

ANÁLISE DOS RESULTADOS DE RNA APLICADA À ESTIMAÇÃO DE DEMANDA ELÉTRICA RESIDENCIAL DE CURTO PRAZO

Marília Facundo Santana ¹, Antonio Alisson Pessoa Guimarães ²

RESUMO

O setor energético está em constante crescimento desde de que a eletricidade foi criada e se difundiu. Os países mais desenvolvidos são os mais dependentes de energia e, consequentemente, os que mais a produzem. No entanto, para que o crescimento energético de qualquer local se desenvolva amplamente e com segurança, é necessário fazer um planejamento que envolva a previsão de demanda (carga) elétrica. Contudo, a atividade de previsão de carga não é uma tarefa simples, bem como identificar padrões de comportamento de consumo dos usuários. Dessa forma, realizou-se o desenvolvimento de uma ferramenta de Inteligência Artificial (IA) visando à estimação de demanda média de carga de curto prazo, com medições horárias para o mês de janeiro de 2019, em demanda residencial. Adotou-se, para previsão média de carga, o modelo de Redes Neurais Artificiais (RNAs) do tipo multicamadas e com entradas à rede, as medições horárias da série histórica do período de 2014 a 2018, para o mês supracitado, cujas medições foram coletadas do banco de dados da companhia elétrica americana Southern California Edison (SCE). Por fim, para avaliar o desempenho da RNA proposta, em termos do Erro Quadrático Médio (EQM), faz-se uma análise comparativa dos resultados gerados pela rede com o modelo de previsão da SCE, para o mês de janeiro de 2019.

Palavras-chave:

Rede Neural Artificial. Demanda Elétrica. Previsão.

¹ Unilab, IEDS, Discente, e-mail: marilia_facundo@hotmail.com

² Unilab, IEDS, Docente, e-mail: alisson@unilab.edu.br

INTRODUÇÃO

Para que um planejamento energético seja feito, é imprescindível que seja realizado a previsão da demanda elétrica futura do local e questão. É possível realizar esse prognóstico de inúmeras formas, dentre elas as Redes Neurais Artificiais. Esta é uma boa forma de se obter os dados, pois, após a construção da Rede, é necessário somente a introdução de dados históricos da demanda elétrica do mesmo local para que o programa forneça as previsões esperadas.

As Redes Neurais Artificiais (RNAs) podem ser definidas como

“[...] modelos computacionais inspirados no sistema nervoso dos seres vivos. Possuem a capacidade de aquisição e manutenção de conhecimento e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões.” (SILVA; SPATTI; FLAUZINO, 2010)

Visto isso, compreende-se que o uso de Redes Neurais é bastante seguro e eficiente, podendo ser utilizado para a previsão dos mais variados objetivos. Faz-se necessário compreender que a estimativa de carga é de extrema importância para o mundo atual, visto que, todos os setores da economia de um país dependem especialmente de energia elétrica. Dias (2010) exemplifica melhor o porquê da previsão de demanda.

“A importância da previsão de consumo de energia elétrica transformou-se numa questão muito discutida recentemente. Depois de enfrentar o racionamento, em 2001, as empresas de energia elétrica se depararam com o desafio de se realizar uma previsão de carga mais exata possível. Um dos pilares desse desenho são as regras para a compra de energia pelas distribuidoras, que exigem altíssimo nível de exatidão nas previsões de carga. Em maior ou menor grau, todas as distribuidoras brasileiras precisaram aperfeiçoar o processo de elaboração das previsões, tendo em vista o novo modelo para o setor elétrico.”

Nesse contexto, este trabalho visa a construção de uma RNA para estimar, para o mês de janeiro de 2019, a demanda residencial de carga elétrica de curto prazo de medições horárias, a partir do banco de dados da Southern California Edison – SCE (SCE, 2019), cujos dados são de domínio público. Também objetiva-se avaliar o desempenho da rede na comparação dos dados de estimação propostos pela SCE e pelos resultados gerados pela RNA utilizada.

METODOLOGIA

O objetivo deste trabalho é obter uma estimativa de carga de curto prazo de um consumidor residencial, referente ao mês de janeiro de 2019, através de uma RNA com supervisionamento. O processo metodológico que consistiu nas seguintes etapas: coleta de dados; definição das variáveis; pré-processamento dos dados; definição de parâmetros da rede e, por fim a fase de treinamento, validação e teste da RNA.

Foram utilizados os valores de demanda do banco de dados público da Southern California Edison (SCE), uma empresa de distribuição elétrica estadunidense que atende quase 14 milhões de consumidores na região central, litoral e sul da Califórnia (SCE, 2019). Os arquivos utilizados são os perfis de carga estática referentes ao mês de janeiro dos anos de 2014 a 2019 para um grupo de clientes residenciais. Os perfis de carga são retratados em todos os 31 dias de janeiro, medidos de forma horária.

Foram definidas 6 variáveis para a camada de entrada e uma camada de saída. As entradas da RNA referem-se às médias diárias de carga, do mês de janeiro, dos anos de 2014 à 2018. A rede desenvolvida foi do tipo supervisionada, dessa forma, foi definida a média de carga de 2019 como a saída desejada da rede (obtida pela SCE).

Foi verificado que no banco de dados da SCE todas as medidas horárias das variáveis da rede estão completas. Após isso, tais dados foram normalizados para valores compreendidos entre 0 e 1, baseados no critério de normalização proposto em Lima, Pinheiro e Santos (2014, p. 112).

O conjunto de dados foi armazenado em forma de matriz, as linhas representam as variáveis de entrada da

rede e as colunas, as medições horárias da demanda de carga, com todos os valores normalizados. A matriz de dados foi dividida em três submatrizes, chamadas de: matriz de treinamento, validação e teste. A primeira contendo 70% dos dados, a segunda e a terceira com 15% cada uma.

A arquitetura escolhida foi do tipo feedforward de camadas múltiplas com processo de aprendizado supervisionado e treinamento da rede baseado no algoritmo backpropagation (SILVA; SPATTI; FLAUZINO, 2010).


A RNA possui três camadas ocultas com quatro neurônios na primeira camada, dois na segunda e quatro neurônios na terceira. Ademais, foi acrescentado um nível bias para cada camada. A precisão da previsão foi avaliada com base no Erro Quadrático Médio (EQM), com base na diferença entre os valores gerados pela rede e os valores reais da SCE. Além disso, a função de ativação usado foi a função sigmóide, a taxa de aprendizagem foi de 0,1 e os pesos foram gerados aleatoriamente.

Os procedimentos realizados na fase de treinamento foram repetidos na fase de validação, com uma menor quantidade de dados. Ao final, aplicou-se a fase de teste para verificar a capacidade de generalização, apresentando-se dados de entradas ainda não disponibilizados durante dos processos anteriores.

RESULTADOS E DISCUSSÃO

O EQM foi analisado com base na diferença entre os valores reais de estimativa média de demanda de 2019 com os valores gerados pela rede. Em termos normalizados, nesta fase obteve-se um valor de aproximadamente 0,000017 para o EQM. Mostrando, dessa forma, um aprendizado satisfatório e uma adequada capacidade de generalização. É possível ver o quão próximos são os valores reais e os simulados pela RNA através da figura abaixo

Figura 1: Comparação de demanda média entre valores reais e simulados.




Fonte: elaborada pelos autores.

Conclui-se que a Rede Neural desenvolvida neste trabalho atingiu com sucessos os seus objetivos, como visto na Figura 1 que mostra o quão próximos foram os valores reais e os simulados. Podendo, dessa forma, afirmar que esta Rede poderia ser usada para ajudar em um planejamento energético com previsão para curto prazo. Nota-se, também, que o erro é quase zero para cada hora do dia, medidos durante um período de 24 horas.

A Figura 2 ilustra que as curvas apresentaram um mesmo comportamento de convergência apresentando-se,

para cada caso, um EQM muito próximo de zero. Mostrando, dessa forma, que a RNA implementada por este trabalho possui uma ótima capacidade de generalização.

Figura 2: Convergência do EQM para as fases de treinamento e validação.



Fonte: elaborada pelos autores.

CONCLUSÕES

O trabalho focou no desenvolvimento de uma RNA multicamadas, objetivando estimar a demanda de curto prazo para o mês de janeiro de 2019, em caso residencial, com medição horária, com base no banco de dados disponibilizado pela Southern California Edison. Com os dados obtidos pela rede, os quais foram comparados, em termos do erro quadrático médio, com as estimativas de medições obtidas pela SCE, pode-se concluir a notável exatidão para a estimativa de carga de curto prazo, atingindo os objetivos inicialmente propostos.

AGRADECIMENTOS

Primeiramente, agradeço a Deus por ter me dado tantas oportunidades. Ao meu orientador, professor Alisson Guimarães, pela sua ajuda durante o processo de desenvolvimento da pesquisa. Ao Programa Institucional de Bolsa de Iniciação Científica - PIBIC - por me dar a incrível experiência que é ser uma pesquisadora. Ao meu namorado por me incentivar a vencer todos os meus desafios e aos meus pais que sempre me motivaram e apoiaram meus estudos.

REFERÊNCIAS

ANEEL - Agência Nacional de Energia Elétrica, Resolução Normativa n° 414, de 9 de junho de 2019.

DIAS, Robson da Silva. Metodologia de Previsão de Carga de Longo Prazo de Energia Elétrica. 2010. 70 f.

TCC (Graduação) - Curso de Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, 2010.

LIMA, Isaias; PINHEIRO, Carlos A. M.; SANTOS, Flavia A. Oliveira. Inteligência Artificial. 1. ed. Rio de Janeiro: Campus, 2014.

OLIVEIRA, André Luis Barros de. Modelo neural para predição de demanda elétrica de curto prazo na região metropolitana da cidade de Fortaleza - CE. 2019. 86 f. TCC (Graduação) - Curso de Engenharia de Energias, Universidade da Integração Internacional da Lusofonia Afro-brasileira, Redenção, 2019.

MARQUES, Marthiello dos Santos. Metodologia para modelagem de curvas típicas de demanda elétrica utilizando redes neurais artificiais considerando variáveis climáticas. 2014. 120 f. tcc (mestrado) - Curso de Engenharia Elétrica, Universidade Federal do Pampa, Alegrete, 2014.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. Redes Neurais Artificiais para engenharia e ciências aplicadas. São Paulo: Artliber, 2010.

SCE - Southern Califórnia Edison. Disponível em: Acesso em: 14 de maio de 2019