimental**. Piracicaba: ESALQ, 2009.

PINHEIRO, T. C.; SANTOS, J. A. A.; PASA, L. A. **Gestão da produção de frangos de corte por meio de redes neurais artificiais**. *Revista Holos*. vol. 2, 2020.

PINTO, M. O. **Energia elétrica: geração, transmissão e sistemas interligados**. 1. ed. Rio de Janeiro: Editora LTC, 2018. ISBN 978-85-216-2525-4.

RASMUSSEN, CE. **Gaussian Processes in Machine Learning**. *Lecture Notes in Computer Science*, Heidelberg, v. 3176, p. 63-71, 2004.

RASMUSSEN, Carl E.; WILLIAMS, Christopher K. I. **Gaussian processes for machine learning**. New York: MIT Press, 2006.

SANTOS, C. B.; PEDROSO, B.; GUIMARÃES, A. M.; PILATTI, L. A.; KOVALESKI, J. L. **Previsão do índice de desenvolvimento humano de 2013 a 2024 por meio de técnicas de mineração de dados em séries temporais univariadas e multivariadas**. *Interciencia*, 2019.

SCARAVONATTI, J. H. S. **Aplicação da técnica de regressão para análise de dados climáticos e previsão de safra**. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná. Medianeira, 2015.

SILVA, Alessandra Ribeiro. **Estudo Preliminar Da Aplicação De Redes Neurais No Sistema De Controle De Temperatura Em Uma Planta Didática**. 2015. Trabalho de conclusão de curso (Bacharelado em engenharia química) - Universidade Federal Fluminense, Rio de Janeiro, 2015.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático**. 5. ed. São Paulo: Editora Artliber, 2010.

SOUZA, B. C. S. **Mineração de dados aplicada a previsão do preço de ações utilizando o WEKA**. Trabalho de Conclusão de Curso. Pontifícia Universidade Católica de Goiás. Goiânia, 2021.

WANG, X.; MENG, M. **A Hybrid Neural Network and ARIMA Model for Energy Consumption Forecasting**. Journal of Computers, v. 7, 2012.

WEKA3 (ed.). **Data Mining: Practical Machine Learning Tools and Techniques**. [S. l.], 20 jan. 2016. Disponível em: <https://www.cs.waikato.ac.nz/ml/weka/book.html>. Acesso em: 30 mar. 2022.

WITTEN, H. I. et al. **Data mining: practical machine learning tools and techniques**. 3. ed. [S.l.]: Morgan Kaufmann, 2016.

ZENG, Y. R. et al. **Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network**. Energy, v. 127, p. 381–396, 2017.