

PREVISÃO DO CONSUMO DE ENERGIA ELÉTRICA EM UM FRIGORÍFICO: UM ESTUDO DE CASO USANDO REGRESSÃO LINEAR, REDES NEURAIIS E MÁQUINAS DE VETOR DE SUPORTE

PREDICTING ELECTRIC CONSUMPTION IN A SLAUGHTERHOUSE: A CASE STUDY USING LINEAR REGRESSION, NEURAL NETWORKS AND SUPPORT VECTOR MACHINES

José Airton Azevedo dos Santos¹
Alex Lemes Guedes³

Eduarda Araujo Antonioli²
Leandro Antonio Pasa³

RESUMO

Os avanços tecnológicos, nos últimos anos, permitiram a geração, com precisão, de um maior volume de dados. Também houve, neste período, o desenvolvimento de ferramentas, baseadas em inteligência artificial, que auxiliam na extração de informação destes dados. Neste contexto, este trabalho tem como objetivo comparar modelos, de séries temporais, para previsão do consumo de energia elétrica de um frigorífico de aves, localizado no interior do estado do Paraná. A base de dados, disponibilizada pela Câmara de Comercialização de Energia Elétrica (CCEE), apresenta uma série histórica do consumo de energia elétrica no período entre 2016 e 2021. Modelos de previsão, de regressão linear, redes neurais artificiais e máquinas de vetores de suporte, foram implementados por meio do software WEKA. Resultados obtidos, dos três modelos, foram comparados por meio das métricas MAPE (*MeanAbsolutePercentageError*), MAE (*MeanAbsoluteError*) e RMSE (*Root Mean Squared Error*). Verificou-se, para um horizonte de seis meses, que o modelo de máquina de vetores de suporte apresentou melhor desempenho.

Palavras-chave: Energia. Inteligência artificial. Séries temporais. WEKA.

ABSTRACT

Lately, technological advances have allowed a greater and more precise data volume. There was also the development of tools based on artificial intelligence, which helps extracting information from these data. In this context, this paper aims to compare time series models to predict the consumption of electric energy in a poultry slaughterhouse in the interior of Paraná state, Brazil. Database, provided by the Electric Energy Trading Chamber (EETC), presents historical series of electricity consumption from 2016 to 2021. Predictive models, linear regression, artificial neural networks and support vector machines were implemented using WEKA software. Results from the three models were compared using MAPE (Mean Absolute Percentage Error), MAE (Mean Absolute Error) and RMSE (Root Mean Squared Error). It was observed that, for the next six months, the support vector machine model presented a better performance.

Key Words: Energy. Artificial intelligence. Time series. WEKA.

¹ Pós-graduando em Tecnologias Computacionais para o Agronegócio da Universidade Tecnológica Federal do Paraná. e-mail: airton@utfpr.edu.br

² Pós-graduanda em Tecnologias Computacionais para o Agronegócio da Universidade Tecnológica Federal do Paraná.

³ Professor do Departamento de Engenharia Elétrica da Universidade Tecnológica Federal do Paraná.

1 INTRODUÇÃO

Com a reestruturação do setor elétrico, nos anos 90, abriu-se a possibilidade a alguns consumidores, que cumpram requisitos específicos, de escolher seu fornecedor de energia elétrica. A compra de energia, por um consumidor livre, é feita através de negociações bilaterais, onde são acertadas entre as partes questões como preço, prazo e o volume de energia a ser adquirido (PINTO, 2018; BARROS *et al.*, 2020).

O uso de previsões do consumo de energia, ou seja, a capacidade de avaliar o histórico e projetar uma resposta, pode trazer benefícios para o setor elétrico. As projeções são um meio de fornecer informações, para tomadas de decisões, que proporcionam economia e segurança no fornecimento de energia elétrica, evitando questões como apagões, cortes, deterioração dos sistemas e, até mesmo, paralização de indústrias e serviços. O planejamento de investimentos, com redes e capacidade produtiva, é diretamente dependente do consumo (CASTRO; FERRARI, 2016).

Nota-se, ao observar a literatura da área, que grande parte dos trabalhos são focados em previsões com um aspecto nacional, como em Ogcü *et al.* (2012), Kaytez *et al.* (2015) e Vasconcelos *et al.* (2017), regional, como em Santos; Chaucoski (2020) e Nizami; Al-Garni (1995) ou para as distribuidoras de energia, como nos trabalhos de Campos (2008) e Fogliatto *et al.* (2005). Ou seja, os trabalhos consideram apenas volumes expressivos de energia. Alguns autores, como Amaral (2020), realizaram previsões de consumo para consumidores residenciais. Porém, previsões, para unidades industriais, são de extrema importância.

Supor um consumo acima do real faz com que os recursos financeiros sejam utilizados em investimentos supérfluos. Subestimar esse valor implica em custos maiores de operação e potenciais faltas de energia, que acarretam em penalidades e multas. Assim, além da contribuição para uma operação estável e confiável, as previsões representam uma vantagem operacional e financeira (KAYTEZ *et al.*, 2015)

A natureza da energia elétrica torna sua previsão complexa, uma vez que é impactada por muitos fatores, como condições climáticas e econômicas. A escolha do modelo adequado depende do acesso aos dados históricos, do horizonte da previsão e pode ainda ter outras considerações, dependendo de cada caso (KAYTEZ *et al.*, 2015; ZENG *et al.*, 2017; MORDJAQUI *et al.*, 2017).

É cada vez mais comum a disponibilização, dos dados de consumo, pelas empresas que fornecem energia ou, até mesmo, a instalação de equipamentos específicos para esse fim. Surge, com o avanço da tecnologia e do aumento da capacidade de coleta e armazenamento

de dados, a oportunidade da aplicação de técnicas e ferramentas, como algoritmos de aprendizagem de máquina, para extrair informações, auxiliando no processo de tomada de decisão (WITTEN, 2016; CASTRO; FERRARI, 2016)

Neste contexto, este trabalho tem como objetivo comparar modelos, de séries temporais, para previsão do consumo de energia elétrica de um frigorífico de aves, situado no interior do estado do Paraná. Para isso, propõe-se o uso da ferramenta WEKA, um software que, além da interface amigável e de um ambiente simples de operar, permite utilizar diferentes técnicas como base de aprendizagem, entre elas tem-se a Regressão Linear (LR), as redes neurais artificiais (RNA) e as máquinas de vetor de suporte (SVM).

2 MATERIAL E MÉTODO

A metodologia utilizada neste trabalho pode ser classificada, quanto a natureza, como aplicada, porque busca soluções para problemas específicos, gerando conhecimentos para aplicações práticas (GERHARDT; SILVEIRA, 2009). Quanto à forma de abordar o problema, pode ser considerada quantitativa, porque enfatiza o raciocínio dedutivo, lógico e argumentos mensuráveis (GIL, 2008).

Como estratégia de pesquisa, foi utilizado o estudo de caso que, conforme Yin (2001), é ideal em situações organizacionais reais, como no caso da unidade consumidora analisada, em que o pesquisador não tem controle dos fenômenos.

2.1 A unidade consumidora

A empresa, com sede no estado do Paraná, atua em diversos ramos, entre eles, redes de postos de gasolina e supermercados, unidades de recebimento de grãos e unidades industriais. Identificou-se, junto à empresa, que a área com custos mais representativos, relacionados à energia elétrica, é uma das unidades industriais de aves.

O processo, na planta, inclui o recebimento das aves, abate, congelamento e armazenamento. Além do frango inteiro, a unidade produz cortes individuais, e também a transformação da carne de frango em outros produtos, como empanados e linguiças.

Devido a seu grande porte, a empresa optou pelo atendimento em 138 kV, com subestação própria. Apesar dos custos de implementação da subestação, as tarifas da distribuidora são mais baixas para essa tensão, tanto para o consumo quanto para a demanda.

Além das considerações de tamanho e custos com energia, a escolha desta unidade consumidora está vinculada a operacionalidade da mesma. A unidade em questão deixou o ambiente cativo e migrou para o mercado livre em 2016, visando economia ao poder optar por diferentes fornecedores de energia elétrica.

2.2 O software WEKA

O software WEKA (*Waikato Environment for Knowledge Analysis*) é um sistema desenvolvido pela Universidade de Waikato, na Nova Zelândia. Escrito em Java, consiste em uma coleção de algoritmos de aprendizagem de máquina e ferramentas de processamento de dados. Oferece suporte para todo o processo de mineração de dados, que inclui a preparação das entradas de dados, a avaliação estatística dos esquemas de aprendizado e a visualização dos dados de entrada e de saída. Conforme Witten (2016), o WEKA pode ser utilizado de três formas principais:

- Aplicação de métodos de aprendizagem para análise das saídas e coleta de informações;
- Utilização dos modelos de aprendizagem para previsões de novos casos;
- Comparação da performance de diferentes métodos de aprendizagem.

O WEKA trabalha com arquivos no formato ARFF (*Attribute-Relation File Format*), um tipo de arquivo de atributo e relação (WITTEN, 2016; RAMOS, *et al.*, 2012). O ARFF é um arquivo texto contendo um conjunto de observações, precedido por um pequeno cabeçalho (Figura 1).

Figura 1 –Arquivo ARFF

```
% Arquivo no formato ARFF
%
@relation 'Banco de dados - 2016 a 2020'

@attribute Data date "MM-yyyy"
@attribute Consumo numeric

@data
11-2016,5851,370
12-2016,6474,573
```


Fonte: Autoria própria, 2021.

2.3 Base de dados

Como a unidade consumidora, em estudo, faz parte do mercado livre de energia, os dados de consumo são disponibilizados pela Câmara de Comercialização de Energia Elétrica (CCEE), na plataforma de Sistema de Coleta de Dados de Energia (SCDE) (CCEE, 2021). O relatório do sistema fornece informação do ponto de medição, data, hora, tipo de medição (bruta ou líquida), energia ativa gerada, energia ativa consumida, assim como energia reativa gerada e consumida. A origem da medição, que também faz parte dos dados fornecidos, pode ser do tipo coleta diária, inspeção lógica, hora ajustada ou hora faltante.

Para previsão, do consumo de energia, utilizou-se uma base de dados com 56 meses (Nov/2016 – Jun/2021). Os dados obtidos, dessa base de dados, são apresentados, na Figura 2, na forma de *boxplot*.

Figura 2 – *Boxplot* – Consumo de energia elétrica



Fonte: Autoria própria, 2021.

2.4 Algoritmos

Neste trabalho utilizaram-se, como métodos de previsão, a Regressão Linear, as Rede Neurais Artificiais e as Máquinas de vetor de suporte:

Regressão Linear (LR – *Linear Regression*):

Regressão Linear é um dos algoritmos supervisionados, de *Machine Learning*, utilizado para análises preditivas. As regressões são chamadas de lineares quando a relação entre as variáveis predictoras e a resposta segue um comportamento linear. Quando há uma

única variável independente, é dita regressão linear simples. Caso haja mais de uma entrada, é denominada regressão linear múltipla. Em mineração de dados o algoritmo de regressão linear é muito utilizado para fazer previsão, e pode ser encontrado em vários softwares estatísticos (CASTRO; FERRARI, 2016).

Redes Neurais (MLP – *Multilayer perception*):

As redes neurais MLP são sistemas celulares físicos com a capacidade de adquirir, armazenar e utilizar conhecimento experimental. São compostas por unidades de processamento simples chamadas neurônios. Os neurônios são dispostos em camadas interligadas por conexões. As conexões são associadas a pesos. Seu aprendizado, por meio do algoritmo *backpropagation*, acontece por meio de exemplos (treinamento supervisionado). As redes MLP são muito utilizadas em tarefas de previsão de séries temporais (SPANCERSKI; SANTOS, 2021).

Máquinas de Vetores de Suporte (SVM - *Support Vector Machines*):

As SVMs são algoritmos, de aprendizado de máquinas, baseados na teoria de aprendizagem estatística. Da mesma forma que as redes neurais, a SVM pode ser aplicada para solução de problemas de classificação, agrupamento de dados e regressão. Para regressão é denominado de SVR (*Support Vector Regression*). O SVR é um método de previsão muito robusto. No WEKA, o SVR é conhecido como SMOreg (SHEVADE, 2000; SANTOS *et al.*, 2018).

2.5 Métricas

As métricas utilizadas para avaliar a precisão, das previsões obtidas pelos modelos, são (PINHEIRO *et al.*, 2020; BASTIANI *et al.*, 2018; CANKURT; SUBASI, 2015; SANTOS, 2021):

- *Mean Absolute Error* (MAE): o Erro Médio Absoluto é calculado por meio da diferença entre os valores atuais e os preditos (Equação 1).

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)| \quad 1$$

- *Root Mean Squared Error* (RMSE): O RMSE penaliza mais os erros maiores, permite avaliar a qualidade de um preditor em relação aos dados (Equação 2).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n ((y_i - \hat{y}_i)^2)} \quad 2$$

- *Mean Absolute Percent Error* (MAPE): O MAPE mede o tamanho do erro em termos percentuais (Equação 3).

$$MAPE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)/y_i| \times 100 \quad 3$$

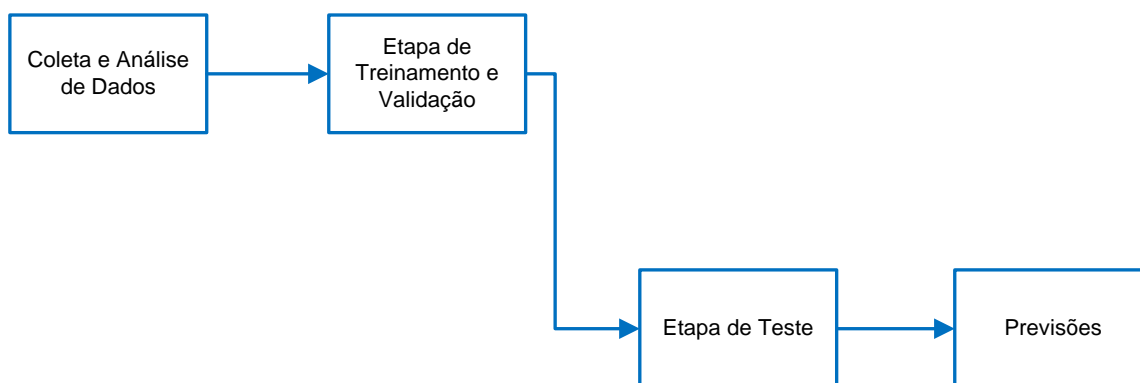
Onde: y_i é o valor real do período i , \hat{y}_i é a previsão para o período i e n é o número de observações.

2.6 Etapas do trabalho

Inicialmente, realizou-se a coleta e a análise dos dados do consumo, de energia elétrica, do frigorífico. Em seguida, na etapa de treinamento e validação, foram selecionados, por meio do software WEKA, os melhores modelos LR, MLP e SMOreg. Neste trabalho, utilizou-se o método de fragmentação de *Houldout* onde a base de dados foi dividida com 70% dos dados para treinamento dos algoritmos e 30% para validação. Na sequência, na etapa de teste, testaram-se os modelos para os dados que não participaram da etapa de treinamento e validação (Janeiro/2021 à Junho/2021). Por fim, realizou-se previsões para o ano de 2021.

Na Figura 3 apresentam-se as etapas realizadas para previsão do consumo de energia elétrica do frigorífico

Figura 3 – Etapas do trabalho



Fonte: Autoria própria, 2021.

3 RESULTADOS E DISCUSSÃO

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados (Tabela 1).

Tabela 1 – Análise descritiva dos dados


Parâmetro analisado	Consumo
Média (MWh)	7148,833
Mínimo (MWh)	5585,362
Máximo (MWh)	9885,828
Desvio Padrão (MWh)	1033,128
Coefficiente de Variação (%)	14,45

Fonte: Aatoria própria, 2021.

Pode-se observar, dos dados apresentados na Tabela 1, que o consumo, para o período em estudo, ficou em média 7148,833 MWh. Apresentando, neste período, consumos mínimo e máximo de 5585,362 e 9885,828 MWh, respectivamente. Observa-se também, da Tabela 1, que o coeficiente de variação é 14,45%, o que indica que os dados são homogêneos em relação à média.

O consumo mensal de energia elétrica (MWh), para o período de novembro de 2016 a março de 2021, é apresentado na Figura 4.

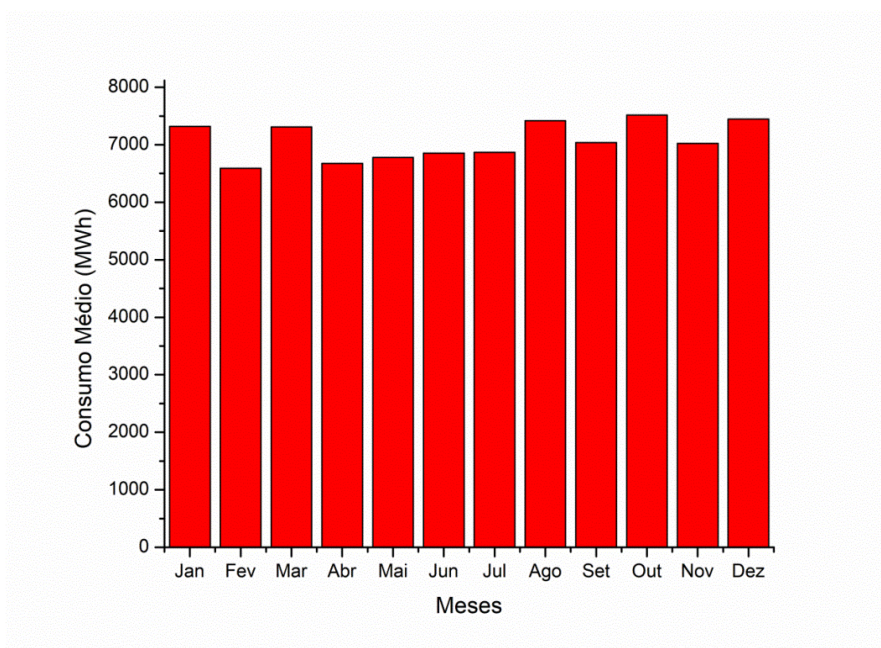
Figura 4 – Gráfico ilustrativo da série temporal do consumo de energia elétrica



Fonte: Aatoria própria, 2021.

A média mensal do consumo de eletricidade, durante o período de Janeiro de 2017 à Dezembro de 2020, é apresentada na Figura 5. Observou-se, neste período, um consumo médio mínimo de 6593,397 (MWh) no mês de Fevereiro e um consumo médio máximo de 7516,884 (MWh) para o mês de Outubro. Além de Fevereiro, que tem apenas 28 ou 29 dias, os meses de Abril, Maio, Junho e Julho apresentaram os menores consumos de eletricidade.


Figura 5 – Média mensal do consumo de eletricidade



Fonte: Autoria própria, 2021.

Na Figura 6 apresentam-se os consumos dos anos 2017, 2018, 2019 e 2020.

Figura 6 – Consumo anual de 2017 à 2020



Fonte: Autoria própria, 2021.

Pode-se observar, por meio da Figura 6, um crescimento anual do consumo de energia elétrica do frigorífico.

3.1 Treinamento e validação

Vários modelos, dos três algoritmos, foram treinados por meio do software WEKA. Os melhores parâmetros, encontrados para os três modelos, são apresentados na Tabela 2.

Tabela 2 – Parâmetros de configuração dos modelos

LinearRegression		MultilayerPerceptron		SMOreg	
attributeSelectionMet	M5	GUI	False	batchSize	10
batchSize	10	autoBuild	True	c	1
debug	False	batchSize	10	debug	False
doNotCheckCapab.	False	debug	False	doNotCheckCapab.	False
eliminateColinearAt.	True	decay	False	filterType	Normalizaing
minimal	False	doNotCheckCapabilities	False	kernel	PolyKernel
numDecimalPlaces	4	hiddenLayers	10	numDecimalPlaces	2
outputAdditionalStats	False	learningRate	0.1	reOptimizer	RegSMOImp
ridge	0.001	momentum	0.3		
useQRDecomposition	False	nominalToBinaryFilter	True		
		normalizeAttributes	True		
		normalizeNumericClass	True		

Fonte: Autoria própria, 2021.

Na Tabela 3 apresentam-se os valores médios das métricas, para um, dois e três passos à frente (1,2,3-Step-Ahead), para os três algoritmos.

Tabela 3 – Médias – MAE, MAPE e RMSE

Métricas	LR	MLP	SMOreg
MAE (MWh)	553,03	398,4714	381,36
MAPE (%)	6,77	4,97	4,58
RMSE (MWh)	672,05	485,64	506,75

Fonte: Autoria própria, 2021.

Observa-se, dos resultados, apresentados na Tabela 3, que o algoritmo SMOreg obteve menores erros para as métricas MAE e MAPE e o algoritmo MLP obteve o menor erro para a métrica RMSE.

Na sequência, realizaram-se previsões, do consumo de energia elétrica, para os meses, de Janeiro, Fevereiro, Março, Abril, Maio e Junho de 2021, que não participaram da etapa de treinamento e validação (Tabela 4).

Tabela 4 – Previsão do consumo de energia (MWh) e MAPEs (%)


CCEE	LR	MLP	SMOreg	Erro_LR	Erro_MLP	Erro_SMOreg
9245,34	8758,54	9546,85	9057,56	5,27	3,26	2,03
8059,53	8551,31	8708,29	8358,686	6,1	8,05	3,71
9885,83	8833,94	9415,76	8907,503	10,64	4,75	9,89
7945,46	8119,75	8762,69	7988,09	2,19	10,29	0,53
8135,06	7555,79	8591,97	8083,043	7,12	5,62	0,63
8133,6	7215,69	8322,75	7822,872	11,29	2,33	3,82
MAPE				7,1	5,72	3,43

Fonte: Autoria própria, 2021.

Por meio dos resultados apresentados, na Tabela 4, conclui-se que as previsões, dos três modelos, estão próximas aos fornecidos pela CCEE. Contudo, o modelo SMOreg apresenta um erro percentual relativo absoluto médio (MAPE) menor que os modelos LR e MLP.

Na Figura 7 apresentam-se as previsões, do algoritmo SMOreg, para os meses de janeiro/2021 a dezembro de 2021.

Figura 7 – Consumo de energia elétrica – Previsões para o ano de 2021



Fonte: Autoria própria, 2021.

A superioridade do algoritmo SMOREg, para a previsão do consumo de energia elétrica, é corroborada por Kaytez *et al.* (2015), Ogcü *et al.* (2012), Vasconcelos *et al.* (2017) e Usha; Balamurugan (2016), confirmando a eficácia da máquina de vetores de suporte para esse tipo de previsão.

4 CONCLUSÕES

Neste trabalho apresentou-se uma aplicação, de modelos de séries temporais, para previsão do consumo de energia elétrica de um frigorífico de aves. Os modelos, construídos com os dados disponibilizados pela Câmara de Comercialização de Energia Elétrica (CCEE), passaram pelas fases de: preparação de dados, definição das estruturas, estimativas, avaliação dos resultados e validação.

Inicialmente, validaram-se os modelos LR, MLP e SMOREg. Na sequência, utilizando os parâmetros encontrados para cada algoritmo de aprendizagem de máquinas, estimaram-se os valores, do consumo de energia elétrica, de Janeiro de 2021 a Junho de 2021. Os dados obtidos foram comparados com valores reais. O modelo com melhor desempenho foi o SMOREg com um MAPE de 3,43%. Nos dados de teste a rede neural atingiu resultados melhores que a regressão. Para a previsão do semestre, a MLP teve um erro de 5,72%, frente a 7,1% da regressão linear.

Observou-se, durante a revisão de literatura, que os trabalhos existentes, de forma geral, analisam o consumo do ponto de vista residencial, da distribuidora ou da nação. Identificou-se a necessidade de modelos para a previsão do consumidor, em especial o industrial. Tendo em vista o crescimento do mercado livre de energia, se torna fundamental o acesso a ferramentas, como os modelos implementados neste trabalho, que permitam que o consumidor tenha informações sobre o seu consumo futuro.

Apesar dos modelos, LR, MLP e SMOREg, apresentarem resultados adequados para uma previsão de curto prazo, sugere-se, para outro trabalho de pesquisa, proceder a estimação, do consumo de energia elétrica, por meio de modelos híbridos.

REFERÊNCIAS

AMARAL, H. L. M. **Desenvolvimento de uma nova metodologia para previsão de consumo de energia elétrica de curto prazo utilizando redes neurais artificiais e decomposição de séries temporais.** [Tese], Universidade de São Paulo, São Paulo, 2020.

BARROS, B. F.; BORELLI, R.; GEDRA, R. L. **Gerenciamento de energia: ações administrativas e técnicas de uso adequado da energia elétrica**. São Paulo: Editora Érica, 2020.

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**, vol. 8, 2018. CCEE (Câmara de Comercialização de Energia Elétrica) Plataforma de Sistema de Coleta de Dados de Energia (SCDE). Disponível em: <<https://www.ccee.org.br/web/guest>>. Acesso em: 20 mar. 2021.

CAMPOS, R. J. **Previsão de séries temporais com aplicações a séries de consumo de energia elétrica**. [Dissertação], Universidade Federal de Minas Gerais, Belo Horizonte, 2008.

CANKURT, S.; SUBASI, A. Comparasion of linear regression and neural network models forecasting tourist arrivals to turkey. **Eurasian Journal of Science & Engineering**, v.1, p.21-26, 2015.

CASTRO, L. N.; FERRARI, D. G. **Introdução à mineração de dados: conceitos básicos, algoritmos e aplicações**. São Paulo: Editora Saraiva, 2016.

FOGLIATTO, F. S. Previsão de demanda por energia elétrica - método e aplicação. **Produção Online**, v.5, p.3100-3107, 2005

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

GIL, A. C. **Métodos e Técnicas de Pesquisa Social**. São Paulo: Editora Atlas, 2008.

KAYTEZ, F.; TAPLAMACIOSLU, M. C.; CAM, M.; HARDLOC, F. 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.

MORDJAJUI, M.; SALIM, H.; MEDOUED, A.; LAOUAFI, A. Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network. **Energy**, v.42, p. 17655-17663, 2017.

NIZAMI, S. S. A.; AL-GARNI, A. Z. Forecasting electric energy consumption using neural networks. **Energy Policy**, v. 23, p. 1097-1104, 1995.

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.

PINHEIRO, D. R. Previsão de preços para a cultura do arroz irrigado e sequeiro do estado do Paraná utilizando séries temporais. **In...Congresso de Contabilidade (2UEU)**. Uberlândia, Minas Gerais, 2005.

PINTO, M. O. **Energia elétrica: geração, transmissão e sistemas interligados**. Rio de Janeiro: Editora LTC, 2018.

RAMOS, C. C. O.; SOUZA, A. N.; GASTALDELLO, D. S.; PAPA, J. P. Identification and feature selection of non-technical losses for industrial consumers using the software WEKA. **In...International Conference on Industry Applications(INDUSCON 2012)**, Fortaleza, Ceará, 2012.

SANTOS, J. A. A.; CHAUCOSKI, Y. Previsão do consumo de energia elétrica na região sudeste: Um estudo de caso usando sarima e lstm. **Revista Cereus**, v.12, p.4, p. 93-104, 2020.

SANTOS, C. B.; PILATTI, L. A.; PEDROSO, B.; GUIMARÃES, A. M. Forecasting electricity consumption with neural networks and support vector regression. **Ciência & Saúde Coletiva**, v. 23, p. 4574-4587, 2018.

SANTOS, J. A. A. Aplicação de Redes Neurais na Previsão de Custos de Produção de Frangos de Corte no Estado do Paraná. **Revista FSA**, v. 18, n.6, p. 169-185, 2021.

SHEVADE, Shirish K. *et al.* Melhorias no algoritmo SMO para regressão SVM. **Transações IEEE em redes neurais**, v. 11, n.5, p.1188-1193, 2000.

SPANCERSKI, J. S.; SANTOS, J. A. A. Previsão do preço do açúcar: um estudo de caso usando o WEKA. **Revista Engenharia e Tecnologia**, v. 13, p. 145-154, 2021.

USHA, TM; BALAMURUGAN, S. Appavu Alias. Previsão de demanda de eletricidade com base sazonal usando análise de séries temporais. **Circuitos e Sistemas**, v. 7, n. 10, pág. 3320-3328, 2016.

VASCONCELOS, L. P.; COELHO; I. H.; SILVA, J. M. M. Uma comparação de técnicas de regressão para a previsão de consumo de energia residencial no cenário nacional. **In...XLIX Simpósio Brasileiro de Pesquisa Operacional**, Blumenau, Santa Catarina, 2017.

WITTEN, H. I. **Data mining: practical machine learning tools and techniques**. Burlingon: Editora Morgan Kaufmann, 2016.

YIN, R. K. **Estudo de caso: planejamento e métodos**. Porto Alegre: Editora Bookman, 2001.

ZENG, Yu-Rong *et al.* Previsão de consumo de energia influenciada por vários fatores usando rede neural de retropropagação aprimorada. **Energia**, v. 127, p.381-396, 2017.