

# Controlador adaptivo neural para mesa de coordenadas X-Y

## NEURAL ADAPTIVE CONTROLLER FOR COMPOUND TABLE

José Bezerra de Menezes Filho  
Curso de Pós-Graduação em Engenharia Mecânica – CT-UFPB  
Simplicio Arnaud da Silva  
Benedito Santana de Oliveira  
José Antônio Riul  
Departamento de Tecnologia Mecânica - CT-UFPB

### RESUMO

O presente trabalho trata do projeto de um controlador neural para uma mesa de coordenadas de dois graus de liberdade composta de duas bases. As bases deslocam-se num plano horizontal e são acionadas por dois motores CC. As posições das bases são medidas por dois sensores de posição. Como estas mesas são utilizadas em aplicações onde se exige alto grau de exatidão, controladores adaptativos são indispensáveis. Um controlador adaptativo neural é projetado em duas etapas para cada base. Na primeira etapa, uma rede neural para cada base, com três camadas, possuindo quatro neurônios na camada de entrada, oito na oculta e um na de saída, é treinada de modo "off line", usando as funções de transferência de cada base, obtidas do algoritmo de identificação dos mínimos quadrados. Os sinais de entrada para as redes neurais são determinados a partir de uma analogia com um controlador PD2. A saída de cada rede neural corresponde a variável de controle de cada base. Na segunda etapa, implementa-se o controlador em tempo real, usando os pesos sinápticos obtidos na primeira etapa como valores iniciais, e a cada instante de tempo mantém-se o treinamento, em função do movimento das bases. Para validação do controlador, resultados experimentais são mostrados.

### PALAVRAS CHAVE

Controle adaptativo. Mesa de coordenadas X-Y. Rede neural.

### ABSTRACT

The present work is about a position neural adaptive controller for a table with two degrees of freedom, composed of two bases. The bases are dislocated in the horizontal plan, and are driven by two DC motors.

The basis positions are obtained with two positions sensors. As these systems are used in mechanical systems measurements which need high degree of accuracy, adaptive controllers are indispensable to carry out these tasks. A neural adaptive controller is used for each base and is designed to operate in two steps. In the first step, a three layer neural network with four inputs nodes, eight nodes in the intermediate layer and one output node is trained. The inputs of the first layer are designed by analogy with a PD2 controller. The neural network output is the control variable. In this first step, the Transfer Function of each base is used to obtain the weight values of all layers in the off-line mode. In the second step, the weights obtained are used and also updating in the real time, as function of the base movements, furnishing the control variables. Experimental results are presented.

### KEYWORDS

Adaptive control. Compound table. Neural network.

### INTRODUÇÃO

Devido a sua versatilidade, a mesa de coordenadas XY é utilizada em muitas aplicações nas áreas industrial, comercial e de serviços. A grande variedade de mesas XY existentes no mercado usa basicamente dois tipos de acionamento: o acionamento por motor de passo, que trabalha em uma estrutura de malha aberta e o acionamento por servo mecanismo, que utiliza motores de Corrente Contínua ou de indução em malha fechada. Neste caso, há a necessidade de sensores de posição (Encoders) que servem para fornecer a posição angular e velocidade do eixo do motor.

Para o controle de servomecanismo existem várias técnicas implantadas em industriais, tais como a de Ziegler-Nichols (Ziegler, 1942) que é utilizada em casos

onde a Função de Transferência do Sistema não é conhecida e as técnicas de avanço e atraso de fase e de controle moderno (Phillips, 1996; Ogata, 2003; Shanian, 1993 ; Dorf ,2001).

Com a predominância de controle por computador, encontram-se na literatura várias técnicas de projeto e implementação de controladores discretos, (Hemerly, 1996; Astrom & Wittenmark ,1995). Neste trabalho destaca-se o uso do Controlador PD2 (Proporcional derivativo duplo) descrito em Buhler (1982) que é utilizado em sistemas que têm dois pólos dominantes e apresenta comportamento integral (O terceiro pólo igual a 1) . Esta estrutura é derivada de um controlador PD ao qual é adicionada uma componente proporcional à derivada do sinal de erro de posição.

Alternativamente ao controle convencional, tem-se o controle inteligente, consistindo basicamente de três abordagens de acordo com Paraskevopoulos (1995): Sistemas Especialistas baseados em conhecimento, Controle por Lógica Fuzzy e Controle por Redes Neurais.

O Controle por Lógica Fuzzy incorpora a maneira de pensar do Ser Humano em um sistema de controle (Shaw & Simões, 2001). Um exemplo de implementação de um Controle por Lógica Fuzzy em um sistema multivariável é dado por Coelho et al (2000), onde as principais características do sistema controlado são investigadas.

Com relação ao Controlador Neural, várias estruturas estão presentes na literatura. Krishnapura & Jutan (2000) implementaram um Controlador Neural baseado em uma concepção de um controlador do tipo PID. Martins & Alencar (2002) usaram uma Rede Neural com Funções de Base Radial para implementar um controlador em uma estrutura de Controlador do tipo PD. A Função de Base Radial também foi utilizada por Coelho & Moedinger (2002) para identificação de um manipulador de 2 Graus de Liberdade.

Este Trabalho apresenta um sistema automático de posição de uma mesa de Coordenadas X Y que utiliza um Controlador Adaptativo Neural baseado em um Controlador PD2. Este tipo de controlador foi escolhido devido ao fato de não ser previamente conhecida sua carga. As equações discretas que representam a dinâmica das Mesas X e Y são usadas para treinamento inicial das Redes Neurais em um programa de simulação. Estas equações são obtidas através do algoritmo de identificação dos Mínimos Quadrados Recursivo. Após o processo de treinamento on-line as Redes Neurais são implementadas em tempo real. O trabalho é validado com a apresentação dos resultados experimentais obtidos.

## MONTAGEM EXPERIMENTAL

Utilizou-se nesta pesquisa uma Mesa de Coordenadas X Y com mecanismo de transmissão do tipo Fuso de esferas recirculantes. O trabalho foi realizado no Laboratório de Controle e Acionamentos de Sistemas do Centro de Tecnologia da UFPB. Foi escolhido este tipo de mesa por possuir alta eficiência e baixas perdas em comparação com as mesas de correias sincronizadas. No entanto, sua velocidade máxima é limitada em 3m/s enquanto em transmissão por correia sincronizada pode-se alcançar velocidade de até 5m/s.

Para o controle de posição das mesas X e Y foram utilizados dois motores de Corrente Contínua (Motor CC) em malha fechada controlados por Controladores Adaptativos Neurais. Os controladores foram implementados no ambiente LabVIEW<sup>®</sup> residente em um microcomputador Pentium 900 MMX equipado com uma placa de aquisição de dados (DAC) Quatec 801. Para adequar os níveis de corrente para utilização nos motores CC foram utilizados Amplificadores de Potência especialmente projetados para esse fim em laboratório. Para computar a posição do eixo de cada motor foram projetados circuitos detectores de posição. Estes circuitos geram pulsos que alimentam contadores implementados em dois microcontroladores PIC16F84. As saídas digitais dos Microcontroladores são então convertidas em sinais analógicos por Conversores Digital Analógico (DAC) de 8 bits TLC 7226. Finalmente, as saídas dos Conversores D/A são lidas pela placa de aquisição de dados do Microcomputador para servir de sinal de realimentação para os Controladores Adaptativos Neurais. A Mesa de coordenadas X Y utilizada nesta pesquisa é mostrada na Fig. 1.



Figura 1 – Vista da Mesa de Coordenadas X Y

O Diagrama de blocos do sistema de controle da Mesa X Y completo é mostrado na Fig. 2.

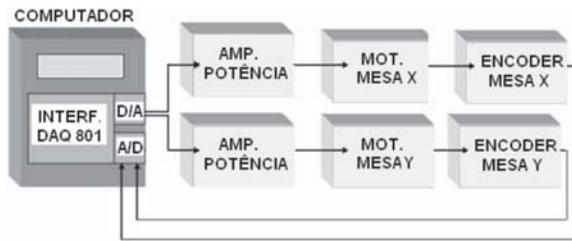


Figura 2 - Diagrama de blocos do Sistema de Controle

## MODELO MATEMÁTICO DO SISTEMA DE POSIÇÃO COM MOTOR CC

Considerando o motor CC de imã permanente com carga, a relação entre a posição angular do eixo e a tensão aplicada na armadura é:

$$\frac{Y(s)}{U(s)} = \frac{Km}{s^3(JLa) + (Ra.J + La.F)s^2 + (Ra.F + Kv.Km)s} \quad (1)$$

onde:

s: variável de Laplace

U(s): tensão de armadura no domínio de Laplace

Kv: constante de velocidade [V/rad/s]

Km: constante de torque da carga e do motor refletida no eixo do motor [Nm/A]

Ra: resistência de armadura do motor CC (Ohms)

La: indutância de armadura [H]

Y(s): posição angular do eixo do motor no domínio de Laplace

A Função de Transferência dada pela Eq. (1) na forma discreta é dada por:

$$\frac{Y(Z)}{U(Z)} = \frac{\Theta_4 Z^2 + \Theta_5 Z + \Theta_6}{Z^3 + \Theta_1 Z^2 + \Theta_2 Z + \Theta_3} \quad (2)$$

onde  $[\Theta_1, \Theta_2, \Theta_3, \Theta_4, \Theta_5, \Theta_6]$  é o vetor de parâmetros da Função de Transferência Discreta.

Reescrevendo a Eq. (2) usando o operador  $Z^{-1}$ , obtém-se a Eq. (3).

$$Y(k) = \Theta_1 Y(k-1) + \Theta_2 Y(k-2) + \Theta_3 Y(k-3) + \Theta_4 U(k-1) + \Theta_5 U(k-2) + \Theta_6 U(k-3) \quad (3)$$

## IDENTIFICAÇÃO DO MODELO MATEMÁTICO DA MESA X Y

Utilizou-se neste trabalho o método dos Mínimos

Quadrados Recursivo (RLS) para obtenção dos parâmetros da Eq. (3) para cada mesa. Neste método a solução é dada pela Eq. (4) (Aguirre, 2000), sendo  $\varepsilon$  o erro de estimação.

$$Y = \Phi^T \Theta + \varepsilon \quad (4)$$

Para cada tempo k procura-se a minimização da Função de Custo "J" definida por Eq. (5).

$$J = \sum_{k=1}^N \varepsilon(k)^2 = \varepsilon^T \varepsilon \quad (5)$$

A minimização da Função de Custo é obtida derivando-se a Eq. (5) com respeito à  $\Theta$ , com  $\Phi$  constante. Após algumas simplificações tem-se a Eq. (6) que fornece o vetor de parâmetros da Eq. (3).

$$\Theta = (\Phi^T \cdot \Phi)^{-1} \Phi^T \cdot Y \quad (6)$$

O algoritmo de identificação pelo método dos Mínimos Quadrados Recursivo encontra-se descrito em Ljung (1987). Um sinal de onda quadrada de nível variável somado com um sinal de ruído randômico foi utilizado como excitação para os motores das mesas. Estas entradas e as saídas correspondentes foram então utilizadas em tempo real nos algoritmos RLS para cálculo dos parâmetros da Eq. (3) para cada mesa.

Foram obtidas as seguintes Funções de Transferência das mesas X e Y:

Função de Transferência da Mesa X :

$$\frac{Y(Z)}{U(Z)} = \frac{-0.003923.Z^2 + 0.02278Z + 0.0294}{Z^3 - 0.5696Z^2 - 0.1812Z - 0.2492} \quad (7)$$

Função de Transferência da Mesa Y:

$$\frac{Y(Z)}{U(Z)} = \frac{-0.0176Z^2 + 0.03027Z + 0.05749}{Z^3 - 0.8226Z^2 - 0.3556.Z + 0.1782} \quad (8)$$

Na Figura 3.a são mostrados os sinais de saída real e estimada pelo algoritmo identificador RLS para o motor da Mesa X. Na Fig. 3.b é mostrado o sinal de excitação para este motor.

Na Fig.4.a e na Fig.4.b são mostradas os mesmos sinais para o motor da mesa Y.

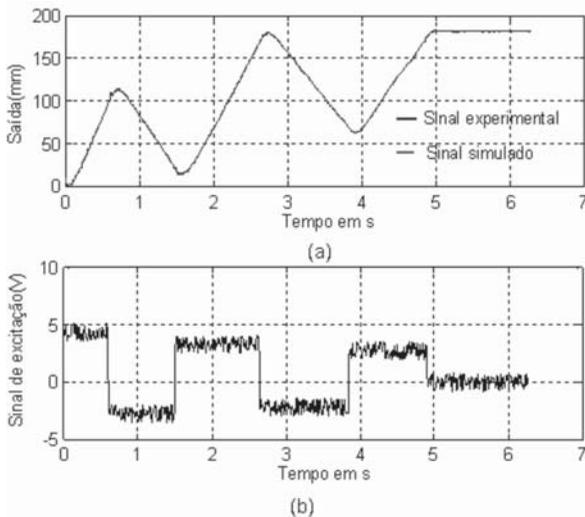


Figura 3 – Mesa X; a) Saídas experimental e simulada; b) Sinal de entrada

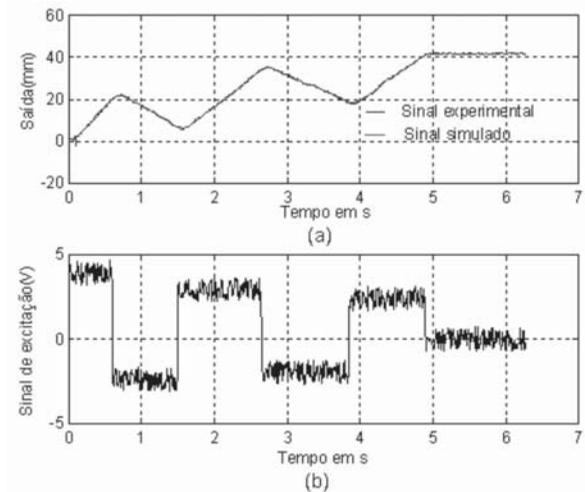


Figura 4 – Mesa Y; a) Saídas experimental e simulada ; b) Sinal de entrada

## O CONTROLADOR ADAPTATIVO NEURAL

Para posicionamento das bases que compõem a mesa de coordenadas foi utilizada para cada base uma Rede Neural de Multicamada (RNMC) composta de três camadas. A excitação de cada Rede Neural é composta de um conjunto de  $n_{in} = 4$  sinais de entrada.

Os sinais de entrada de cada Rede Neural foram determinados através da analogia com o controlador PD2 (Proporcional derivativo duplo) que é utilizado em sistemas que apresentam comportamento integral. Este tipo de controlador é derivado de um controlador PD com a adição de um termo ligado a derivada do erro.

A Equação discreta do controlador PD2 é, de acordo com Buhler (1982), dado por :

## FALTA EQUAÇÃO (9)

onde:

$u^*[k]$ : valor da saída discreta do controlador

$K_p$ : ganho proporcional do controlador

$K_d$ : ganho aplicado ao sinal de erro

$K_{d_2}$ : ganho aplicado a derivada o sinal de erro

$e^*[k]$ : erro no instante de amostragem  $k$

$e^*[k-1]$ : erro armazenado no instante anterior ao tempo  $k$

$e^*[k-2]$ : erro armazenado na amostragem anterior ao tempo  $k-1$

A Figura 5 apresenta a configuração de um dos Controladores Adaptativos Neurais usados neste trabalho para o controle de posição da Mesa X Y.

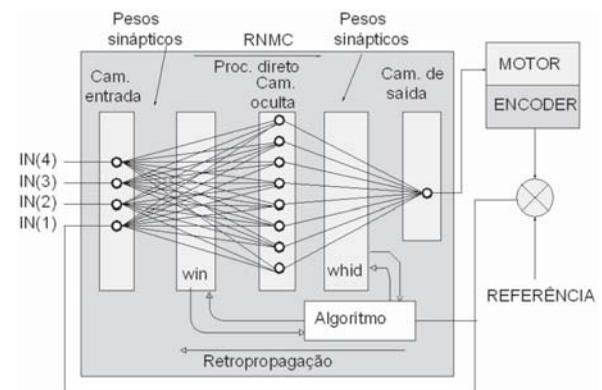


Figura 5 – Estrutura do Controlador Adaptativo Neural usado no controle de posição da Mesa X Y

A segunda camada (camada oculta) da RNMC tem  $n_{hid} = 8$  neurônios. Para estes neurônios, é definido o Campo induzido  $vin(i)$  para cada neurônio  $i$ , dado pela Eq. (10), como a combinação linear das entradas  $in(i)$  ponderadas por fatores  $win(j,i)$ , chamados pesos sinápticos.

$$vin(i) = \sum_{j=1}^{n_{hid}} \sum_{i=1}^{n_{in}} win(j,i).in(j) \quad (10)$$

O Campo induzido de cada neurônio oculto é aplicado em uma função do tipo Sigmóide, chamada de Função de Ativação. A saída de cada Função Sigmóide é chamada de Sinal Funcional do neurônio oculto, dado pela Eq. (11).

$$yh(i) = S(vin(j)) = \frac{1}{1 + \exp(-betahid.vin(i))} \quad (11)$$

A terceira camada (camada de saída) consiste de 1 neurônio. Para este neurônio, define-se o Campo Induzido, dado pela Eq. (12), como a combinação linear das saídas dos Sinais Funcionais dos neurônios ocultos  $yh(i)$  ponderados com os pesos sinápticos  $whid(1,i)$ .

$$vout = \sum_{i=1}^{nhid} whid(1,i).yh(i) \quad (12)$$

A Função de Ativação de cada neurônio da camada de saída, do tipo Tangente hiperbólica, dada pela Eq. (13), fornece o sinal de saída  $outs$ , que é o sinal de controle para os motores das mesas X "

$$outs = \text{Tanh}(vout) = \frac{1 - \exp(-vout)}{1 + \exp(-vout)} \quad (13)$$

A estrutura utilizada foi escolhida pelo fato de apresentar o melhor resultado para o controle do sistema pesquisado em relação a outras estruturas testadas.

## IMPLEMENTAÇÃO DA REDE NEURAL DE MULTICAMADA

De acordo com Haykin (2001), a utilização da Rede Neural de Multicamada (RNMC), compreende dois passos: o primeiro é chamado de propagação para frente e o segundo é a retropropagação. Na propagação para frente, os pesos sinápticos são mantidos sem mudança. O fluxo de processamento vai dos neurônios de entrada para o neurônio de saída, o qual fornece o sinal de controle para os motores. Na retropropagação todos os pesos da Rede são ajustados. A retropropagação é iniciada pelo gradiente local da camada de saída que é definido como o produto da derivada da Função de Ativação do neurônio de saída e o erro de posição (diferença entre o ângulo de posição do eixo do motor e a referência) e é dado por.

$$gradout = er.deriv(\tanh(vout)) \quad (14)$$

A derivada da Tangente hiperbólica é dada por

$$deriv(\tanh(vout)) = (outs + 1)(1 - outs). \quad (15)$$

Com o Gradiente local dado pela Eq. (14), são calculadas as variações dos pesos ( $whid$ ) que ligam a

camada de saída com a camada oculta, dadas pela Eq. (16):

$$\delta(i) = fatcon.gradout.yh(i) \quad \text{para } i = 1 \text{ a } nhid \quad (16)$$

$fatcon$  é o fator de convergência do algoritmo

Finalmente as modificações dos pesos sinápticos ( $whid$ ) são dados pela Eq. (17):

$$whid(1,i) = whid(1,i) + \delta(i) \quad \text{para } i = 1 \text{ a } nhid \quad (17)$$

A modificação dos pesos sinápticos entre a primeira camada e a camada oculta é iniciada com o cálculo dos gradientes locais de cada neurônio da camada oculta dado pela Eq. (18) .

$$grad(i) = whid(1,i).gradout.derivS(i) \quad \text{para } i = 1 \text{ a } nhid \quad (18)$$

A derivada da Função Sigmóide dos neurônios ocultos é dada pela Eq. (19):

$$derivS(i) = yh(i).(1 - yh(i)) \quad \text{para } i = 1 \text{ a } nhid \quad (19)$$

Através do Gradiente local dado pela Eq (18), a variação dos pesos entre a camada de entrada e camada oculta ( $win$ ) é calculada de acordo com a Eq. (20).

$$\delta(m) = fatcon.grad(i).in(m) \quad \text{para } i=1 \text{ a } nhid \text{ e } m=1 \text{ a } nin \quad (20)$$

Finalmente é calculada a modificação dos pesos sinápticos ( $win$ ), que ligam cada neurônio de entrada com os neurônios da camada oculta, de acordo com a Eq. (21).

$$win(i,m) = win(i,m) + \delta(m) \quad \text{para } i=1 \text{ a } nhid \text{ e } m=1 \text{ a } nin \quad (21)$$

Após o processo de retropropagação o processamento para frente é aplicada na RNMC fornecendo os sinais de controle para posicionamento da mesa X Y.

## IMPLEMENTAÇÃO EXPERIMENTAL DO CONTROLADOR ADAPTATIVO NEURAL

Os Controladores Adaptativos Neurais foram

implementados em um ambiente LabVIEW<sup>®</sup> utilizando um tempo de amostragem de 10ms. Para treinamento da RNMC de cada mesa, os pesos sinápticos da camada oculta (win) e da camada de saída (whid) foram inicialmente obtidos de modo aleatório através de um programa em Matlab<sup>®</sup>. Com estes pesos sinápticos iniciais foi realizada uma seqüência de simulações em ambiente LabVIEW<sup>®</sup> para treinamento “off-line” das RNMC que compõem o controlador neural, utilizando-se como modelos das bases X e Y, as Funções de Transferência dadas pela Eq. (7) e pela Eq. (8). Após o treinamento “off-line” o Controle Adaptativo Neural foi implementado em tempo real, com seus pesos reajustados a cada intervalo de amostragem, para o sinal de

referência senoidal. A Fig. 6 mostra os sinais de saída para cada mesa observando-se trajetórias muito próximas das sinais de referência com um pequeno atraso no tempo.

Sinais de referência do tipo degrau com mudança de amplitude a cada 2 s, foram usados com o objetivo de avaliar o desempenho do sistema de controle frente a mudanças de sinais de referência. Na Fig. 7.a e na Fig. 7.b, são mostrados os sinais de referência, de saída e de controle para a Mesa X e na Fig. 8.c e na Fig. 8.d são observados os mesmos sinais para a Mesa Y, onde observa-se um erro relativo muito pequeno de regime permanente.

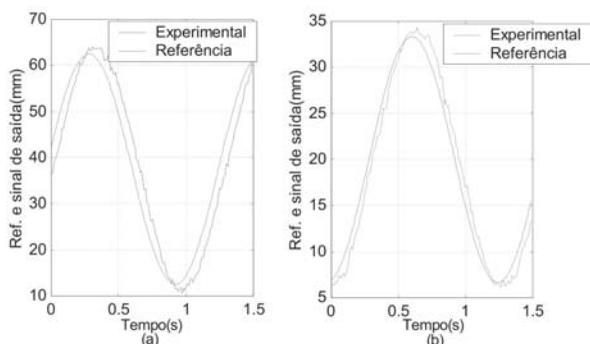


Figura 6 – Sinais de saída e de Referência ; a) Mesa X ; b) Mesa Y

## CONCLUSÃO

Neste trabalho foi mostrada a implementação de Controladores Adaptativos Neurais para uma mesa de coordenadas X Y utilizando Redes Neurais de Multicamadas ( RNMC). Inicialmente as Funções de Transferência das Mesas X e Y foram obtidas com a utilização do algoritmo de Identificação Mínimo Quadrado Recursivo (RLS). Com estas Funções de Transferência efetuou-se o treinamento inicial da RNMC de modo “off-line” através de um programa de simulação. Com a obtenção dos pesos sinápticos obtidos no treinamento “off-line” da RNMC foram implementados os Controladores Adaptativos Neurais para cada Mesa. Foi realizado um experimento envolvendo uma excitação senoidal e outro envolvendo sinais do tipo degrau. Nos experimentos, observou-se que os sinais de saída de cada mesa continham ruídos gerados pelos encoders, porém, isto não afetou o desempenho dos controladores. No caso das saídas das mesas excitadas por degraus observou-se a presença de sobre-sinal. Acreditamos que estes sobre-sinais possam ser

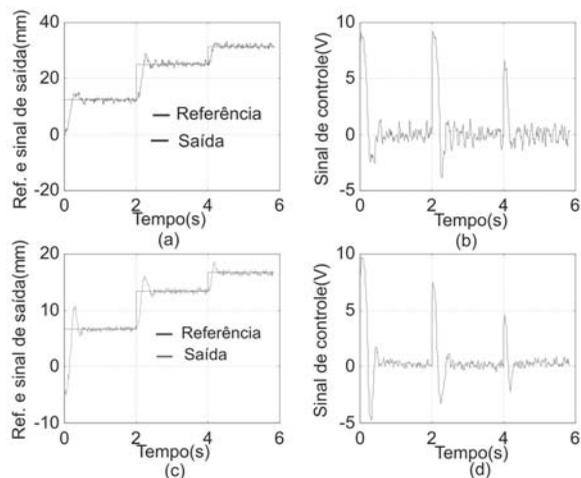


Figura 7 – Sinais Experimental, de referência e controle da Mesa de coordenadas X and Y

minimizados através da repetição do treinamento da Rede e uma investigação mais aprofundada nos fatores de convergência e nos formatos das Funções de Ativação das RNMCs. Estes melhoramentos de desempenho dos Controladores Adaptativos Neurais serão objetos de trabalhos futuros.

## REFERENCIAS

- Aguirre, L. A., 2000. Introdução à Identificação de Sistemas: Técnicas Lineares e não-Lineares Aplicadas a Sistemas Reais, 2ª Edição UFMG, Belo Horizonte, MG, Brasil.
- Alsina, P. J., 1996. Controle Neuroadaptativo Modular de Manipuladores Robóticos. PhD Thesis.: Federal University of Paraíba/Brazil.

- Astrom, K. J. & Wittenmark, B. , 1995. *Adaptive Control*. Editora Addison Wesley, Segunda Edição.
- Buhler, Hansruedi. Réglages échantillonnés, 1982. Presses polytechniques romandes. Lausanne. Suisse.
- Coelho, L. S., Almeida, O. M., & Coelho, A. R., 2000. Fundamentos Relevantes de Controle Nebuloso: Aspectos de Implementação e Estudo de Caso Multivariável. *XIII Congresso Brasileiro de Automática*. Florianópolis, SC - Brasil.
- Coelho, L. S., & Moedinger, L. H., 2002. Projeto e Sintonia de Controle PID baseado em Programação Evolutiva e Redes Neurais". *XIV Congresso Brasileiro de Automática*.
- Dorf, R. C., 2001. Sistemas de Controle Moderno. Livraria LTC, São Paulo, SP. Brasil.
- Haykin, S., Redes Neurais, Princípios e Prática, Tradução de Paulo Martins Engel. 2ª Edição, Bookman, Porto Alegre, RS - Brasil.
- Hemerly, E. M., 1996. *Controle Por Computador de Sistemas Dinâmicos*. Ed. Edgard Blucher LTDA, S. Paulo, Brasil.
- Krishnapura, Venugopal G., & Jutan, A. (2000). "A neural adaptive controller". *Chemical Engineering Science* 55, 3803-3812.
- Ljung, Lennart, System Identification, Theory for the User. Prentice-Hall , Inc. New Jersey, USA.
- Martins, N. A., & Alencar, M., 2002. Projeto de Controlador Adaptativo para Robôs Manipuladores no Espaço de Juntas. *XIV Congresso Brasileiro de Automática*. Natal, RN - Brasil.
- Ogata, K., 2003. Engenharia de Controle Moderno. Editora Prentice Hall. São Paulo - Brasil.
- Phillips C. L., & Harbor, R. D., 1997. Sistemas de Controle e realimentação. MAKRON Books do Brasil Editora LTDA.
- Paraskevopoulos, P.N., 1996. Digital Control Systems. First Edition, Prentice Hall, USA.
- Shahian, B. Hassul, M., 1993. Control System Design. Prentice Hall, USA.
- Simões, M. G., 2001. Controle e Modelagem Fuzzy. Editora Edgard Blucher Ltda. São Paulo, SP- Brasil.
- Ziegler , J.G., and Nichols, N.B., 1942, Optimum Settings for Automatic Controllers. *ASME Trans.* 64, pp. 759-768.