

Redes neurais artificiais na obtenção e estimativa das magnitudes das tensões em sistemas elétricos de potência

Arthur Lopes Criscimani, Alfredo Bonini Neto, Wesley Prado Leão dos Santos, Faculdade de Ciências e Engenharia, Tupã, Engenharia de Biossistemas, arthur.lopes@unesp.br, alfredo.bonini@unesp.br, Bolsa PIBIC – CNPq.

Palavras Chave: Inteligência artificial, previsão, margem de carregamento.

Introdução

A eletricidade é um benefício importante para a sociedade, gerando indicadores de desenvolvimento socioeconômico. Portanto, hoje em dia, a qualidade e a continuidade do fornecimento de energia elétrica são essenciais para nosso modo de vida. Várias ferramentas são propostas com intuito de melhorar ainda mais a qualidade da energia. As redes neurais artificiais (RNA) são uma delas.

Objetivo

Utilizar RNA para estimar os perfis das tensões nos barramentos dos sistemas elétricos de potência.

Material e Métodos

O sistema estudado nesse trabalho corresponde à configuração IEEE 14-barras. As 173 amostras utilizadas para treinamento, validação e teste foram obtidas com um método parametrizado¹. Cada amostra é composta por 17 dados, 3 de entrada, (fator de carregamento λ e a potência ativa e reativa gerada na barra de referência, $P_{g,slack}$ e $Q_{g,slack}$) e 14 dados de saída (magnitudes das tensões de todas as barras do sistema). A figura 1 apresenta a RNA utilizada neste trabalho (Multicamadas Perceptron). O software utilizado para preparação dos dados e obtenção dos resultados foi o Matlab®².

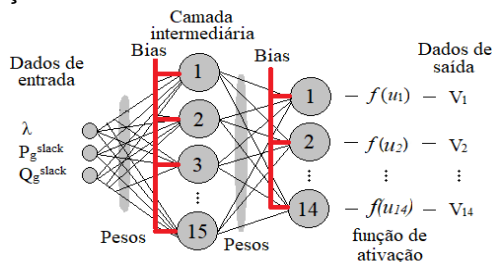


Figura 1. RNA utilizada neste trabalho

Resultados e Discussão

A figura 2(a) apresenta resultados das 173 amostras para o treinamento, validação e teste na configuração de 121 amostras para o treinamento (70%), 26 amostras para validação (15%) e 26 amostras para a fase de teste (15%). Nota-se um bom treinamento, com erro de 3.8×10^{-5} . Já a figura 2(b), mostra a diferença entre a saída desejada Y_{des} e obtida Y_{ob} por

meio do gráfico de histograma. Pode-se observar o acúmulo de dados próximos de zero. O tempo de treinamento foi de 3 segundos com 6 iterações. Para validação e teste, de amostras que não fizeram parte do treinamento, o erro foi de 3.2×10^{-5} e 4×10^{-5} , respectivamente. A figura 3 apresenta as curvas P-V (fator de carregamento λ vs a tensão) para todas as barras do sistema IEEE 14 e, pode-se observar a similaridade entre as saídas desejada (Y_{des}) e obtida (Y_{ob}) pela RNA.

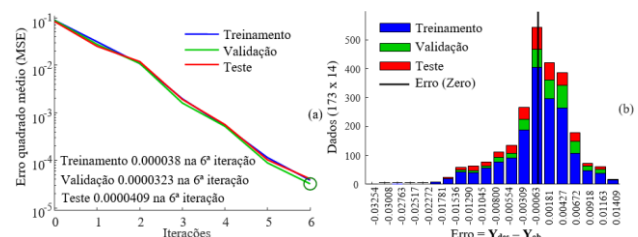


Figura 2. Performance da RNA, (a) MSE, (b) histograma do erro ($Y_{des} - Y_{ob}$).

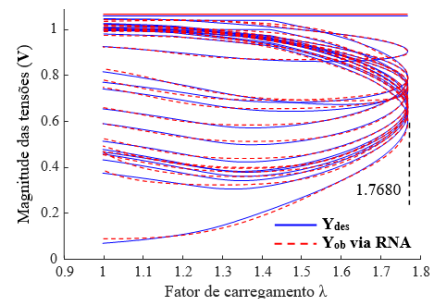


Figura 3. Perfis das tensões de cada barra, saídas Y_{des} e Y_{ob} via RNA.

Conclusão

Observa-se que a rede teve um bom treinamento, validação e teste com valores em torno de 10^{-5} . Pode-se observar que as tensões para Y_{des} e Y_{ob} são bem semelhantes, mostrando que a rede aqui apresentada é uma boa ferramenta na estimativa das tensões de todas as barras do sistema.

Agradecimentos

CNPq

¹Bonini Neto, A., Magalhães, E. M. and Alves, D. A. Geometric Parameterization Technique for Continuation Power Flow Based on Quadratic Curve. Electric Power Comp. and Syst., vol. 45, no. 17, pp. 1905-1917, 2018.

²Mathworks. Disponível em: <http://www.mathworks.com>. Acesso em: 02 de março de 2021.