

Estimativa da Magnitude das Tensões Via Rede Neural Artificial para o Fluxo de Carga Continuado Aplicado em Sistema Contingenciado

A. Bonini Neto¹, C. C. de Oliveira², D. A. Alves³, C. R. Minussi⁴

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

²Instituto Federal do Amapá – IFAP – Centro de Referência Pedra Branca do Amapari,
Macapá (e-mail: cout_cris@yahoo.com.br).

³Faculdade de Engenharia de Ilha Solteira (FEIS), Universidade Estadual Paulista (UNESP),
Ilha Solteira, SP, Brasil (e-mail: dilson.alves@unesp.br)

⁴Faculdade de Engenharia de Ilha Solteira (FEIS), Universidade Estadual Paulista (UNESP),
Ilha Solteira, SP, Brasil (e-mail: carlos.minussi@unesp.br)

Abstract: This work presents an approach using artificial neural networks (ANN) to obtain complete P-V curves of electrical power systems subjected to contingency. The differential of this methodology is in the speed in obtaining all the P-V curves of the system, under normal operating conditions or with contingencies. The great advantage of using ANN models is that they can capture the nonlinear characteristics of the studied system to avoid iterative procedures. From the results, the ANN performed well, with mean squared error in training below the specified value. From the samples that were not part of the training, the network was able to estimate 98% of the voltage magnitude values within the established range, with residues around 10^{-3} and a percentage of success between the desired and obtained output of approximately 97.3%.

Resumo: Este trabalho apresenta uma abordagem utilizando redes neurais artificiais para obtenção de curvas P-V completas de sistemas elétricos de potência submetidos a contingência. O diferencial desta metodologia está na rapidez na obtenção de todas as curvas P-V do sistema, em condições normais de operação ou contingenciado. A grande vantagem de usar os modelos de RNA é que eles podem capturar as características não lineares do sistema estudado para evitar procedimentos iterativos. 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 98% dos valores das magnitudes das tensões dentro da faixa estabelecida, com resíduos em torno de 10^{-3} e percentual de acerto entre a saída desejada e obtida de 97.3%, aproximadamente.

Keywords: Continuation power flow; artificial intelligence; contingencies; P-V curves; mathematical modeling

Palavras-chaves: Fluxo de carga continuado; inteligência artificial; contingências; modelagem matemática; curvas P-V.

1. INTRODUÇÃO

Eletricidade é um benefício indispensável ao redor do mundo e a continuidade e a qualidade no fornecimento é fundamental para nossa qualidade de vida (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 os sistemas elétricos 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 vem da energia hidráulica (ONS, 2020).

Sistemas que operam próximos de seus limites operacionais, estão sujeitos a ocorrência de um maior número de contingências. Nesse contexto, a análise de segurança é fundamental para identificar as contingências que podem afetar o sistema. Um sistema elétrico é submetido a uma grande quantidade de contingências, mas poucas são severas o suficiente para causar a instabilidade do mesmo (Matarucco et. al. 2014).

A análise de estabilidade estática de tensão, as quais envolvem as curvas P-V e Q-V para obtenção da margem de carregamento é a principal ferramenta nos estudos de contingências. O fluxo de carga continuado (FCC) com técnicas de parametrizações (Tostado-Véliz et. al. 2020), (Bonini Neto et. al. 2018) e (Canossa et. al. 2018) são os métodos utilizados para obtenção dessas curvas, os quais conseguem obter toda a curva P-V devido a utilização do parâmetro adequado.

Sabe-se que Western System Coordinating Council (WSCC, 1998) exige de suas empresas uma margem segura de carregamento de 5% para a potência ativa em qualquer contingência simples (N-1), para contingências duplas (N-2) a margem de carregamento é de 2.5% para a potência ativa.

Esses processos motivaram o setor elétrico a investirem 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 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.

Neste contexto, esse trabalho apresenta uma abordagem diferente em relação aos trabalhos comentados anteriormente para obtenção das curvas P-V de pré e pós contingência. É proposto a utilização de redes neurais artificiais (RNA) para estimar a magnitude das tensões e consequentemente a margem de carregamento em um sistema não apenas em condições normais de operação, e sim, submetido a uma contingência, simples ou severa.

2. METODOLOGIA

O sistema estudado nesse trabalho corresponde à configuração IEEE 14-barras, apresentado na Fig. 1. As 1890 amostras utilizadas para treinamento, validação e teste foram obtidas com o método apresentado em Bonini Neto et al. (2018). Cada amostra é composta por 18 dados, os de entrada da RNA (4 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 o número do ramo (linhas de transmissão ou transformadores) e os dados de saída (14 dados) representados pelas magnitudes das tensões de todas as barras do sistema.

O sistema IEEE 14 -barras apresenta 20 ramos, conforme apresentado na Fig. 1. Foram obtidas 90 amostras para cada ramo retirado do sistema, representando a contingência aplicada. Ao retirar o ramo 1 (r1) do sistema, o mesmo é submetido a uma contingência severa N-2 (contingência dupla) acarretando em uma redução drástica na margem de

carregamento do sistema, conforme mostrado nos resultados. As demais contingências são consideradas simples (N-1). Neste trabalho, o símbolo N-0 é considerado o sistema sem contingência, ou seja, curva P-V de pré contingência (r0).

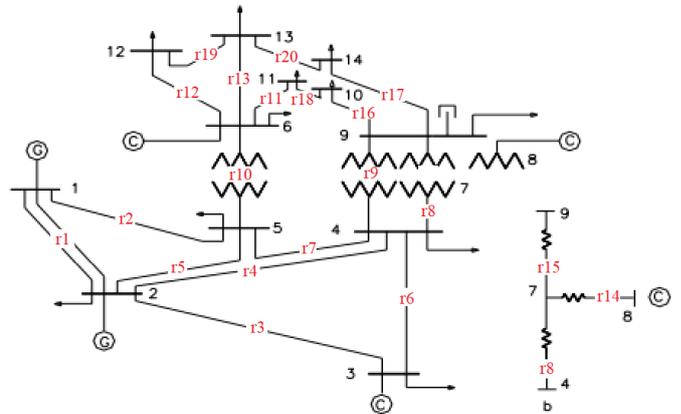


Fig. 1. Sistema IEEE 14 - barras com os respectivos ramos r .

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 4 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).

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 a 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.

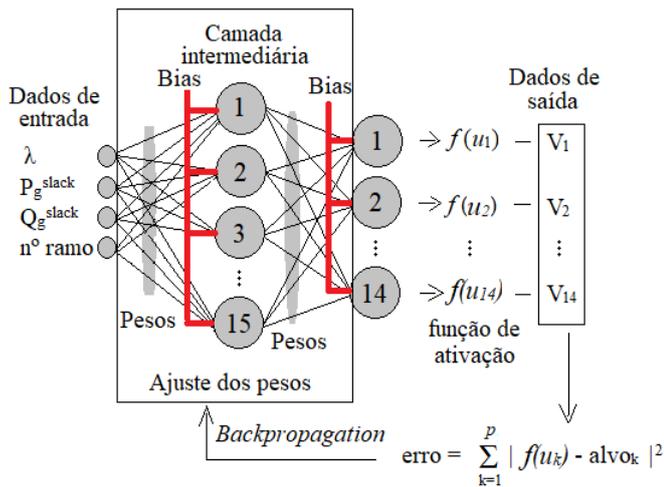


Fig. 2. RNA utilizada neste trabalho.

3. RESULTADOS

A Tabela 1 e as Figs. 3, 4 e 5 apresentam resultados das 1890 amostras para o treinamento, validação e teste na configuração de 1322 amostras para o treinamento (70%), 284 amostras para validação (15%) e 284 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 30ª iteração, com valor de treinamento em 0.0009854 e 7 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 grande vantagem de usar os modelos de RNA é que eles podem capturar as características não lineares do sistema estudado para evitar procedimentos iterativos.

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

Treinamento (70%)		
	Valores especificados	Valores alcançados
Iterações	100	30
Tempo (segundos)	20	7
Performance (MSE)	0.001	*0.0009854
Regressão R	1.0	0.98894
Validação (15%)		
Validação checada	10	0
Performance (MSE)	0.001	0.0010816
Regressão R	1.0	0.98885
Teste (15%)		
Performance (MSE)	0.001	*0.00090737
Regressão R	1.0	0.99005
Geral (100%)		
Regressão R	1.0	0.98909

* critério alcançado

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 1890 amostras (14x1890 dados), 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).

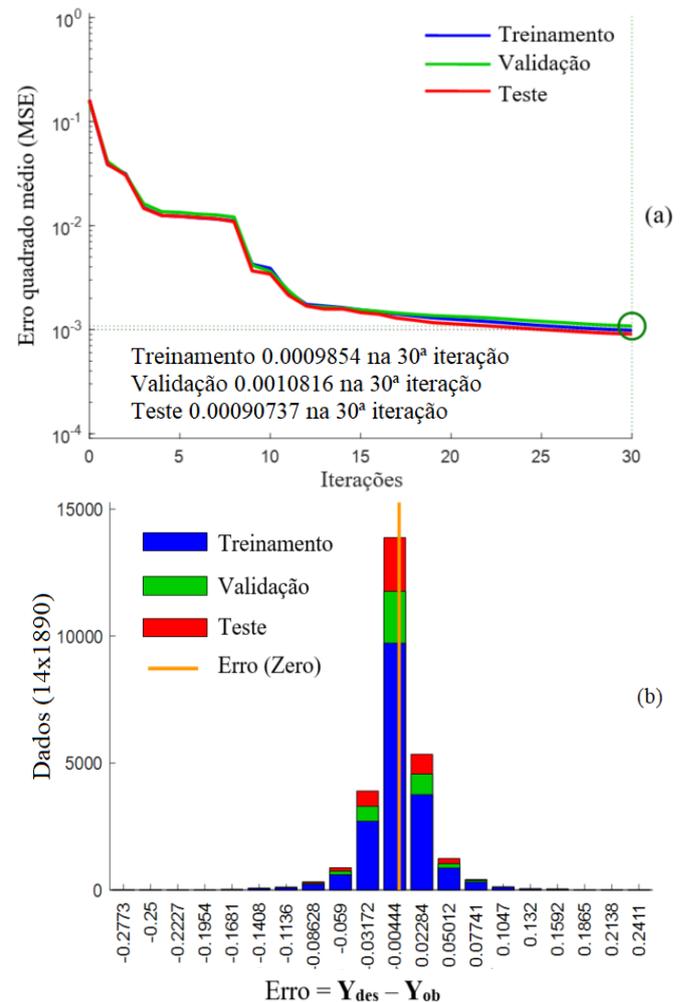


Fig. 3. Treinamento, validação e teste da RNA, (a) performance (MSE), (b) histograma do erro ($Y_{des} - Y_{ob}$) com 20 intervalos para as 1890 amostras.

A Fig. 4 apresenta as retas de regressão (ajustes) e os valores de R (correlação) para as três fases da rede. Na Fig. 4(a), a reta de ajuste $Y_{ob} \approx 0.98 Y_{des} + 0.016$ ficou bem próxima ao esperado ($Y_{ob} = Y_{des}$) com o valor de R em 0.98894 mostrando que a rede ficou bem treinada e não houve discrepância entre os valores desejados e obtidos na classificação das 1322 amostras na fase de treinamento (em torno de 98% de correlação da saída Y_{ob} em relação a saída Y_{des}). Já as Figs. 4(b), (c) e (d) apresentam as retas de ajuste e os valores das correlações entre as duas saídas nas fases de validação, teste e para 100% das amostras (três fases juntas), com valores em 0.98885, 0.99005 e 0.98909 respectivamente para R.

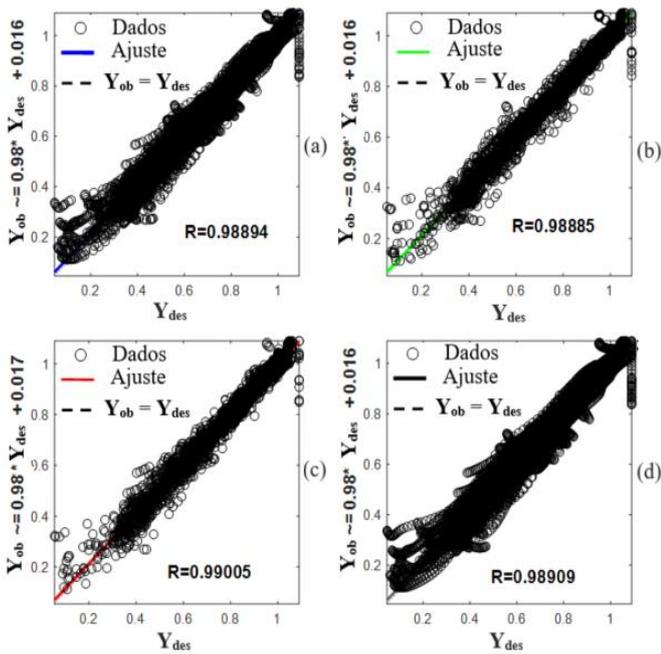


Fig. 4. Análise de regressão entre as variáveis: saída desejada (Y_{des}) e saída obtida (Y_{ob}), (a) treinamento com 70% das amostras, (b) validação com 15% das amostras, (c) teste com 15% das amostras e (d) todas as amostras (100%).

A Fig. 5 apresenta os valores da magnitude das tensões de pré contingência r_0 e para todas as 20 contingências ($r_1, r_2, r_3, \dots, r_{20}$) do sistema IEEE 14 barras, ou seja, as saídas desejada (Y_{des}) e obtida (Y_{ob}) nas três fases da rede (100% das amostras) 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 o número do ramo. Pode-se notar a similaridade entre as saídas, com alguns pequenos pontos de erros, por exemplo na barra 8, nas contingências r_{14} e r_{15} . Os valores dos pontos de máximo carregamento (PMC) bem como a diferença entre as saídas desejadas e obtidas são apresentados na Tabela 2, onde a média do erro no PMC foi de 0.0266, ou seja, 2.66%.

Os valores das magnitude das tensões para cada fase da RNA, podem ser vistos na Fig. 6, em que, nesta fase, considerada a mais importante do processo, ou seja, a fase que a rede aprende a dar respostas baseada na saída desejada (alvo a ser seguido) inserida a mesma, é que ela torna apta a estimar dados que não fizeram parte do treinamento. Neste trabalho foi utilizado a configuração 70%, 15% e 15% para especificar o número de amostras para cada fase da rede. Por exemplo, a Fig. 6(a) e (d), onde é apresentado os valores das magnitude das tensões nas barra de geração 2 e carga 14 na fase de treinamento para 70% das amostras (1322). Nota-se uma boa similaridade entre as saídas.

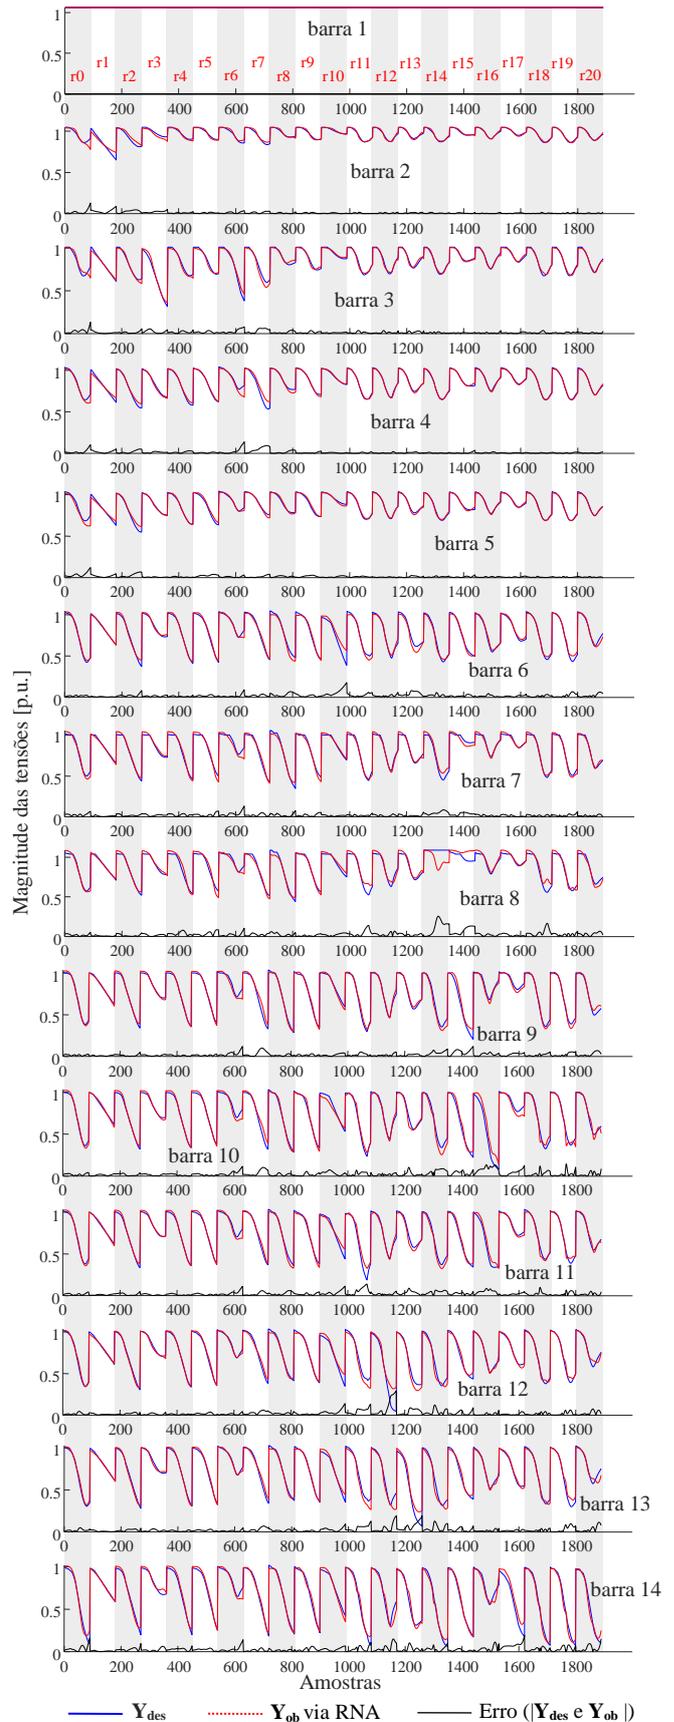


Fig. 5. Magnitude das tensões de todas as barras do sistema para todas as contingências aplicadas (todas as 1890 amostras), saída desejada (Y_{des}) vs saída obtida (Y_{ob}) via RNA.

Uma vez a rede treinada, agora ela está apta a fazer o diagnóstico, classificar ou estimar dados que não fizeram parte do treinamento, neste caso, as fases de validação e teste são apresentadas na Fig. 6(b) e (c) para a barra de geração 2 e Fig. 6(e) e (f) para a barra de carga 14. Observa-se agora, que foram utilizados 15% das amostras para cada fase (284 amostras), lembrando que estas amostras não fizeram parte do treinamento da rede e mesmo nas fases de validação e teste, pode-se notar uma similaridade entre as saídas desejadas (Y_{des}) e obtidas (Y_{ob}) via RNA, mostrando que a rede teve um bom treinamento (MSE de 0.0009854). Os MSE apresentados nas fases de validação e teste foram 0.0010816 e 0.00090737 respectivamente.

Tabela 2. Valores da magnitude das tensões dos PMC da barra 14 obtidos via RNA para cada contingência

Contingências	λ	$V_{14} (Y_{des})$	$V_{14} (Y_{ob})$	$ Y_{des} - Y_{ob} $
r0	1.7680	0.6063	0.5854	0.0209
r1	0.9810	0.8348	0.8563	0.0215
r2	1.3970	0.6448	0.6495	0.0047
r3	1.2991	0.7828	0.8063	0.0235
r4	1.5872	0.6266	0.6111	0.0155
r5	1.6600	0.6059	0.6040	0.0019
r6	1.7166	0.6804	0.6759	0.0045
r7	1.5924	0.6415	0.6296	0.0101
r8	1.5685	0.6488	0.6318	0.0170
r9	1.6789	0.6065	0.5981	0.0084
r10	1.3421	0.7023	0.6932	0.0091
r11	1.7508	0.6068	0.6019	0.0049
r12	1.7433	0.6160	0.6364	0.0204
r13	1.6611	0.5924	0.6371	0.0447
r14	1.6792	0.5879	0.6246	0.0367
r15	1.4666	0.6319	0.6715	0.0396
r16	1.7213	0.6556	0.6319	0.0237
r17	1.6181	0.5287	0.6619	0.0932
r18	1.7656	0.6141	0.5947	0.0194
r19	1.7666	0.6133	0.5675	0.0458
r20	1.7478	0.5830	0.5308	0.0522

A Fig. 7 apresenta a curva P-V de pré contingência e as curvas P-V de pós contingências para todas as barras e contingências do sistema. Por exemplo, no primeiro plano, há duas curvas P-V de pré contingência (desejada - Y_{des} e obtida - Y_{ob} via RNA) e 14 curvas P-V de pós contingência, todas obtidas via RNA ao aplicar a contingência r1 (saída da LT entre as barras 1 e 2, contingência N-2). Os demais planos da Fig. 7 apresentam as curvas P-V para as outras 19 contingências N-1 do sistema.

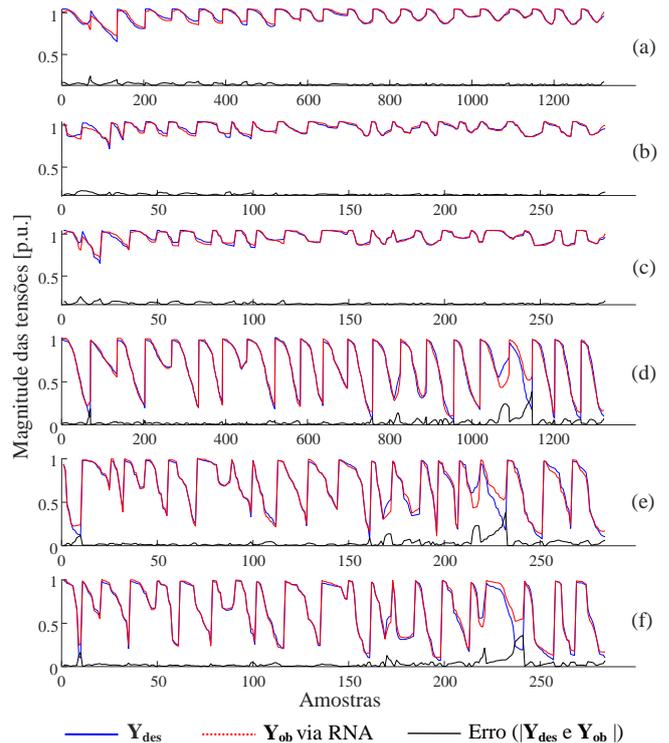


Fig. 6. Magnitude das tensões das barras de geração 2 e carga 14, para todas as contingências aplicadas, (a) fase de treinamento (70% das amostras - 1322) da barra 2, (b), fase de validação (15% das amostras - 284) da barra 2, (c) fase de teste (15% das amostras - 284) da barra 2, (d) fase de treinamento (70% das amostras - 1322) da barra 14, (e) fase de validação (15% das amostras - 284) da barra 14, (f) fase de teste (15% das amostras - 284) da barra 14.

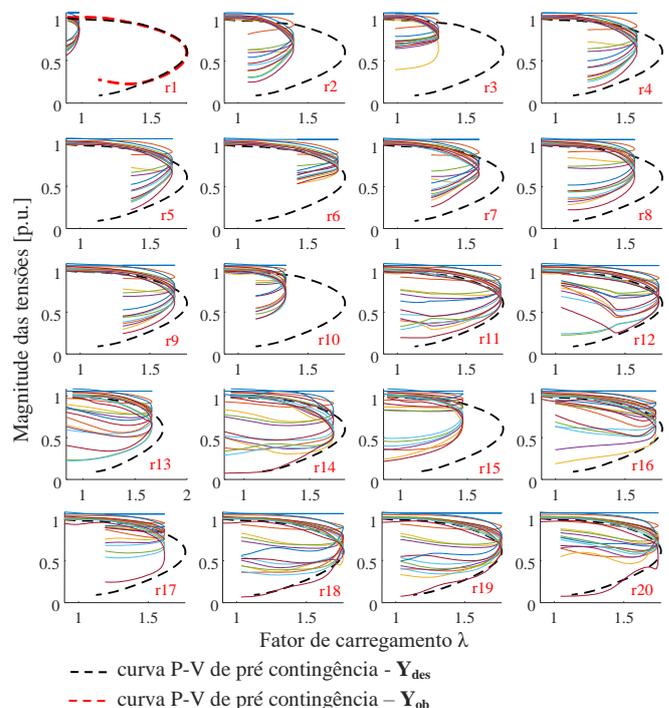


Fig. 7. Saída obtida (Y_{ob}) via RNA, curvas P-V para todas as contingências r do sistema.

A Fig. 8, apresenta a curvas P-V da barra crítica 14 para todas as contingências do sistema IEEE 14 barras e, pode-se observar a similaridade entre as saídas desejada (Y_{des}) e obtida (Y_{ob}) pela RNA.

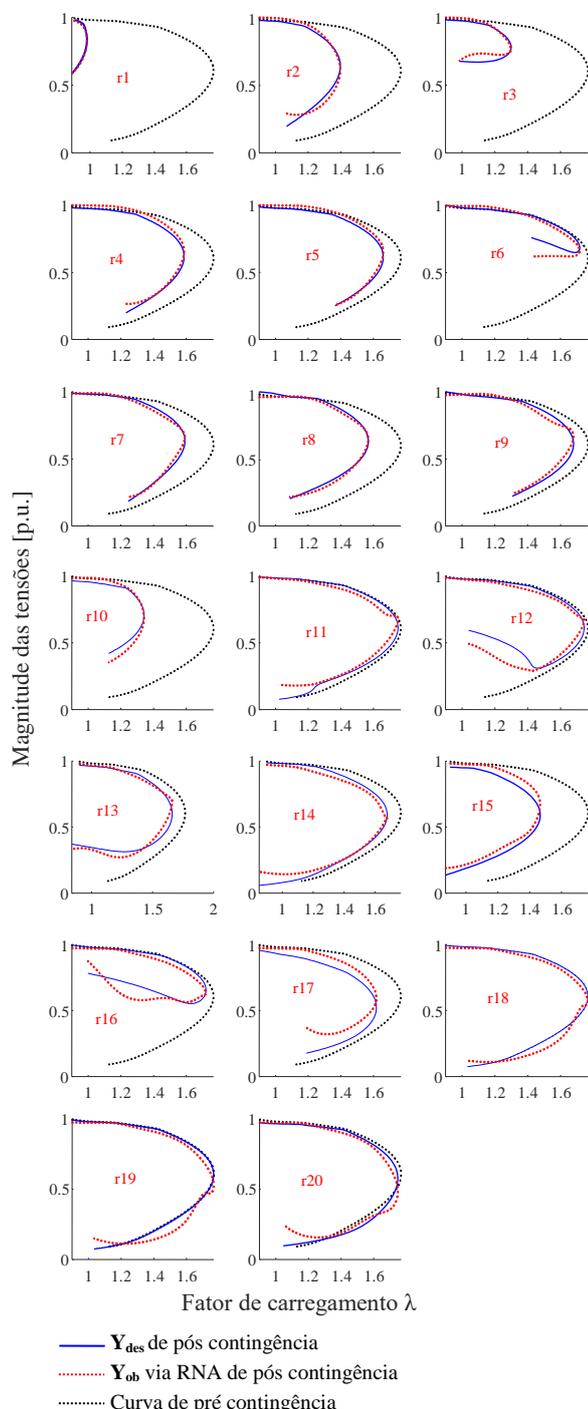


Fig. 8. Saída desejada (Y_{des}) e saída obtida (Y_{ob}) pela RNA do sistema IEEE 14-barras, curvas P-V para todas as contingências r do sistema da barra de carga 14.

Por exemplo, se observar o primeiro plano relativo a contingência r_1 , há três curvas apresentadas, uma corresponde a curva P-V de pré contingência (N-0) e as outras duas de pós contingência (Y_{des} e Y_{ob}). A contingência r_1 correspondente a saída da linha de transmissão entre as barras 1 e 2 (N-2), ver Fig. 1, nota-se uma redução drástica na margem de carregamento, menor que o valor correspondente ao caso base, com valor de (λ, V_{14}) no PMC de pós contingência em (0.9810, 0.8563) obtido pela RNA, conforme Tabela 2. O erro na obtenção desse ponto se comparado ao valor desejado foi de 2.15%, ou seja, 0.0215. Para outro exemplo, no caso o segundo plano relativo a contingência r_2 (saída da LT entre as barras 1 e 5) da Fig. 8, o valor do PMC obtido pela RNA foi de $(\lambda, V_{14}) = (1.3970, 0.6495)$, neste caso o erro calculado na obtenção desse ponto se comparado a saída desejada foi de 0.0047, (0.47%), mostrando que a rede neural artificial teve um bom treinamento. Conforme comentado anteriormente, a média do erro na obtenção de todos os PMC se comparado a saída desejada, foi de 0.0266, ou seja, 2.66% para todas as contingências aplicadas.

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 submetido a uma contingência em função do fator de carregamento λ , potências ativa e reativa geradas na barra de referência (P_g^{slack} e Q_g^{slack}) e o número do ramo. Dos resultados, observa-se que a rede teve um bom treinamento, com MSE em 0.0009854 na trigésima iteração, o tempo de treinamento foi de 7 segundos e o valor de R para o treinamento foi de 0.98894, 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 0.0010816 e 0.00090737, respectivamente, abaixo do especificado de 0.001, exceto a validação que ficou muito próximo, 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%.

AGRADECIMENTOS

Agradecemos a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) – processo 2018/12353-9, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), ao processo 408630/2018-3 do CNPq e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

- Aydin, F., Gümüş, B. (2020). Study of Different ANN Algorithms for Voltage Stability Analysis, Innovations in Intelligent Systems and Applications Conference (ASYU), pp. 1-5.
- Bompard, E., Huang, T., Wu, Y., 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., Piazzentin, J. C., Alves, D. A. (2018). Vandermonde Interpolating as Nonlinear Predictor Applied to Continuation Method. *IEEE Latin America Transactions*, vol. 16, no. 12, pp. 2954-2962.

Canossa, J. H. Bonini Neto, A., Alves, D. A., Putti, F. F., Gabriel Filho, L. R. A. (2018). Development of an Interactive Program to Study of the Continuation Power Flow," *IEEE Latin America Transactions*, vol. 16, no. 4, pp. 1227-1235.

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.

Matarucco, R. R., Bonini Neto, A., Dilson, D. A. (2014). Assessment of branch outage contingencies using the continuation method. *International Journal of Electrical Power & Energy Systems*, vol. 55, pp. 74-81.

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/AcervoDigitalDocumentosEPublicacoes/ONS_PEN2020_24_final%20\(6\).pdf](http://www.ons.org.br/AcervoDigitalDocumentosEPublicacoes/ONS_PEN2020_24_final%20(6).pdf). Acesso em 17 jun. 2020.

Tostado-Véliz, M., Kamel, S., Jurado, F. (2020). Development and Comparison of Efficient Newton-Like Methods for Voltage Stability Assessment. *Electric Power Components and Systems*, vol. 48, pp. 1798-1813.

Werbos, P.J. (1974). *Beyond regression: new tools for prediction and analysis in the behavioral sciences*, Ph.D. Thesis. Harvard University, Harvard.

Western System Coordinating Council (WSCC) (1998). Reactive Power Reserve Work Group. Final Report, Voltage Stability Criteria, Undervoltage Load Shedding Strategy, and Reactive Power Reserve Monitoring Methodology, May, 154p.

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.