

ESTABILIZADOR DE SISTEMAS DE POTÊNCIA COM CONTROLE PREDITIVO GENERALIZADO E SUPERVISOR NEURAL A PARTIR DE UMA REDE DE MODELOS LOCAIS

CAROLINA A. GUEDES, CARLOS T. DA COSTA JÚNIOR, FABRÍCIO G. NOGUEIRA, JOSÉ A. L. BARREIROS

*Laboratório de Engenharia Elétrica e Computação, Anexo 01 (NESC) sala 03, Universidade Federal do Pará,
Rua Augusto Corrêa, CEP: 66075-900, Belém – PA*

*E-mails: carol_azg@yahoo.com.br; cartav@ufpa.br; fabricioufpa@yahoo.com.br;
barreiro@ufpa.br*

Abstract— This paper describes a Power System Stabilizer (PSS) designed from a neural supervisor, previously trained from a Local Model Network. The parameters of the system are provided through the neural supervisor, for any operation point of the power system (represented by a synchronous machine - infinite bus), determining the linear model. Then, after the model is obtained, uses the Generalized Predictive Control (GPC) method for the development of adaptive PSS control law. The proposed PSS showed good performance when compared with results obtained through simulations of conventional PSS (fixed parameters), thereby improving the system stability, making it more secure and reliable.

Keywords— Power System Stabilizer, Generalized Predictive Controller, Neural Networks, Local Model Network, Adaptive Control.

Resumo— Este trabalho descreve um Estabilizador de Sistemas de Potência (ESP) projetado a partir de um supervisor neural, previamente treinado a partir de uma Rede de Modelos Locais (RML). Os parâmetros do sistema são fornecidos através do supervisor neural, para qualquer ponto de operação do sistema de potência (aqui representado por uma máquina síncrona – barramento infinito), determinando o modelo linear do mesmo. Após o modelo atual ser obtido, utiliza-se o método do Controle Preditivo Generalizado (GPC) como lei de controle para o desenvolvimento do ESP adaptativo. O ESP proposto apresentou bom desempenho quando comparado com os resultados obtidos, através de simulações, de um ESP convencional (a parâmetros fixos), melhorando, dessa forma, a estabilidade do sistema tornando-o mais seguro e confiável.

Palavras-chave— Estabilizador de Sistema de Potência, Controle Preditivo Generalizado, Redes Neurais, Rede de Modelos Locais, Controle Adaptativo.

1 Introdução

Estabilizadores de Sistema de Potência (ESPs) tornaram-se de uso bastante comum em sistemas de excitação de máquinas síncronas devido à sua capacidade de aumentar o amortecimento de oscilações eletromecânicas, logo, aumentar as margens de estabilidade dinâmica e, com isso, proporcionar uma operação mais segura e confiável desses sistemas [1 – 2].

A implementação convencional de um ESP é feita utilizando-se um modelo linearizado do sistema de potência para uma determinada condição de operação, mas que será utilizado durante toda a operação do sistema de potência. Esses ESPs possuem um desempenho muito bom, porém apenas para o ponto de operação para o qual foi projetado. Como grandes variações podem ocorrer, alterando as condições de operação dos sistemas de potência, pode-se projetar ESPs sintonizando o controlador para as atuais condições de operação do sistema, atualizando permanentemente os parâmetros do sistema através de identificação por meio de técnicas adaptativas [3 – 5].

Este artigo tem como objetivo projetar um ESP com estrutura de um controlador adaptativo auto-ajustável indireto [6], com seus parâmetros determinados através de um supervisor neural, a partir de uma rede de modelos locais. A rede neural proposta utiliza um conjunto de modelos lineares, em pontos de operação do sistema, como seus padrões de trei-

namento. De início, para cobrir toda a faixa de operação do sistema, escolhem-se vários pontos num plano PxQ, formado pelas potências ativa e reativa geradas. Utilizando um algoritmo baseado em minimização do quadrado do erro entre as saídas do sistema e do modelo [7], é possível estimar os parâmetros de modelos estruturais para o sistema e, assim, formar uma Rede de Modelos Locais (RML) [8], que são armazenados numa tabela para consulta em tempo real.

Em qualquer instante de amostragem, o supervisor neural identifica o atual ponto de operação e determina um modelo paramétrico a partir da RML. O supervisor neural utiliza uma RNA (Rede Neural Artificial) do tipo perceptron multicamadas [9] que terminado seu treinamento fornece modelos válidos para o sistema mesmo para pontos de operação que não fizeram parte do conjunto de padrões de treinamento. Após o modelo atual de o sistema ser obtido, utiliza-se o método do Controle Preditivo Generalizado (GPC, de suas iniciais em inglês) [4] para o projeto do ESP digital. Os resultados obtidos, através de testes simulados com perturbações demonstram que, o ESP proposto, apresenta melhores resultados do que aqueles obtidos com um ESP a parâmetros fixos.

2 Controle Preditivo Generalizado

O algoritmo de GPC proposto por [10] utiliza um modelo para prever o comportamento da planta

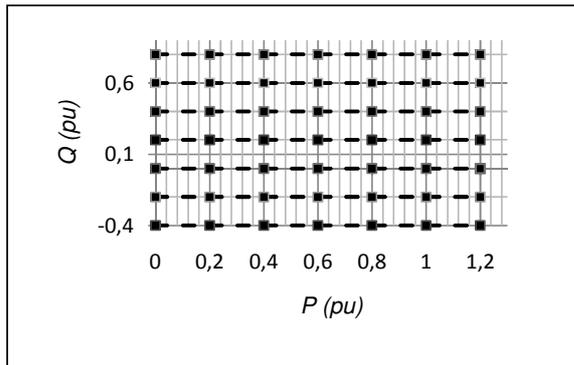


Figura 1. Pontos de operação do sistema para a RML.

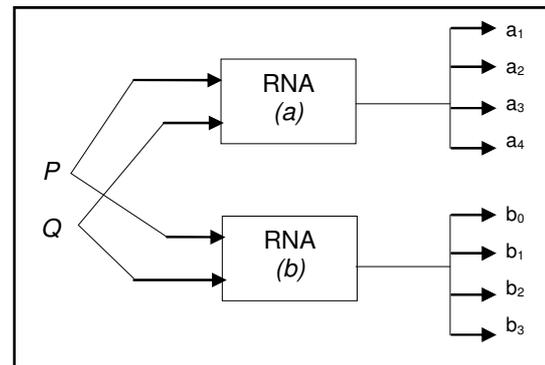


Figura 2. Estrutura do Supervisor Neural

num dado horizonte, calcula-se a ação de controle a partir da minimização de um critério que considera o erro entre a mencionada predição e a referência assim como uma ponderação do esforço de controle. Desta forma o sistema de controle obtido possui duas partes principais. Na primeira parte ou etapa calculam-se as predições da saída da planta usando-se, para isto, um preditor ótimo que permite encontrar o valor esperado da saída, na presença de perturbações estocásticas, como função dos controles futuros. Na segunda etapa as ponderações do erro e do esforço de controle devem ser definidas para a minimização do critério [11].

O método GPC foi originalmente empregado em um CARIMA (do inglês Controller Auto-Regressive Integrated Moving-Average) [10], que é dado pela equação 1, porém outras formulações podem ser utilizadas neste método de controle.

$$A(q^{-1})y(t) = B(q^{-1})u(t-d) + C(q^{-1})\frac{e(t)}{\Delta} \quad (1)$$

onde os polinômios $A(q^{-1})$, $B(q^{-1})$ e $C(q^{-1})$ são definidos pelas equações 2, 3 e 4, respectivamente.

$$A(q^{-1}) = 1 + a_1q^{-1} + a_2q^{-2} + \dots + a_nq^{-n} \quad (2)$$

$$B(q^{-1}) = b_0 + b_1q^{-1} + b_2q^{-2} + \dots + b_nq^{-n} \quad (3)$$

$$C(q^{-1}) = 1 + c_1q^{-1} + c_2q^{-2} + \dots + c_nq^{-n} \quad (4)$$

e $1/\Delta$ é o operador $1/(1 - q^{-1})$; $u(t)$ e $y(t)$ são a entrada e a saída, respectivamente e $e(t)$ é um ruído branco de média nula. O polinômio $C(q^{-1})$ representa as características estocásticas do ruído, geralmente como este polinômio é difícil de estimar, é comum utilizar na prática um modelo com $C(q^{-1}) = 1$ para a análise do algoritmo do GPC.

O objetivo do método GPC é de minimizar a função de custo, definida pela equação 5.

$$J = E\left\{\sum_{k=N_1}^{N_2} [y(t+k) - w(t+k)]^2 + \sum_{k=1}^{N_u} \rho(t+k-1)[\Delta u(t+k-1)]^2\right\} \quad (5)$$

em que $\Delta u(t)$ são os incrementos na ação de controle, $w(t+k)$ é a seqüência de registros futuros, N_1 e N_2 são os horizontes de predição inicial e final, respectivamente, N_u é o horizonte de controle e ρ representa uma seqüência de pesos das ações de controle futuras.

3 RML com Supervisor Neural

Pode-se obter um modelo linear para um determinado ponto de operação de sistemas não-lineares, o qual é chamado de modelo local do sistema. Rede de Modelos Locais (RML) [8] são grupos de modelos locais para vários pontos de operação do sistema. Para a construção da RML deste trabalho, foram selecionados 49 pontos de operação no plano P-Q, mostrados na figura 1, e seus respectivos modelos lineares foram previamente calculados.

O Supervisor Neural [12 – 14], deste trabalho obtém os parâmetros que definem o modelo do sistema através do processo de treinamento de duas RNAs, feito através do método de retropropagação do erro e função de ativação do tipo sigmóide [9], com os padrões de treinamento formados pelo conjunto de modelos lineares que compõem a RML do sistema. As camadas de entrada de cada RNA possuem dois neurônios, correspondentes as potências ativa (P) e reativa (Q) na saída do gerador síncrono, e as camadas de saída têm quatro neurônios cada, correspondendo aos valores dos parâmetros a_i e b_i para cada uma das redes, de acordo com a figura 2. Dessa forma, o supervisor neural será capaz de determinar um modelo linear para o sistema, mesmo se o ponto de operação atual não foi utilizado como um dos padrões de treinamento.

4 ESP baseado em GPC e Supervisor Neural

Para o projeto do ESP digital utilizam-se os parâmetros do sistema obtidos através do supervisor neural. Estes parâmetros definem o modelo linear de um sistema elétrico de potência, que neste trabalho é representado como um sistema máquina síncrona – barramento infinito. A partir do modelo linear definido, utiliza-se o método de Controle Preditivo Generalizado – GPC para projetar o ESP digital, como mostrado na figura 3.

Foi utilizado um modelo estrutural discreto de quarta ordem [15], do tipo ARMAX (do inglês Auto-

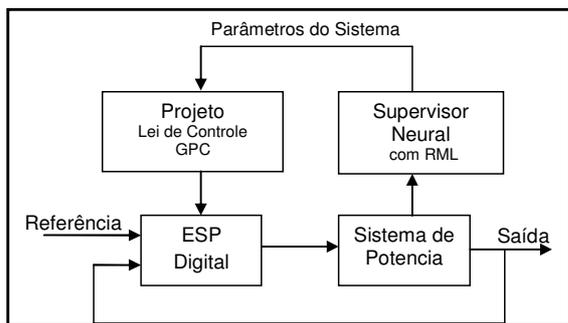


Figura 3. Esquema de controle para o ESP com o Supervisor Neural e GPC.

Regressive Moving Average with eXogenous input), que, em termos do operador atraso q^{-1} , tem a seguinte forma descrita pela equação 6 [7].

$$A(q^{-1})y(t) = B(q^{-1})u(t-1) + C(q^{-1})e(t) \quad (6)$$

em que y , u e e são, respectivamente, a saída da planta, a entrada e uma seqüência do tipo ruído branco discreto. $C(q^{-1}) = 1$ e os polinômios $A(q^{-1})$ e $B(q^{-1})$, já definidos, anteriormente, pelas equações 2 e 3, porém neste caso $n=4$, por se tratar de um sistema de quarta ordem, com os parâmetros a_1, a_2, a_3, a_4 e b_0, b_1, b_2 e b_3 que são determinados pelo supervisor neural.

O ESP digital é determinado através da lei do controle preditivo generalizado, que por sua vez é obtida através da minimização da função de custo [4], dada pela equação 7.

$$J = E\left\{\sum_{k=1}^{N_2} [y(t+k) - w(t+k)]^2 + \sum_{k=1}^{N_u} \rho [u(t+k-1)]^2\right\} \quad (7)$$

onde, neste trabalho, $N_2 = 7$, e $N_u = 2$ e $\rho = 0,01$ com período de amostragem de 50ms [4].

5 Resultados e simulações

Para a avaliação do desempenho do sistema máquina síncrona – barramento infinito mostrado na figura 4, o ESP digital com supervisão neural e lei de controle GPC foi projetado. As equações deste sistema são descritas pelo modelo 4 [16], os parâmetros do sistema de potência são apresentados na Tabela 1 e por um Regulador Automático de Tensão (RAT) de primeira ordem [17], cujos parâmetros são $K_a=200$; $T_a=30ms$; e $-6 < E_{fd} < 6$.

O ESP com supervisor neural e GPC proposto

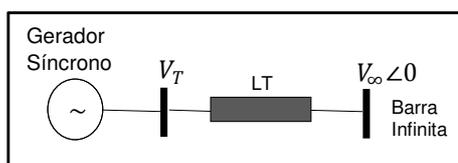


Figura 4. Sistema Máquina barra infinita.

Tabela 1. Parâmetros do gerador síncrono.

$H=4,27$	$R_d=0,001$
$R_e=0,02$	$X_e=0,415$
$X_d=1,445$	$X_q=0,959$
$X'_d=0,316$	$X''_q=0,162$
$X''_d=0,179$	$T'_{d0}=5,256$
$T''_{d0}=0,0282$	$T''_{q0}=0,157$

por este trabalho foi comparado com um ESP convencional, cuja estrutura é formada por um bloco washout, dois blocos lead-lag, um ganho e um limitador [18]. Os resultados das simulações são mostrados pelas figuras 5, 6 e 7 que apresentam o comportamento dos dois estabilizadores quando o sistema está inicialmente operando com $P = 0,75$ pu e $Q = -0,2$ pu, para o primeiro caso e $P = 0,95$ pu e $Q = -0,2$ pu, para os outros dois casos simulados.

A primeira simulação realizada (figura 5) submeteu o sistema a um curto-circuito com duração de 100ms, aplicado no instante $t=2s$. A segunda simulação (figura 6) submeteu o sistema a um degrau, de amplitude 0,1 pu, aplicado na referência de tensão em $t=5s$. Já a última simulação (figura 7) submeteu o sistema a um degrau aplicado na potência mecânica, com amplitude -0,3 pu e $t=5s$.

Pode-se analisar que em todos os casos simulados, o ESP adaptativo apresentou melhor desempenho que o ESP convencional, melhorando o amortecimento do modo de oscilação eletromecânica local.

6 Conclusão

Neste trabalho, desenvolveu-se um ESP adaptativo projetado para determinar os parâmetros da planta do sistema a partir de uma rede de modelos locais, que, por sua vez, é usada para treinar a rede

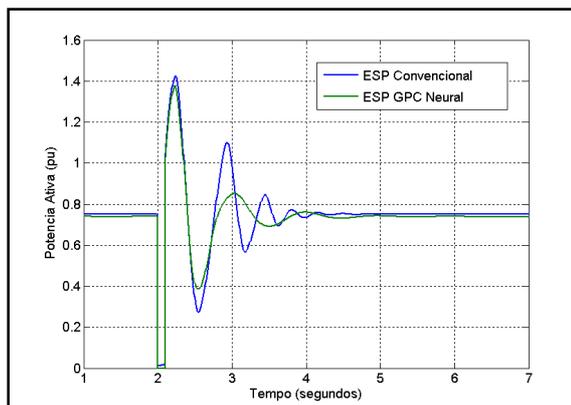


Figura 5. Resposta do sistema a um curto-circuito.

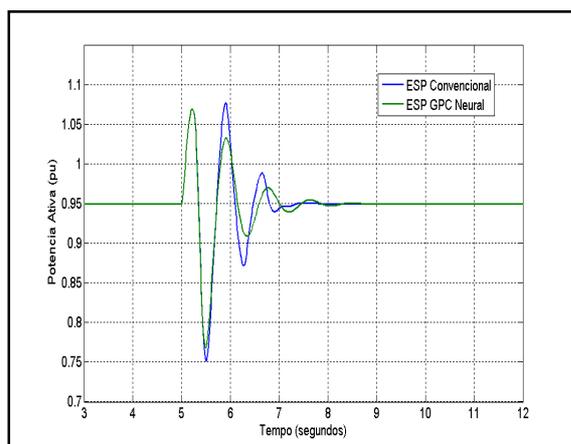


Figura 6. Resposta do sistema a um degrau na referência de tensão.

neural do supervisor utilizado. O supervisor neural recebe os valores de potências ativa e reativa, para qualquer ponto de operação do sistema, e determina os parâmetros de A e B do modelo discreto da planta. Através de uma técnica de Controle Preditivo Generalizado – GPC, a lei de controle do ESP adaptativo é calculada. Os testes simulados mostraram que o desempenho do ESP adaptativo proposto foi superior ao desempenho do ESP a parâmetros fixos para as diversas condições de faltas simuladas neste trabalho.

É importante ressaltar que o esforço computacional para o desenvolvimento deste ESP é menor em comparação com outros estabilizadores adaptativos que usam permanente identificação da planta do sistema por estimação recursiva de seus parâmetros, tornando-se, assim, de fácil implementação.

Com este método, sempre estará disponível, para qualquer condição de operação do sistema, um ESP sintonizado. Dessa forma, pode ser observada a melhoria significativa da estabilidade dinâmica do sistema e, ainda, evitar problemas resultantes de um processo permanente de identificação paramétrica.

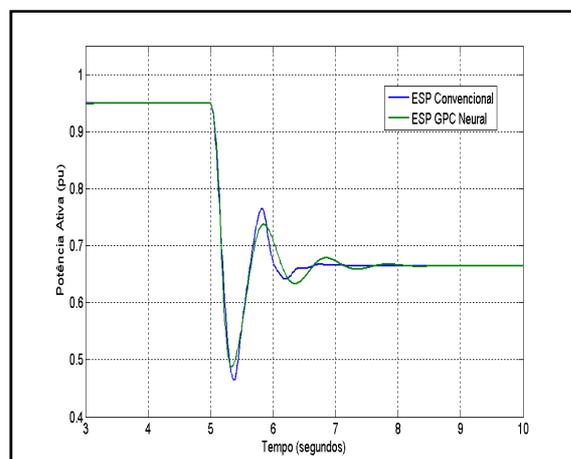


Figura 7. Resposta do sistema a um degrau na potência mecânica.

Referências Bibliográficas

- [1]. F.P. de Mello and C. Concordia. (1969) Concepts of Synchronous Machine Stability as Affected by Excitation Control, *IEEE Trans. on Power Apparatus and Systems*, Vol.88, N°. 4, pp 316-327.
- [2]. E.V. Larsen and D.A. Swann. (1981). Applying Power System Stabilizers – Parts 1-3, *IEEE Trans. on Power Apparatus and Systems*, Vol.100, pp 3017-3046.
- [3]. S. Cheng, Y.S. Chow, O.P. Malik and G.S. Hope. (1986) An Adaptive Synchronous Machine Stabilizer, *IEEE on Power Systems*, Vol. PWR-1, N°3, pp. 101-109.
- [4]. J.A.L. Barreiros, A.S. Silva, A.J. Simões Costa. (1998) A Self-Tuning Generalized Predictive Power System Stabilizer, *Electric Power & Energy Systems*, Vol.20, N° 3, pp.213-219.
- [5]. J.A.L. Barreiros, A.S. Silva, A.J. Simões Costa. (1992) A Self-Tuning Power System Stabilizer Based on an Implicit Pole-Placement Method, in *Proc. of the IX Automatic Brazilian Congress (in Portuguese)*, pp 263-267.
- [6]. K. J. Aström and B. Wittenmark. (1995) *Adaptive Control*, Addison Wesley, Reading, Massachusetts, Second Edition.
- [7]. I. D. Landau. (1993) *Identification et commande de Systemes, Traitement des Nouvelles Technologies, Seire Automatique*. Ed. Hermes, Deuxième Edition.
- [8]. Hunt, K.J. e Johansen, T.A. (1997) Design and Analysis of Gain-Scheduled Control Using Local Controller Networks. *International Journal of Control*, 66(5): 619-651.
- [9]. Haykin, S.S. (1998). *Neural Networks: A Comprehensive Foundation*. Prentice-Hall, Inc., Englewood Cliffs, New Jersey.
- [10]. Clarke, D., Mothadi, C. & Tuffs, P. (1987a). Generalized Predictive Control. Part I: the basic algorithm, *Automatica* 23(2): 137-148.
- [11]. J. E. N. Rico (2000). Controle Preditivo de Processos com grandes atrasos de transporte, *Mini-curso n° 1 XIII CBA*.
- [12]. Hsu, Y.Y. e Chen, C.R. (1991). Tuning of Power System Stabilizers Using an Artificial Neural Network. *IEEE Trans. on Energy Conversion*, 6(4): 612-619.
- [13]. C.T da Costa Jr, J.A.L. Barreiros, W. Barra Jr, C.T.L. Pedreira (2001). Controle Preditivo Generalizado com Supervisão Fuzzy numa Rede de Modelos Locais para Síntese de Estabilizador de Sistema de Potência, *XIV CBA*.
- [14]. C.T da Costa Jr, J.A.L. Barreiros, A.M.D. Ferreira, W. Barra Jr (2002). Estabilizador de Sistemas de Potência com Supervisão Neural a partir de uma Rede de Modelos Locais, *XV CBA*.

- [15]. C. Tavares da Costa Jr. (1999). Adaptive Control Methods by Supervision for the Regulation of a Generator Entrained by Hydraulic Turbine," Ph.D. dissertation, Institute National Polytechnique de Grenoble, France (in French).
- [16]. J. Arrilaga, C. P. Arnold, B. J. Harker. (1983) Computer Modelling of Electrical Power Systems, John Wiley & Sons Ltd.
- [17]. K. Hirayama, Y Tone, K. Takagi, H. Murakami, M. Shibata, H. Nagamura and Y. Takagi. (1993) Digital AVR Application to Power Plants, IEEE Transactions on Energy Conversion, Vol.8, N°. 4, pp 602-609.
- [18]. P. Kundur (1994). Power System Stability and Control, McGraw-Hill, Inc.