

Estimativa da Magnitude das Tensões em Sistemas Elétricos de Potência via Redes Neurais Artificiais

A. Bonini Neto¹, A. L. Criscimani², W. P. L. dos Santos³, J. C. Piazzentin⁴, D. A. Alves⁵, C. R. Minussi⁶

¹Faculdade de Ciências e Engenharia (FCE), Universidade Estadual Paulista (UNESP),
Tupã, SP, Brasil, (e-mail: alfredo.bonini@unesp.br)

²Faculdade de Ciências e Engenharia (FCE), Universidade Estadual Paulista (UNESP),
Tupã, SP, Brasil, (e-mail: arthur.lopes@unesp.br)

³Faculdade de Ciências e Engenharia (FCE), Universidade Estadual Paulista (UNESP),
Tupã, SP, Brasil, (e-mail: wesley.prado@unesp.br)

⁴Faculdade de Ciências Agrônomicas (FCA), Universidade Estadual Paulista (UNESP),
Botucatu, SP, Brasil, (e-mail: professorpiazzentin@gmail.com)

⁵Faculdade de Engenharia de Ilha Solteira (FEIS), Universidade Estadual Paulista (UNESP),
Ilha Solteira, SP, Brasil (e-mail: dilson.alves@unesp.br)

⁶Faculdade de Engenharia de Ilha Solteira (FEIS), Universidade Estadual Paulista (UNESP),
Ilha Solteira, SP, Brasil (e-mail: carlos.minussi@unesp.br)

Abstract: Loading margin evaluation is one of the essential tasks of power system voltage stability analysis. Conventional methods for loading margin calculation are based on continuation power flow techniques. Recently, there is growing interest to apply artificial neural network (ANN) techniques to rapidly predict the loading margin. However, traditional ANN learning algorithms usually suffer from excessive training or tuning burden and unsatisfactory generalization performance. In this work, an ANN to estimate the voltage magnitude is presented, as well as all P-V curves of electrical power systems with reduced training time. From the results, ANN presented good performance, with a mean square error in training below the specified value. Of the samples that were not part of the training, the network managed to estimate 100% of the values of the magnitude of the voltage within the established range, with residues around 10^{-4} and a percentage of correctness between the desired and obtained output of 99.6%.

Resumo: A avaliação da margem de carregamento é uma das tarefas essenciais na análise de estabilidade de tensão dos sistemas elétricos de potência. Os métodos convencionais para o cálculo da margem de carregamento são baseados nas técnicas de fluxo de carga continuado. Recentemente, há um interesse crescente em aplicar técnicas baseadas em redes neurais artificiais (RNA) para prever rapidamente essa margem. No entanto, algoritmos de aprendizagem de RNA tradicionais geralmente sofrem de treinamento excessivo ou carga de ajuste e desempenho insatisfatório de generalização. Neste artigo é apresentada uma RNA para estimar a magnitude das tensões, bem como toda curva P-V dos sistemas elétricos de potência com tempo de treinamento reduzido. Dos resultados, a RNA apresentou bom desempenho, com erro quadrado médio no treinamento abaixo do valor especificado. Das amostras que não fizeram parte do treinamento, a rede conseguiu estimar 100% dos valores das magnitudes das tensões dentro da faixa estabelecida, com resíduos em torno de 10^{-4} e percentual de acerto entre a saída desejada e obtida de 99,6%.

Keywords: Artificial intelligence; Continuation power flow; P-V curve; Maximum loading point; Mathematical modeling.

Palavras-chave: Inteligência artificial; Fluxo de carga continuado; Curva P-V; Ponto de máximo carregamento; Modelagem matemática.

1. INTRODUÇÃO

A eletricidade é um benefício importante para a sociedade, gerando indicadores de desenvolvimento socioeconômico. O mercado de eletricidade, em geral, passou por uma série de reformas e reestruturações entre as quais se destaca a privatização das indústrias estatais de eletricidade, que aumentou a concorrência entre as empresas do setor (Bompard et al. 2013). Hoje em dia, com o crescimento da

demanda, junto a desregulamentação do setor elétrico e políticas de restrições nas construções de novas linhas de transmissão e usinas hidroelétricas, têm levado o sistema elétrico de potência (SEP) a operarem próximos aos seus limites operacionais, ou seja, perto do ponto de máximo carregamento (PMC). Sem falar a falta de chuva que, muitas vezes, levam ao racionamento de energia, principalmente em países que possuem sua matriz energética em hidroelétricas, o caso do Brasil, onde 60% da demanda vêm da energia

hidráulica (ONS, 2021). Esse processo de transformação motivou o setor elétrico a investir em ferramentas na busca de melhorias nos sistemas de geração, transmissão e distribuição de energia elétrica (Zhang et al. 2013). A rede neural artificial (RNA) (Haykin, 2008) é uma delas.

Em Zhang et al. (2013) foi proposto o uso de um algoritmo de aprendizado relativamente novo e promissor chamado *extreme learning machine* (ELM) (Huang et al. 2006) para uma previsão da margem de estabilidade de tensão mais precisa e eficiente. As entradas do modelo de predição são parâmetros operacionais do sistema e direção de carregamento, e a saída é a margem de estabilidade de tensão. Com o uso do algoritmo, o erro médio percentual é de apenas 3,32% e o erro médio é de apenas 0,0495, os quais são satisfatórios para o uso prático.

Resultados promissores foram encontrados em Aydin e Gümüş (2020), cuja RNA usada reproduziu os mesmos resultados com alta precisão e rapidez que os métodos convencionais de cálculo de estabilidade de tensão. Para este efeito, o parâmetro de carregamento e o índice da margem de estabilidade de tensão foram calculados usando oito variáveis de entrada diferentes e quatorze funções de treinamento diferentes. Foi possível verificar qual função de treinamento foi o mais rápido e com melhor recurso para prever a margem de carregamento e o índice de estabilidade de tensão.

Balasubramanian e Singh (2011) apresentaram um método baseado em RNA, envolvendo o uso de métodos do fluxo de carga continuado para avaliação da estabilidade de tensão on-line de sistemas de potência. Este método gera os pontos críticos das curvas, utilizados para análise de estabilidade de tensão do sistema que, por sua vez, é utilizada como a saída desejada para o treinamento da RNA, encontrando a distância para o colapso de tensão do ponto de operação do sistema atual. A RNA treinada forneceu, como saída, os indicadores de proximidade do colapso de tensão para todas as barras de carga vulneráveis do sistema. A RNA treinada mostrou ser precisa em um grau muito grande para todos os conjuntos dos novos padrões de carregamento, que não foram usados para o treinamento. Para todos os valores nesses novos conjuntos de entradas, o erro percentual máximo para todos os barramentos de carga vulneráveis foi em torno de 2%.

Outros trabalhos envolvendo RNA na obtenção da margem de carregamento e avaliação da estabilidade de tensão podem ser encontrados em Dinavahi e Srivastava (2001), Kamalasadán et al. (2006) e Zhou et al. (2010).

Neste contexto, o objetivo deste trabalho foi utilizar uma RNA para estimar as magnitude das tensões e, conseqüentemente, a obtenção do ponto de máximo carregamento (PMC) dos sistemas elétricos de potência em função de parâmetros e carregamento do mesmo, com um tempo consideravelmente baixo para o treinamento.

2. METODOLOGIA

O sistema estudado nesse trabalho corresponde à configuração IEEE 14-barras, apresentado na Fig. 1. As 173 amostras utilizadas para treinamento, validação e teste foram

obtidas com o método apresentado em Bonini Neto et al. (2018). Cada amostra é composta por 19 dados, os de entrada da RNA (5 dados), representados pelo fator de carregamento λ , a potência ativa e reativa gerada na barra de referência (P_g^{slack} e Q_g^{slack}) e as perdas totais de potência ativa e reativa (P_a e Q_a) e os dados de saída (14 dados) representados pelas magnitudes das tensões de todas as barras do sistema.




Fig. 1: Sistema IEEE 14-barras.

A RNA utilizada foi a *feedforward multilayer perceptron* (Haykin, 2008) com algoritmo de aprendizado no treinamento *backpropagation* (Werbos, 1974) com três camadas: de entrada com 5 neurônios, intermediária com 15 e saída com 14 neurônios conforme a Fig. 2. O *software* utilizado para preparação dos dados e obtenção dos resultados foi o Matlab® (Mathworks, 2021).

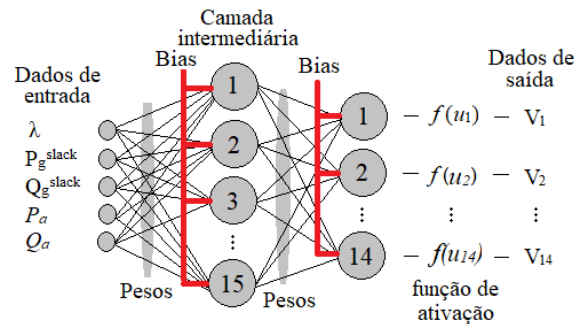


Fig. 2: RNA utilizada nesse trabalho.

O valor de \mathbf{u}_k (1) representa o somatório dos produtos das entradas \mathbf{x} pelos respectivos pesos \mathbf{W} mais o bias que tem a função de aumentar os graus de liberdade, permitindo uma melhor adaptação, por parte da rede neural, ao conhecimento à ela fornecido.

$$\mathbf{u}_k = \sum_{i=1}^n \mathbf{x}_i \mathbf{W}_i + \text{bias} \quad (1)$$

Após obtido o valor de \mathbf{u}_k , é necessário calcular o valor da função de ativação $\mathbf{f}(\mathbf{u}_k)$ para obter a saída. A função de ativação utilizada neste trabalho para a saída de ambas as

camadas foi a função tangente hiperbólica (2) (Haykin, 2008):

$$f(u) = \frac{(1 - e^{-\lambda u})}{(1 + e^{-\lambda u})} \quad (2)$$

em que λ é uma constante arbitrária e corresponde a inclinação da curva.

3. RESULTADOS

A Tabela 1 e as Figs. 3, 4 e 5 apresentam 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%). A Fig. 3(a) apresenta o erro quadrado médio (MSE) do treinamento, validação e teste nessa configuração (70%, 15%, 15%). O processo iterativo interrompe quando um dos valores especificados na Tabela 1 é atingido, nesse caso na 6ª iteração, com valor de treinamento em 0.0000385 e 3 segundos de CPU (processador Intel(R) Core i7 de 2.20GHz e RAM de 16 GB), mostrando que a rede teve um bom treinamento. A Fig. 3(b) apresenta o gráfico de histograma do erro (saída obtida (Y_{ob}) em relação à saída desejada (Y_{des})) com 20 intervalos para as 173 amostras, nas fases de treinamento, validação e teste. Nota-se que as amostras do treinamento, validação e teste ficaram próximas de zero proporcionalmente, explicando a performance apresentada na Fig. 3(a).

Tabela 1: Valores especificados e alcançados nas fases de treinamento, validação e teste da RNA.

Treinamento (70%)		
	Valores especificados	Valores alcançados
Iterações	100	6
Tempo (segundos)	20	3
Performance (MSE)	0.0001	*0.0000385
Regressão R	1.0	0.99969
Validação (15%)		
Validação checada	10	0
Performance (MSE)	0.0001	0.00003232
Regressão R	1.0	0.99975
Teste (15%)		
Performance (MSE)	0.0001	0.000040978
Regressão R	1.0	0.99966

* critério alcançado

A Fig. 4 apresenta as retas de regressão (ajustes) e os valores de R para as três fases da rede. Na Fig. 4(a), a reta de ajuste $Y_{ob} \sim 0.99 Y_{des} + 0.0052$ ficou bem próxima ao esperado ($Y_{ob} = Y_{des}$) com o valor de R em 0.9996 mostrando que a rede ficou bem treinada e não houve discrepância entre os valores desejados e obtidos na classificação das 121 amostras na fase de treinamento (100% de acerto para atender ao critério do MSE).

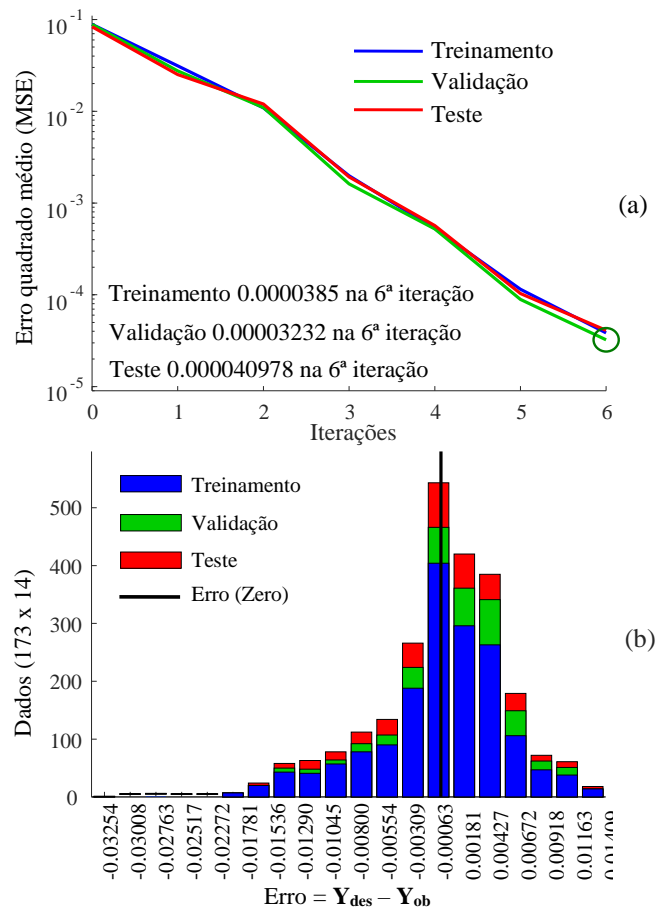


Fig. 3: Treinamento, validação e teste da RNA, (a) performance (MSE), (b) histograma do erro ($Y_{des} - Y_{ob}$) com 20 intervalos para as 120 amostras.

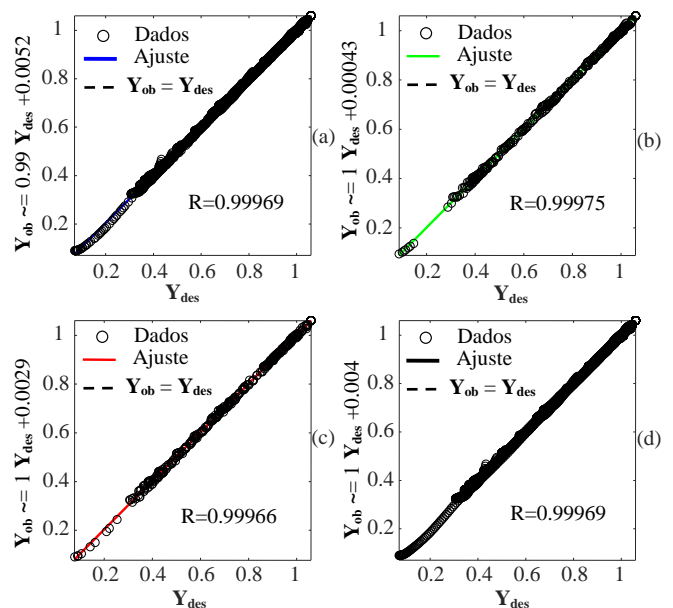


Fig. 4: Análise de regressão entre as variáveis: saída desejada (Y_{des}) e saída obtida (Y_{ob}), (a) treinamento com 70% das amostras, (b) validação com 15% das amostras, (c) teste com 15% das amostras e (d) todas as amostras (100%).

Na Fig. 4(b) e (c), resultados nas fases de validação e teste das 52 amostras restantes que não fizeram parte do treinamento são apresentados (26 amostras (15%) para cada fase). Nota-se, que ocorreram bons ajustes das retas e valores de R em 0.9997 e 0.9996, respectivamente, similar ao treinamento por causa da ausência de erros acima do especificado, nenhuma amostra foram classificadas fora da faixa estabelecida na Tabela 1 para o MSE (100% dentro do esperado). A Fig. 4(d) apresenta a reta de regressão e o valor de R para 100% das amostras nas três fases da rede.

A Fig. 5 apresenta as curvas P-V, ou seja, as saídas desejada (Y_{des}) e obtida (Y_{ob}) também nas três fases da rede, e são representadas pelas magnitudes das tensões de cada barra do sistema (14 barras) em função do fator de carregamento λ , a potência ativa e reativa gerada na barra de referência (P_g^{slack} e Q_g^{slack}) e as perdas totais de potência ativa e reativa (P_a e Q_a).

A Fig. 5(a) apresenta as curvas P-V 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. Já a Fig. 5(b) e (c) apresenta as curvas P-V desejada e obtida para cada barra do sistema.

A Fig. 6 apresenta os resultados para o treinamento, validação e teste para uma barra em particular, a barra crítica 14. A Fig. 6(a) mostra os valores da magnitude da tensão desejada e obtida para o treinamento da RNA, são 70% das amostras, ou seja, 121 amostras. Já a Fig. 6(b) e (c) apresenta resultados para as amostras que não fizeram parte do treinamento, as fases de validação e teste (diagnóstico da rede). Foram utilizadas 52 amostras (30%) nessas fases, 26 amostras para cada (15%). Nota-se que as saídas desejada (Y_{des}) e obtida (Y_{ob}) são similares, acarretando em um MSE de 0.00003232 na validação e 0.000040978 no teste respectivamente, abaixo do especificado de 0.0001. Isso foi possível por causa da especificidade dos dados e do desempenho do treinamento da RNA, que é o processo mais importante quando se trabalha com redes neurais. Uma vez que todos os pesos ajustados para dar uma saída próxima à desejada, a rede estará apta a classificar amostras que não fizeram parte do treinamento, como ocorrido neste trabalho. A Fig. 6(d) apresenta resultados nas três fases da rede, ou seja, para 100% das amostras.

A Tabela 2 e Fig. 7 apresentam os valores desejados e obtidos via RNA das magnitudes das tensões no caso base e no PMC. Pode-se notar pela Tabela 2 e Fig. 7(a), no caso base, que os valores estão bem próximos uns dos outros, em especial as barras 1, 9 e 13. No PMC, todos os valores ficaram bem próximos uns dos outros, conforme Fig. 7(b).

A Tabela 3 apresenta o erro e seu índice percentual dos valores das magnitudes das tensões das saídas desejada (Y_{des}) e obtida (Y_{ob}) via RNA no PMC, pode-se notar o baixo valor do erro (em média 0.0035), mostrando o bom desempenho da RNA aplicada neste trabalho para obtenção das magnitudes das tensões e consequentemente de toda a curva P-V. Para o fator de carregamento λ , não houve erro, pois o mesmo foi utilizado como dado de entrada, por isso foi comparado apenas os valores das magnitudes das tensões de todas as barras. Em média o erro percentual foi de 0.3557%.

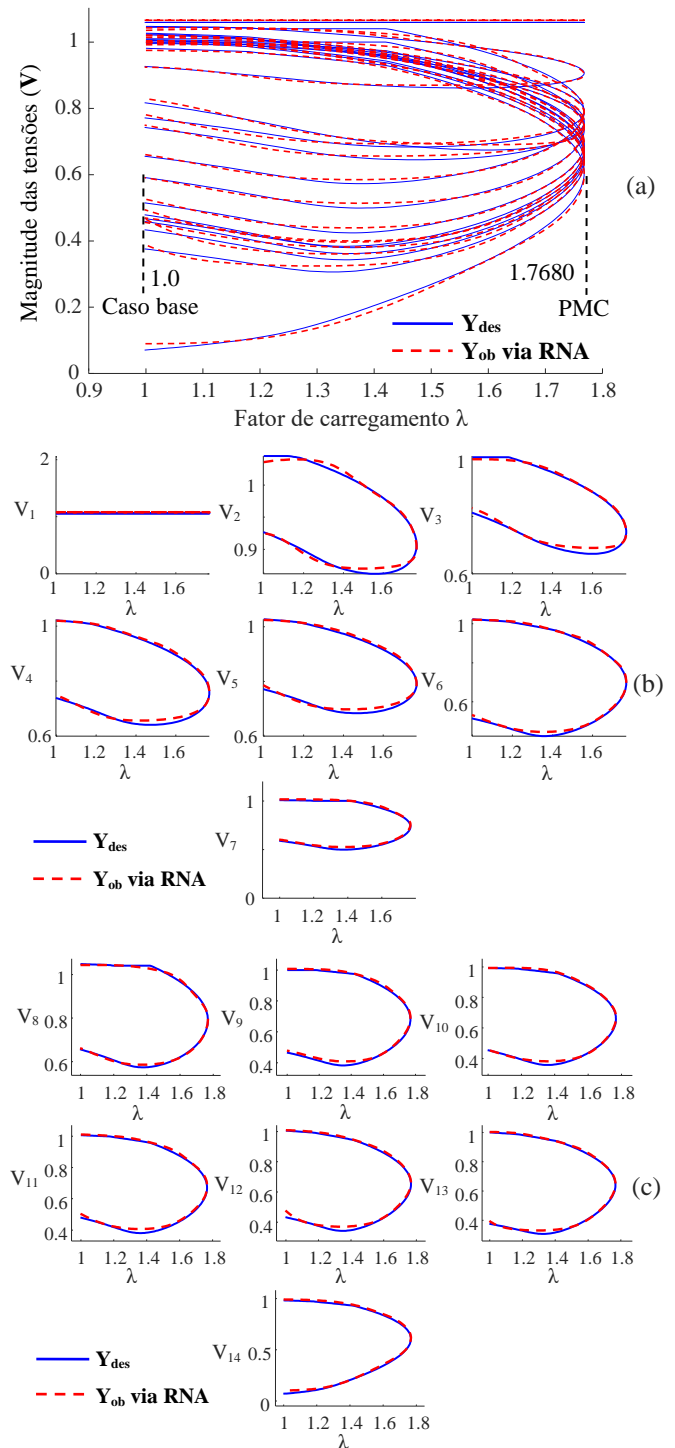


Fig. 5: Saída desejada (Y_{des}) e saída obtida (Y_{ob}) pela RNA do sistema IEEE 14-barras, (a) curvas P-V para todas as barras do sistema, (b) curvas P-V para as barras 1, 2, 3, 4, 5, 6 e 7, (c) curvas P-V para as barras 8, 9, 10, 11, 12, 13 e 14.

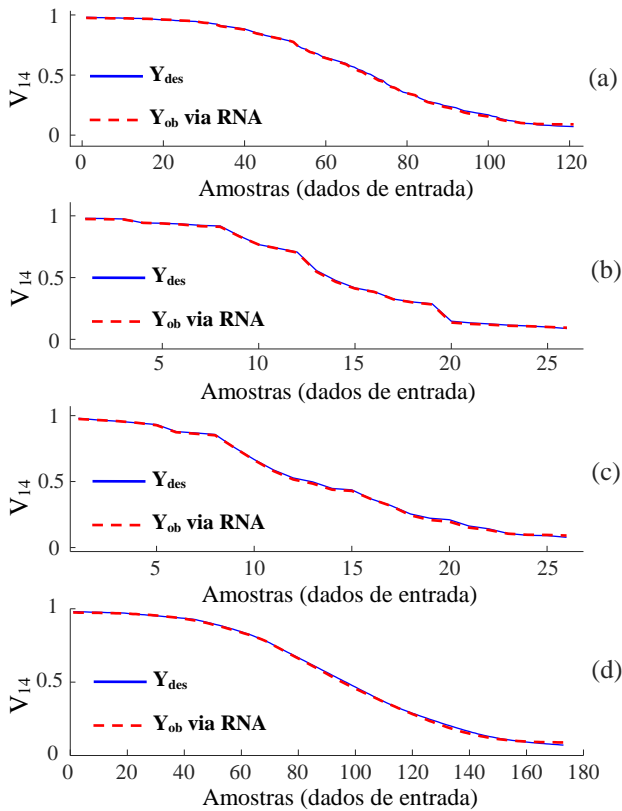


Fig. 6: Magnitude da tensão da barra crítica 14, saída desejada (Y_{des}) vs saída obtida (Y_{ob}) via RNA, (a) na fase de treinamento (70% das amostras), 121 amostras, (b) na fase de validação (15% das amostras), 26 amostras, (c) na fase de teste (15% das amostras), 26 amostras, (d) na três fases (100% das amostras), 173 amostras.

Tabela 2. Valores da magnitude de tensão obtidos no caso base e no PMC para cada barra do sistema IEEE 14-barras ($\lambda = 1.0$ e $\lambda = 1.7680$)

Barras	Valor desejado (Y_{des})		Valor obtido (Y_{ob})	
	Caso base	PMC	Caso base	PMC
1	1.0600	1.0600	1.0600	1.0600
2	1.0450	0.9067	1.0358	0.9025
3	1.0100	0.7504	0.9996	0.7429
4	1.0249	0.7610	1.0198	0.7580
5	1.0271	0.7911	1.0210	0.7860
6	1.0224	0.6945	1.0148	0.6945
7	1.0074	0.7358	1.0041	0.7439
8	1.0477	0.7893	1.0434	0.7936
9	1.0000	0.6806	0.9977	0.6797
10	0.9961	0.6623	0.9924	0.6673
11	1.0055	0.6686	1.0009	0.6694
12	1.0063	0.6518	0.9992	0.6488
13	1.0007	0.6393	0.9997	0.6408
14	0.9813	0.6064	0.9755	0.6000

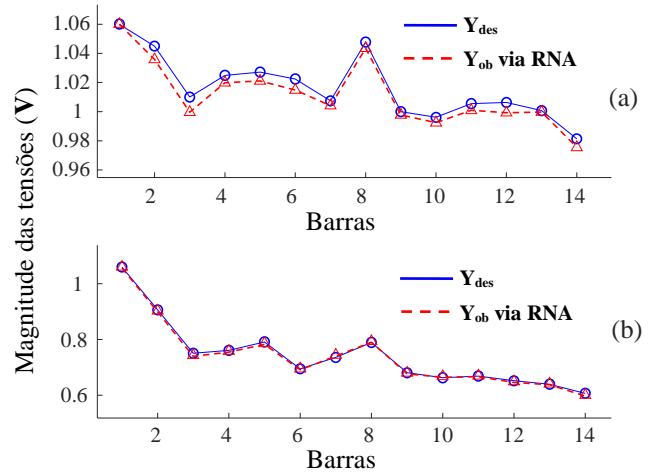


Fig. 7: Valores desejados e obtidos via RNA das magnitudes das tensões no, (a) caso base, (b) PMC.

Tabela 3. Porcentagem de erro para a magnitude da tensão no PMC entre as saídas desejadas e obtidas no sistema IEEE 14-barras

Barras	Valor desejado (Y_{des})	Valor obtido (Y_{ob})	$ Y_{des} - Y_{ob} $	% de erro
1	1.0600	1.0600	0.0000	0.00%
2	0.9067	0.9025	0.0042	0.42%
3	0.7504	0.7429	0.0075	0.75%
4	0.7610	0.7580	0.0030	0.30%
5	0.7911	0.7860	0.0051	0.51%
6	0.6945	0.6945	0.0000	0.00%
7	0.7358	0.7439	0.0081	0.81%
8	0.7893	0.7936	0.0043	0.43%
9	0.6806	0.6797	0.0009	0.09%
10	0.6623	0.6673	0.0050	0.50%
11	0.6686	0.6694	0.0008	0.08%
12	0.6518	0.6488	0.0030	0.30%
13	0.6393	0.6408	0.0015	0.15%
14	0.6064	0.6000	0.0064	0.64%
Média			0.003557	0.3557%

6. CONCLUSÕES

Este trabalho apresentou uma metodologia, via redes neurais artificiais, para obtenção das magnitudes das tensões, bem como as curvas P-V completas de sistemas elétricos de potência em função do fator de carregamento λ , potências ativa e reativa geradas na barra de referência (P_g^{slack} e Q_g^{slack}) e as perdas totais de potência ativa e reativa (P_a e Q_a) do sistema. Dos resultados, observa-se que a rede teve um bom treinamento, com MSE em 0.0000385 na sexta iteração, o tempo de treinamento foi de 3 segundos e o valor de R para o treinamento foi de 0.99969, mostrando que a saída desejada ficou bem próxima à obtida. Nas fases de validação e de teste, para amostras que não fizeram parte do treinamento, os resultados para o MSE foram 0.00003232 e 0.000040978, respectivamente, abaixo do especificado de 0.0001, acarretando numa margem de carregamento bem próxima a

desejada. Em geral, a média de erro para a magnitude da tensão no PMC foi de 0.3%. Pretende-se utilizar a RNA para estimar os perfis das tensões em sistemas contingenciados.

AGRADECIMENTOS

Agradecemos a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) – processo 2018/12353-9 e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) – processo 408630/2018-3.

REFERÊNCIAS

- Aydin, F. and Gümüş, B. (2020). Study of Different ANN Algorithms for Voltage Stability Analysis, *Innovations in Intelligent Systems and Applications Conference (ASYU)*, pp. 1-5.
- Balasubramanian, R. and Singh, R. (2011). Power system voltage stability analysis using ANN and Continuation Power Flow Methods, *16th International Conference on Intelligent System Applications to Power Systems*, pp. 1-7.
- Bompard, E., Huang, T., Wu, Y. and Cremenescu, M. (2013). Classification and trend analysis of threats origins to the security of power systems, *International Journal of Electrical Power & Energy Systems*, vol. 50, pp. 50-64.
- Bonini Neto, A., Magalhães, E.M. and Alves, D.A. (2018). Geometric Parameterization Technique for Continuation Power Flow Based on Quadratic Curve, *Electric Power Comp. and Syst.*, vol. 45, no. 17, pp. 1905-1917.
- Dinavahi, V.R. and Srivastava, S.C. (2001). ANN based voltage stability margin prediction, in Proc. *IEEE PES General Meeting*, Jul. vol. 2, pp. 1275–1280.
- Haykin, S. (2008). *Neural networks and learning machines*, Prentice-Hall, 2008, 3rd. edition.
- Huang, G.B.; Zhu, Q.Y. and Siew, C.K. (2006). Extreme learning machine: theory and applications, *Neurocomputing*, Vol. 70, No. 1, pp. 489–501. Doi:10.1016/j.neucom.2005.12.126.
- Kamalasadan, S., Srivastava, A.K. and Thukaram, D. (2006). Novel algorithm for online voltage stability assessment based on feed forward neural network,” in Proc. *IEEE PES General Meeting*, Jun. 18–22.
- Mathworks. Disponível em: <<http://www.mathworks.com>>. Acesso em: 02 de março de 2021.
- Operador Nacional do Sistema Elétrico – ONS. PEN 2020. Sumário Executivo. Plano de Operação Energética 2020/2024. Disponível em: <http://www.ons.org.br/paginas/conhecimento/acervo-digital/documentos-e-publicacoes> Acesso em 11 nov. 2021.
- Werbos, P.J. (1974). Beyond regression: new tools for prediction and analysis in the behavioral sciences, Ph.D. Thesis. Harvard University, Harvard.
- Zhang, R., Xu, Y., Dong, Z.Y., Zhang, P. and Wong, K.P. (2013). Voltage stability margin prediction by ensemble based extreme learning machine, *IEEE Power & Energy Society General Meeting*, pp. 1-5.
- Zhou, D.Q., Annakkage, U.D. and Rajapakse, A.D. (2010). Online monitoring of voltage stability margin using an artificial neural network, *IEEE Trans. Power Syst.*, vol. 25, no. 3, pp. 1566-1574.