

ESTABILIZADOR DE SISTEMA DE POTÊNCIA AJUSTADO POR REDES NEURAIAS

EDWARD, DANIEL, L. F.

*Departamento de Engenharia Elétrica, Centro de Tecnologia, Universidade Federal do Ceará
Campus do Pici, Caixa Postal 6001 – CEP 60455760 – Fortaleza-CE
E-mails: edwardlennon@gmail.com*

FRANCIS, SOUZA, M. F.

JOSÉ, SILVA JUNIOR, N. R.

MARCELO, FALCUCCI

JOSÉ, NASCIMENTO, A.

JOSÉ, CAMPOS, C. T.

ARTHUR, BRAGA, P. S.

*Departamento de Engenharia Elétrica, Centro de Tecnologia, Universidade Federal do Ceará
Campus do Pici, Caixa Postal 6001 – CEP 60455760 – Fortaleza-CE*

*E-mails: francismarry@yahoo.com.br,
nilorjunior@yahoo.com.br, mfaluccci@endesabr.com.br, almeida@dee.ufc.br,
teles@ufc.br, arthurb@dee.ufc.br*

Abstract— This paper presents a parameter tuning to Power System Stabilizers using artificial neural networks; Multi Layer Perceptron and Radial Basis Function are used. The neural networks use its searches the better dynamic stability performance of the electric power systems through of the better damping oscillation when a disturbance occurs. The PSS parameters are automatically adjusted by the neural network in sense to give a satisfactory control when some variation in current plant operating conditions occurs. Simulations were used to verify the model performance proposed. The simulations were based in nonlinear dynamic model with a machine connected in an infinite bus. The modeling proposed confirm your efficiency through simulation results, which the dynamic performance was improved.

Keywords— Power System Stabilizer, PSS, Neural Network, RBF, MLP.

Resumo— Este trabalho propõe um ajuste de parâmetros para os Estabilizadores de Sistemas de Potência utilizando redes neurais artificiais, *Multi Layer Perceptron* e *Radial Basis Function*. A utilização dessas redes neurais busca o aprimoramento da estabilidade dinâmica em sistemas elétricos de potência através do melhor amortecimento das oscilações eletromecânicas da máquina quando submetida a perturbações. Os parâmetros do estabilizador passam a ser ajustados automaticamente pelas redes neurais de modo a manter satisfatório o desempenho do sistema de controle quando existirem variações nas condições operacionais da planta. Simulações foram utilizadas na análise do desempenho da modelagem proposta. As simulações basearam-se em modelo dinâmico não linear com uma máquina conectada a uma barra infinita. A modelagem proposta confirma sua eficiência através dos resultados das simulações, nas quais são obtidas melhorias no desempenho.

Palavras-chave— Estabilizador do Sistema de Potência, Redes Neurais, RBF, MLP.

1 Introdução

O comportamento dinâmico das máquinas em sistemas de potência é de importância fundamental para o desempenho e continuidade do fornecimento de energia, este comportamento determinará o estudo da estabilidade do sistema.

A estabilidade dinâmica está relacionada com as oscilações eletromecânicas de baixa frequência, que quando mal amortecidas, são prejudiciais ao sistema elétrico, haja vista que elas podem causar a perda de sincronismo dos geradores. A utilização de Estabilizadores de Sistemas de Potência (*Power System Stabilizers* - PSS) para a melhoria da estabilidade dinâmica dos sistemas de potência tem recebido maior atenção nessa última década (Kundur, 1994).

Os ajustes dos parâmetros utilizados nesses controladores são determinados com base em um modelo linearizado do sistema ao redor de um ponto nominal de operação. Com isso, o desempenho do PSS convencional se degrada de acordo com as mudanças desse ponto de operação (Anderson, 1994).

Diversas técnicas tais como controle adaptativo têm sido propostas como solução do problema (Ghahra, 1988), (Xia, 1983). Porém, a maioria dos controles adaptativos é baseada na identificação de parâmetros do modelo do sistema em tempo real, o que consome muito tempo. Técnicas como controle robusto, lógica fuzzy e projeto de PSS baseado em Lyapunov também são outras alternativas para tratar o problema (Swarzewicz, 2001), (Arrifano, 2004), (Robak, 2001) (You, 2003), (Yadiah, 2004). Entretanto, suas

suas respostas são lentas e as aplicações em tempo real são limitadas.

Neste artigo são propostas duas formas de ajustes dos parâmetros para o PSS através de duas redes neurais: a MLP (*Multi Layer Perceptron*) e a RBF (*Radial Basis Function*). A utilização de uma rede neural para ajuste de parâmetros torna possível a implementação prática do método e a adequação dos parâmetros para os diferentes pontos de operação. A vantagem da rede neural está nos diversos pontos de operações utilizados já que opera com dados imprecisos e situações não totalmente definidas.

2 Descrição do Sistema

O incentivo a novas fontes de geração de energia elétrica contribuiu para aumentar a utilização do gás natural. As usinas termelétricas se beneficiam da tecnologia do ciclo combinado para melhor aproveitar o gás natural e conseqüentemente aumentar o rendimento das mesmas.

Uma usina termelétrica a ciclo combinado tem associadas à mesma planta turbinas a gás e a vapor gerando energia elétrica através de um processo que combina a operação do ciclo Brayton (duas turbinas a combustão) e do ciclo Rankine (turbinas a vapor gerando pela recuperação de energia dos produtos de combustão).

A termelétrica em estudo possui uma potência instalada de 310,7MW, sendo composta por: (i) duas turbinas a gás, cada uma com potência nominal de 112,8MW, (ii) uma turbina a vapor com potência nominal de 113,1MW, (iii) duas caldeiras de recuperação de calor, (iv) dois conjuntos geradores de 133,8MVA e (v) um conjunto gerador com potência nominal de 147MVA (Souza, 2006).

O processo inicia-se com o ar atmosférico sendo sugado pelos compressores das turbinas de combustão. O ar é comprimido, misturado com o gás natural, e em seguida esta mistura é queimada. Este processo origina gases a altas temperaturas e pressões que são enviados para a turbina responsável por converter a energia térmica em mecânica.

O gerador elétrico acoplado ao eixo da turbina converte a energia mecânica em elétrica. O processo, até esta etapa, caracteriza-se como geração de energia por ciclo simples.

Após a expansão dos gases, eles são enviados para as caldeiras de recuperação, onde se aproveitará o calor dos gases quentes provenientes das turbinas a gás para gerar o vapor que movimentará a turbina a vapor. Ao sair da turbina, o vapor é condensado e retorna para as caldeiras de recuperação, fechando o ciclo. Esta turbina converte a energia armazenada no vapor em alta pressão e temperatura em energia de rotação, que é transformada em energia elétrica pelo gerador.

A figura 1 representa a máquina de forma simplificada. O regulador de tensão controla a excitação do

gerador para que a tensão gerada e a potência reativa variem de acordo com o desejado.

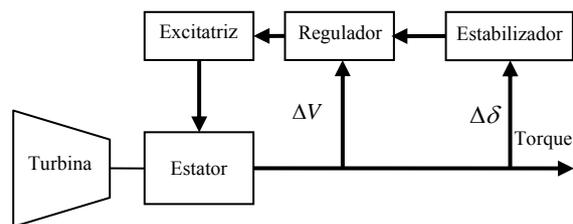


Figura 1. Representação da Máquina em Diagrama de Blocos.

A finalidade do Estabilizador é usar a excitação do gerador para melhor regular as oscilações de potência, aumentando a estabilidade do gerador e melhorando o sistema de transmissão como um todo (Kundur, 1994). O PSS opera via regulador de tensão do gerador, influenciando seu ponto de ajuste.

3 Modelagem Convencional de Parâmetros

Os parâmetros do estabilizador são ajustados fazendo uso do modelo linearizado de 3ª ordem encontrado na literatura e mostrado na Fig. 2. O modelo baseia-se numa máquina ligada à barra infinita através de uma impedância equivalente em torno de um ponto fixo de operação (Anderson, 1994), (Abido, 1997).

Através desse modelo convencional são obtidos os parâmetros para diversos pontos de operação, que formarão um conjunto não-linear a ser utilizado como base para treinamento das redes neurais na abordagem proposta neste trabalho.

As equações do modelo são expressas em função das constantes K_1 a K_6 . A equação (1) representa a variação do torque elétrico ΔT_E para uma variação no ângulo do rotor $\Delta\delta$, com fluxo concatenado no eixo direto constante.

$$K_1 = \left. \frac{\Delta T_e}{\Delta\delta} \right|_{e'_q = cte} \quad (1)$$

$$= K_t V_\infty \{ V_{x0} [R_e \text{sen}\delta_0 + (x'_d + x_e) \cos\gamma] + I_{q0} (x_q - x'_d) [(x_q + x_e) \text{sen}\gamma - R_e \cos\gamma] \}$$

A equação (2) expressa a variação do torque elétrico ΔT_E para uma variação do fluxo concatenado no eixo direto $\Delta e'_q$, com ângulo do rotor δ constante.

$$K_2 = \left. \frac{\Delta T_e}{\Delta e'_q} \right|_{\delta = cte} \quad (2)$$

$$= K_t \{ R_e V_{x0} + I_{q0} [R_e^2 + (x_q + x_e)^2] \}$$

O termo seguinte refere-se à (3) e representa o fator de impedância.

$$K_3 = \frac{1}{[1 + K_i(x_d - x'_d)(x_q + x_e)]} \quad (3)$$

As constantes K_4 , K_5 e K_6 representam, respectivamente: o efeito desmagnetizador de uma variação do ângulo do rotor $\Delta\delta$, com tensão de campo E_{fd} constante; a variação da tensão terminal ΔV_t para uma variação do ângulo do rotor, com fluxo concatenado no eixo direto e_q' constante e a variação da tensão terminal com a variação de e_q' , para ângulo do rotor constante.

$$K_4 = \frac{1}{K_3} \frac{\Delta e_q'}{\Delta \delta} \Big|_{E_{fd}=cte} \quad (4)$$

$$= V_\infty K_i (x_d + x'_d) [(x_q + x_e) \text{sen} \gamma - R_e \cos \gamma]$$

$$K_5 = \frac{\Delta V_t}{\Delta \delta} \Big|_{e_q'=cte} \quad (5)$$

$$= \left(\frac{V_\infty K_i}{V_{t0}} \right) \{ x'_d V_{q0} [R_e \cos \gamma - (x_q + x_e) \dots \text{sen} \gamma] \} - (x'_d - x_e) \cos \gamma + R_e \text{sen} \gamma$$

$$K_6 = \frac{\Delta V_t}{\Delta e_q'} \Big|_{\delta=cte} \quad (6)$$

$$= \left(\frac{V_{q0}}{V_{t0}} \right) [1 - K_i x'_d (x_q + x_e)] - K_i x_q R_e \left(\frac{V_{d0}}{V_{t0}} \right)$$

$$K_i = \frac{1}{[R_e^2 + (x_q + x_e)(x'_d + x_e)]} \quad (7)$$

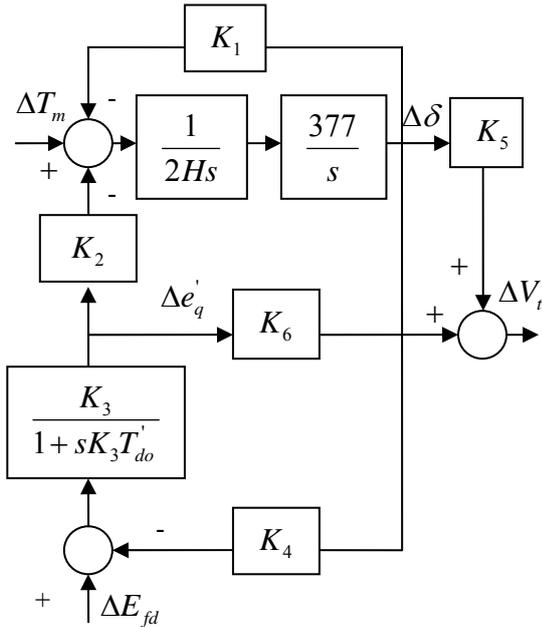


Figura 2. Diagrama de blocos do sistema máquina barra infinita.

Sendo:

V_∞ = tensão na barra infinita.

V_{x0} = tensão que define a posição do eixo e que fornece o valor inicial do ângulo de torque.

δ_0 = ângulo de torque inicial.

x_d = reatância no eixo direto.

x'_d = reatância transitória no eixo direto.

x_q = reatância no eixo de quadratura.

x'_q = reatância transitória no eixo de quadratura.

x_e = reatância própria do circuito do ferro do rotor.

γ = ângulo da admitância série equivalente menos o ângulo de torque.

I_{q0} = componente da corrente no eixo de quadratura.

V_{q0} = componente da tensão terminal do gerador no eixo de quadratura na referência da máquina.

V_{d0} = componente da tensão terminal do gerador no eixo direto na referência da máquina.

V_{t0} = tensão terminal do gerador em regime permanente (valor absoluto).

4 Estabilizador de Sistema de Potência (PSS)

Um PSS é um elemento, ou grupo de elementos, que fornece uma entrada adicional ao regulador para melhorar o desempenho dinâmico dos sistemas de potência. A principal função do sinal condicionado à rede do PSS é compensar o atraso do sistema a ser controlado (Anderson, 1994).

A compensação de fase é realizada pelo uso de funções avanço-atraso que fornece avanço de fase sobre a escala de frequência de interesse. O diagrama da Fig. 3 representa o estabilizador. O primeiro bloco representa o ganho K , o segundo bloco é um filtro washout para eliminar erros no sinal de entrada, e o terceiro bloco é um circuito avanço-atraso com constantes de tempo T_1 e T_2 .

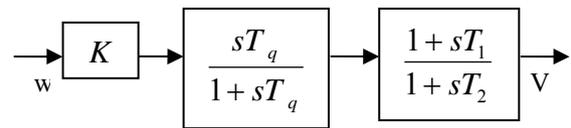


Figura 3. Diagrama de blocos do PSS.

A Tabela 1 representa os dados que serão utilizados como base para treinamento das redes neurais. Os dados de entrada composto por potência ativa (P) e reativa (Q) são condições ou pontos distintos de operações dos geradores. Portanto, com essas condições de potência, tornou-se possível a obtenção dos dados de saída através do modelo convencional do estabilizador, como mostrado na Fig. 4.

Tabela 1. Dados de Entrada e saída das redes neurais.

Entradas		Saídas	
P	Q	T ₁	T ₂
10	-17.5	1.2290	0.0132
20	-18.2	1.1354	0.0139
30	-18.8	1.0980	0.0148
40	-19.2	0.6139	0.0264
50	-19.6	0.4691	0.0346
60	-19.8	0.3834	0.0425
70	-20	0.3398	0.0478
80	-20	0.3063	0.0530
90	-19.9	0.2861	0.0567
100	-19.7	0.2686	0.0604

5 Modelagem via Redes Neurais MLP e RBF

A utilização do modelo clássico ou convencional para ajuste de parâmetros, em comparação com as redes neurais, tem como desvantagem a limitação do ajuste a apenas um ponto de operação. Logo, disporá apenas de uma frequência estabelecida. Portanto, o amortecimento poderá tornar-se ineficiente para condições diferentes das encontradas no ponto ajustado.

Dois algoritmos envolvendo redes neurais foram implementados, o da Rede Neural RBF, que é composto por uma camada intermediária e uma camada de saída, e o da Rede Neural MLP, que possui duas camadas intermediárias e uma de saída.

Diferentemente da Rede MLP, onde cada neurônio define um plano de separação e as camadas intermediárias utilizam funções de ativação sigmoideal (Sharaf, 1993), a RBF define um círculo no espaço de entrada através de uma função gaussiana.

Outra diferença entre estas redes é o fato da MLP utilizar produtos internos, enquanto a RBF utiliza distâncias. Na Rede RBF implementada, a cada dado de entrada associou-se um centro específico. Nela a ativação de um neurônio escondido foi determinada por uma função não-linear da distância entre o vetor de entrada e um vetor de referência.

A RBF tem uma arquitetura simples, consistindo de duas camadas de pesos (W_e e W_s), em que a primeira contém os parâmetros das funções de base radial e a segunda forma combinações lineares das ativações das funções de base radial para gerar a saída. Ela possui 10 neurônios na camada escondida e 2 na de saída. É treinada em 2 estágios, com as funções de base radial sendo determinadas primeiramente por técnicas não-supervisionadas, usando para tal os dados de entrada e a segunda camada (pesos), sendo posteriormente determinada por métodos lineares supervisionados, de rápida convergência.

Já a MLP possui 10 neurônios em cada camada escondida e 2 na de saída. Ela tem seu treinamento realizado através da retro-propagação do erro para as camadas intermediárias.

As redes neurais apresentadas têm como entradas e saídas os valores estabelecidos na Tabela 1. A saída ou parâmetros fornecidos pelas redes neurais são inseridos na entrada do estabilizador conforme mostrado na Fig. 4. Portanto, após o treinamento das redes, o sistema poderá operar e ter os ajustes modificados em tempo real.

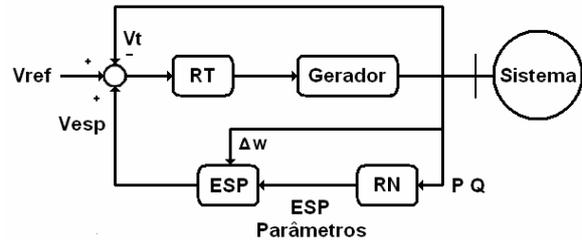


Figura 4. Diagrama de blocos do sistema com a inclusão da rede neural.

A capacidade de interpolação das redes neurais é uma característica útil ao problema tratado, uma vez que o uso de tabelas para armazenar os valores dos parâmetros T_1 e T_2 em diferentes pontos de operação seria extenso devido à infinidade de pontos situados entre dois pontos.

Esta habilidade das redes neurais as têm tornado úteis para a modelagem de sistemas não-lineares. Já que o conjunto de pontos de operações encontrados na Tabela 1 é não-linear. A característica mais significativa das redes neurais está em sua habilidade de aproximar qualquer função contínua não-linear de um grau de correção desejado.

Tabela 2. Dados para validação das redes neurais.

Entrada		Saída MLP		Saída RBF	
P	Q	T ₁	T ₂	T ₁	T ₂
55	-19.7	0.4250	0.0377	0.4142	0.0400
95	-19.8	0.2790	0.0579	0.2761	0.0588
110	-19.4	0.2515	0.0584	0.2671	0.0607

6 Resultados

O modelo matemático das máquinas e dos controladores foi incorporado ao programa ANATEM (Análise de Transitórios Eletromecânicos), no qual foram realizadas simulações que serviram para a composição da base de dados utilizada no treinamento e validação das redes neurais.

As redes neurais MLP e RBF foram projetadas para convergência com erro máximo de 0.00001. A MLP apresentou convergência em 10 iterações e a RBF em 8 iterações. Os dados obtidos pelas redes estão ilustrados na Tabela 2.

Foi aplicado um degrau de 2% na carga e simulado o sistema em três situações (Figura 5): (i) sem o estabilizador, (ii) utilizando o estabilizador ajustado

em campo e (iii) utilizando o estabilizador com parâmetros projetados.

Como pode ser verificado pelas curvas, o sistema sem o estabilizador é bastante oscilatório, o que pode levar a perda de sincronismo da máquina. Com o PSS pode-se observar a vantagem em se utilizar o ajuste de parâmetros utilizando redes neurais pelo maior amortecimento, em detrimento dos parâmetros obtidos através do modelo convencional.

As Figuras 6, 7, e 8 mostram a influência dos ajustes para dois pontos de operação. À medida que o parâmetro fixo calculado para potência nominal se afasta da mesma, o ajuste dos parâmetros pelas redes

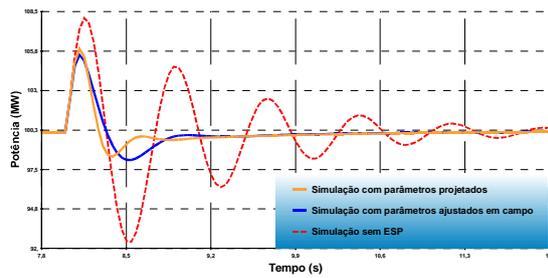


Figura 5. Comparação entre valores de campo e calculados para 100% de carga.

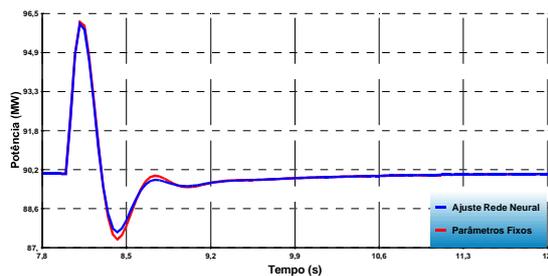


Figura 6. Ajuste de parâmetros via redes neurais e via modelo convencional para 90% de carga.

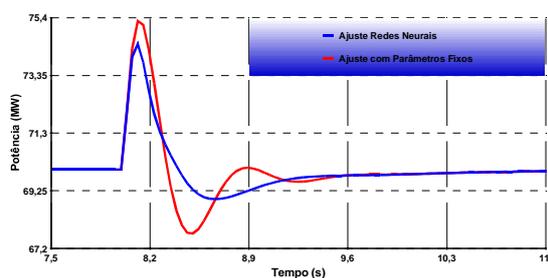


Figura 7. Ajuste de parâmetros via redes neurais e via modelo convencional para 70% de carga.

neurais torna-se mais relevante.

As Figuras 9, 10 e 11 utilizam o ajuste da Tabela 2 na validação das redes neurais MLP e RBF propos-

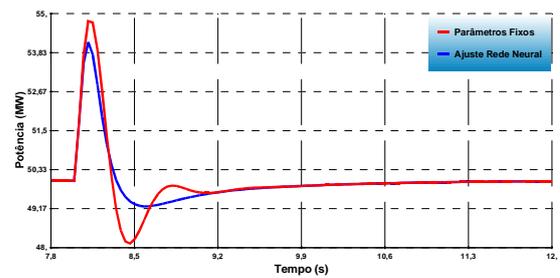


Figura 8. Ajuste de parâmetros via redes neurais e via modelo convencional para 50% de carga.

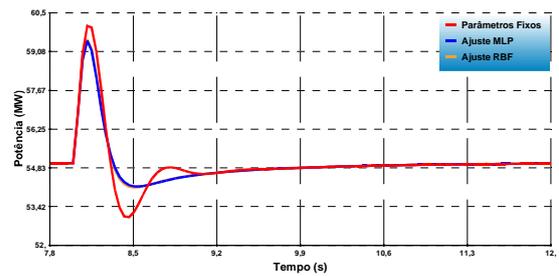


Figura 9. Ajuste de parâmetros via redes neurais e via modelo convencional para 55% de carga.

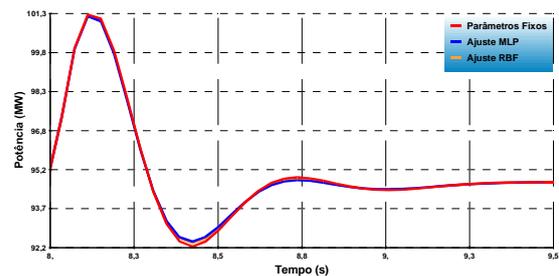


Figura 10. Ajuste de parâmetros via redes neurais e via modelo convencional para 95% de carga.

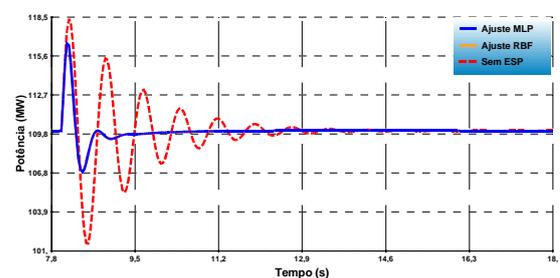


Figura 11. Comparação entre ajuste via redes neurais MLP e RBF e sistema sem PSS aplicados em 110%.

tas, uma vez que os pontos estão fora do conjunto de treinamento e mostram a capacidade das redes em interpolar e extrapolar dados.

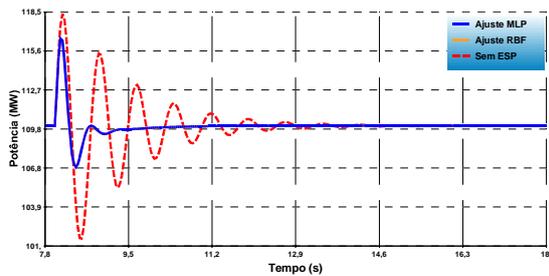


Figura 11. Comparação entre ajuste via rede neural e sistema sem PSS aplicados em 110% de carga.

Ainda se observa, na Fig. 11, que as redes neurais apresentaram boa extrapolação de dados, já que os valores encontrados para os parâmetros obtiveram um melhor amortecimento quando aplicado a uma carga de 110%.

7 Conclusão

As soluções apresentaram resultados satisfatórios. Entretanto, os testes realizados mostraram que a aplicação da RBF convergiu mais rapidamente que a realizada com a MLP. O ajuste dos centros das gaussianas a cada entrada do conjunto de treinamento tornou a convergência do sistema mais rápida. Com apenas 8 iterações para os ajustes foi possível a obtenção de uma aproximação bastante precisa. A principal vantagem observada com a utilização de redes neurais na modelagem dos parâmetros do PSS foi a obtenção de controladores capazes de se adaptarem automaticamente a diferentes pontos de operação, o que incrementou o amortecimento das oscilações. As simulações comprovaram que o amortecimento da máquina ajustada por parâmetros fixos se deteriora à medida que a condição de operação se afasta do ponto de operação estabelecido.

Agradecimentos

Os autores agradecem a Central Geradora Termelétrica Fortaleza – CGTF, empresa do grupo ENDESA, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES pelo apoio técnico e financiamento à pesquisa.

Referências Bibliográficas

- Abido, M. A. and Y. L. Abdel-Magid (1997). Radial Basis Function Network Based Power System Stabilizers for Multimachine Power Systems. IEEE Trans. PWRs, pp. 7803-4122.
- Anderson, P. M. and A. A. Fouad (1994). Power System Control and Stability. IEEE, New York.
- Arrifano, N. S. D., V. A. Oliveira and R. A. Ramos (2004). Design and Application of Fuzzy PSS for

Power Systems Subject to Random Abrupt Variations of the Load. Proceedings of the American Control Conference, Vol. 2, pp. 1085 - 1090, Boston.

- Ghandra, A., O. P. Malik and G. S. Hope (1988). A self-tuning controller for the control of multi-machine power systems. IEEE Trans. PWRs, Vol. 3, no. 3, pp. 1065-1071.
- Kundur, P. (1994). Power System Stability and Control. McGraw-Hill, New York.
- Robak, S., J. W. Bialek and J. Machowski (2001). Comparison of different control structures for lyapunov-based power system stabilizer. IEEE Power Industry Computer Applications, pp. 229-234, Baltimore.
- Sharaf, A. M., T. T. Lie and H. B. Gooi (1993). Neural Network Based Power System Stabilizers. IEEE Trans. PWRs, pp. 8186-4260.
- Souza, F. M. F. e Outros (2006). Modelagem de Reguladores de Tensão e Estabilizadores de Sistemas de Potência de Usinas Termelétricas a Ciclo Combinado. Anais do IX Encontro de Modelagem Computacional, Belo Horizonte.
- Swarcewicz, A. and K. Wróblewska-Swarcewicz (2001). Robust Power System Stabilizer. Proceedings of the IEEE Porto Power Tech Conference, pp. 7803-7139, Porto.
- Xia, D. and G. T. Heydt (1983). Self-tuning controller for generator excitation control. IEEE Trans. PAS, Vol. 102, pp. 1877-1885.
- You, R., Eghbali, H., and Nehrir, M. (2003). An online adaptive neuro-fuzzy power system stabilizer for multi-machine systems. IEEE Trans. PWRs, Vol. 18, N^o.1, pp. 128-135.
- Yadiah, N., Ganga Dinesh Kumar, A., Bhattacharya, J. L. (2004). Fuzzy based coordinated controller for power system stability and voltage regulation. Electric Power System Research 69, pp. 169-177.