

## CONTROLE ATIVO DE VIBRAÇÃO TORCIONAL EM MÁQUINAS ROTATIVAS USANDO REDES NEURAS MULTICAMADAS

### **Evaldo Khater**

Departamento de Engenharia Mecânica  
FUNREI - São João del Rei/MG khater@funrei.br

### **Eurípedes G. O. Nóbrega**

Departamento de Mecânica Computacional  
UNICAMP - Campinas/SP

### **Márcio L. A. Netto**

Depto. Eng. Computação e automação Industrial  
UNICAMP - Campinas/SP

**Resumo.** *O trabalho visa o desenvolvimento de estratégias de controle de vibração torcional em sistemas rotativos, com o objetivo de atenuar os modos significativos da vibração em regime. O controle ativo é empregado através de um controlador neural multicamada, usando o método “back-propagation”. O sistema é realimentado através do próprio motor elétrico (CC) do acionamento. Uma bancada experimental de um sistema rotativo é utilizada para o ajuste do modelo e na emulação da planta usando rede neural multicamada para treinar o controlador adequado ao sistema real. Um circuito eletrônico embarcado na extremidade do eixo flexível, transmite o sinal amplificado da deformação angular indicada por uma ponte de extensômetros elétricos. Os resultados indicam que um controlador neural pode ser uma boa alternativa para os sistemas rotativos reais.*

**Palavras-chave:** *Vibração torcional, Controle ativo, Controle de vibração, Redes neurais, Máquinas rotativas*

## **1. INTRODUÇÃO**

A partir dos anos 80 a pesquisa em sistemas rotativos tornou-se, no meio acadêmico, uma preocupação que até então era tratada somente em motores alternativos e eixos de navios através de otimizações empíricas dos parâmetros no sentido de atenuar ou eliminar excitações vibratórias torcionais.

A nova preocupação acadêmica surgiu em virtude da exigência de uma tecnologia moderna, com o advento da informática propiciando enormes e rápidos avanços nos diversos segmentos tecnológicos alterando inclusive o perfil tradicional da Mecânica o que, aliado aos

conhecimentos de outras áreas como por exemplo a eletrônica, definiu uma nova linha para a Mecânica hoje denominada Mecatrônica.

A vibração torcional em sistemas rotativos encontram-se nesse meio apesar de representar uma importante ferramenta para diagnósticos de falhas constitui uma linha ainda praticamente não explorada tanto no país como no exterior, onde todo o trabalho de viabilidade das soluções técnicas ainda necessita ser feito.

O presente trabalho desenvolveu uma pesquisa para viabilizar máquinas rotativas industriais mais leves e mais velozes, assegurando melhor desempenho, no lugar das máquinas de grande porte, pesadas, lentas, com eixos superdimensionados no intuito de evitar falhas, como as que existem hoje em plantas industriais de Mineração, Siderurgia e em motores alternativos (Khater, 1996).

Para tanto o propósito é desenvolver estratégias de controle ativo de vibrações torcionais numa bancada que simula a dinâmica de equipamentos rotativos, como por exemplo um Laminador Siderúrgico.

## 2. ALGORITMO DE APRENDIZAGEM

De acordo com o nível de informação considerado na definição de ajuste dos pesos, os algoritmos de 1ª ordem baseados no método do gradiente e os de 2ª ordem baseados no método do gradiente conjugado, são utilizados comumente nos processos de aprendizagem.

A diferença básica entre os dois algoritmos é que os de 1ª ordem consideram uma aproximação linear da função erro, enquanto os de 2ª ordem uma aproximação quadrática. Portanto, o desempenho dos algoritmos vai depender, além da carga de cálculo requerida, do nível de adequação da aproximação empregada. Com relação à adequação de aproximação, em geral, aproximações lineares têm um melhor desempenho em regiões de operação afastadas dos pontos críticos (ponto onde o gradiente se anula), ou seja, na fase inicial do treinamento, enquanto aproximações de 2ª ordem são mais adequadas em pontos de operação próximos aos pontos críticos, ou seja, em fases avançadas do treinamento (Fletcher, 1975).

Um procedimento interessante seria uma composição de algoritmos de 1ª e 2ª ordem durante o processo de treinamento, de tal forma que a direção de ajuste na fase inicial de treinamento seja a fornecida pelo algoritmo de 1ª ordem, enquanto que na fase final de treinamento seja a fornecida pelo algoritmo de 2ª ordem. Uma implementação desta composição de algoritmos pode ser aplicada com o método de Levenberg-Marquardt (Hagan, 1994), expresso por:

$$\Delta w = [J^T(w)J(w) + \mu I]^{-1} J^T(w)e(w) \quad (1)$$

onde  $J(w)$  é a matriz Jacobiana e  $J^T(w)J(w) + \mu I$  é a matriz Hessiana.

O parâmetro  $\mu$  é multiplicado por um fator ( $\beta$ ) quando o passo resultar em um acréscimo de  $\varepsilon_{av}(w)$  e dividido por ( $\beta$ ) no caso contrário, ou ainda, aumenta-se  $\mu$  para passo não minimizante e para  $J^T(w)J(w) + \mu I$  singular e aumenta-se  $\mu$  para passo minimizante. Nota-se também que quando  $\mu$  é grande o algoritmo se torna o método do gradiente com passo  $1/\mu$  e quando  $\mu$  é pequeno o algoritmo se torna o método de Gauss-Newton. Desta forma o algoritmo de Levenberg-Marquardt torna-se muito útil ao se comportar como o método do gradiente em regiões afastadas do mínimo e como o método de Gauss-Newton em regiões próximas do mínimo, sendo uma boa alternativa para uma

convergência mais rápida em redes com perceptron multicamadas que utilizam o método da retropropagação do erro (Khater, 1998).

### 3. BANCADA EXPERIMENTAL

A bancada experimental é formada essencialmente por um motor de corrente contínua com ímã permanente, que por meio de uma correia traciona duas polias conectadas por um eixo elástico. A alimentação do motor é fornecida por um circuito configurado como fonte controlada de corrente, possibilitando a determinação da corrente aplicada ao sistema. A corrente é monitorada por meio da queda de tensão em um sensor resistivo (shunt) ligado em série com o motor. Uma ponte de extensômetros elétricos permite medir a oscilação torcional do eixo flexível. A velocidade do eixo é monitorada através de um “encoder” posicionado na extremidade do eixo ligado ao rotor R1.

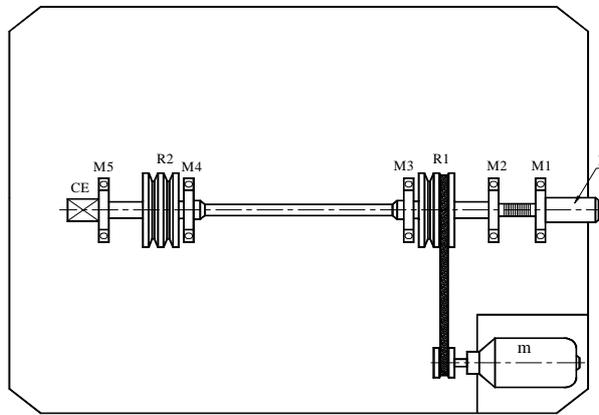


Figura 1 - Montagem da Bancada Experimental

m: motor elétrico CC; E: encoder  
R1 e R2: rotores  
M1, M2, M3, M4 e M5: mancais de rolamentos  
R1 e R2: rotores  
CE: circuito eletrônico embarcado

### 4 - Modelagem Analítica

O modelo analítico da bancada é um modelo de estado considerado linear de sexta ordem incluindo a equação elétrica do motor, apesar de a bancada apresentar características não lineares devido a folgas nos mancais e elasticidade da correia de transmissão. Um ajuste do modelo foi feito com base nos dados experimentais.

O modelo pode então ser representado pelo seguinte conjunto de equações diferenciais:

$$\Delta \dot{I} + \frac{k_b}{L} (\Delta \dot{\theta}_m + w_0) + \frac{R}{L} (\Delta I + I_0) = \frac{1}{L} V_a$$

$$\Delta \ddot{\theta}_m + \frac{C_e}{j_m} (\Delta \dot{\theta}_m + w_0) + \frac{k_c}{j_m} \theta_c = \frac{k_a}{j_m} (\Delta I + I_0) \quad (2)$$

$$\ddot{\theta}_c + \frac{(n^2 j_m + j_l) k_c}{j_m j_l} \theta_c - \frac{(n-2) k_t}{j_l} \theta_t + \frac{C_e}{j_m} (\Delta \dot{\theta}_m + w_0) = \frac{k_a}{j_m} (\Delta I + I_0)$$

$$\ddot{\theta}_t + \frac{2k_t}{j_l} \theta_t - \frac{n k_c}{j_l} \theta_c = 0$$

onde:

$\Delta I$ : oscilação da corrente elétrica

$I_0$ : corrente do motor em regime

$k_b$ : constante de força contra-eletromotriz

$k_a$ : constante da armadura do motor

$L$ : indutância do motor

$\Delta \theta_m$ : oscilação do deslocamento angular do motor

$w_0$ : velocidade angular do motor em regime

$R$ : resistência da armadura do motor

$V_a$ : tensão da armadura do motor

$C_e$ : coeficiente de amortecimento viscoso equivalente

$j_m$ : momento de inércia do rotor do motor

$j_l$ : momento de inércia do rotor da planta

$k_c$ : constante de rigidez torcional da correia

$k_t$ : constante de rigidez torcional do eixo flexível

$\theta_c$ : deslocamento torcional da correia

$\theta_t$ : deslocamento torcional do eixo flexível

$n$ : relação de transmissão

## 5. INSTRUMENTAÇÃO E PROCESSAMENTO DOS SINAIS

Foram utilizados quatro extensômetros elétricos instalados no eixo flexível em arranjo de ponte completa de Wheatstone, de modo que dois extensômetros opostos sofrem tração e, os outros dois sofrem compressão.

A ponte de extensômetros localizada no meio do eixo tem o sinal elétrico associado à torção e amplificado antes da transmissão. Isso se dá através da utilização do amplificador de instrumentação montado no circuito embarcado localizado na extremidade do eixo. O sinal é transmitido por meio de anéis e escovas e após passar pelo amplificador é enviado para a placa de aquisição que digitaliza o sinal já multiplicado por um ganho 1000.

A figura abaixo ilustra a montagem completa.

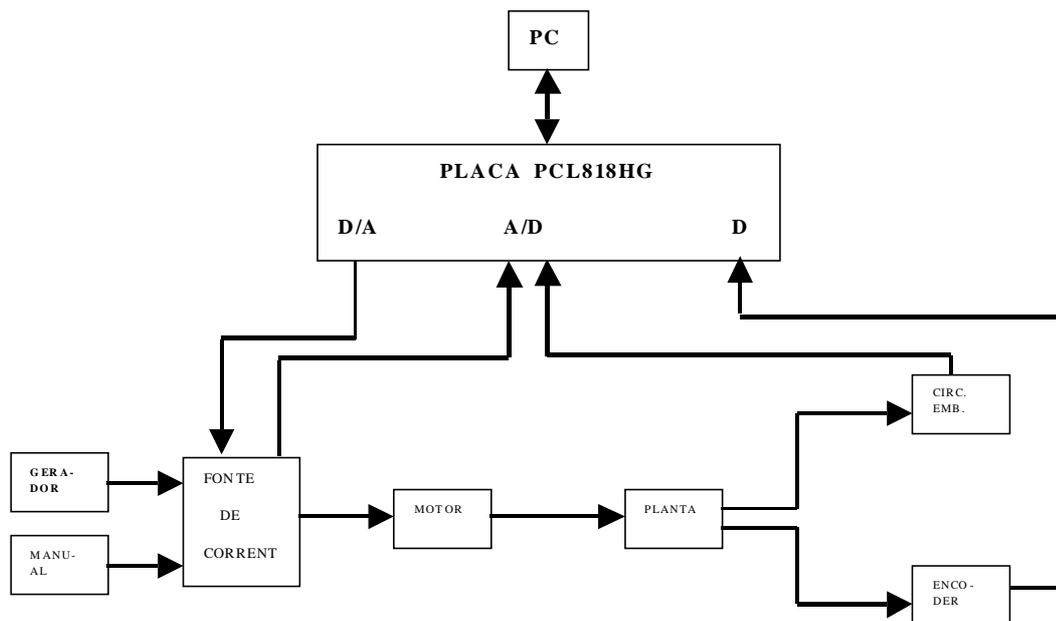


Figura 2 - Esquema global do circuito de instrumentação e controle

## 6. CONTROLADOR NEURAL

O controlador foi desenvolvido a partir de uma rede treinada com dados do modelo ajustado e testada com sinais experimentais da bancada experimental, até obter-se uma boa convergência entre os dois resultados.

Este processo é denominado emulação. Obteve-se deste modo uma rede neural que emula o comportamento experimental da bancada. A técnica empregada nos treinamentos da rede tanto na emulação quanto no controle foi o algoritmo de retropropagação do erro.

O treinamento foi feito em uma ampla faixa de frequências com excitações senoidal e onda quadrada, com amplitude 1,5 V p-p. Esta condição condiz com os testes a que a bancada foi submetida. Desta forma quando o sistema vier a sofrer uma excitação dentro das condições operacionais na faixa para a qual as redes foram treinadas, o controlador deverá atuar no sentido de conduzir o sistema para a condição desejada.

Assim, uma arquitetura adequada para treinar o controlador neural foi necessária, tendo sido desenvolvido um emulador específico para o controlador. A escolha se baseou em não formar uma rede muito complexa, o que aumentaria em muito o custo em horas de processamento. Além disso, vários treinos foram necessários até conseguir uma rede capaz de conduzir o sistema para qualquer situação nas proximidades dos treinamentos realizados uma vez que o controlador neural foi treinado conjuntamente com os dados experimentais.

Para treinar o controlador é necessário a rede que representa o modelo. A partir deste modelo, que representa a bancada experimental, é treinado o controlador através de simulações “off-line”

O diagrama abaixo ilustra o procedimento descrito acima.

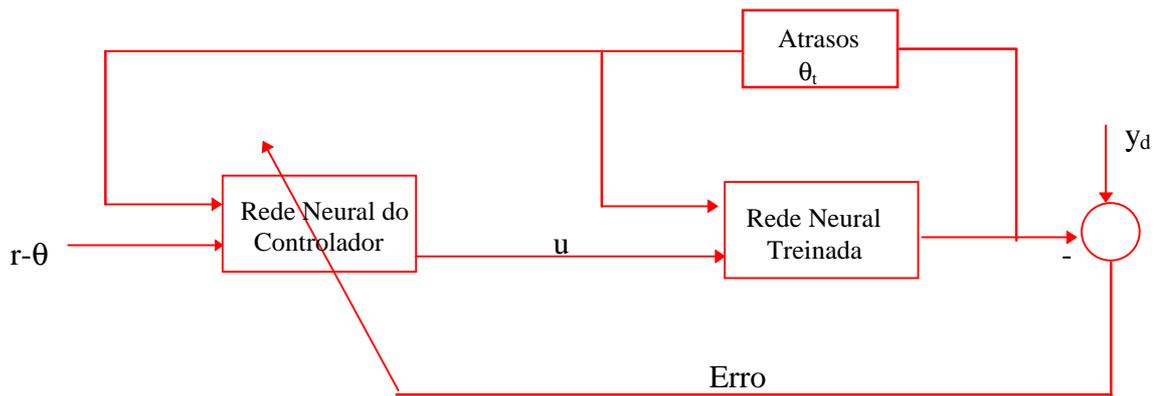


Figura 3 - Treino do controlador neural

Onde  $r$  é a entrada de referência e  $u$  é a saída do controlador neural.

A arquitetura da rede treinada (emulador) apresenta 8 entradas, sendo 7 atrasos e uma entrada externa senoidal com frequência de 85 Hz e amplitude de 1.5 V p-p. Uma camada oculta com 20 neurônios e uma camada de saída com 1 neurônio, representando o sinal da vibração torcional no eixo elástico.

O gráfico abaixo mostra o resultado da rede treinada, que servirá de modelo para o treino do controlador neural. O primeiro gráfico representa a saída desejada, o segundo é a rede treinada (emulador) e o terceiro o erro absoluto entre a saída desejada e a rede treinada.

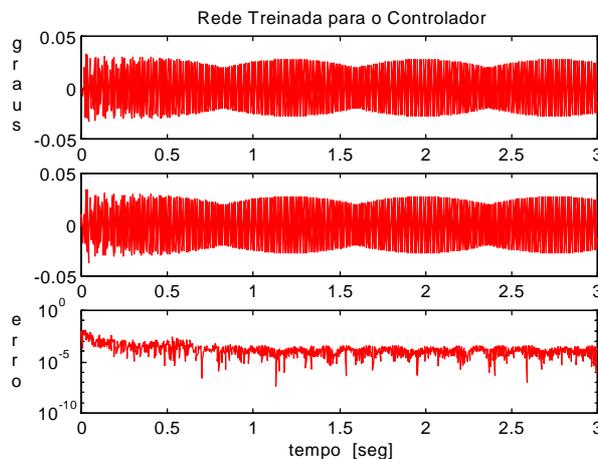


Figura 4 - Rede emulada para o controlador neural

A rede do controlador é formada por uma camada de 8 entradas, sendo 7 atrasos da saída da rede emulada e a oitava entrada é o erro entre os sinais desejado e a saída da rede, uma camada oculta com 20 neurônios e uma camada de saída com um neurônio (saída do controlador). Esta saída passa a ser uma das entradas da rede treinada, juntamente com os 7 atrasos dela própria.

Neste treinamento o erro é retropropagado através do emulador sem alterar os seus parâmetros, pois a rede já se encontra treinada. O erro realimenta a rede do controlador, determinando o processo de aprendizagem.

A Figura 5 apresenta a arquitetura do conjunto de treinamento, ou seja, rede do controlador e emulador.

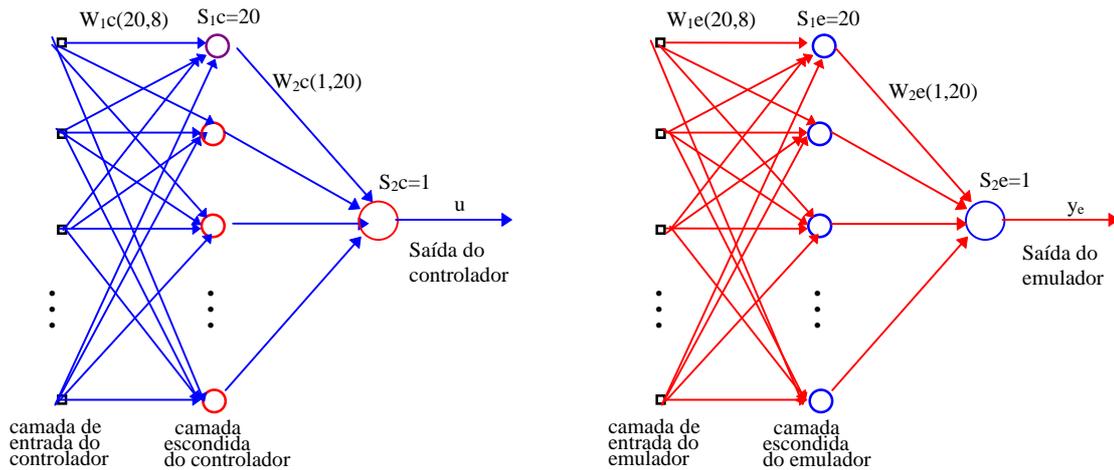


Figura 5 - Arquitetura do controlador e rede treinada

O controlador neural foi treinado para a partir de uma condição inicial, conduzir o sistema para zero, segundo uma rampa descendente. Após o treino, a partir de qualquer condição inicial ao longo da rampa treinada, o controlador conduzirá o sistema para o valor desejado.

O controlador treinado é mostrado no gráfico abaixo para uma condição inicial de 0,02 graus, determinado a partir dos experimentos como um bom valor de referência.

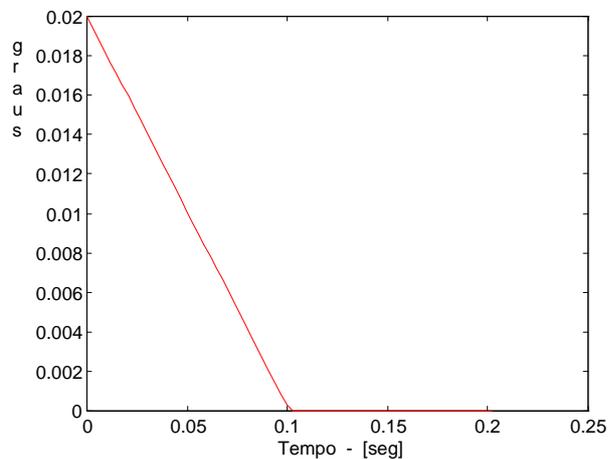


Figura 6 - Saída desejada

Abaixo é mostrada a saída real da planta representada pelo emulador após o treinamento da rede do controlador neural, indicando uma condução do sistema para o valor de referência em 0,1 segundos semelhante à saída desejada.

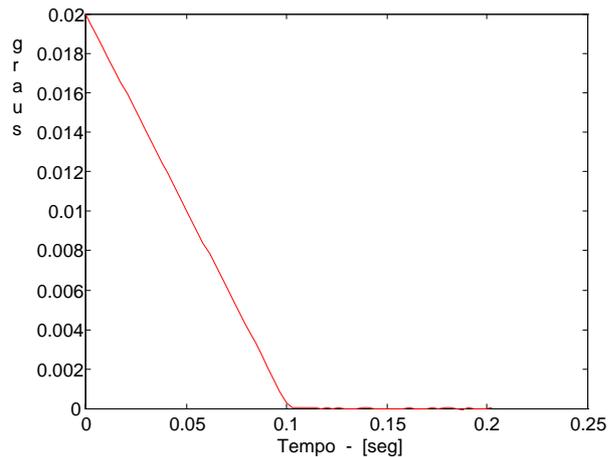


Figura 7 - Saída do emulador

O gráfico abaixo mostra a saída controlador neural para conduzir o sistema para a condição desejada.

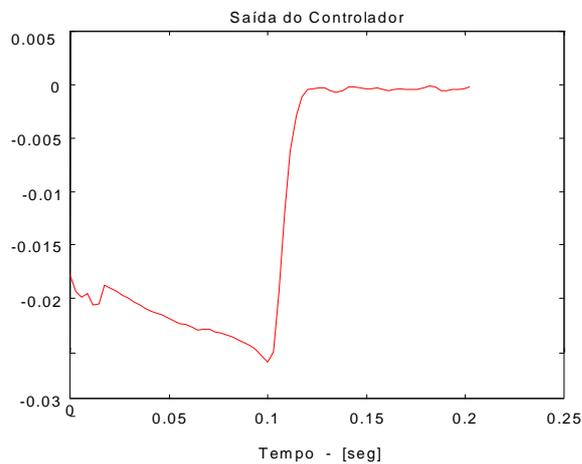


Figura 8 - Saída do controlador neural

## 7. CONCLUSÃO

Com o desenvolvimento de mecanismos providos de altas velocidades e maior complexidade dinâmica, a medição e controle de vibração torcional nos sistemas rotativos torna-se cada vez mais uma condição necessária, embora os recursos técnicos de instrumentação sejam ainda bastante escassos.

As redes neurais artificiais aplicadas aos sistemas dinâmicos envolvem várias etapas de desenvolvimento, desde a unidade processadora, seguida pela otimização de critérios de desempenho adequadamente definidos para cada problema de aplicação, vinculado à arquitetura específica para cada caso, e finalmente a definição do procedimento para o treinamento.

O treino simulado do controlador neural foi feito através de uma rede treinada e que representava o modelo ajustado e que foi testada com sinais extraídos da bancada experimental. O controlador foi projetado para seguir uma rampa descendente, a partir de uma condição inicial, e conduzir o sistema para o valor desejado em 0,1 segundo.

Algumas vantagens diferencia o controlador neural usando retropropagação de outras técnicas de controle. Uma delas é que o sistema segue a rampa sem oscilar, figura 7. Outra

vantagem é que o controlador pode ser treinado fora do sistema a ser controlado, não exigindo, a priori, o conhecimento completo do modelo e, finalmente, admite as não-linearidades características dos sistemas reais.

O controlador neural, apesar de não ter sido testado experimentalmente, leva a crer em resultados condizentes com os esperados, uma vez que foi treinado com uma rede que representava o modelo e testada com sinal experimental durante a emulação.

A utilização de redes neurais artificiais em sistemas mecânicos na identificação de parâmetros e desenvolvimento de estratégias de controle, se encontra ainda no início de aplicação de uma ampla teoria disponível, que poderá em muito, ajudar no desenvolvimento de novas metodologias, principalmente se tratando de sistemas não-lineares.

As questões acima podem motivar o interesse no desenvolvimento de estudos ainda em andamento e, especificamente complementar resultados a este trabalho que apresenta os primeiros passos no desenvolvimento de um controlador neural aplicado a sistemas rotativos.

## REFERÊNCIAS

- Asriel, L. U., Narendra, S. K. Control of Nonlinear Dynamical Systems Using Neural Networks: Controllability and Stabilization. . IEEE Trans. on Neural Networks, v. 4, n. 2, march 1993.
- Asriel, L. U., Narendra, S. K. Control of Nonlinear Dynamical Systems Using Neural Networks: Observability, Identification and Control . IEEE Trans. on Neural Networks, v. 7, n. 1, january 1996.
- Chen, M. H., Qi, Z. G., Yang, S. C. J., Amini, F. Neural Network For Structural Dynamic Model Identification. Journal of Engineering Mechanics, december 1995.
- Fletcher, R. Practical Methods of Optimization. John Wiley & Sons, 1975.
- Hagan, T. M., Demuth B. H., Beale, M. Neural Network Design. PWS Publishing Company, 1996.
- Hagan, T. M., Menhaj, B. M. Training Feedforward Networks With the Marquardt Algorithm. IEEE Trans. on Neural Networks, v. 5, n. 6, november 1994.
- Haykin, S. Neural Networks: A Comprehensive Foundation. Prentice-Hall, 1994, 696p.
- Hopfield, J. J. Neural Networks and physical systems with emergent collective computational abilities. Proceedings of the National Academy of Sciences 79, p. 2554-2558, 1982.
- Huang, S., Huang, Y. Learning Algorithms for Perceptrons Using Back-Propagation with Selective Updates. IEEE Control Systems Magazine, april 1990.
- Khater, E., Nóbrega, E. G. O., Netto, M. L. A. Controle Ativo de vibração torcional em sistemas acionados por motores de corrente contínua. IV CEM-NNE/96, p. 583-588, junho 1996.
- Khater, Evaldo. *Acelerômetro angular com circuito embarcado*. Rio de Janeiro: Universidade Federal do Rio de Janeiro, COPPE, 1992. 107 p. Tese (Mestrado).
- Khater, Evaldo. *Controle de Vibração Torcional em Sistemas Rotativos Usando Redes Neurais Multicamadas*. Campinas - SP: Universidade Estadual de Campinas, UNICAMP, 1998. 114 p. Tese (Doutorado).
- Naidu, R. S., Zafiriou, E., Mcavoy, J. T. Use of Neural Networks for Sensor Failure Detection in a Control System. IEEE Control Systems Magazine, april 1990.
- Narendra, S. K., Parthasaraty, K. Identificacion and Control of Dynamical Systems Using Neural Networks. IEEE Trans. on Neural Networks, v. 1, n. 1, march 1990.
- Rumelhart, D. E., Hinton, G. E., Williams, R. J. Learning Internal Representations by Error Propagation. Explorations in the Microstructure of Cognition, v. 1: Foundations. M.I.T. Press, Cambridge, Massachusetts, p. 318-362, 1986.

- Werbos J. P. Backpropagation Through Time: What It Does and How to Do It. Proceedings of the IEEE, v. 78, n. 10, october 1990.
- Yang, M. S., Lee, S. G. Vibration Control of Smart Structures by Using Neural Networks. Trans. ASME Journal of Dynamic Systems, Measurement, and Control, v. 119, march 1997.