

REDES NEURAIIS ARTIFICIAIS E COMPUTAÇÃO EVOLUCIONÁRIA APLICADOS EM MODELAGEM DE UM TURBO-GERADOR

Leandro dos Santos Coelho e Antonio Augusto Rodrigues Coelho
UFSC/DAS - Caixa Postal 476 - 88040.900 - Florianópolis - SC - BRASIL
e-mail: {lscoelho; aarc}@lcmi.ufsc.br

Abstract: This paper evaluates the application of the computational intelligence methodologies in a nonlinear process identification. The different intelligent methodologies utilized are evolutionary computation (hybrid genetic algorithms with simulated annealing) and artificial neural networks (feedforward and recurrent topologies). The simulations are realized in the identification of a turbogenerator mathematical model through a step signal, pseudo-random binary sequence, and white noise excitation signals. The performance of the techniques are presented and discussed.

Keywords: Process identification, evolutionary computation, genetic algorithms, simulated annealing, artificial neural networks.

1. INTRODUÇÃO

As necessidades de projetistas e engenheiros em tratar sistemas de controle cada vez mais complexos, têm viabilizado a identificação e o controle de sistemas não-lineares pela utilização da inteligência artificial ou computacional (IC). Diversas ferramentas da IC possibilitam o tratamento adequado de restrições, a fim de satisfazer os requisitos em projeto e implementação na área de automação industrial, onde os algoritmos convencionais apresentam dificuldades na modelagem e controle.

A IC constitui-se de uma área emergente que abrange um conjunto de paradigmas bastante amplo e multidisciplinar, onde o desenvolvimento da IC, por pesquisadores das mais diversas áreas do conhecimento, tem levado a promissores resultados (Åström, 1991; Chipperfield & Fleming, 1996; Passino, 1996). As aplicações industriais, militares, na medicina e em produtos comerciais que empregam com sucesso técnicas como lógica nebulosa, computação evolucionária, "simulated annealing", redes neurais artificiais, redes neurais nebulosas, sistemas especialistas e sistemas híbridos inteligentes, têm conduzido a diversas pesquisas na área de controle de processos (Chipperfield & Fleming, 1996; Galante et al., 1993; Hull & Johnson, 1994; Passino, 1996; Rock & Hirsh, 1993). A figura 1 ilustra a interação entre as técnicas convencionais da teoria de controle e IC em controle de processos.

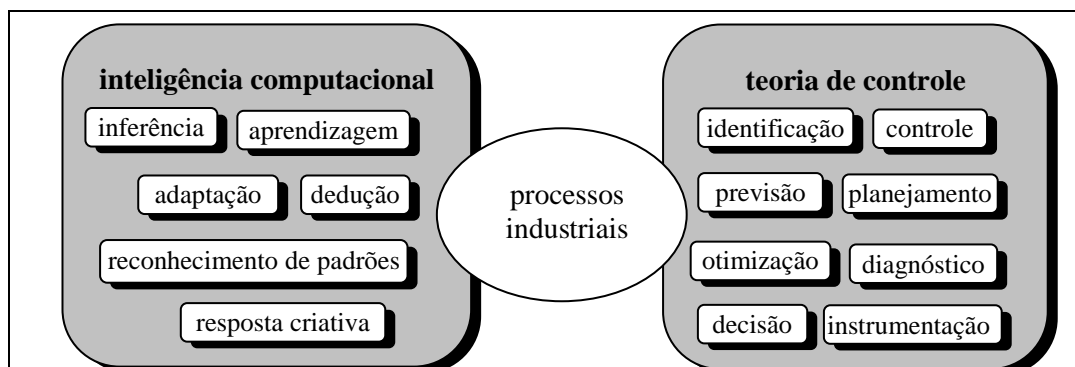


Figura 1 - Interação de metodologias convencionais e inteligentes em controle de processos.

Neste artigo utiliza-se os paradigmas da IC denominados computação evolucionária e redes neurais artificiais em identificação (modelagem) de um modelo

não-linear que representa um turbo-gerador, em escala de laboratório. As simulações são realizadas com a utilização de sinais degrau, ruído branco e “pseudo-random binary sequence” (PRBS). As quatro fases da identificação são abordadas: i) obtenção das medidas; ii) determinação da estrutura; iii) estimação do modelo, e iv) validação do modelo estimado. O artigo é organizado como segue. Na seção 2, o paradigma da computação evolucionária denominado algoritmo genético é descrito brevemente. Na seção 3 são apresentadas as redes neurais artificiais “feedforward” e recorrente. A descrição do modelo matemático do turbo-gerador e as simulações realizadas são tratados na seção 4, enquanto a conclusão é apresentada na seção 5.

2. COMPUTAÇÃO EVOLUCIONÁRIA

Atualmente, a computação evolucionária (CE) constitui-se numa alternativa às técnicas convencionais de busca e otimização (Fogel, 1995). A CE engloba um número crescente de metodologias, das quais as mais importantes são: algoritmos genéticos, estratégias evolutivas, programação evolucionária, programação genética e sistemas classificadores. O paradigma CE atualmente tende a interagir de modo a dar origem aos denominados algoritmos evolutivos ou evolucionários (Fogel, 1995; Goldberg, 1989; Tanomaru, 1995). O paradigma da CE denominado algoritmo genético híbrido com “simulated annealing” é tratado na determinação dos parâmetros mais adequados de um modelo NARX (“Non-linear AutoRegressive model structure eXogenous inputs”) para modelagem do turbo-gerador (Chen *et al.*, 1990).

Os algoritmos genéticos (AGs) são técnicas não-determinísticas de busca, otimização e aprendizagem de máquina, que manipulam um espaço de soluções potenciais utilizando mecanismos inspirados nas teorias de seleção natural de Darwin e na genética de Mendel. Neste artigo utiliza-se a representação por ponto flutuante (real) dos cromossomos, pela sua adequação ao tratamento de problemas com restrições e por apresentarem maior precisão e eficiência quanto ao tempo de CPU que a representação binária. Os operadores abordados são os operadores evolutivos de mutação não-uniforme e recombinação aritmética (Janikow & Michalewicz, 1990).

O algoritmo “simulated annealing” (SA) é um método de otimização estocástica que se baseia no processo físico em que substâncias são elevadas a altos níveis de energia e, posteriormente, são gradualmente resfriadas até alcançarem um estado de baixa energia. O processo de SA é aplicado ao AG, a cada geração, após as operações de recombinação e mutação, através de uma pequena perturbação randômica nos cromossomos do AG para o aprimoramento das buscas locais do AG (AGSA).

3. REDES NEURAS ARTIFICIAIS

As redes neurais artificiais (RNs) são conhecidas por serem “aproximadores universais” e não serem baseadas em modelos, sendo que podem ser utilizadas para modelagem de processos lineares e não-lineares (Cybenko, 1989; Hornik *et al.*, 1989). Em identificação é importante o papel das RNs em modelos “black-box” (identificação estrutural) de sistemas dinâmicos não-lineares, conforme tratado por Sjöberg (1994). As RNs abordadas, neste trabalho, são: a RN “multilayer perceptron feedforward” (MLP) com treinamento “backpropagation” e a RN parcialmente recorrente de Elman modificada.

O MLP representa uma generalização da RN “perceptron” de camada única. O MLP tem sido aplicado com sucesso para resolver problemas de mapeamento, por meio de aprendizado supervisionado, utilizando o algoritmo da retropropagação do erro ou “error backpropagation” (BP). O algoritmo BP consiste, basicamente, de duas

fases através das diferentes camadas da RN: fase “forward” e fase “backward”. O diagrama esquemático do algoritmo BP é sintetizado na figura 2(a).

A RN de Elman modificada é baseada na RN de Elman convencional (RNPREE) proposta por Elman (1990), contudo para obter-se desempenho mais adequado em identificação de processos introduz-se “auto-conexões” nas unidades de contexto da RNPREE, para dar a RNPREE unidades de inércia (“units inertias”) e, assim melhorar a capacidade de memorização deste tipo de RN tanto para utilização de funções de ativação lineares quanto não-lineares (RNPREMOD) (Pham & Liu, 1992). O diagrama esquemático da RNPREMOD é apresentado na figura 2(b).

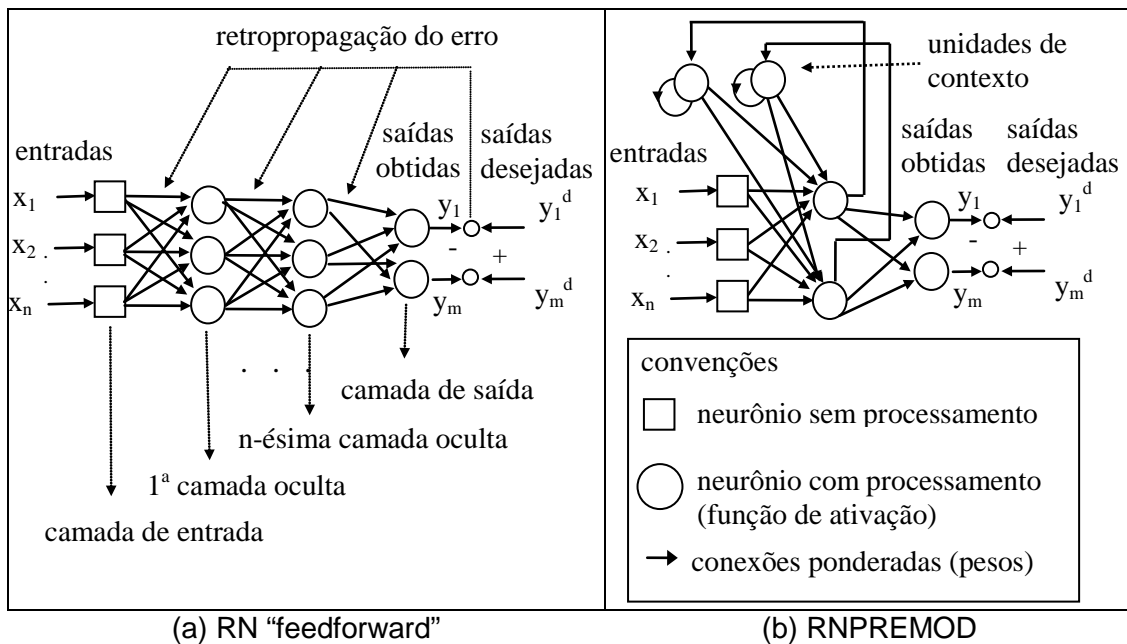


Figura 2 - Diagrama esquemático da RN “feedforward” e RNPREMOD.

4. MODELO MATEMÁTICO DO TURBO-GERADOR E SIMULAÇÕES

A planta do turbo-gerador utilizada nas simulações é representada pela seguinte equação a diferenças não-linear

$$y(k) = 0.0888 u(k-1) + 0.9909 u(k-2) + 0.3633 y(k-1) - 0.0467 u(k-2)^2 + 0.6193 u(k-1)y(k-1) + 0.0242 u(k-3)^2 - 0.2500 y(k-1)^2 - 0.8098 u(k-3)y(k-1) + 0.3974 y(k-1)y(k-2) \quad (1)$$

obtida de um processo real de laboratório em procedimento de identificação não-linear (Pickhardt & Unbehauen, 1994). As simulações utilizando o modelo do turbo-gerador representado pela equação (1) visaram duas simulações, descritas a seguir.

Simulação 1: A estimação do modelo matemático do processo é realizada utilizando-se um sinal de entrada degrau unitário durante as amostras 0 a 100. Entre as amostras 100 e 300 é aplicado à entrada do processo, um sinal PRBS₁ (sinal degrau unitário mais $\pm 5\%$ de um PRBS de -1 ou +1). Uma seqüência aleatória normalmente distribuída (ruído branco) com média zero e variância um, entre as amostras 300 e 500. O sinal de entrada (degrau + PRBS + ruído branco) aplicado ao turbo-gerador em malha aberta é apresentado na figura 3(a). Os algoritmos de identificação utilizam-se das primeiras 500 amostras para identificar o turbo-gerador. Após a fase de estimação, os modelos matemáticos são validados frente a outras 300 amostras (entre

500 e 800) através de uma entrada PRBS₂ (sinal degrau unitário mais $\pm 10\%$ de um PRBS de -1 ou +1), utilizando-se de uma semente de números aleatórios diferente do PRBS₁.

Simulação 2: A estimação do modelo matemático do processo é realizada utilizando-se um sinal de entrada PRBS₁ (-1 ou 1) durante as amostras 0 a 300, e uma seqüência aleatória normalmente distribuída (ruído branco), com média zero e variância um entre as amostras 300 e 500. O sinal de entrada (PRBS + ruído branco) aplicado ao turbo-gerador em malha aberta é apresentado na figura 3(b). Os algoritmos de identificação utilizam-se das primeiras 500 amostras para identificar o turbo-gerador. Após a fase de estimação, os modelos matemáticos são validados frente a outras 300 amostras (entre 500 e 800) através de uma entrada PRBS₂ (-1 ou +1), utilizando-se de uma semente de números aleatórios diferente do PRBS₁.

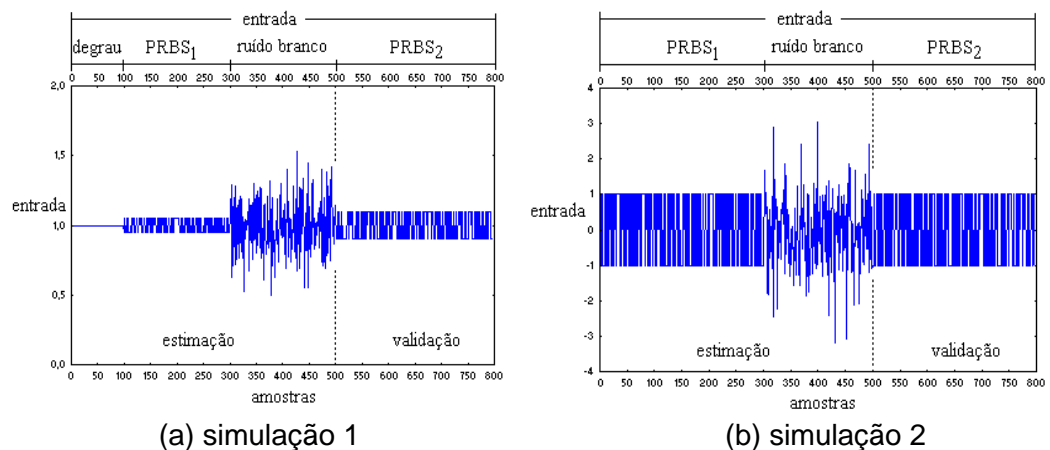


Figura 3 - Sinal de entrada aplicado ao turbo-gerador em malha aberta.

A aplicação da CE objetiva a estimação dos parâmetros de um modelo matemático NARX para o turbo-gerador. Os modelos NARX são regidos por equação a diferenças não-lineares estruturadas por parâmetros lineares. A estrutura típica de um modelo NARX pode ser abordada pela seguinte equação:

$$\begin{aligned}
 y(t) = & \sum_{i=1}^{nb} b_i u(t-d-i+1) - \sum_{i=1}^{na} a_i y(t-i) + \text{cte} + \\
 & \text{(termos não - lineares)} \\
 & + \sum_{i=1}^{na} \sum_{j=1}^{nb} \sum_{k=1}^{pep-1} \sum_{m=1}^{pep-1} c_{ijkm} u(t-d-i+1)^k y(t-j)^m \\
 & + \sum_{i=1}^{nb} \sum_{j=1}^{nb} \sum_{k=1}^{pep-1} \sum_{m=1}^{pep-1} d_{ijkm} u(t-d-i+1)^k u(t-d-j+1)^m \\
 & + \sum_{i=1}^{nb} \sum_{j=1}^{nb} \sum_{k=1}^{pep-1} \sum_{m=1}^{pep-1} e_{ijkm} y(t-i)^k y(t-j)^m
 \end{aligned} \tag{2}$$

onde o termo “pep” é responsável pela potência de expansão polinomial. O modelo NARX utilizado na identificação do turbo-gerador é estipulado em nb=3, na=2 e pep=3, o que totaliza $n_t = 56$ termos (Chen et al., 1990). A estimação do modelo do turbo-gerador é adequada se os critérios de erro, adotados na estimação, estão em valores admissíveis, pela análise do projetista. Os critérios de erro em identificação são os seguintes:

$$SSE = \frac{\sum_{k=1}^N [y(k) - \hat{y}(k)]^2}{N} \quad (3)$$

$$RPE = \frac{\sum_{k=1}^N [y(k) - \hat{y}(k)]^2}{\sum_{k=1}^N [y(k)]^2} \quad (4)$$

$$ISE = \sum_{k=1}^N [y(k) - \hat{y}(k)]^2 \quad (5)$$

onde $y(k)$ é a saída desejada, $\hat{y}(k)$ é a saída estimada e N é o número de amostras coletadas na simulação. O AGSA utilizado tem os seguintes parâmetros: população de 30 cromossomos, seleção "breeder", probabilidade de recombinação e de mutação de 0.8 e 0.1, respectivamente. O AGSA visa a estimação dos 56 termos do modelo NARX para identificação do turbo-gerador. Contudo, estão em estudo implementações com AGs que otimizem além dos parâmetros a ordem do modelo, de maneira análoga ao proposto por Li & Jeon (1993), onde a estrutura do modelo é codificada em uma "string" binária ("1" representa a inclusão de um termo no modelo e "0" representa a ausência do termo). Os resultados mais adequados dos 10 experimentos realizados com o AGSA são apresentados na tabela 1.

Tabela 1: Identificação do turbo-gerador via AGSA.

simulação 1			simulação 2		
ISE	SSE	RPE	ISE	SSE	RPE
1.7198	3.40×10^{-3}	1.18×10^{-3}	110.2344	2.20×10^{-1}	1.84×10^{-1}

A figura 4(a) apresenta o resíduo entre a resposta real e estimada do turbo-gerador em malha aberta obtido pelo algoritmo AGSA na simulação 1, enquanto a figura 4(b) apresenta o resultado mais adequado à simulação 2.

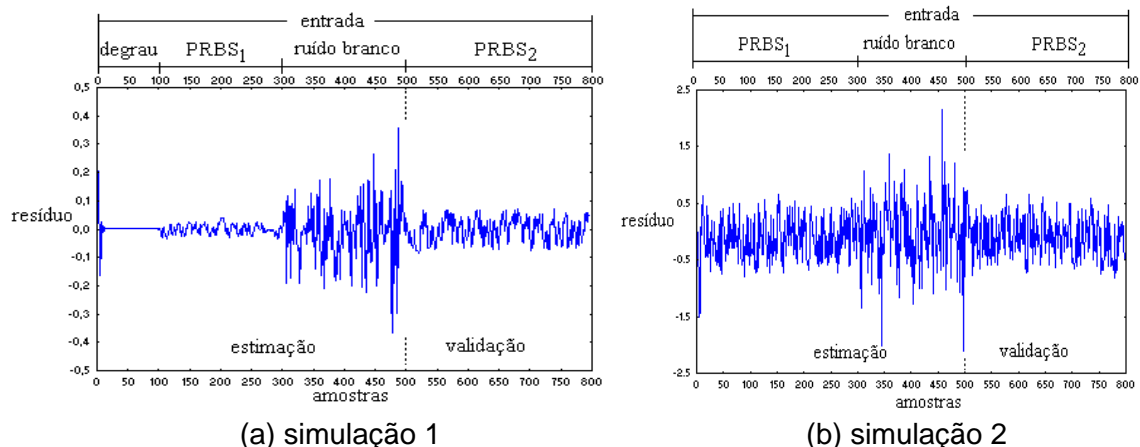


Figura 4 - Resíduo da modelagem do turbo-gerador em malha aberta via AGSA.

Na identificação dos processos pela RN é estipulado como critério de parada 2000 iterações. O coeficiente de aprendizado e momento adotados são de 0.1 (RN "feedforward" e RNPREMOM), enquanto que o parâmetro α da RNPREMOM é ajustado para 0.6 (Pham & Liu, 1992). A tabela 2 resume os resultados obtidos com a RN "feedforward" e RNPREMOM.

Tabela 2: Identificação do turbo-gerador via RNs.

simulação 1									
RN "feedforward"									
entradas					saída	índice de desempenho			
neurônios	y(k-1)	y(k-2)	u(k-1)	u(k-2)	y(k)	ISE	SSE	RPE	
2-20-1	X		X		X	3.4045	6.81×10^{-3}	2.34×10^{-3}	
3-20-1	X		X	X	X	4.6512	9.30×10^{-3}	3.19×10^{-3}	
3-20-1	X	X	X		X	4.0925	8.19×10^{-3}	2.81×10^{-3}	
4-20-1	X	X	X	X	X	6.0013	1.20×10^{-2}	4.12×10^{-3}	
RNPREMOD									
entradas					saída	índice de desempenho			
neurônios	y(k-1)	y(k-2)	u(k-1)	u(k-2)	y(k)	ISE	SSE	RPE	
2-20-1	X		X		X	2.5921	5.18×10^{-3}	1.78×10^{-3}	

simulação 2									
RN "feedforward"									
entradas					saída	índice de desempenho			
neurônios	y(k-1)	y(k-2)	u(k-1)	u(k-2)	y(k)	ISE	SSE	RPE	
2-20-1	X		X		X	12.5427	2.51×10^{-2}	2.09×10^{-2}	
3-20-1	X		X	X	X	11.3033	2.26×10^{-2}	1.88×10^{-2}	
3-20-1	X	X	X		X	9.6991	1.94×10^{-2}	1.62×10^{-3}	
4-20-1	X	X	X	X	X	16.4032	3.28×10^{-2}	2.73×10^{-2}	
RNPREMOD									
entradas					saída	índice de desempenho			
neurônios	y(k-1)	y(k-2)	u(k-1)	u(k-2)	y(k)	ISE	SSE	RPE	
2-20-1	X		X		X	9.6668	1.93×10^{-2}	1.61×10^{-2}	

O resíduo da resposta real em relação a resposta estimada em malha aberta do turbo-gerador é apresentado nas figura 5(a) e 5(b), para as simulações 1 e 2, respectivamente. Enquanto as curvas de aprendizado do turbo-gerador do resultado mais adequado via RNs são apresentadas na figura 6.

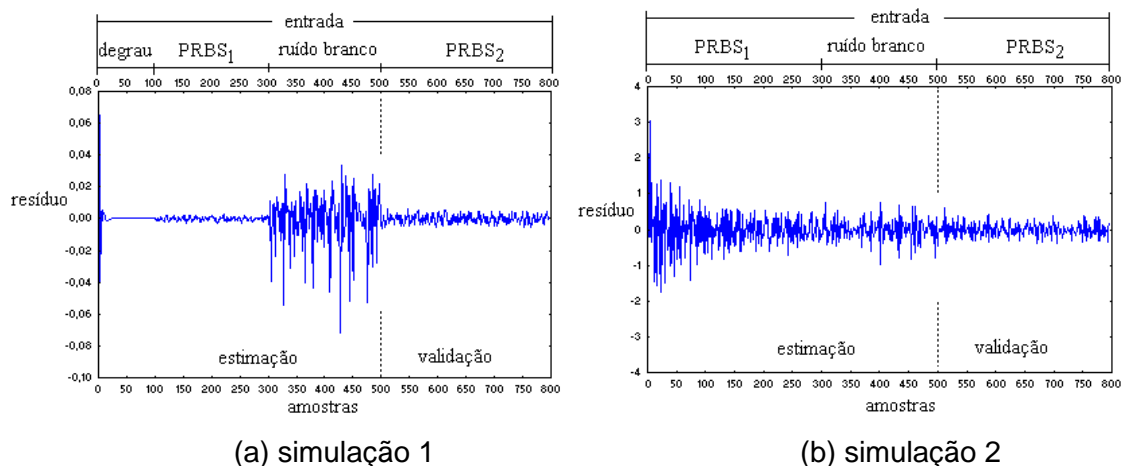


Figura 5 - Resíduo do turbo-gerador em malha aberta via RNs.

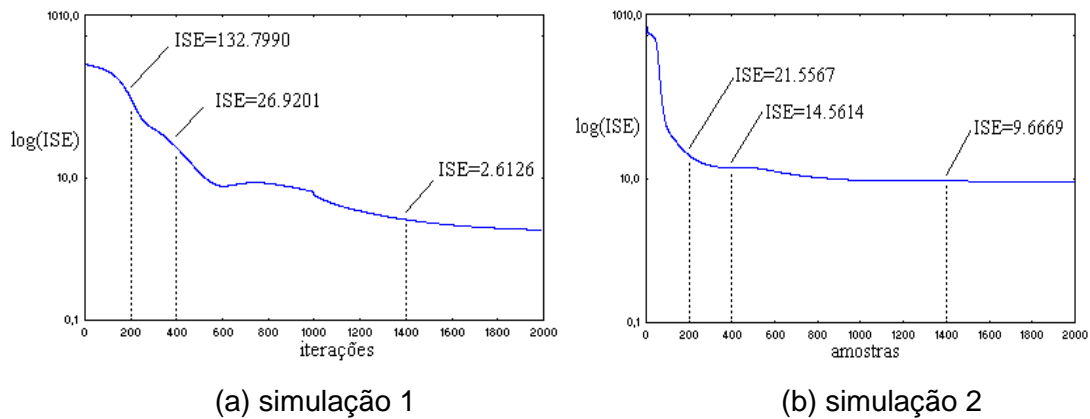


Figura 6 - Curva de aprendizado do turbo-gerador via RNs.

5. CONCLUSÃO

Este trabalho apresentou a aplicação dos paradigmas da IC, denominados de CE e RNs para modelagem de um modelo matemático que representa um turbo-gerador. A metodologias da CE utilizada foi o AG híbrido com SA, enquanto as RNs utilizadas foram a RN "feedforward" e RNPROMOD. As metodologias utilizadas foram adequadas a modelagem do turbo-gerador.

Os resultados foram promissores, contudo deve-se ressaltar a necessidade de análise mais aprofundada de critérios de complexidade algorítmica e convergência das metodologias aplicadas em relação a métodos convencionais de controle e de acordo com as necessidades do projetista, se necessária a identificação "on-line" ou "off-line" e se a metodologia escolhida é a mais adequada para tratamento das dificuldades decorrentes das complexidades do processo a ser modelado (Sjöberg *et al.*, 1994).

Quanto as RNs concluiu-se que devido as características de aprendizado, adaptabilidade e paralelismo inerente têm se consolidado com uma promissora ferramenta para reconhecimento de padrões, previsão, identificação, controle inteligente e adaptativo. Entretanto, apesar das vantagens das RNs, sua implementação apresenta limitações por não poder justificar suas respostas ("black-box"), alto custo computacional, baixa velocidade de aprendizado para aplicações "on-line" e, heurística para determinação da arquitetura e parâmetros ligados ao aprendizado.

O paradigma CE constitui-se numa poderosa ferramenta para o tratamento de problemas multidimensionais e multimodais. Além disso, os paradigmas da CE são técnicas de otimização de procura global pelo espaço de soluções possíveis (não depende de mínimos locais) e com aplicação em sistemas de controle lineares e não-lineares, de fase mínima e não-mínima, para identificação de pólos e zeros (Kristinsson & Dumont, 1992). Outras áreas de aplicação são em problemas de otimização, projeto, roteamento e escalonamento, sendo particularmente significante em aplicações na indústria aero-espacial e automotiva, telecomunicações e engenharia química (Coelho & Coelho, 1996; EvoNews, 1996).

6. REFERÊNCIAS

- Åström, K.J. (1991). Intelligent Control, *European Control Conference*, Grenoble, France, pp.2328-2339.
- Chen, S., S.A. Billings, C.F.N. Cowan & P.M. Grant (1990). Practical Identification of NARMAX Models Using Radial Basis Function, *Int. Journal of Control*, vol.52, no.6, pp.1327-1350.

- Chipperfield, A. & P. Fleming (1996). Evolutionary Algorithms for Control Engineering, *13th World Congress of IFAC*, San Francisco, USA, pp. 181-186.
- Coelho, L.S. and A.A.R. Coelho (1996). Metodologias Inteligentes em Controle de Processos, *Automação & Indústria*, no. 64, pp. 13-16.
- Cybenko, G. (1989). Approximation by Superpositions of a Sigmoidal Function, *Mathematics, Signals, and Systems*, vol.2, pp. 303-314.
- Elman, J.L. (1990). Finding Structure in Time, *Cognitive Science*, 14, p. 179-211.
- EvoNews (1996). Newsletter of the EvoNet Network of Excellence in Evolutionary Computation (Special Issue: Industrial Applications of Evolutionary Computing). *European Commission's ESPRIT IV Programme*.
- Fogel, D.B. (1995). *Evolutionary Computation: Toward a New Philosophy of Machine Intelligence*, IEEE Press.
- Galante, M., M. Cerrolaza & W. Annicchiarico (1993). Optimization of Structural and Finite Element Models via Genetic Algorithms, *World Congress on Optimal Design of Structural Systems*, vol.II, In: J. Herskovits (eds.), Rio de Janeiro, Brazil, pp.127-136.
- Goldberg, D.E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley Publishing Company.
- Hornik, K., M. Stinchcombe & H. White (1989). Multilayer Feedforward Networks are Universal Approximators, *Neural Networks*, vol.2, pp. 359-366.
- Hull, A.R. & R.W. Johnson (1994). Performance Enhancement of a Missile Autopilot via Genetic Algorithm Optimization Techniques, *Proc. of the American Control Conference*, Baltimore, Maryland, USA, pp.1680-1684.
- Janikow, C.Z. & Z. Michalewicz (1990). A Specialized Genetic Algorithm for Numerical Optimization Problems, *Proc. 2nd Int. IEEE Conf. on Tools for Artificial Intelligence*, Herndon, VA, USA, pp.798-804.
- Kristinsson, K. & G.A. Dumont (1992). System Identification and Control Using Genetic Algorithms, *IEEE Trans. on System, Man and Cybernetics*, vol.22, no. 5, pp.1033-1046.
- Li, C.J. & Y.C. Jeon (1993). Genetic Algorithm in Identifying Non Linear Auto Regressive with Exogenous Input Models for Non Linear Systems, *Proc. of American Control Conference*, San Francisco, CA, USA, p. 2305-2309.
- Pham, D.T. & X. Liu (1992). Dynamic System Modeling Using Partially Recurrent Neural Networks, *Journal of System Engineering*, vol.2, pp.90-97.
- Pickhardt, R. & H. Unbehauen (1994). An Indirect Adaptive Predictive Controller for Linear and Nonlinear Plants, *Proc. of American Control Conf.*, Baltimore, USA, pp.2585-2589.
- Rock, D. & J. Hirsh (1993). Will GAs Breed with Aerospace?, *AI Expert*, pp.29-34.
- Sjöberg, J., H. Hjamarsson & L. Ljung (1994). Neural Networks in System Identification, *Preprint 10th IFAC Symposium on System Identification*, vol.2, Copenhagen, Denmark, pp.187-190.
- Passino, K.M. (1996). Intelligent Control, in Levine (eds.), W.S., *The Control Handbook*, IEEE Press and CRC Press, Inc., pp.994-1017.
- Tanomaru, J. (1995). Motivação, Fundamentos e Aplicações de Algoritmos Genéticos, *II Congresso Brasileiro de Redes Neurais*, Curitiba, PR, Brasil, p.373-403.