

Previsão de Demanda de Energia Elétrica no Setor de Produção do Laticínio do IFMG - Campus Bambuí Utilizando Regressão de Vetores de Suporte

Brayan Rawlison Castoril¹, Bruno Alberto Soares Oliveira², Servílio Souza de Assis³, Bárbara Roberta Morais⁴, Francisco Heider Willy dos Santos⁵.

Resumo

A tarifação e os custos crescentes da energia elétrica nos fazem buscar soluções para reduzir os gastos e melhorar o controle do consumo de energia elétrica. Uma forma de se reduzir custos de energia é evitar multas provenientes de picos de demanda. A previsão de demanda de energia é importante para o desenvolvimento de controladores de demanda, pois esses podem atuar no controle de cargas elétricas antecipando ocorrências de picos, e dessa forma, evitar a ultrapassagem da demanda contratada. Nesse sentido, foi desenvolvido um sistema de medição de potência elétrica trifásica utilizando-se a plataforma Arduino. Além disso, avaliou-se um método de previsão de demanda de energia de curtíssimo tempo no setor de produção do laticínio do IFMG, a partir da estratégia Support Vector Regression (SVR). O sistema de medição foi avaliado e apresentou um erro médio de leitura de 1,16%, 1,34% e 1,1% para cada fase, em relação ao multimedidor utilizado para aferir. A coleta de dados durou sete dias e após esse período foi realizada a avaliação de um método de previsão SVR e foi obtido um coeficiente de determinação (R^2) de 0,60 e um erro médio absoluto percentual (MAPE) de 11,1%.

Palavras-chave: Previsão de Demanda de Energia Elétrica; Regressão de Vetores de Suporte (SVR); Sistemas Embarcados.

Abstract

Tariffs and increasing costs of electric energy make us seek solutions to reduce expenses and improve control of electricity consumption. One way to reduce energy costs is to avoid fines of demand peaks. The forecast of energy demand is important for the development of demand controllers, since these can act in the control of electrical charges anticipating occurrences of peaks, and, in this way, avoiding the exceedance of contracted demand. In this sense, a three-phase electrical power measurement system was developed using the Arduino platform. In addition, a very short-term energy demand prediction method was evaluated in the IFMG dairy industry, based on the Support Vector Regression (SVR) strategy. The measuring system was evaluated and presented an average reading error of 1,16%, 1,34% and 1,1% for each phase, in relation to the multimeter used to measure. Data collection lasted seven days and after that period the evaluation of an SVR prediction method was performed and a determination coefficient (R^2) of 0,60 and an absolute percentage error (MAPE) of 11,1% were obtained.

Keywords: Electrical Energy Demand Forecasting; Support Vector Regression (SVR); Embedded Systems.

¹Instituto Federal de Minas Gerais - Campus Bambuí. Faz. Varginha - Rodovia Bambuí/Medeiros - km 05. Caixa Postal 05 - Bambuí - MG - CEP: 38900-000, E-mail: brayanbrc@gmail.com

²Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais - Av. Antônio Carlos 6627, 31270-901, Belo Horizonte, MG, Brasil, E-mail: brunoalbertobambui@ufmg.br

³Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais - Av. Antônio Carlos 6627, 31270-901, Belo Horizonte, MG, Brasil, E-mail: servilio.souza@gmail.com

⁴Instituto Federal de Minas Gerais - Campus Bambuí. Faz. Varginha - Rodovia Bambuí/Medeiros - km 05. Caixa Postal 05 - Bambuí - MG - CEP: 38900-000, E-mail: barbararobertamorais@gmail.com

⁵Instituto Federal de Minas Gerais - Campus Bambuí. Faz. Varginha - Rodovia Bambuí/Medeiros - km 05. Caixa Postal 05 - Bambuí - MG - CEP: 38900-000, E-mail: francisco.santos@ifmg.edu.br

1 Introdução

Segundo dados de EPE (2017), a energia elétrica foi a fonte de energia mais consumida no país, representando um custo significativo nas contas das empresas brasileiras. Guedes (2011) explica que para unidades consumidoras do grupo A, a tarifação de energia é cobrada baseando-se na quantidade da demanda contratada. Se uma certa unidade ultrapassar um valor de 10% além da demanda contratada, é cobrada uma multa de três vezes seu valor.

Para Vieira (2016), uma forma de se reduzir gastos com energia é minimizando os custos gerados por multas provenientes de picos de demanda, o que justifica a importância da medição e análise da mesma. Segundo Oliveira (2004), a previsão de demanda, junto à produtividade e seu consumo, é um tema de grande importância para gestão energética, pois os erros de previsão acabam por gerar um custo financeiro muito elevado, levando a oneração da produção da matéria prima.

Segundo a definição de Guedes (2011), o consumo de energia é a quantidade de potência elétrica utilizada em um intervalo de tempo. Assim, podemos expressá-lo em quilowatt-hora (kWh). Ele define também que demanda é a medida de potências elétricas (kW) ativas ou reativas solicitada ao sistema elétrico pelos dispositivos que precisam desta energia para trabalhar durante um intervalo de tempo especificado. As leituras de demanda são realizadas pela concessionária em intervalos de 15 minutos.

Os estudos de identificação de demanda de energia elétrica, em geral, utilizam dados de entrada referentes à cidades, estados ou países, apresentando como resultado séries temporais com padrão de repetição bem definido. Neste trabalho, é proposto a previsão de energia elétrica do setor de produção do laticínio do IFMG - Campus Bambuí, que apesar de ser uma indústria de pequeno porte, se comporta como um setor de produção real, o qual possui várias cargas diferentes e essas podem se comportar de forma aleatória.

Nesse sentido, este trabalho propõe-se a va-

lidar um sistema de previsão de demanda de forma que seja feita a leitura de demanda de energia elétrica. São utilizadas técnicas estatísticas baseada em SVR (*Support Vector Regression* ou, Regressão vetor suporte), com base nas medições da corrente aparente realizadas no setor de laticínios do IFMG - Campus Bambuí. Salienta-se que por se tratar de uma indústria, a distribuição de cargas assemelha-se a uma indústria em regime de consumo real.

1.1 Trabalhos Relacionados

Oliveira, Assis e Nolli (2019) desenvolveram um sistema de monitoramento, via internet, do consumo de energia elétrica do sistema de ar-condicionado de um dos laboratórios de informática do IFMG – Campus Bambuí, levando-o a desenvolver um sistema de medição de demanda utilizando sensores de corrente invasivos.

Vieira (2016), teve como objetivo melhorar o desempenho do controlador de demanda, adquirido pela Universidade Federal de Lavras (UFLA). Para isso, o autor utilizou RNA (Redes Neurais Artificiais) para previsão de demanda com um horizonte de 15 minutos, para controle de prioridade de desligamento das cargas.

Quando Vieira (2016) analisou os resultados simulados do sistema desenvolvido, foi verificado que para o previsor de cargas, a média e desvio para o EMQ na fase de teste foi de 0,00006701 +/- 0,00000262720; o coeficiente R^2 de treinamento obtido foi de 0,9634 +/- 0,00289; e o R^2 de teste obtido foi de 0,987 +/- 0,00152. Para a classificação, foi verificado o valor do EMQ na fase de treinamento em 0,0014436. Também foi observado o índice Kappa de acertos da sequência geral em 0,8239, o autor pôde concluir que o controlador de demanda obteve uma otimização do processo de desligamento das cargas.

Ruas et al. (2012) utilizaram dois métodos de previsão, RNA e SVR, para previsão de demanda de energia elétrica. Com a Rede Neural, eles obtiveram um MAPE (*Mean Absolute Percentage Error* ou erro percentual absoluto médio) de 5,67% e utilizando SVR, com

84 dias de entrada, encontraram um MAPE de 3,32%. O uso de RNA obteve resultados satisfatórios, comparáveis com os publicados na literatura, porém sua grande desvantagem é a definição automática da estrutura da rede, que envolve um grande número de testes, e muita experiência por parte do projetista.

Campos (2008) utilizou metodologias de modelagem para previsão de séries temporais não estacionárias de consumo de energia elétrica. Para resolver o problema de regressão, utilizou-se Redes Neurais e Lógica Fuzzy em duas séries temporais: consumo de energia da cidade de New England e consumo de energia do Estado de Minas Gerais, com intuito de realizar previsões de 60 passos (meses) à frente. Os resultados obtidos para os dois estudos de caso mostram que os modelos ARIMA, NARIMA, RNF e RNA são ferramentas eficientes que podem auxiliar no planejamento e tomadas de decisões no setor elétrico.

Segundo Andrade (2010), foi possível empregar a técnica de ANFIS (*Adaptive Neuro Fuzzy Interference System*) para previsão de demanda em curtíssimo prazo. A metodologia aplicada foi pensando em prever apenas um passo a alguns minutos à frente, cujas mudanças no clima e razões sociais não puderam influenciar significativamente o comportamento dos dados que serão mensurados alguns minutos à frente. O estudo foi realizado nas cidades de Cordeirópolis, Mogi-Guaçu, Ubatuba e Votuporanga, localizadas no interior do estado de São Paulo. O autor obteve um MAPE entre 0,47% e 1,89%.

Oliveira et al. (2018) propuseram avaliar a aplicação de uma Rede Neural Artificial (RNA) Perceptron Multi-Camadas (MLP) utilizando como objeto de aplicação os dados de pluviometria acumulada mensal oriundos do Sistema Cantareira. O treinamento da MLP foi realizado tomando-se por base as medições pluviométricas de outros cinco grandes sistemas brasileiros. Os resultados obtidos mostraram que foi possível cumprir o objetivo colocado e validar o modelo de previsão proposto.

Vasconcelos et al. (2017b) realizaram uma revisão da literatura sobre a previsão de con-

sumo de energia elétrica residencial. Analisaram técnicas de aprendizado de máquina que são aplicados no problema proposto, puderam constatar que os algoritmos SVM e RNAs são os mais empregados, possuindo melhores resultados. Os autores avaliaram trabalhos tanto nacionais quanto internacionais.

Torrini (2014) propôs um modelo para fornecer previsões de consumo de eletricidade de longo prazo do Brasil. Foi utilizado modelos de Lógica Fuzzy a partir de variáveis como a população do Brasil e o valor do PIB, tendo sido considerados os estado e setores juntamente com suas variações. Os resultados obtidos foram comparados com o modelo oficial vigente oferecido pela EPE (Empresa de pesquisa energética). Os resultados finais obtidos da maioria dos modelos propostos, com exceção do setor industrial e dos outros setores, são de projeções subestimando as expectativas oficiais fornecidas pela a EPE.

Vasconcelos et al. (2017a) realizaram uma comparação de métodos de regressão para consumo de energia no país. Dentre as regressões estavam RNA, SVR e Regressão linear. Além disso, seus resultados foram comparados com os resultados de Torrini (2014), e, quando comparado a Lógica Fuzzy, Vasconcelos et al. (2017a) conseguiram obter melhores resultados.

Não foram encontrados trabalhos relacionados com o objetivo de fazer a previsão de demanda de curto prazo aplicado a uma pequena empresa, tornando este trabalho uma pesquisa exploratória. Além disso, a compreensão do comportamento da curva de carga do setor de laticínio, permite futura implementação de um plano de ação para conter picos elevados e até mesmo a implementação de um controlador de demanda, pois esses podem atuar em cargas e, caso sejam antecipadas ocorrências de picos, podem evitar a ultrapassagem da demanda contratada e, dessa forma, evitar multas.

Acredita-se que o método de previsão de demanda elétrica desenvolvido neste trabalho, uma vez que o mesmo foi avaliado positivamente, permitirá a utilização do modelo em outras unidades industriais.

2 Referencial Bibliográfico

2.1 Energia Elétrica

2.1.1 Consumo e Demanda

Guedes (2011) define o consumo como a quantidade de potência elétrica é consumida em um intervalo de tempo. Podemos expressá-lo em quilowatt-hora (kWh). Guedes (2011) também define que demanda é a medida de potências elétricas (kW) ativas ou reativas que são solicitadas ao sistema elétrico pelos dispositivos, uma vez que estes precisam desta energia para trabalhar durante um intervalo de tempo especificado. Tais medidas são realizadas pela concessionária em um intervalo de 15 minutos (OZUR; PEREIRA; JOANA, 2012).

2.1.2 Tarifação Energética

Guedes (2011) explica que existem dois grupos de unidades consumidoras de energia no Brasil. O Grupo B, que são consumidores de baixa tensão - inferior a 2300 volts (v) - normalmente sendo 110 ou 220 volts, sendo tarifados apenas pela energia elétrica consumida, e o Grupo A, que são consumidores de alta tensão e são tarifados tanto pelo consumo de energia do mês quanto pela demanda.

Para tarifar a demanda de energia, é exigido um contrato específico entre as unidades consumidoras e a concessionária que, segundo Guedes (2011), pactua-se um valor único da demanda pretendida pelo consumidor, chamada de demanda contratada, independente da hora do dia, ou período do ano. Caso o consumidor ultrapasse esse valor em 10%, será cobrado uma multa, sendo a tarifa de ultrapassagem três vezes maior que a tarifa de demanda.

2.1.3 Cálculo de potência

Para Boylestad (2012), a tensão é estabelecida quando há separação de cargas negativas e positivas, e se um total de 1 Joule (J) de energia é usado para mover a carga negativa de 1 coulomb (C), há uma diferença de 1 volt (V). Segundo Boylestad (2012), para calcular a potência elétrica, é necessário saber a corrente elé-

trica (Trabalho) em um determinado intervalo de tempo. Essa grandeza é medida em watts (W) que pode ser obtida a partir de:

$$P = V * i \quad (1)$$

Onde,

- P = Potência (W)
- V = Tensão (V)
- i = Corrente (A)

O sistema trifásico é um dos métodos mais comuns de geração, transmissão e distribuição de energia elétrica em corrente alternada. É considerado como o mais utilizado e aplicado nas redes elétricas em todo o mundo, no processo de transmissão de energia elétrica (STEVENSON, 1975). A tensão de fase e de linha pode ser medida através dos pontos apresentados como na Figura 1.




Figura 1: Exemplo de sistema trifásico.

A potência transmitida em cada fase do circuito é obtida por:

$$S_f = V_f * I_f \quad (2)$$

onde V_f a é tensão de fase do alimentador e I_f é a corrente de cada fase do circuito. A potência aparente total S é dada por:

$$S_t = S_{f_1} + S_{f_2} + S_{f_3} \quad (3)$$

Então, para se calcular a potência aparente total, é utilizada a seguinte expressão:

$$S_t = V_f * (I_{f_1} + I_{f_2} + I_{f_3}) \quad (4)$$

2.2 Microcontrolador e Circuitos

2.2.1 Plataforma de prototipagem Arduino

Um microcontrolador é um mini computador utilizado para aplicações específicas. Possui periféricos de entrada e saída, um núcleo de processamento e memória. Segundo McRoberts (2011), o Arduino é um pequeno computador programável que pode processar entradas e saídas entre ele e componentes externos conectados a ele. De acordo com Souza et al. (2011), a plataforma utiliza-se de uma camada simples de software implementada na placa, que é um *bootloader*, e uma interface amigável no computador que utiliza a linguagem Processing, baseada na linguagem C/C++, a qual é também *open source*. Através do *bootloader* é dispensável o uso de programadores para o *chip*, não sendo necessário o uso de compiladores ou hardware adicional. A Figura 2 apresenta o modelo de placa Arduino Uno, versão utilizada neste trabalho.



Figura 2: Arduino Uno.

As interfaces de entrada e saída de dados do Arduino são denominados de portas. O Arduino possui portas digitais e analógicas. As portas digitais trabalham com dois estados, alto ou baixo. Algumas das portas digitais permitem a utilização de modulação por largura de pulso (PWM). Já as portas analógicas, possuem conversores de sinal analógico para digital e digital para analógico. A resolução padrão é de 10 bits, isto é, o sinal de 0 V a 5 V pode ser mapeado em 1024 valores inteiros.

2.2.2 Filtro de sinais

De acordo com Boylestad (2012), toda combinação de dispositivos passivos (resistores, indutores ou capacitores) ou ativos (transistores e amplificadores operacionais) empregados em um projeto de circuito para selecionar uma faixa de frequência específica é chamado de filtro.

Quanto às funções, os filtros de sinais podem ser classificados como passa-baixa, passa-alta, passa-faixa e rejeita-faixa. Com o objetivo de permitir passagem de frequências elétricas abaixo de uma determinada frequência, são utilizados os filtros passa-baixa. Tal frequência limiar é conhecida como frequência de corte (F_c). A Figura 3 apresenta o circuito de um filtro passa-baixa RC.




Figura 3: Filtro R-C Passa Baixa.

O circuito consiste em um resistor (R) e um capacitor (C). Em seu funcionamento, um sinal de entrada (V_i) passa pelo circuito que então gera um sinal de saída (V_o). O cálculo da frequência de corte para o filtro passa-baixa é dado por:

$$F_c = \frac{1}{2\pi RC} \quad (5)$$

2.3 Métodos de Previsão

2.3.1 Séries Temporais

De acordo com Torrini (2014), a grande maioria dos métodos de previsão de demanda elétrica é dividida em modelos de curto-prazo (de minutos até 24 horas), modelos de médio-prazo (de dias até meses) e modelos de longo-prazo (de 1 a 10 anos). Geralmente, estes modelos podem ser classificados em métodos paramétricos ou métodos baseados em inteligên-

cia artificial. Os métodos paramétricos presumem que os dados são provenientes de um tipo de distribuição de probabilidade e faz inferências sobre os parâmetros da distribuição. Já os métodos baseados em IA constituem-se na capacidade em que um modelo possa se ajustar para prever ou classificar dados.

Segundo Ruas et al. (2008), para prever a demanda é necessária a avaliação da curva de carga diária, que é basicamente uma série temporal de medições de demanda. Ela favorece o reconhecimento de padrões para a previsão de demanda.

Séries temporais, como o próprio nome diz, são uma sequência de medições relativas a um determinado evento, organizadas cronologicamente, que aparentemente não seguem nenhuma lei ou tendência. No entanto, em séries temporais relacionadas a fenômenos naturais, econômicos ou físicos, podemos notar certas características que se repetem após certo período de tempo (sazonalidade) e outras que se mantêm durante o intervalo considerado (tendências), mesmo que não obedeçam a padrões lineares Bagattello, Cordeiro e Junior (2005).

Makridakis, Wheelwright e Hyndman (1998) afirmam que o objetivo de métodos de previsão de séries temporais é descobrir o padrão na série de dados históricos e extrapolar esse padrão para o futuro e para medições de curtíssimo prazo. Nesse sentido, o trabalho de Andrade (2010) conclui que todos os dados estão na própria série temporal e, conseqüentemente, acreditam que são remotas as chances para que se possa acontecer uma mudança no comportamento dos dados em um curto intervalo de tempo.

2.3.2 Support Vector Regression

Como pode ser encontrado em Ruas et al. (2008), a SVR é uma técnica de regressão não-linear baseada em Máquina de Vetores-Suporte (SVM, do inglês *Support Vector Machine*). Essa técnica têm como base a teoria de aprendizado estatístico ou na teoria de Vapnik e Chervonenkis (VC).

A SVM inicialmente era proposta para problemas de classificação binária linear, mas

posteriormente o conceito no qual se baseiam esses algoritmos foi ampliado para ser utilizado em problemas de classificação não linear, agrupamento de dados (aprendizagem não-supervisionada), classificação multiclasse e regressão (ASSIS et al., 2019).

Segundo Basak, Pal e Patranabis (2007), a teoria foi originalmente desenvolvida por Vapnik, Chervonenkis e seus colegas de trabalho, com base em um problema de bipartição separável. O SVM implementa um algoritmo de aprendizado, útil para reconhecer padrões sutis em conjuntos de dados complexos. O algoritmo realiza a classificação discriminativa aprendendo, por exemplo, a prever as classificações de dados anteriormente não vistos. A complexidade de tempo de treinamento da maioria dos algoritmos para construção de SVMs é quadrática ou cúbica em relação ao número de amostras de treinamento, o que é uma das desvantagens desses algoritmos Vasconcelos et al. (2017b).

De acordo com Albuquerque (2014), a SVR busca encontrar uma função a qual aproxima determinado conjunto de dados. Nesse caso, deseja-se encontrar uma função $f(x)$ que aproxima um determinado vetor y a menos de um erro de previsão ϵ especificado. Ele também explica que o SVR minimiza simultaneamente o recíproco da margem e permite variáveis de folga, conforme Figura 4.




Figura 4: Representação gráfica de função de regressão linear.

3 Materiais e Métodos

Para que o sistema de previsão de demanda de energia elétrica fosse desenvolvido, bem como para compreender o comportamento da curva de carga do setor de laticínio, foi necessário seguir duas etapas. O primeiro passo foi a elaboração do projeto e a construção do sistema de captura de dados, que é necessário para a coleta de informações da demanda de energia elétrica do setor de laticínio. Para isso, foi projetado um circuito analógico para processamento do sinal e um microcontrolador Arduino para aquisição e armazenamento de dados. Em seguida, foi realizada a amostragem de dados, tendo sido feita uma análise da curva de demanda. Com essa informação, foi avaliado o método de previsão de demanda, através do SVR, para um tempo posterior, donde será analisado o resultado das informações ao final desta pesquisa.

3.1 Sistema de medição de corrente

Inicialmente, foi feita uma visita *in loco*, em que houve uma entrevista com o responsável pelo setor. Foi obtido informações sobre o modo de operação, bem como a verificação acerca da potência dos motores e do maquinário existente no setor de produção do laticínio. Ao final, foi então realizado o levantamento dos motores listados na Tabela 1 com suas respectivas potências.

Tabela 1: Lista de motores.

Motor	Potência (W)
Bomba de água gelada para iogurteira	552,0
Iogurteira	368,0
Bomba de água gelada para o pasteurizador	1472,0
Pá do taxo	1472,0
Sugador de vapor do tacho	368,0
Desnatadeira	372,5
Envase	89,4
Bomba de água gelada para o pasteurizador	552,0

A partir disso, foi desenvolvido o sistema de captura de dados. Esse foi empregado para a coleta de dados de demanda no setor de laticínio. Para o desenvolvimento desse sistema, foram utilizados os seguintes materiais: Arduino UNO; 3 sensores de corrente SCT-013-050; 3 conectores P2 fêmea; 2 resistores 1 k Ω ; 1 capacitor 47 μ F; 1 módulo RTC DS1302; 1 shield Ethernet; 1 cartão SD com capacidade de armazenamento de 2GB; 1 fonte de alimentação bifásica com saída 12V, 1A; 1 estabilizador de energia; placa de fenolite; cabos blindados.

O sistema de captura de dados é composto por um circuito de condicionamento de sinais, o qual é responsável por condicionar o sinal em um formato para processamento. O sistema é constituído também por um software para captura dos sinais desenvolvido no Arduino, por um relógio de tempo real e um dispositivo de armazenamento de dados para guardar as informações obtidas. Esse sistema foi construído seguindo os passos enumerados descritos abaixo:

1. Projetar e montar o divisor de tensão com o filtro passa-baixa.
2. Calibrar o transformador de corrente no arduino.
3. Montar a placa de fenolite.
4. Integrar os módulos RTC e SD Card.
5. Testar o sistema de coleta de dados.

3.1.1 Desenvolvimento do sistema de medição

Para desenvolver tal sistema, foi utilizado o sensor de corrente SCT-013-050. Este dispositivo foi escolhido porque é um medidor não invasivo, permitindo ser instalado no setor sem a necessidade de modificar a instalação elétrica. O dispositivo tem como especificação em que a cada 50 amperes mensurados serão emitidos 1 V AC. A Figura 5 apresenta o modelo do sensor de corrente SCT-013-050, produzido pela YHDC, que foi utilizado neste trabalho.

Para integrar o Arduino com o sensor de corrente, é necessário um divisor de tensão, e esse



Figura 5: Sensor de corrente SCT-013-050.

último precisa ser alimentado com uma tensão de 2,5 volts. O divisor de tensão é alimentado com uma entrada (V_{in}) de 5 volts pelo Arduino e foi montado com dois resistores de $1\text{k}\Omega$ com a finalidade de alimentar o sensor de corrente. Para que seja filtrada altas frequências e ruídos, foi conectado em paralelo a um segundo resistor, um capacitor de $47\ \mu\text{F}$. A Figura 6 ilustra esse circuito.

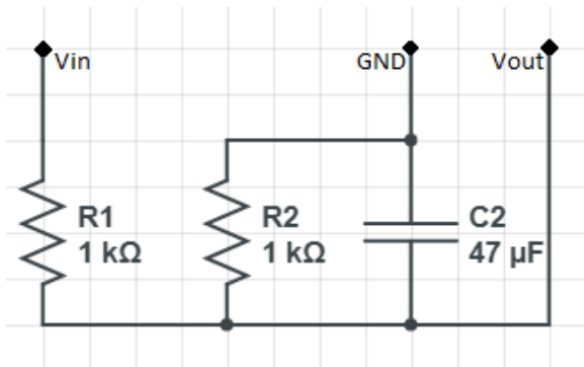


Figura 6: Circuito filtro passa-baixa.

O sistema de medição foi projetado de modo que o Arduino seja capaz de interpretar qual a corrente em que o sensor de corrente mensurou. Como o setor de laticínio é alimentado por três fases, foram produzidos três dos circuitos como o da Figura 6. Para conectar o sensor de corrente ao circuito, foram utilizados conectores P2 fêmea, pois os sensores são adquiridos com o conector P2 macho. Uma entrada do conector P2 foi ligado na saída do divisor de tensão e a outra foi ligada às portas analógicas

do Arduino A0, A1 e A2. No intuito de evitar interferências externas, todas as ligações com os circuitos foram interligados com cabos blindados.

O circuito foi projetado para ser construído em uma placa de fenolite, através do software Proteus 8.5. A Figura 7 apresenta o projeto de trilhas para impressão e confecção da placa.




Figura 7: Circuito trilhas de impressão.

A Figura 8 representa o resultado da placa depois de montado, em que a entrada VCC é a alimentação do circuito, GND o terra, e as saídas S0, S1 e S2 são saídas para os sensores.




Figura 8: Visualização do circuito em três dimensões.

No intuito de comprovar e validar os resultados obtidos através do sistema desenvolvido, foi utilizado o transformador de corrente

M.E.S. 30, juntamente com o multimedidor digital, modelo HD 194E-9SY, apresentados na Figura 9 para fins de comparação entre as leituras.



Figura 9: Multimedidor e Sensor de Tensão.

Distribuídos no Brasil pela JNG Materiais Elétricos, os dois equipamentos possuem capacidade de leitura até 50 Amperes, com uma precisão de 0,5%. Para comparar os resultados e regular o sensor de corrente, foi utilizado como objeto de demanda de energia uma planta didática bifásica, disponível no laboratório de automação do IFMG - Campus Bambuí. Todos os medidores foram conectados à mesma fase para aferi-los.

Para integrar o módulo do relógio de tempo real (RTC DS1302) com o Arduino, este foi conectado nas portas digitais 5, 6 e 7 da plataforma de prototipagem. O RTC utiliza um cristal externo de 32.768kHz e apresenta um erro de 23ppm, que representa aproximadamente um minuto por mês. Esse dispositivo foi alimentado com 3,3 V a partir do Arduino. O RTC foi utilizado para padronizar o tempo de leitura e garantir que as leituras serão realizadas e armazenadas no início de cada minuto. Em seguida, foi utilizado o shield Ethernet W5100 (apenas como suporte para leitura e escrita no cartão de memória) juntamente com um cartão SD de 2 GB. Eles foram utilizados exclusivamente para armazenar os dados da demanda coletados.

3.1.2 Programando o Arduino

Para a programação do Arduino, foi utilizado o ambiente de desenvolvimento Arduino IDE, pois ele é específico para a criação do código

fonte para o dispositivo, além de ser capaz de carregá-lo na placa imediatamente após a compilação.

Foi utilizada a biblioteca EmonLib (*Arduino Energy Monitoring Library*), criada pela Free Software Foundation em 2007, para a leitura da corrente elétrica. Essa biblioteca permite que ao configurar a porta que será usada para leitura de corrente, seja passado um parâmetro para calibrar qual a corrente correta a ser lida. Tendo isso em vista foi desenvolvido um *script* somente para enviar a corrente lida pelo sensor por barramento serial para o computador. Dessa forma é possível comparar visualmente a corrente medida pelo sensor com a corrente lida pelo multimedidor e assim ser feito o ajuste no sistema de medição de corrente.

Para a leitura e armazenamento dos dados no cartão de memória, foi utilizado a biblioteca SD Card. Esta biblioteca já é embutida junto ao Arduino IDE e permite fazer a gravação dos dados lidos pelo sistema de medição de corrente no cartão de memória SD Card. Para configurar e fazer a leitura do RTC, foi utilizada a biblioteca *virtuabotixRTC*, desenvolvida por Krodall, Datillo e Murph entre 2013 e 2014. Essa biblioteca foi utilizada por ser desenvolvida especialmente para o módulo RTC DS1302 e nos permite configurar a data e hora do relógio, bem como realizar a leitura desse horário.

Dessa forma, após a inicialização do programa, o Arduino realizava em média 87 leituras de corrente de cada sensor por segundo, fazendo uma média desses 87 valores para retirar possíveis grandes variações de correntes em um curto período de tempo, e também não perder informações sobre possíveis picos de demanda. No minuto seguinte, o Arduino deve aplicar um filtro passa-baixa digital fazendo a média dos valores medidos durante esse intervalo de tempo.

Após efetuada as leituras, foi armazenado no cartão de memória as três medidas, e também, a hora e data, respectivamente, sendo esses separados por vírgula conforme apresentado na Tabela 2.

Tabela 2: Exemplo de disposição dos dados.

Leitura 1 (A)	Leitura 2 (A)	Leitura 3 (A)	Hora e Data
11,18	8,96	5,59	12:26:0 Sunday 11/3/2018
11,23	8,9	5,77	12:27:0 Sunday 11/3/2018
11,23	8,9	5,75	12:28:0 Sunday 11/3/2018
11,18	8,89	5,75	12:29:0 Sunday 11/3/2018
13,04	10,44	7,59	12:30:0 Sunday 11/3/2018

3.1.3 Coleta de dados

Foi instalado para alimentação uma fonte de energia de entrada de 100 a 250 VAC e com saída de 12 VCC e 1 A. A fonte foi conectada a um estabilizador de energia. Os sensores foram colocados de forma que cada um envolvesse uma fase, conseguindo medir sua corrente. Eles foram posicionados entre os fusíveis e a chave geral, que é alimentada com energia provida do transformador. O transformador, por sua vez, é alimentado pela concessionária de energia (CEMIG), como representado no diagrama unifilar na Figura 10. Vale lembrar que os motores estão listados na Tabela 1, fazendo assim, a leitura de cada fase do setor de produção do laticínio. Os dados foram coletados durante 7 dias, mesmo período de tempo utilizado por Andrade (2010) para previsão de curtíssimo prazo.

3.2 Predição de demanda

Nesta etapa, foi realizada a predição de demanda a partir dos dados obtidos. Para isso, foram utilizadas as seguintes ferramentas:

- Python versão 2.7.12;
- biblioteca Scikit-Learn 0.19.1;
- biblioteca Pandas;
- biblioteca Numpy;
- biblioteca Matplotlib.

Para a realização dessa etapa, foram necessários alguns passos na seguinte ordem:

1. Preparar os dados.

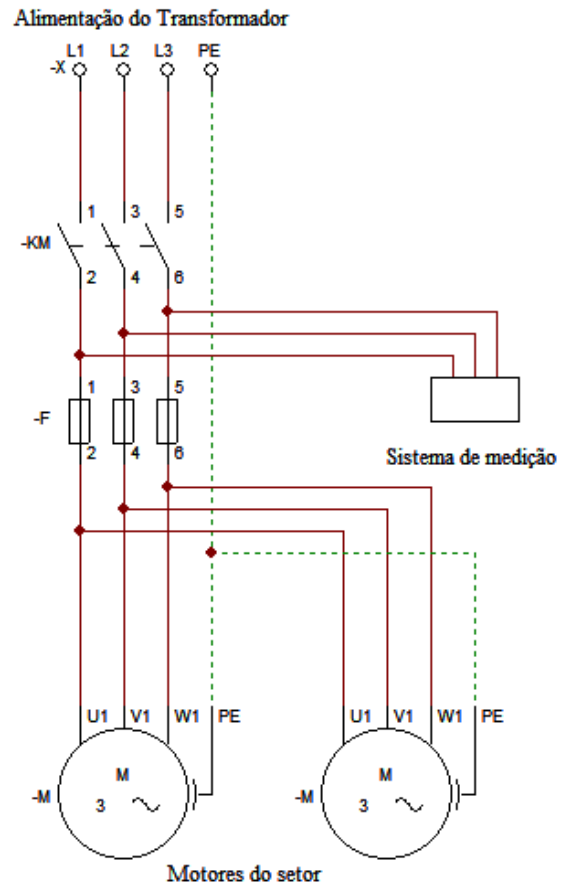


Figura 10: Diagrama da alimentação dos motores trifásicos.

2. Programar o script de previsão utilizando SVR com Validação Cruzada.
3. Ajustar os parâmetros da SVR.
4. Comparar os resultados.

3.2.1 Preparo e análise dos dados

Nesta etapa, foi realizada a análise da curva de carga do setor de laticínio do IFMG - Campus

BambuÍ, com os dados medidos coletados na etapa anterior. Primeiramente, foi necessária uma preparação dos dados. Como o arquivo de saída do Arduino nos mostrava as três leituras de corrente e a data, sendo essas leituras efetuadas a cada minuto, foi desenvolvido um *script* para ler e somar as correntes elétricas de cada fase. Observamos que a auto correlação da integralização da demanda de energia não era satisfatória, e, então, propomos efetuar uma média a cada 15 leituras caracterizando como filtro passa-baixa digital, com a intenção de aumentar a auto correlação da série temporal e, em seguida, armazenar o resultado separando por linha em um outro arquivo.

Com base na série temporal armazenada em um arquivo de saída da etapa anterior, foi programado um *script* para criar 60 arquivos com extensão “.csv”. Cada arquivo contém uma quantidade de dados por linha com base nessa série temporal, sendo essa quantidade o nome do arquivo mais um dado, tal como no exemplo do arquivo “com4dados.csv” da Tabela 3. Esses arquivos eram usados como entrada de dados para o *script* SVR.

Tabela 3: Exemplo de disposição dos dados de entrada para o SVR.

t_{-3}	t_{-2}	t_{-1}	t_0	t_1
25,73	34,95	34,70	34,69	34,51
34,95	34,70	34,69	34,51	27,02
34,70	34,69	34,51	27,02	26,92
34,69	34,51	27,02	26,92	26,79

3.2.2 Previsão de demanda

Nesta etapa, a biblioteca Scikit-Learn foi utilizada juntamente com o Python para implementar o SVR. Primeiramente, foi realizada a leitura dos dados de um arquivo anteriormente preparado e, então, atribuído às variáveis X e Y, as listas a serem analisadas e a lista a ser prevista, respectivamente. No exemplo da Tabela 3, os valores de t_{-3} até t_0 eram atribuídos a X, e os valores da coluna t_1 , atribuídos a Y.

Em seguida, os valores de X devem ser normalizados. Para isso, foi calculada a média,

com base nos dados de X e, em seguida, foi realizada a padronização centralizando e normalizando os valores de X. Posteriormente, para realizar a validação cruzada de 10 dobras, foi utilizado o método k-fold. Para realizar a previsão, a função Kernel escolhida foi a função de base radial (RBF) que é, apesar de ser a mais complexa entre as funções, e normalmente a mais usada para essas aplicações, é, também, a mais geral. A margem ϵ (épsilon) escolhida foi de 0,05, o que após a normalização representa um erro de 2,5% acima ou abaixo dos dados de treinamento. Este processo foi realizado com todos os 60 arquivos de entrada, além disso, o parâmetro C (custo) foi aumentado gradativamente de forma que não houvesse uma mudança significativa no erro.

Por fim, a potência aparente foi calculada pela Equação 4 utilizando-se o valor eficaz da corrente elétrica coletada pelo medidor desenvolvido e o valor eficaz da tensão elétrica foi estimada em 127 Volts, conforme informação da CEMIG.

3.2.3 Avaliação dos resultados

Os resultados foram avaliados com a estatística MAPE que foi escolhida por ter sido utilizada por Andrade (2010), Ruas et al. (2012) entre outros. Também o parâmetro R^2 que Brito et al. (2003) consideram satisfatório assim como o coeficiente de correlação entre a série obtida com a real, que podem ser avaliadas na Tabela 4.

Tabela 4: Parâmetros de avaliação de correlação.

$R = 1$	Correlação perfeita
$0,91 < R < 0, 99$	Correlação fortíssima
$0,61 < R < 0, 91$	Correlação forte
$0,31 < R < 0, 60$	Correlação média
$0,01 < R < 0, 30$	Correlação fraca
$R = 0$	Correlação nula

4 Resultados e Discussão

4.1 Sistema de medição

Desenvolvido o resultado final da primeira etapa deste trabalho, o sistema de medição de corrente pode ser observado na Figura 11.




Figura 11: Sistema de Medição.

Após a montagem da placa de fenolite, foi necessário ajustar os valores passados para a biblioteca EmonLib para que essa faça a interpretação correta da corrente observada. Para esse ajuste e posterior calibração, foi utilizado o multimedidor JNG, observado do lado esquerdo na Figura 9, juntamente com o medidor JNG MES-30, apresentado na Figura 9. Ambos foram utilizados para efetuarem a leitura de corrente. Os resultados apresentaram um erro de 1,16%, 1,34% e 1,1% para cada sensor, como mostrado na Tabela 5 quando comparado com as leituras do multimedidor.

O sistema de medição foi instalado no setor de laticínio conforme a Figura 12, que nos mostra a imagem do quadro de distribuição com as garras dos sensores acopladas.

A coleta de dados durou um intervalo de 7 dias, totalizando 10.086 leituras armazenadas no cartão de memória do sistema, mesmo tempo que Andrade (2010) utilizou para previsão de demanda de energia elétrica utilizando abordagem Neurofuzzy. A maior potência medida foi de 6,78VA.




Figura 12: Imagem do quadro de distribuição do setor de laticínio com as garras dos sensores instaladas para medição de corrente.

O erro de leitura resultado em cada sensor apresentou um MAPE entre 1,1% a 1,3% para o sensor e provou ser capaz de levantar a curva de carga do setor de laticínio.

4.2 Avaliação do Método de Previsão


4.2.1 Análise dos dados

Inicialmente, para analisar os dados, conforme a Equação 4, foram adicionadas as correntes elétricas decorrentes das leituras de cada sensor com a finalidade do cálculo de potência para que, posteriormente, a previsão de carga seja calculada com a potência aparente, utilizando a tensão de fase de 127 V. Uma vez que o objetivo desta pesquisa é analisar uma série temporal, assumiu-se que o comportamento das medições tem como predominância os valores da corrente elétrica, tendo utilizado um valor médio para a tensão, que possui uma baixa variação. Foi implementado um filtro digital passa-baixa do tipo média móvel com janela de n amostras, equivalentes a cada 15 minutos para diminuir os ruídos da série. Em seguida, foi gerado o gráfico da curva de carga da Figura 13 em que foi aplicada a previsão com um horizonte de 15 minutos.

É possível, a partir da análise da Figura 13, calcular qual seria a demanda a ser contratada pelo setor de laticínio, ou outra indústria em que fosse utilizado o sistema de medidor de demanda, bem como fazer ajustes no cronograma do setor para que não seja ultrapassada essa demanda.

Tabela 5: Tabela de cálculo de erro do sensor.

Tempo	Sensor 1 (A)	Sensor 2 (A)	Sensor 3 (A)	Multimedidor (A)
t1	28,50	28,23	28,25	28,52
t2	28,00	28,31	28,01	28,46
t3	28,22	28,06	28,28	28,39
t4	28,20	28,23	28,28	28,70
t5	28,26	28,09	28,50	28,76
Média	28,24	28,18	28,26	28,57
Erro	1,16%	1,34%	1,10%	–

**Figura 13:** Potência em função dos dados na série temporal com intervalo de 15 em 15 minutos.

4.2.2 Análise da previsão

Esta etapa foi realizada para avaliar o método de previsão de demanda. Após os ajustes dos parâmetros de treinamento, foi apresentado um MAPE médio da previsão dos dados desconhecidos pela SVR de 11,10%, utilizando como entrada os 21 dados anteriores ao previsto. Foi obtido um coeficiente de determinação médio (R^2) de 0,60, que de acordo com a Tabela 4, é considerado uma correlação média, porém é um valor muito próximo de ser considerado como alto. A Tabela 6 apresenta os coeficientes de erros para cada dobra da série prevista.

O gráfico da Figura 14 foi gerado a partir dos dados reais e dos valores previstos pela SVR.

As métricas de erro apresentaram um MAPE superior quando comparadas com tra-

Tabela 6: Erros MAPE e coeficiente R^2 por dobra.

Dobra	MAPE(%)	R^2
1	9,06	0,71
2	9,09	0,69
3	15,58	0,51
4	12,18	0,63
5	7,52	0,80
6	11,96	0,54
7	9,51	0,54
8	11,20	0,51
9	14,25	0,52
10	10,74	0,56

balhos relacionados, isso pode ser justificado pelo fato de que os dados utilizados para previsão foram extraídos de uma indústria real. Na bibliografia, não foram encontrados trabalhos que possuíssem o objetivo de previsão de demanda de curto prazo em uma unidade industrial, fazendo desta pesquisa uma pioneira na área. Nesse sentido, foi analisado o coeficiente de auto correlação para uma chave de 21 dados e ele nos mostrou que a auto correlação da série temporal foi de 10,58%, um valor baixo, porém levando em conta o cenário em que foi realizado as medições, pode-se perceber que as utilizações das cargas são bastante aleatórias por se tratar de um ambiente de estudo em que os motores podem ser ligados a qualquer momento.

Esse resultado de previsão leva em consideração um modelo que utilizou toda a série temporal juntamente com uma previsão que utiliza validação cruzada de 10 dobras, fazendo




Figura 14: Gráfico expressando os valores previsto e reais.

com que essa previsão não possua dados viciados em nenhuma parte da série. Isso permite ao modelo ser utilizado em outras séries com características semelhantes, diferentemente de trabalhos relacionados, como os de Ruas et al. (2012) e Andrade (2010), que utilizaram, respectivamente, uma porcentagem de dados específica para treinamento e teste, fazendo validação cruzada com três faixas de treino e teste diferentes.

5 Conclusão

No presente trabalho, foi desenvolvido um sistema de medição de demanda de energia elétrica. A coleta de dados de demanda foi realizada no setor de laticínio do IFMG - Campus Bambuí, bem como procedemos a avaliação do método de previsão, utilizando SVR, com o objetivo de realizar a previsão em um intervalo temporal de 15 em 15 minutos.

Foi verificado que o sistema de medição de demanda, quando comparado ao multimetro, apresentou erros de 1,1%, 1,3% e 1,1% para cada sensor, no entanto, esses valores são percentuais aceitáveis. Além disso, o sistema proposto no presente artigo foi capaz de reali-

zar a medição de demanda de energia de forma a mostrar picos e quedas, no setor de produção do laticínio do IFMG Campus-Bambuí, como proposto neste trabalho. A coleta de dados foi realizada em um intervalo de 7 dias obtendo um total de 10086 leituras. A partir do levantamento da curva de carga, é possível, a partir da análise dos dados, calcular qual seria a demanda a ser contratada pelo setor de laticínio, ou em outra indústria em que fosse utilizado o sistema de medidor de demanda.

Diferente de trabalhos encontrados na literatura, esta pesquisa foi realizada com o objetivo de previsão de demanda de uma pequena unidade industrial que contém uma grande variação de carga. A curva de carga apresentou uma auto correlação de 10,58%. Para avaliação do sistema de predição de demanda, foram utilizadas as métricas como MAPE e R^2 , com o objetivo de avaliar o método de previsão. Esse sistema apresentou um MAPE médio para cada dobra de 11,1% e apresentou um coeficiente médio R^2 de 0,60. A previsão de demanda foi capaz de prever os picos e as quedas de energia, que é interessante para a implementação de um controlador de demanda. Como a previsão foi validada com metodolo-

gia de validação cruzada de 10 dobras, é possível que se utilize esse modelo em outros ambientes similares e até mesmo em diferentes períodos de tempo.

Para trabalhos futuros é interessante explorar a utilização de outras metodologias de previsão, como por exemplo, RNA e Fuzzy e, até mesmo, variar o tempo de coleta de dados para a previsão. Trabalhos podem ser desenvolvidos de modo a utilizar uma estratégia para que seja feito o ajuste da previsão dos picos de demanda, para que esses acompanhem a real curva de previsão, obtendo, assim, resultados mais fiéis. Outros trabalhos futuros podem também avaliar este modelo de previsão para outras séries de dados.

Agradecimentos

O presente trabalho foi realizado com o apoio financeiro da CAPES - Brasil. Os autores agradecem ao Instituto Federal de Minas - campus Bambuí e a Universidade Federal de Minas Gerais pela infraestrutura cedida.

Referências

ALBUQUERQUE, P. H. *Previsão de séries temporais financeiras por meio de máquinas de suporte vetorial e ondaletas*. [S.l.], 2014.

ANDRADE, L. C. M. de. *Abordagem neurofuzzy para previsão de demanda de energia elétrica no curtíssimo prazo*. Dissertação (Mestrado) — Escola de Engenharia de São Carlos da Universidade de São Paulo, 2010.

ASSIS, S. S. de et al. Desenvolvimento de um protótipo para classificação de perfis de pulverização utilizando processamento digital de sinais e redes neurais artificiais. *Revista Brasileira de Computação Aplicada*, v. 11, n. 1, p. 14–27, 2019.

BAGATTELLO, V. A.; CORDEIRO, M. X.; JUNIOR, A. D. P. Redes neurais aplicadas a previsão de séries temporais. In: *XI Encontro de Iniciação Científica e Pós Graduação do ITA*. [S.l.: s.n.], 2005.

BASAK, D.; PAL, S.; PATRANABIS, D. C. Support vector regression. *Neural Information Processing-Letters and Reviews*, Citeseer, v. 11, n. 10, p. 203–224, 2007.

BOYLESTAD, R. L. Introdução à análise de circuitos. *Tradução de José Daniel Vieira e Jorge Ritter. Revisão técnica de Benedito Donizete Bonatto*. São Paulo : Pearson Prentice Hall, v. 12, 2012.

BRITO, N. M. et al. Validação de métodos analíticos: estratégia e discussão. *Pesticidas: Revista de Ecotoxicologia e Meio Ambiente*, v. 13, 2003.

CAMPOS, R. J. *Previsão de séries temporais com aplicações a séries de consumo de energia elétrica*. 2008. 85 f. Tese (Doutorado) — Dissertação (Mestrado em Engenharia Elétrica)-Universidade Federal de Minas Gerais, Belo Horizonte, 2008.

EPE, B. E. de P. E. Balanço energético nacional, séries completas. *Disponível: <http://www.mme.gov.br/documents/10584/>*. Acesso, v. 13, 2017.

GUEDES, J. Manual da tarifação de energia elétrica. *Rio de Janeiro-RJ: PROCEL EDIFICA*, 2011.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. *Forecasting: methods and applications*. [S.l.]: John Wiley & Sons, 1998.

MCROBERTS, M. *Arduino básico*. São Paulo: Novatec, v. 1, 2011.

OLIVEIRA, A. Novo modelo elétrico - papel ampliado para geração distribuída. *INEE - Instituto Nacional de Eficiência Energética*, 2004.

OLIVEIRA, B. A. S.; ASSIS, S.; NOLLI, C. Development of a prototype electrical energy monitoring system via internet/desenvolvimento de um protótipo de sistema de monitoramento de energia elétrica via internet. *Revista de Engenharia da Universidade Católica de Petrópolis*, v. 12, n. 1, p. 48–61, 2019.

OLIVEIRA, B. A. S. et al. Avaliação de uma rede neural artificial como estimador temporal pluviométrico no sistema de abastecimento cantareira. *Revista de Informática Aplicada*, v. 14, n. 1, 2018.

OZUR, F. S.; PEREIRA, T. H.; JOANA, D. Controle de demanda de energia elétrica. *e-xacta*, v. 4, n. 3, 2012.

RUAS, G. I. et al. Electrical energy demand prediction using artificial neural networks and support vector regression. In: IEEE. *Communications, Control and Signal Processing, 2008. ISCCSP 2008. 3rd International Symposium on*. [S.l.], 2008. p. 1431–1435.

RUAS, G. I. S. et al. *Previsão de Demanda de Energia Elétrica Utilizando Redes Neurais Artificiais e Support Vector Regression*. 2012.

SOUZA, A. R. de et al. A placa arduino: uma opção de baixo custo para experiências de física assistidas pelo pc. *Revista Brasileira de Ensino de Física*, v. 33, n. 1, p. 1702, 2011.

STEVENSON, W. D. *Elements of power system analysis*. McGraw-Hill, 1975.

TORRINI, F. C. *Modelos de Lógica Fuzzy para a Previsão de Longo Prazo de Consumo de Energia*. Tese (Doutorado) — PUC-Rio, 2014.

VASCONCELOS, L. P. et al. Uma comparação de técnicas de regreção para a previsão de consumo de energia residencial no cenário nacional. 2017.

VASCONCELOS, L. P. et al. Uma revisão da literatura na previsão de consumo de energia elétrica residencial utilizando técnicas de aprendizado de máquina. 2017.

VIEIRA, M. C. *Controlador de Demanda de Energia Utilizando Inteligência Computacional*. Dissertação (Mestrado) — Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia de Sistemas e Automação da Universidade Federal de Lavras, 2016.