

REDES NEURAIS ARTIFICIAIS APLICADAS NA PREVISÃO DA DEMANDA DE ENERGIA ELÉTRICA EM CURTO PRAZO DE CONSUMIDORES FINAIS

CÂNDIDO, André Victor Luiz¹; PEREIRA, Marco Antônio Silva²

¹Estudante do curso de Bacharelado em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais (IFMG) - *Campus* Formiga, E-mail: andrevluiz15@gmail.com

²Professor orientador do IFMG - *Campus* Formiga, E-mail: marco.silva@ifmg.edu.br

RESUMO

Estimar a demanda futura por energia elétrica possibilita a determinação da capacidade de geração necessária para atender os consumidores de maneira adequada, fornecendo energia com qualidade, segurança e confiabilidade, observando-se o menor custo possível. Neste contexto, o presente projeto propõe a utilização de Redes Neurais Artificiais (RNA's) para realizar a previsão do consumo de uma instalação elétrica, considerando-se um horizonte de tempo em curto prazo (até 24 horas à frente). Inicialmente, as RNA's estão sendo implementadas utilizando a *toolbox* para RNA's do *software Matlab*, em que a variação de parâmetros como número de neurônios e camadas em suas estruturas é necessária para definir o modelo que mais se adequa ao problema. Como objeto de estudo, está em avaliação o perfil de consumo do *campus* Formiga do IFMG, o qual possui grande variação ao longo do dia devido às particularidades existentes em uma instituição de ensino com diferentes cursos, cujos horários e necessidades são diferentes. Sendo assim, estão sendo coletadas informações provenientes do sistema de gerenciamento de energia fotovoltaica, instalado no próprio *campus*, como banco de dados para teste das implementações. Destaca-se que, dentre as informações disponíveis, as variáveis consideradas como potenciais fatores impactantes na demanda de energia são: dia da semana, hora do dia, temperatura ambiente, nível de tensão, irradiação solar, velocidade do vento e valores históricos de consumo. Sendo assim, foram definidas as variáveis de entrada para as RNA's implementadas, sendo que a saída é estabelecida pelas correntes demandadas do sistema. Como testes iniciais, considerando-se que 70% dos dados coletados são utilizados para treinamento das redes, obtiveram-se resultados satisfatórios, visto que os erros médios quadráticos entre os valores reais e os previstos encontram-se na ordem numérica de 0,01. Vale destacar que, a implementação final do projeto, prevê a medição do consumo total da instalação, ou seja, não apenas o que é demandado pelo sistema fotovoltaico. Sendo assim, um sistema de aquisição de dados será montado na entrada de energia do *campus* com o objetivo de obter uma estimativa completa do consumo.

INTRODUÇÃO:

Qualquer pessoa física ou jurídica, que solicite o fornecimento de energia elétrica ou o uso do sistema de alguma concessionária de energia, é denominada como unidade consumidora e assume a responsabilidade pelo pagamento das faturas e demais obrigações fixadas em normas e regulamentos da ANEEL (Agência Nacional de Energia Elétrica), vinculando-se a contratos de fornecimento, de adesão e de utilização (ANEEL, 2021). A demanda por energia elétrica desses consumidores, no entanto, varia ao longo do tempo de acordo com diversos fatores, tais como a localização geográfica, finalidade de utilização (residência, comércio ou indústria), perturbações causadas pela carga ao sistema, tarifação, tensão de fornecimento, eventos televisivos, umidade do ar, luminosidade, temperatura, etc. (MARQUES, 2014).

Tendo em vista que a eletricidade deve ser gerada em tempo real, a previsão da carga demandada pelos consumidores é de fundamental importância para a definição das unidades geradoras necessárias para garantir o suprimento de energia. Além disso, previsões sobre o consumo, em um determinado horizonte temporal, podem auxiliar na manutenção da qualidade da energia fornecida, além de garantir a eficiência da operação e do planejamento de sistemas elétricos de potência (BOU; et. al, 2014). Superestimar a demanda de energia elétrica pode gerar um nível desnecessário de fornecimento de reserva operacional e na compra excessiva de energia. Outra preocupação envolvida está relacionada com os possíveis desperdícios de investimento, dados pela construção de centrais elétricas em excesso. Por outro lado, subestimar esta demanda pode resultar em uma operação arriscada e em potência não suprida, fazendo com que o sistema

opere em região vulnerável a perturbações e com uma preparação insuficiente de reserva operacional (FAN; HYNDMAN, 2012).

Geralmente, a previsão de carga é realizada em intervalos horários, diários, semanais e anuais, estimando-se a demanda do sistema e seu respectivo valor máximo. Neste contexto, pode-se dizer que as previsões são classificadas como de curto, médio, e de longo prazo, dependendo do horizonte de tempo (ANTUNES; et. al, 2013). Métodos baseados em séries de dados estatísticos eram comumente utilizados para realizar estas previsões. No entanto, com o desenvolvimento das ferramentas de inteligência computacional, modelos implementados por Redes Neurais Artificiais (RNAs) se caracterizaram por resultados mais adequados para este tipo de problema, dependendo da quantidade e qualidade dos dados disponíveis (CHANG-IL; et. al, 2002).

Neste contexto, tendo como base a importância de realizar previsões da demanda de energia dos consumidores, e também nos métodos mais adequados para esta finalidade, pretende-se, com o presente projeto de pesquisa, utilizar os conceitos de RNAs para realizar a previsão da demanda de curto prazo de instalações de um consumidor específico. Para tal, serão considerados os efeitos da temperatura, dia da semana, horário e valores passados de demanda, os quais serão medidos e utilizados como variáveis de entrada para diversas estruturas de RNAs, implementadas com o auxílio de *toolbox* do *software* *MATLAB*.

METODOLOGIA:

Para que seja possível elaborar um modelo capaz de prever o consumo de uma instalação elétrica, é necessário que seja realizado, previamente, um estudo sobre as principais metodologias utilizadas em modelos de previsão de carga, podendo citar os estudos disponíveis em (GUIRELLI, 2006; FIGUEIREDO, 2009; BRAGA, 2010; FERNANDES et. al., 2021). Dentre as metodologias, destacam-se aquelas que utilizam conceitos de inteligência computacional, especificamente as RNAs, as quais são inspiradas no funcionamento do sistema nervoso dos seres vivos. Tais modelos possuem a capacidade de aquisição e manutenção do conhecimento através de um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são dispostas em uma ou mais camadas interligadas por um determinado número de conexões, conforme mostrado na Figura 1. Na maioria dos modelos, estas conexões estão associadas a pesos com a função de armazenar o conhecimento e servir para ponderar variáveis recebidas na entrada de cada neurônio da RNA (FURTADO, 2019).




Figura 1: Representação de uma RNA com múltiplas camadas.

Fonte: FURTADO, 2019.

A estrutura de uma rede neural pode se modificar de diversas formas, conforme a necessidade de aplicação. Basicamente, pode-se variar três aspectos principais: o número de neurônios e/ou camadas intermediárias (arquitetura), o método de determinação dos pesos das conexões (algoritmo de treinamento ou aprendizagem) e a função para ativação das saídas de cada camada da rede. Sendo assim, basta definir adequadamente as variáveis de entrada e saída do problema em análise e variar os parâmetros do modelo com o objetivo de obter os melhores resultados possíveis.

A princípio, as variáveis de entrada para os modelos de previsão de carga, considerando-se seus efeitos na demanda de energia, foram definidas: dia da semana, hora do dia, temperatura ambiente, nível de tensão, irradiação solar, velocidade do vento e valores históricos de consumo. Como saída, considerou-se a previsão da corrente demandada por um sistema fotovoltaico instalado no *campus* Formiga do IFMG, o qual possui um sistema para gerenciamento da energia fotovoltaica através de inversores da fabricante GOODWE e miniestação meteorológica. Tais informações são disponibilizadas pelo site da GOODWE que permite, após *login* com as credenciais da instalação, exportar relatórios contendo os dados de interesse para um determinado intervalo de tempo. Uma vez definido o intervalo de tempo a ser analisado, os dados extraídos da instalação devem ser organizados de forma a adequá-los para entrada e saída a serem utilizados nas RNA's implementadas na *toolbox Neural Network Training* do *Matlab*. A Figura 2 ilustra a interface de utilização da referida *toolbox*.

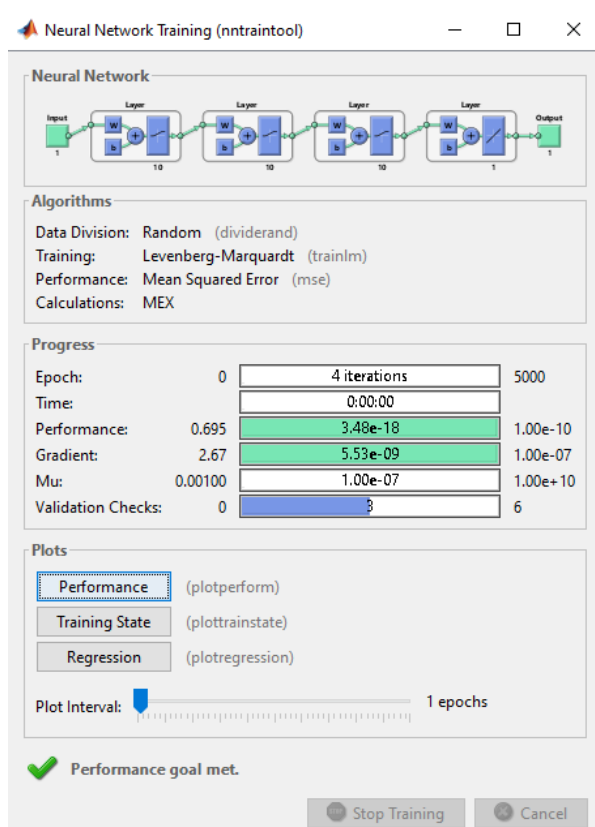


Figura 2: *Neural Network Training Toolbox*.
Fonte: Autores, 2022.

RESULTADOS E DISCUSSÕES:

Os resultados iniciais obtidos podem ser visualizados pela Figura 3, ilustrada a seguir. Neste caso, o gráfico de saída (direita da Figura 3) representa as correntes reais (curva em laranja) de cada fase do sistema fotovoltaico e respectivos valores estimados pela rede (curva em azul) em sua fase de validação. Nota-se que as formas de onda são semelhantes e existe a possibilidade da ocorrência de *overfitting*, que é um fenômeno

caracterizado pela memorização do comportamento das variáveis de entrada pela rede, reduzindo a capacidade de adaptação a pequenas variações dos padrões de entrada (outros dados). No entanto, os resultados se referem apenas a um modelo de RNA definido de forma empírica com os parâmetros especificados na Tabela 1 e, para a implementação final do trabalho, será considerada a aplicação do modelo em conjuntos de dados diferentes para verificar a necessidade de inserir técnicas de regularização, alterações na arquitetura e demais parâmetros da rede neural para evitar o *overfitting*.

Tabela 1: Especificação do Modelo da RNA Implementada.

Descrição do Parâmetro	Especificação
Número de camadas intermediárias	3
Número de neurônios em cada camada	10
Número máximo de épocas (iterações)	5000
Número de dados de treinamento/teste	21
Número de dados de validação	594
Tolerância	0.01
Função de ativação	Log-Sigmoide/Linear
Algoritmo de Treinamento	Levenberg-Marquardt

Fonte: Autores, 2022.

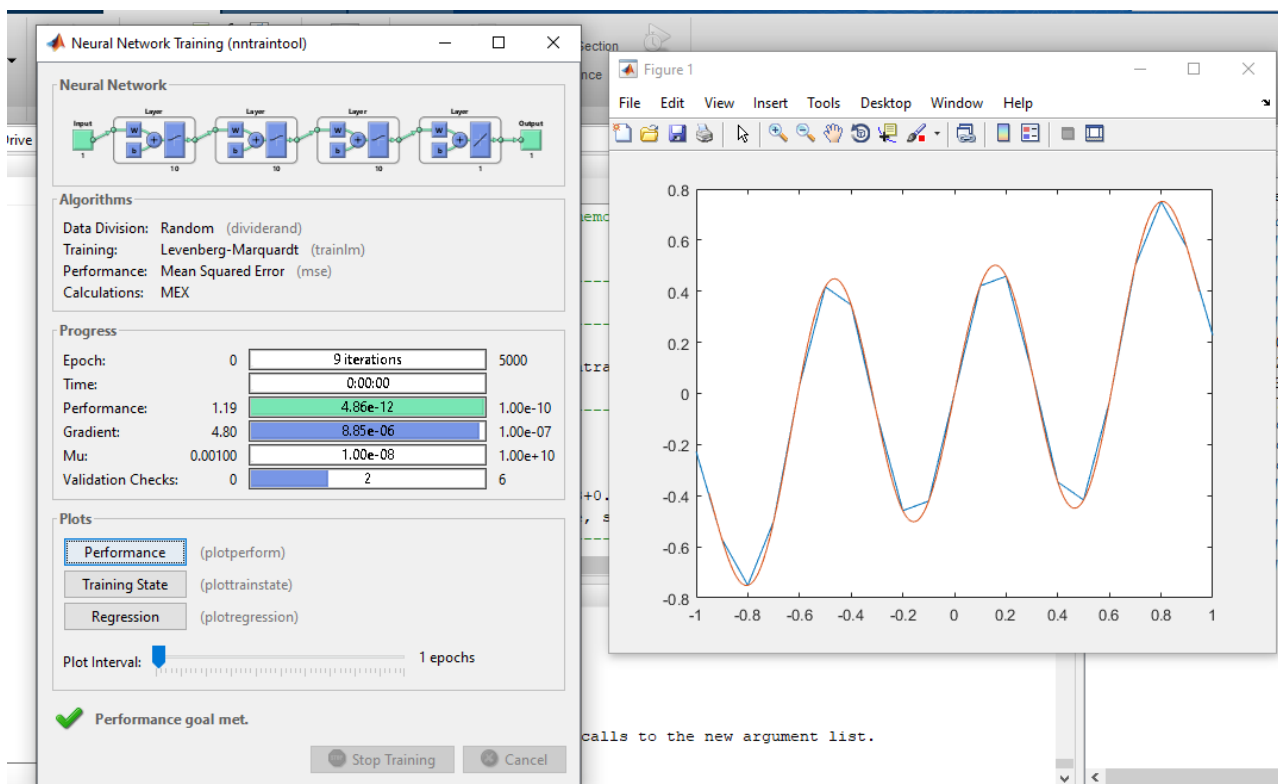


Figura 3: Resultados iniciais de modelo RNA para previsão de carga (próprio autor, 2022).

Fonte: Autores, 2022.

Os resultados apresentados indicam um bom comportamento para a rede implementada, sendo que a performance do modelo pode ser verificada pela análise de métricas de validação. A Figura 4 demonstra a evolução do erro quadrático médio (MSE) entre os valores reais e os previstos ao longo das iterações (épocas) de execução da RNA. Nota-se que, ao final da última época, o MSE para os 70% de dados especificados

para treinamento é da ordem de 0,0001, enquanto os resultados de validação indicam MSE da ordem de 0,01, considerado satisfatório.

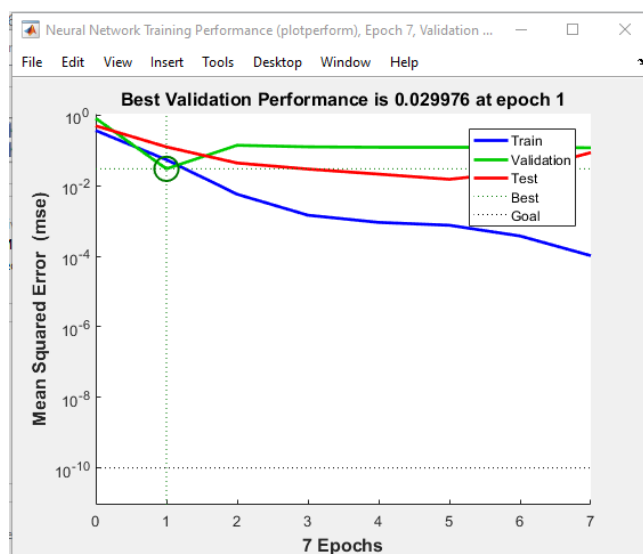


Figura 4: Performance do modelo de RNA para previsão de carga (próprio autor, 2022).

Fonte: Autores, 2022.

CONCLUSÕES:

Neste trabalho foram apresentados os resultados parciais deste projeto de pesquisa, o qual objetiva a implementação de redes neurais artificiais para a previsão de cargas elétricas. Foi possível desenvolver modelos básicos de RNAs em ambiente *Matlab*, os quais se mostraram eficientes para a solução dos problemas adotados como objeto de estudo, ou seja, informações provenientes do sistema de gerenciamento de energia fotovoltaica do *campus* Formiga do IFMG.

Espera-se, com a implementação completa do projeto, realizar aplicação das RNAs para prever o consumo de energia, em um horizonte de curto prazo, considerando que a demanda não seja definida apenas pelas correntes solicitadas pelo sistema fotovoltaico da instalação e sim pelo quadro de distribuição geral do *campus*. Para tal, deve-se associar as informações disponíveis pelo pelos inversores à um sistema de aquisição de dados auxiliar em desenvolvimento.

REFERÊNCIAS BIBLIOGRÁFICAS:

ANEEL – Agência Nacional de Energia Elétrica. Resolução Normativa ANEEL N° 1.000, de 7 de dezembro de 2021. Disponível em: <<https://www.in.gov.br/en/web/dou/-/resolucao-normativa-aneel-n-1.000-de-7-de-dezembro-de-2021-368359651>>. Acesso em: 06/05/2022.

BOU, A. S. F.; FERREIRA, V. H. Previsão de carga elétrica no curto prazo com redes neurais. ENGEVISTA, v. 16, nº 1, pg 91-101. Rio de Janeiro, março de 2014.

BRAGA, M. de B. Metodologias de inteligência computacional aplicadas ao problema de previsão de carga a curto prazo. Orientador: Ádamo Lima de Santana. 2010. 95 f. Dissertação (Mestrado em Engenharia Elétrica.), Universidade Federal do Pará, Belém, 2010.

CHANG-IL, K.; In-KEUN, Y. and SONG, Y. H. Kohonen neural network and wavelet transform based approach to short-term load forecasting. Electric Power Systems Research, Volume 63, 2002, pg. 169-176. ISSN 0378-7796.

FAN, S.; HYNDMAN, R. J., Short-Term Load Forecasting Based on a Semi-Parametric Additive Model. IEEE - Transactions on Power Systems, Vol. 27, nº. 1, February 2012.

FIGUEIREDO, Rodrigo Marques; Um sistema computacional para previsão de carga em sistemas de energia elétrica baseado em redes neurais artificiais. Dissertação (Mestrado em Engenharia Elétrica) - UNISINOS, São Leopoldo - RS, 2009.

FERNANDES, A. T. dos R.; FONSECA, J. L. T.; SILVA, I. L. P. da; AGAMEZ ARIAS, P. D. M.; RAMOS, R. A.; OLIVEIRA, W. D. Evaluation of the influence of the bus-bar voltage profiles on demand forecasting by using neural networks. Research, Society and Development, v. 10, n. 12, p. e600101220917, 2021. DOI: 10.33448/rsd-v10i12.20917.

FURTADO, M. I. V. Redes neurais artificiais: uma abordagem para sala de aula. Ponta Grossa (PR): Atena Editora, 2019.

GUIRELLI, Cleber Roberto. Previsão da carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial. Tese (Doutorado em Engenharia Elétrica) - USP, São Paulo - SP, 2006.

MARQUES, M. dos S. Metodologia para modelagem de curvas típicas de demanda elétrica utilizando redes neurais artificiais considerando variáveis climáticas. (Dissertação de Mestrado - UNIPAMPA) Alegrete – RS, 2014.