
CONTROLADOR VETORIAL NEURAL PARA MESA DE COORDENADAS XY

José Bezerra de Menezes Filho*

jbmenezesf@hotmail.com

Clivaldo Silva de Araújo†

clivaldo@ct.ufpb.br

Simplício Arnaud da Silva†

sarnaud@ct.ufpb.br

Antônio Feliciano Xavier Filho†

antonio.feliciano@cefetpb.edu.br

*Instituto Federal de Educação Ciência e Tecnologia da Paraíba- IFPB
Av. Primeiro de Maio, 720, Jaguaribe, CEP 58000.00 - João Pessoa, PB.

†Universidade Federal da Paraíba, Centro de Tecnologia, Departamento de Tecnologia Mecânica- Campus I-
Cidade Universitária, CEP 58.059-900- João Pessoa, PB.

RESUMO

Este trabalho apresenta uma nova estratégia de acionamento para uma mesa de coordenadas XY, denominada de Controle Vetorial Neural, utilizando uma rede neural multicausada (RNMC) atuando como controlador adaptativo direto, cujo algoritmo de aprendizagem se baseia na minimização do erro entre o vetor de posição atualizado e o de referência. Duas estratégias de controle são mostradas. A primeira estratégia é baseada no uso de controladores de posição neurais, independentes, para cada eixo e a segunda é apresentada como principal contribuição deste trabalho e é baseada no uso do Controlador Vetorial Neural. A estratégia proposta é diferenciada dos conhecidos controladores de trajetória por não possuírem controladores independentes para cada eixo. A mesa de coordenadas XY, usada para validação, é uma estrutura de dois graus de liberdade considerada como um manipulador de eixos desacoplados. Resultados experimentais e de simulação mostram o desempenho superior do Controlador Vetorial Neural. Um menor tempo de processamento no uso de uma única rede neural é uma vantagem adicional do uso do Controlador Vetorial Neural em relação aos controladores independentes.

PALAVRAS-CHAVE: Controle adaptativo, Mesa de coordena-

nadas XY e Rede Neural.

ABSTRACT

Neural and Vectorial Controller for XY Table

The proposal of this research is to present a new strategy of drive, called of Neural Vectorial Control, using a Multilayer Neural Network acting as a direct adaptive controller, that is based on the minimization of the error between the actual position vector and the vector of reference position. Two strategies of control are shown. The first strategy is based on the use of position neural controllers of independent axes. The second strategy, presented as the main contribution of this paper, is based on the use of the vectorial neural controller. The strategy proposal in this research is differentiated of the well known tracking controllers for not possessing individual closed loops of control for each axis. The XY table used for validation is a structure of two degrees of freedom, that it is considered as a manipulator with detached axes. Experimental and simulated results show the superior performance of the vectorial neural control. A lesser time of processing in the use of an only Neural Network is an additional advantage of the use of the vectorial neural controller in relation to the independent controllers.

KEYWORDS: Adaptive control, Compounds table, Neural Network.

Artigo submetido em 13/05/2008 (Id.: 00874)

Revisado em 07/02/2009, 16/07/2009, 03/10/2009, 09/12/2009, 27/03/2010

Aceito sob recomendação do Editor Associado Prof. Takashi Yoneyama

1 INTRODUÇÃO

As mesas de coordenadas são utilizadas nas indústrias de máquinas ferramenta, robôs industriais, dosadores de fluido, fabricação de placas de circuitos impressos, etc.

Devido à sua grande versatilidade, podem ser utilizadas em diversas aplicações das áreas industriais, comerciais e de serviços. Um grande número de mesas de coordenadas, ainda existentes no mercado, é de acionamento manual, em que o operador deve posicionar a estrutura por meio de volantes. Esse tipo de mesa apresenta a vantagem de reduzido custo de aquisição e de manutenção e pode ser manuseada com facilidade por operários sem que haja necessidade de treinamento adicional.

A principal desvantagem da mesa de coordenadas XY manual é que o posicionamento correto da peça, a ser trabalhada, depende exclusivamente da habilidade e da experiência do operador. Nesse caso, a ausência de um operador experiente, compromete decisivamente à produtividade do ambiente de trabalho, já que o conhecimento acumulado no manuseio da mesa é de fundamental importância para a obtenção de bons resultados.

Como alternativa às mesas de posicionamento manual têm-se as estruturas acionadas por motores elétricos. Nesse caso são utilizados motores de passo, de corrente contínua, de indução e síncronos. A grande maioria dos acionamentos desse tipo de mesa de coordenadas utiliza malhas fechadas de controle, que necessitam de sensores de posição. Como elementos dos sistemas de retroalimentação, são utilizadas estruturas de sensores ligados aos eixos dos motores (*Encoders*) ou sistemas mais complexos de visão artificial compostos de câmeras filmadoras.

Os controladores de máquinas ferramenta, que englobam as mesas de coordenadas, podem ser de acordo com a literatura, de dois tipos fundamentais: o controle de erro de trajetória e o controle de erro de contorno. Para utilização desse último tipo de controlador é necessário à dedução das equações de erro de contorno (Koren, 1978). Esse erro é o resultado da ação conjunta dos eixos (direções de movimento de uma máquina ferramenta) da máquina controlada. O controle de erro de trajetória atua nos eixos de modo independente, estabelecendo malhas fechadas de controle apenas com os valores de posição e referência para cada eixo (Ramesh *et al*, 2005).

Este artigo apresenta uma nova estratégia de acionamento, denominada de controle vetorial neural, utilizando uma rede neural multicamada (RNMC) atuando como controlador adaptativo direto, que se baseia na minimização do erro entre os vetores de posição atualizados e o de referência. A estratégia proposta, neste trabalho, diferencia-se dos controladores de erro de trajetória por não possuir malhas fechadas

individuais de controle para cada eixo.

A título de comparação são mostradas duas estratégias de controle utilizando redes neurais. Uma baseada no uso de controladores neurais de posição de eixos independentes e outra baseada no uso do controlador vetorial neural. Esse último controlador é apresentado como contribuição relevante deste trabalho.

1.1 Estruturas de controle

Para acionamento de sistemas de servomecanismo utilizam-se controladores do tipo malha aberta, que contém motores de passo e controladores em malha-fechada, que utilizam principalmente motores de corrente contínua e motores de indução, com a posição de seus eixos sendo medida por meio de circuitos sensores de posição e de velocidade de rotação.

De acordo com Ramesh *et al* (2005), os controladores em malha fechada podem ser de dois tipos. No primeiro caso trata-se do controle ponto a ponto, no qual tanto o caminho da ferramenta de um ponto de origem ao ponto de referência quanto à velocidade de deslocamento não são importantes. A razão para isso é que a ferramenta não entra em contato com a área de trabalho. Nesse tipo de controle o que importa é a exatidão com que a ferramenta atinge o ponto de referência.

O segundo tipo de controlador, em malha-fechada, é denominado sistema de controle de contorno, no qual o caminho traçado pela ferramenta é de fundamental importância, sendo por este motivo a variável controlada. Esse tipo de controle é muito utilizado em trabalhos de corte, lapidação, pintura, etc.

Um sistema típico de um diagrama de controle de dois eixos é mostrado na Figura 1, conforme Lacerda (1998). A posição de interesse do ponto de vista de controle é a composição das duas posições axiais. Neste diagrama, cabe ao interpolador a tarefa de gerar os sinais de referência para as bases.

Para acionamento de máquinas ferramenta, os controladores devem minimizar a diferença entre a posição de referência e a posição medida da ferramenta de trabalho, que resulta do funcionamento conjunto dos eixos da máquina. Esses erros causam a deterioração do desempenho da máquina, o que influencia diretamente nas especificações do produto final.

Quanto à ação dos controladores, os sistemas em malha-fechada de uma máquina ferramenta podem ser de dois tipos, conforme Ramesh *et al* (2005):

1. Controle de erro de seguimento de trajetória, conhecido na literatura pela denominação *tracking controller*, em que a ação de controle existe no sentido de reduzir o erro em cada eixo, o qual influencia no resultado final.

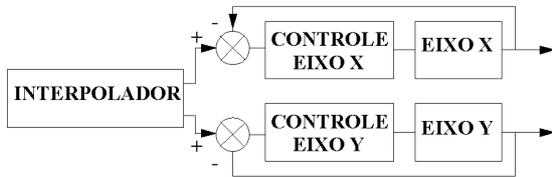


Figura 1: Diagrama de blocos de sistema de controle de máquinas ferramenta biaxial.

- Ação de controle em que o elo de retroalimentação utiliza o erro de contorno em tempo real. Esse tipo de controle é conhecido por *contouring controller*, que é decomposto em tarefas de seguimento de trajetórias independentes. O sucesso desta estratégia se baseia no bom desempenho de seguimento de trajetória de cada eixo, que é difícil de conseguir quando existe diferença na dinâmica de cada eixo e na ocorrência de atritos não lineares e variações de carga. Outra dificuldade inerente aos controladores de erro de contorno é a formulação de modelos desses erros e sua estimação em tempo real.

1.2 Sistemas de controle de erro de trajetória

Em relação ao controle de erro de trajetória, uma significativa contribuição foi dada por Tomizuka (1987), que apresentou um algoritmo de controle com alimentação direta (ZPETC), para eliminar o erro de fase em controle de seguimento de trajetória.

A idéia principal do controlador ZPETC é introduzir um bloco controlador direto (*Feedforward*) em cascata com o sistema realimentado, conforme mostrado na Figura 2, cuja função de transferência $B^{-1}(z)$ deve ser igual à inversa da Função de Transferência em malha-fechada $B(z)$. Desse modo, a saída do sistema torna-se igual à referência.

Um importante aspecto deste tipo de controlador é o fato de que o sistema torna-se instável se um dos zeros da planta estiver situado fora do círculo unitário. Nesse caso, a função de transferência do controlador, projetado, não pode ser exatamente igual à inversa da função de transferência da planta, porque conteria um pólo situado fora da região estável do lugar de raízes do sistema. Para contornar esta situação, deve-se projetar o controlador para eliminar apenas os zeros situados nesta região.

Um controlador que utiliza retroalimentação de estados, por meio do Filtro de Kalman, para estimação com compensação direta de atrito e um controlador de ação direta (*Feedforward*) do tipo ZEPTC foi apresentado por Erkorkmaz e Altintas (2001). De acordo com o artigo desses autores, os blocos de controle foram introduzidos em etapas,

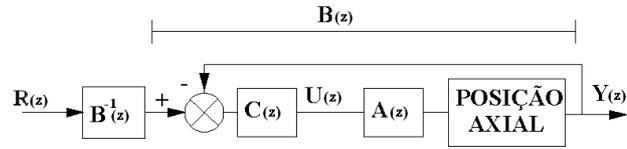


Figura 2: Diagrama do controlador ZPETC.

observando-se a influência de cada um no desempenho global do sistema. Os autores constataram que a contribuição mais significativa na redução do erro de trajetória, com referência circular, em altas velocidades de deslocamento, é dada pelo controlador de ação direta ZEPTC.

1.3 Sistemas de erro de contorno

De acordo com Lacerda (1998), os controladores de erro de contorno foram propostos por Koren (1978), usando o princípio de que a redução do erro de contorno (EC) é o único objetivo do controlador. A ferramenta deve ser levada do ponto A para o ponto C (Figura 3), corrigindo, portanto, o caminho traçado de acordo com a trajetória de referência. Caso haja a atuação apenas dos controladores axiais, a ferramenta seria levada diretamente do ponto A para o ponto B.

Koren propôs a seguinte expressão para cálculo do erro de contorno, conforme Lacerda (1998).

$$e_c \approx \frac{R_y \cdot e_x - R_x \cdot e_y}{\sqrt{R_x^2 + R_y^2}} \quad (1)$$

Sendo e_c o erro de contorno, R_X e R_Y as referências de posição, e_x e e_y os erros de posição para os eixos X e Y, respecti-

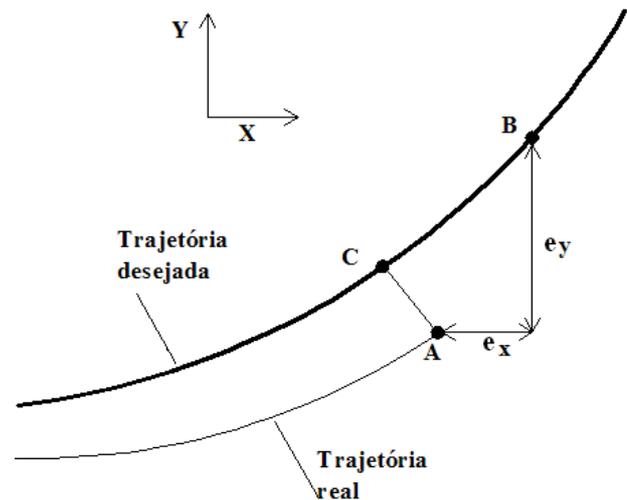


Figura 3: Erro de contorno.

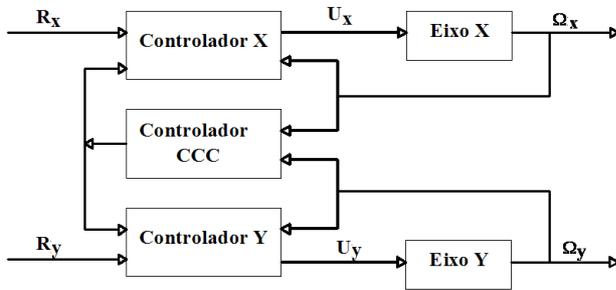


Figura 4: Diagrama de blocos de um controlador CCC.

vamente. O cálculo proposto prevê apenas sua aplicação em trajetórias retilíneas.

O controlador proposto por Koren foi denominado de CCC (Cross-Coupling Control). Os sinais de entrada desse tipo de controlador são R_X e R_Y , que são as referências de velocidade de rotação para cada eixo, considerando uma máquina biaxial. A operação do CCC é baseada na correção do erro e_C e não apenas na correção dos erros axiais. Na Figura 4 é mostrado um diagrama de blocos do controlador CCC proposto por Koren. Observa-se que os sinais de controle para cada eixo são derivados tanto do sinal de posição do eixo quanto do sinal fornecido pelo controlador CCC, que processa o cálculo do erro de contorno a partir dos sinais de posição de ambos os eixos.

Liu *et al* (2005) desenvolveram um sistema de posicionamento baseado em uma mesa de coordenadas XY, de alta velocidade de deslocamento, utilizando a estratégia de controle robusto H_∞ . O sistema possui duas malhas de retroalimentação, sendo uma malha interna de controle de velocidade de deslocamento e uma malha externa de controle de posição. Foi demonstrado que o sistema apresentou um bom desempenho frente a distúrbios.

Erkorkmaz *et al* (2006) apresentaram uma estratégia de planejamento de trajetória com o objetivo de manter a exatidão no posicionamento de uma máquina ferramenta em situações de mudança abrupta de trajetória em altas velocidades de deslocamento. Neste artigo é apresentado um algoritmo de estimação de erro de contorno para determinação do desvio geométrico para uma trajetória de formato aleatório.

Peng e Chen (2007) propuseram um modelo de erro de contorno baseado em um esquema de transformação de coordenadas. Um índice de contorno (CI) é geometricamente medido, o qual pode ser tratado como um erro de contorno equivalente tal que a redução nesse índice implique na redução do erro de contorno.

Em Jamaludin *et al* (2008) é apresentado um controle de trajetória em mesa de coordenadas XY, onde as forças de atrito

dos movimentos das bases são estimadas por um observador. Um compensador, com o modelo inverso da força de atrito estimada atua como controlador da mesa.

1.4 Sistemas inteligentes, adaptativos e robustos de controle de posição

A literatura correlata à área de controle de posição apresenta várias contribuições que utilizam esquemas de controle inteligente. Coelho e Mariani (2006) apresentaram um controlador PID (proporcional, integral e derivativo) multivariável projetado com auxílio de uma rede neural e otimizado com um algoritmo genético. O projeto do controlador PID multivariável foi dividido em três etapas distintas. Na primeira etapa, uma rede neural de função de base radial é utilizada para identificação do processo multivariável. Na segunda etapa, o projeto do controlador é realizado de forma *off-line*, baseado na sintonia de ganhos do controlador PID. Na terceira etapa, os ganhos do controlador PID, obtidos por meio de otimização genética e modelo neural são validados no processo prático.

Uma contribuição no campo do controle neural de uma mesa de coordenadas é dada em Tan *et al* (2006), onde foi apresentado um controlador neural para o controle de uma mesa de coordenadas XY com o objetivo de reduzir o erro geométrico de acompanhamento de trajetória.

Tasinaffo e Neto (2007) mostraram a utilização de Redes neurais na obtenção de modelo de trabalho interno, para esquemas de controle de sistemas dinâmicos, aplicado em um esquema de controle não linear preditivo (NPC) com uma rede *Feedforward* modelando as derivadas médias em uma estrutura de integrador numérico de Euler.

Liuzzo e Tomei (2008) apresentaram o projeto de um controlador PD de aprendizagem adaptativa para um manipulador robótico composto de duas juntas. Neste trabalho, as posições de cada junta foram obtidas a partir da identificação dos coeficientes de Fourier dos sinais fornecidos pelos sensores de posição.

2 MONTAGEM EXPERIMENTAL

Para o desenvolvimento dos trabalhos experimentais, foi utilizada a mesa de coordenadas XY mostrada na Figura 5, a qual é composta de duas bases que se movimentam em quadratura, isto é, seus eixos de translação são perpendiculares.

O alcance máximo de deslocamento da base X é de 200mm e da base Y é de 150mm. Os mecanismos de transmissão são fusos trapezoidais com passo de 3mm por rotação, que se apóiam em mancais fixados em bases de alumínio. Utiliza-se um computador Pentium 1,4 GHZ com o programa compu-

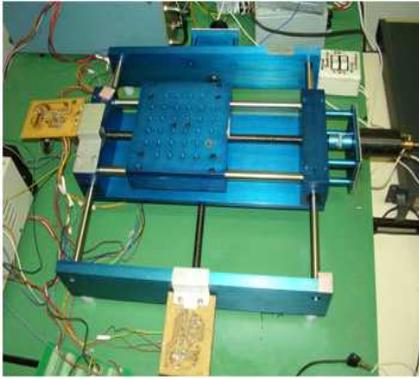


Figura 5: Vista da mesa de coordenadas XY.

tacional LabVIEW® para implementação dos controladores e o programa computacional MATLAB® para apresentação e auxílio na determinação inicial dos parâmetros das redes neurais residentes. Para aquisição e transferência de dados entre o computador e os circuitos eletrônicos de medição de posição é utilizada uma placa de aquisição de dados fabricada pela National Instruments®.

A medição dos deslocamentos de cada base é realizada através de circuitos detectores de posição que utilizam sensores ópticos. Os sinais destes sensores são tratados através de microcontroladores do tipo PIC16F84A da Microship® e convertido em sinais analógicos por meio do CI TLC 7226 da Texas Instruments®.

Para o acionamento dos motores foram projetados e montados em laboratório circuitos amplificadores de tensão e reforçadores de corrente.

O sistema completo consiste de dois conjuntos de sensores ópticos, sendo um para cada motor. Os sinais dos dois conjuntos de sensores ópticos são tratados por circuitos condicionadores, que utilizam amplificadores do tipo Schmitt Trigger, cuja função é aumentar a velocidade de transição entre o nível 0 e 5V, que são os valores mínimo e máximo dos pulsos gerados.

Para cada sensor de posição o Microcontrolador PIC 16F84A realiza a tarefa de contagem dos pulsos. O resultado da contagem é um número binário de oito bits convertido em analógico pelo conversor Digital-Analógico (TLC7226). A relação entre o número de pulsos contados (N_p) e a posição axial x em metros é dada pela Equação (2), sendo K_{cod} o número de pulsos por revolução e P o passo do fuso (m/rev).

$$x(t) = \frac{P}{K_{cod}} \cdot N_p(t) \quad (2)$$

Na Figura 6 é mostrado o diagrama de blocos dos sistemas

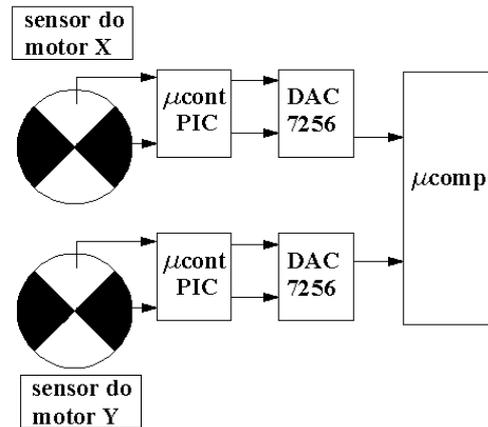


Figura 6: Diagrama de blocos dos detectores de posição.

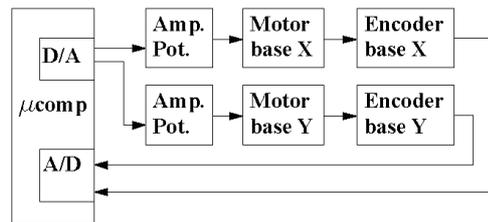


Figura 7: Diagrama de blocos do sistema de controle e aquisição de dados.

detectores de posição montados em laboratório e na Figura 7 é mostrado o diagrama de blocos do sistema de controle e aquisição de dados utilizados.

A vantagem da utilização da contagem de pulsos externa ao computador consiste no fato de que a velocidade de contagem fica limitada apenas ao clock do microcontrolador e não ao intervalo de amostragem da placa de aquisição de dados do computador.

2.1 Modelo de um eixo posicionador da mesa de coordenadas XY

O acionamento por meio de motor de corrente contínua é uma solução de fácil implementação, frente aos demais motores elétricos, pela simplicidade no projeto de seu controlador (Dorf, 2001). A relação entre a posição angular do eixo do motor e a tensão aplicada na armadura, dada pela Equação (3), é bem conhecida na literatura, (Menezes, 2002) :

$$\frac{\Omega(s)}{U(s)} = \frac{K_m}{s^3(JL_a) + (R_a J + L_a F)s^2 + (R_a F + K_a K_m)s} \quad (3)$$

onde:

s - Operador Laplaciano [adimensional].

$\Omega(s)$ - Transformada de Laplace da posição angular do eixo do motor.

$U(s)$ - Transformada de Laplace da tensão aplicada na armadura.

K_a - Constante de velocidade rotação do motor [V/rad/s].

K_m - Constante de torque do motor [Nm/A].

R_a - Resistência de armadura [Ω].

L_a - Indutância de armadura [H].

F - Coeficiente de atrito viscoso [Nm/rad/s].

J - Momento de inércia do motor [kgm²].

Um dos aspectos que limita o grau de exatidão, no posicionamento de uma máquina ferramenta, é o atrito que ocorre entre as partes metálicas. Armstrong *et al* apud Erkorkmaz e Altintas (2001) apresentaram um resumo dos fenômenos físicos geradores do atrito, que são classificados em atrito viscoso, estático e atrito de Coulomb. Para efeito deste trabalho, apenas o efeito do atrito viscoso na determinação da função de transferência dos eixos axiais da mesa de coordenadas XY, foilevado em consideração.

Reescrevendo a função de transferência dada pela Equação (3), tem-se:

$$\frac{\Omega(s)}{U(s)} = \frac{K}{s(s + P_1)(s + P_2)} \quad (4)$$

A Equação (5) representa a função de transferência dada pela Equação (4) na forma discreta.

$$\frac{\Omega(z)}{U(z)} = \frac{B_1 \cdot z^{-1} + B_2 \cdot z^{-2} + B_3 \cdot z^{-3}}{1 + A_1 \cdot z^{-1} + A_2 \cdot z^{-2} + A_3 \cdot z^{-3}} \quad (5)$$

Que pode ser reescrita na forma dada pela Equação (6):

$$\omega_k = -A_1 \cdot \omega_{k-1} - A_2 \cdot \omega_{k-2} - A_3 \cdot \omega_{k-3} + B_1 \cdot u_{k-1} + B_2 \cdot u_{k-2} + B_3 \cdot u_{k-3} \quad (6)$$

2.2 Identificação das funções de transferência dos eixos X e Y

Para a obtenção da equação que representa um sistema, pode-se recorrer a duas abordagens, de acordo com Ljung (1987): a primeira consta da divisão do sistema em subsistemas, dos

quais são conhecidas suas propriedades e que são combinados para formar uma equação que represente o sistema como um todo. Nesse caso, trata-se de uma abordagem conhecida como modelamento.

A segunda é baseada na experimentação, denominada de identificação de sistemas, onde os sinais de entrada e de saída de um sistema são submetidos a uma análise matemática a partir da qual se obtém a função de transferência do sistema.

Na identificação de sistemas, também conhecida como modelagem empírica, são usados dados coletados diretamente dos sistemas (Aguirre, 2000). No caso de um sistema eletromecânico de posição, acionado por um motor de corrente contínua, para se obter um modelo matemático por meio da técnica de modelamento, é necessário o conhecimento da resistência elétrica e da indutância do circuito de armadura do motor, do coeficiente de atrito viscoso dos eixos ou mancais de sustentação e a constante de inércia do conjunto carga e motor.

Por outro lado, utilizando-se técnicas de identificação de sistemas, não é necessário o conhecimento dos parâmetros citados, sendo então mais fácil sua realização. Aguirre e Correa (2004) apresentam uma distinção dos métodos de identificação de sistemas, classificando-os em:

1. Identificação caixa preta. Nesse caso, não se tem nenhuma informação sobre o sistema. Apenas os dados de entrada e de saída do sistema são usados durante a identificação. Nesse tipo de identificação, não existe nenhuma relação óbvia entre a estrutura e seus parâmetros com aspectos físicos do sistema sendo identificado.
2. Identificação caixa branca. Trata-se da modelagem do sistema, onde os dados de entrada e de saída do sistema, quando disponíveis, são usados apenas para validar o modelo.
3. Identificação caixa cinza. É um procedimento de identificação que não se enquadra nem no modelo caixa preta nem no modelo caixa branca. Nesse caso, busca-se combinar as vantagens dos procedimentos de identificação de ambas as abordagens anteriores.

Dentre as várias estruturas que se enquadram na denominação de identificação caixa cinza, tem-se a modelagem caixa cinza física, onde o usuário especifica uma estrutura inicial para o modelo e é utilizado um programa para implementação e estimação de parâmetros e validação.

Esse tipo de abordagem é a utilizada no presente trabalho, pois a identificação das funções de transferência das bases X e Y baseiam-se na estrutura determinada pela Equação (5),

que foi deduzida a partir do conhecimento de leis físicas. O algoritmo de identificação utilizado é o algoritmo de mínimos quadrados (MQ).

Para utilização deste algoritmo reescreve-se a equação de diferença dada pela Equação (6) na forma $\Omega_k = \Phi_k (k-1)^T \Theta$, sendo:

$$\Theta^T = [-A_1 - A_2 - A_3 \ B_1 \ B_2 \ B_3] \quad (7)$$

$$\psi_k (k-1) = [\omega_{k-1} \ \omega_{k-2} \ \omega_{k-3} \ u_{k-1} \ u_{k-2} \ u_{k-3}] \quad (8)$$

onde:

Θ - Vetor de parâmetros do sistema estimado no processo de identificação.

$\psi_k (k-1)$ - É formado na interação k com informação disponível até a interação k-1.

$\omega(k)$ - Valor da saída do sistema no instante k.

No desenvolvimento da busca pelo vetor de parâmetros, dado pela Equação (7), admite-se que a solução é dada pela Equação (9).

$$\omega_k = \psi_k^T (k-1) \cdot \Theta_{k-1} + e_k \quad (9)$$

onde:

e_k - Erro de estimação que existe na determinação do vetor de parâmetros.

No método de mínimos quadrados, busca-se a minimização da seguinte função de custo, relacionada ao erro de identificação:

$$J = \sum_{k=1}^N e_k^2 = e_k^T \cdot e_k \quad (10)$$

Pode-se determinar, em tempo real, o vetor de parâmetros Θ que minimiza a função de custo utilizando o seguinte algoritmo de identificação recursiva:

1. Estabelece-se uma matriz quadrada P(1) de grau igual à ordem do vetor de parâmetros a ser estimado para o sistema. Em seguida procede-se os passos dados em 2, 3 e 4 mostrados a seguir para cada tempo de amostragem k.

2. Calcula-se o erro de estimação usando a Equação (11):

$$e_k = \omega_k - \psi_k^T (k-1) \cdot \Theta_{k-1} \quad (11)$$

3. Atualiza-se o vetor de parâmetros segundo a Equação (12).

$$\Theta_k = \Theta_{k-1} + P_k \cdot \psi_k (k-1) \cdot e_k \quad (12)$$

4. Obtém-se o valor da matriz $P_{(k+1)}$ que servirá para o processamento do algoritmo na interação seguinte, de acordo com a Equação (13).

$$P_{k+1} = \left(P_k - \frac{P_k \cdot \psi_k (k-1) \cdot \psi_k^T (k-1) \cdot P_k}{1 + \psi_k^T (k-1) \cdot P_k \cdot \psi_k (k-1)} \right) \quad (13)$$

5. Repete-se os passos 2, 3 e 4 para um novo período de amostragem.

Os ensaios para a identificação das funções de transferência, aplicados simultaneamente em ambos os eixos, foram realizados utilizando-se um sinal de excitação do tipo onda quadrada adicionando um ruído branco gaussiano.

O objetivo de se utilizar um ruído branco é provocar a excitação de todos os modos do sistema com o uso de um sinal que contenha o espectro de frequência mais amplo possível. A variância do sinal de ruído escolhido foi de 30% da amplitude do sinal da onda quadrada.

A função de transferência da base X, obtida do processo de identificação, é dada pela Equação (14), e a função de transferência da base Y pela Equação (15).

$$\frac{X(z)}{U(z)} = \frac{-0,005167 \cdot z^2 + 0,005810 \cdot z + 0,004237837}{z^3 - 0,7782 \cdot z^2 - 0,1421 \cdot z - 0,0797} \quad (14)$$

$$\frac{Y(z)}{U(z)} = \frac{-0,00335814 \cdot z^2 + 0,003659 \cdot z + 0,004698}{z^3 - 0,469375 \cdot z^2 - 0,387769 \cdot z - 0,142854} \quad (15)$$

Nas Figuras 8 e 9 são mostradas as curvas de resposta estimadas e experimentais bem como o sinal de excitação usado no processo de identificação nos eixos X e Y, respectivamente.

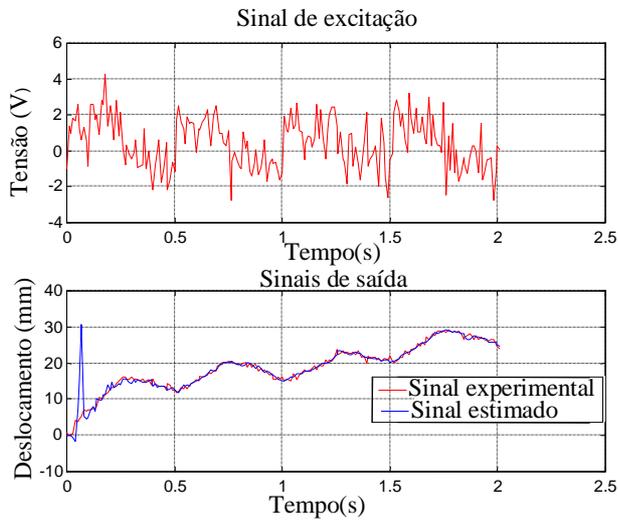


Figura 8: Sinais utilizados na identificação da base X.

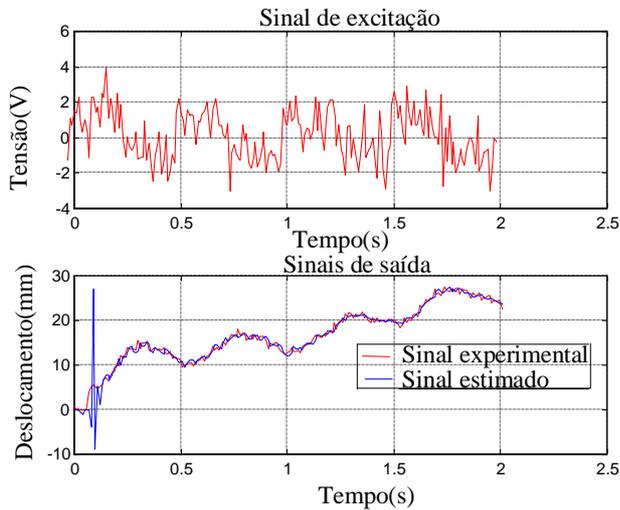


Figura 9: Sinais utilizados na identificação da base Y.

3 CONTROLADORES NEURAIS INDEPENDENTES

Para a implementação dos controladores da mesa de coordenadas XY foram utilizadas redes neurais multicamada (RNMC) do tipo direto, com uma camada oculta contendo 8 neurônios e a camada de saída com um único neurônio. A camada de saída de cada rede fornece o sinal de controle ao motor de sua respectiva base.

O número de neurônios na camada oculta foi determinado de forma empírica, testando-se a RNMC com os valores de 4, 8 e 12 neurônios, no controle de posição dos eixos de forma independente. Dentre as possibilidades testadas, a RNMC com

8 neurônios apresentou o melhor resultado. Nesta estrutura, a camada de entrada serve apenas para conectar a rede neural aos sinais de entrada, possuindo 4 terminais. As ligações entre cada terminal de entrada e os neurônios da camada oculta ocorrem através de 32 pesos sinápticos denominados “win”, que formam uma matriz de 4 linhas e 8 colunas. As ligações entre os neurônios da camada oculta e os neurônios da camada de saída ocorrem através de 8 pesos sinápticos denominados “whid”. Estes últimos pesos sinápticos formam uma matriz de 1 linha e 8 colunas.

O controlador neural é do tipo adaptativo, já que para cada tempo de amostragem, os pesos sinápticos win e whid são reajustados para fornecer o sinal de controle ao motor da respectiva base.

Para cada período de amostragem, ocorrem os processamentos em sentido direto (*Feedforward*) e a retropropagação (*Backpropagation*). Esse último processamento inicia na camada de saída e se propaga em direção à camada de entrada, com o objetivo de atualizar os pesos sinápticos win. Conforme mostrado na Figura 10, os erros entre as referências e as posições atualizadas, através do mecanismo de retropropagação, são utilizados para a determinação dos novos pesos sinápticos. Os valores iniciais dos pesos sinápticos utilizados nos procedimentos experimentais foram obtidos por meio de simulações utilizando-se as funções de transferências obtidas nos processos de identificação da mesa. Tanto o processamento direto quanto a retropropagação são explicados em Haykin (2001).

3.1 Projeto dos controladores neurais independentes

Inicialmente, determinou-se o tipo de sinal da camada de entrada para o controle de posição da mesa de coordenadas XY.

Um exemplo de determinação de sinais de entrada encontra-se em Riul (2000), que implementou uma rede neural multicamada como controlador para um sistema hidráulico estabelecendo na entrada 4 sinais: a derivada primeira da pressão, as derivadas primeira e segunda da posição e o sinal de posição de referência do controlador.

Outro exemplo pode ser encontrado em Nascimento e Yoneyama (2000), que apresentam um esquema de um controlador neural com as seguintes entradas: os sinais de referência no instante atual como primeira entrada e com um e dois atrasos de tempo, como segunda e terceira entradas, bem como mais três entradas correspondente ao erro no instante atual e com um e dois atrasos.

Neste trabalho escolheu-se os sinais de entrada de cada rede neural por meio da analogia com o controlador PD2 (Pro-

porcional Derivativo Duplo) que é utilizado em sistemas que apresentam comportamento integral.

A equação discreta do controlador PD2 é, de acordo com Buhler (1982) a seguinte:

$$u[k] = K_p \cdot \text{erro}[k] + K_d(\text{erro}[k] - \text{erro}[k - 1]) + K_{d2}(\text{erro}[k] - 2 \cdot \text{erro}[k - 1] + \text{erro}[k - 2]) \quad (16)$$

onde:

$u[k]$ - Valor da saída amostrada do controlador no instante k .

K_p - Ganho proporcional do controlador.

K_d - Ganho aplicado a derivada do sinal de erro.

K_{d2} - Ganho aplicado a derivada segunda do sinal de erro.

$\text{erro}[k]$ - Erro no instante da amostragem k .

$\text{erro}[k-1]$ - Erro armazenado no instante anterior ao tempo k .

$\text{erro}[k-2]$ - Erro armazenado no instante anterior ao tempo $k-1$.

Desse modo, os sinais da primeira camada são mostrados na Equação (17).

$$I_n(1) = \text{erro}(k) , I_n(2) = \text{erro}(k - 1) \text{ e } I_n(3) = \text{erro}(k - 2) \quad (17)$$

Na Figura 10 são mostrados os controladores neurais utilizados no acionamento independente para cada base.

Para a implementação do controlador adaptativo direto é necessário calcular os Jacobianos das bases X e Y.

De acordo com Riul (2000), pode-se determinar o Jacobiano por meio de uma relação linear entre a seqüência de saída $y(k)$ e a seqüência de entrada impulsiva $u(k)$. Os Jacobianos são conceituamente iguais as derivadas dos sinais de saída $y(k)$ com relação aos sinais de excitação $u(k)$. Foram utilizados valores normalizados de tensão de entrada tendo como referência 12V e valores normalizados de saída tendo como referência 40mm. A Figura 11 mostra o resultado das simulações realizadas para a obtenção dos Jacobianos das bases X e Y.

Os valores dos Jacobianos determinados para as bases X e Y foram, respectivamente, 1,0103 e 0,6047. Estes valores são então agregados aos algoritmos de retropropagação para as duas bases no acionamento do controle adaptativo direto.

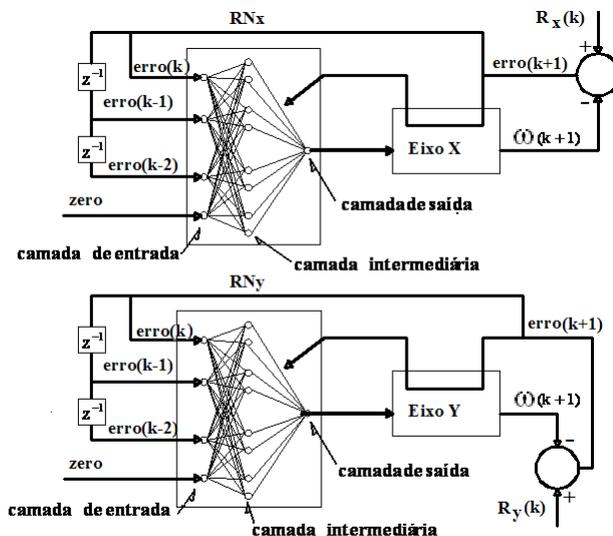


Figura 10: Estruturas das redes neurais utilizadas nos controladores independentes.

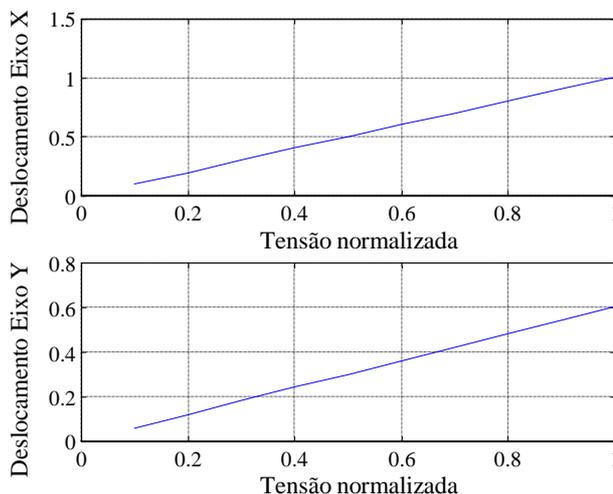


Figura 11: Curvas utilizadas para determinação dos Jacobianos das bases X e Y.

3.2 Simulação dos controladores neurais independentes

Sinais do tipo degrau foram usados como sinais de excitação para as bases X e Y. Para a base X utilizou-se um degrau de 25mm e para a base Y um degrau de 20mm. Inicialmente, foram gerados os pesos sinápticos de maneira aleatória.

Estes valores foram então utilizados como valores iniciais no treinamento da rede, que foi repetidamente acionada, em modo de simulação, até a obtenção de um sinal de erro de posição inferior a 2% do valor de referência. As Figuras 12 e 13 mostram as curvas de resposta simuladas de posição e

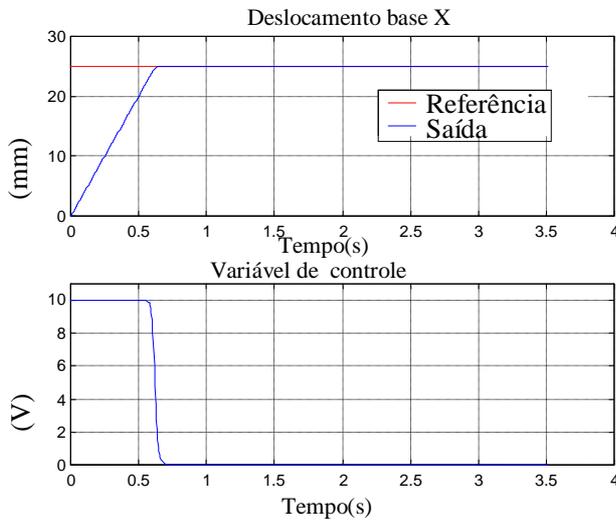


Figura 12: Curvas de resposta simuladas da base X para um sinal de referência degrau com controladores neurais independentes.

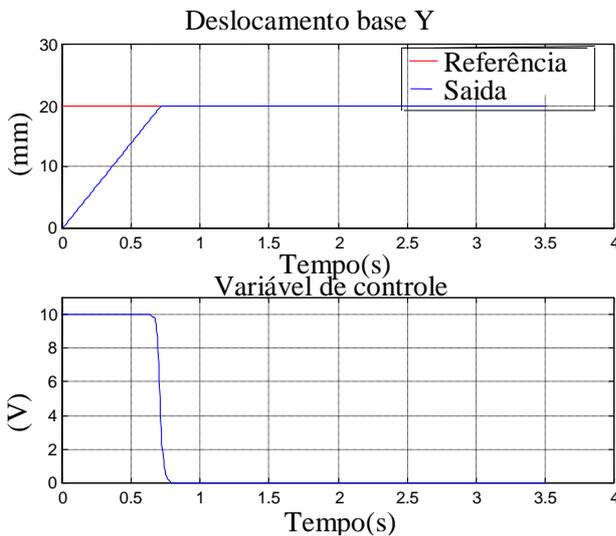


Figura 13: Curvas de resposta simuladas da base Y para um sinal de referência degrau com controladores neurais independentes.

da variável de controle das bases X e Y, respectivamente. A Tabela 1 mostra os resultados obtidos na simulação.

Tabela 1: Valores observados da simulação do controle neural independente para uma entrada degrau.

Valor observado	Base X	Base Y
Sobre-sinal (%)	0,0	0,0
Erro de regime permanente (%)	0,0	0,0

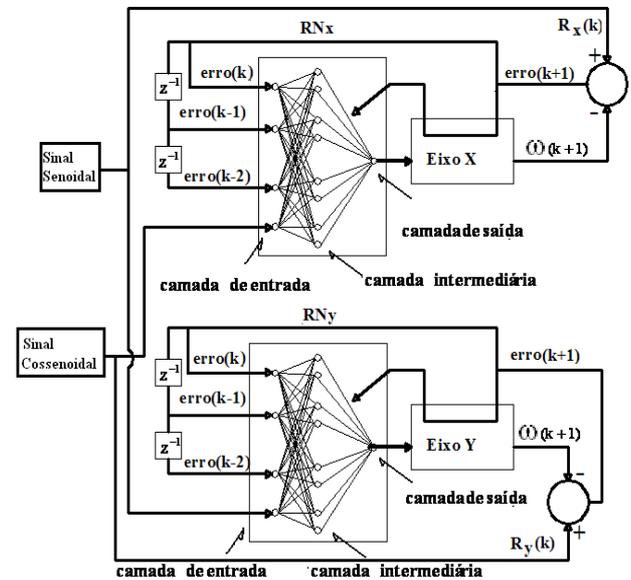


Figura 14: Controladores neurais independentes no acionamento circular.

Em seguida, as bases foram acionadas de modo a seguir uma trajetória pré-determinada. Neste caso, a mesa não sofreu interrupção de seu movimento ao atingir uma determinada referência como no caso anterior. Como os motores precisam ser constantemente excitados, foi acrescentado um sinal de entrada proporcional à velocidade de deslocamento.

A Figura 14 apresenta o esquema de acionamento para a trajetória circular. Para a base X da mesa de coordenadas, o sinal de posição de referência é uma senóide e o sinal de velocidade de deslocamento para esta base é um sinal cossenooidal. Do mesmo modo, para a base Y, a posição de referência é um sinal cossenooidal e a velocidade de deslocamento é um sinal senoidal.

Os sinais de referência e as curvas de resposta das bases X e Y estão mostrados na Figura 15. A composição dos sinais, formando, o círculo, é mostrada na Figura 16.

3.3 Implementação experimental dos controladores neurais independentes

Os controladores neurais foram implementados no ambiente LabVIEW® utilizando um tempo de amostragem de 5ms, com seus pesos reajustados a cada intervalo de amostragem.

Inicialmente, os sistemas de controle foram testados usando-se um sinal de entrada do tipo degrau de 25mm para a base X e de 20mm para a base Y.

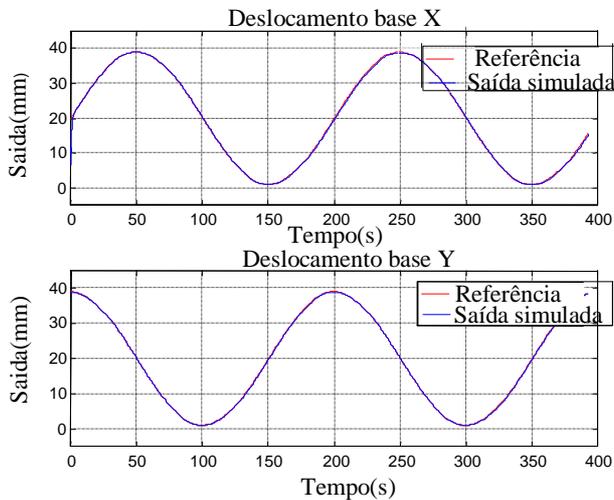


Figura 15: Curvas de resposta simuladas das bases X e Y para entradas de referência senoidais com controladores neurais independentes.

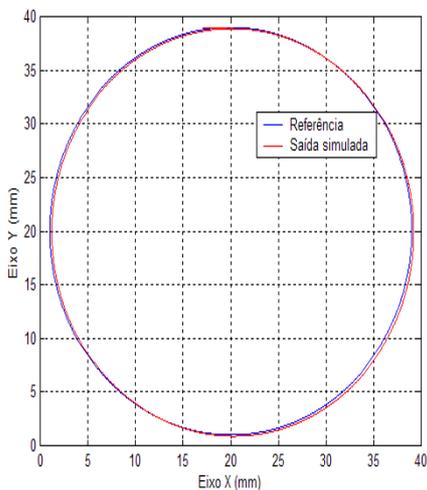


Figura 16: Sinais de referência e de saída simulados das bases X e Y com controladores neurais independentes.

As Figuras 17 e 18 mostram as curvas de resposta de deslocamento e as variáveis de controle das bases X e Y, respectivamente, para um sinal de referência degrau de entrada.

Para evitar que no treinamento das redes neurais sejam determinados os pesos sinápticos referentes a apenas um ponto específico da área de trabalho, os valores de referência foram normalizados. Desse modo, para qualquer valor de referência, os sinais de entrada nas redes neurais têm sempre o valor unitário, permitindo que as matrizes win e whid variem apenas em função de eventuais mudanças da planta que possam ocorrer nos variados pontos de operação, e não em função da referência.

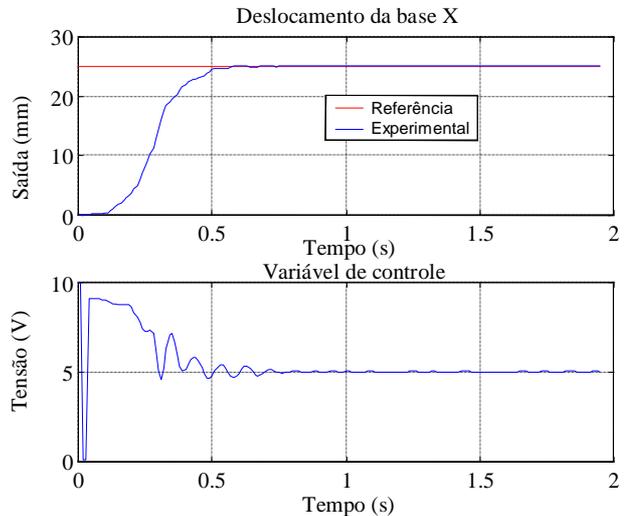


Figura 17: Curvas de resposta experimentais da base X com os controladores neurais independentes para um sinal de referência degrau.

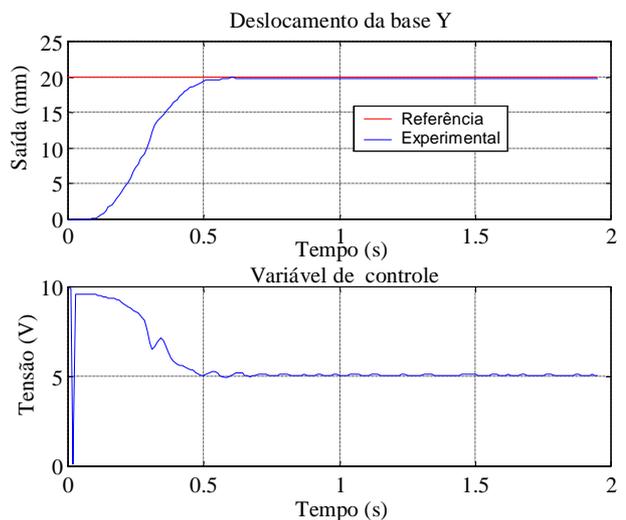


Figura 18: Curvas de resposta experimentais da base Y com os controladores neurais independentes para um sinal de referência degrau.

Em seguida utilizou-se uma sequência de entradas do tipo degrau de amplitude e período distintos.

Nas Figuras 19 e 20 são mostrados os sinais de referência, de deslocamento e da variável de controle para as bases X e Y, respectivamente.

A Tabela 2 mostra os valores dos índices observados no acionamento experimental da mesa de coordenadas XY.

Na terceira etapa, foi imposto um sinal senoidal, respectiva-

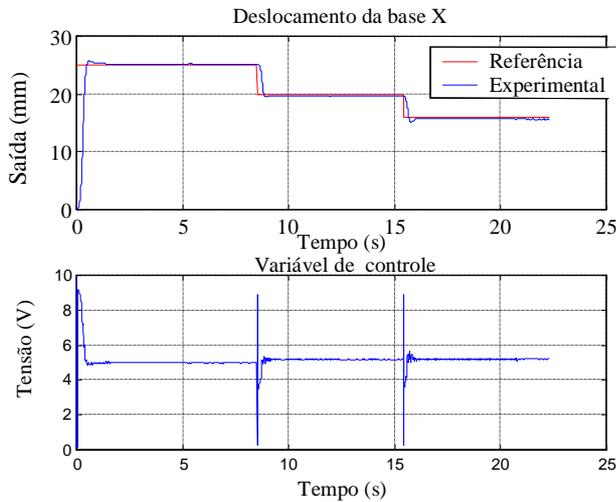


Figura 19: Curvas de resposta experimentais da base X com os controladores neurais independentes para um sinal de referência degrau variável.

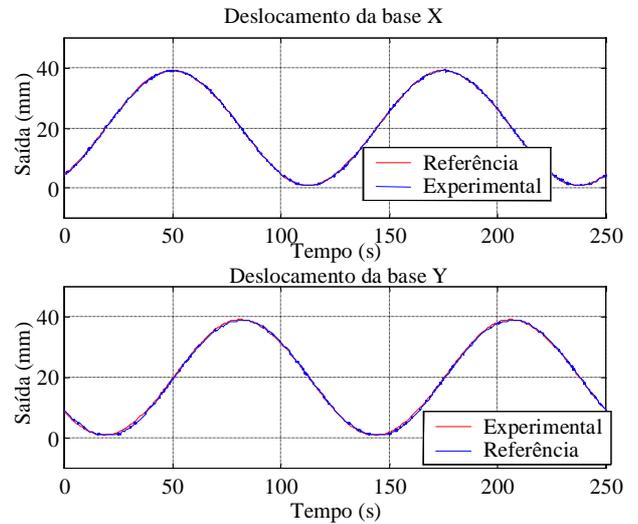


Figura 21: Curvas de resposta experimentais das bases X e Y, para entradas de referência senoidais, com controladores neurais independentes.

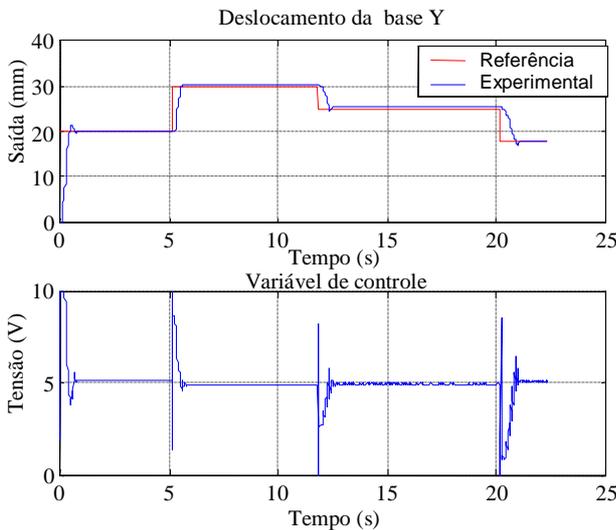


Figura 20: Curvas de resposta experimentais da base Y com os controladores neurais independentes para um sinal de referência degrau variável.

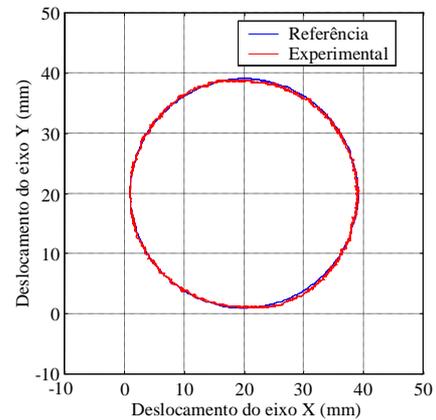


Figura 22: Curva de resposta experimental para sinais de referência senoidais, das bases X e Y com controladores neurais independentes.

mente para as bases X e Y, de amplitude 20 mm, com valor

Tabela 2: Valores experimentais observados dos controladores neurais independentes para uma referência degrau de entrada.

Valor medido	base X	base Y
Sobre-sinal (%)	0,0	0,0
Erro de regime permanente (%)	2,3	1,8

médio de 20mm e período de 125s, como sinais de referência. O programa utilizado foi o mesmo apresentado, sendo adaptado para o acionamento experimental, com os valores dos erros calculados a partir dos sinais obtidos dos conversores de posição. Os valores iniciais das matrizes win e whid para cada rede neural foram os mesmos obtidos da simulação, que foram, ao final do processamento do programa, armazenados. Os resultados do acionamento para as bases X e Y são mostrados na Figura 21.

A composição dos sinais obtidos das bases X e Y com os sinais de referência senoidais é mostrado na Figura 22.

4 CONTROLADOR VETORIAL NEURAL

Para o acionamento vetorial, o sinal de posição da ferramenta de trabalho, da mesa de coordenadas X Y, é convertido em sua forma vetorial, conforme Equações (18), (19) e (20).

$$\hat{V} = \|\hat{V}\| \angle \hat{V} \quad (18)$$

$$\|\hat{V}\| = \sqrt{V_x^2 + V_y^2} \quad (19)$$

$$\angle \hat{V} = \text{atan} \left(\frac{V_y}{V_x} \right) \quad (20)$$

Do mesmo modo, as referências de posição R_x e R_y são convertidas em forma vetorial por meio das Equações (21), (22) e (23).

$$\hat{R} = \|\hat{R}\| R \quad (21)$$

$$\|\hat{R}\| = \left(\sqrt{R_x^2 + R_y^2} \right) \quad (22)$$

$$\angle \hat{R} = \text{atan} \left(\frac{R_y}{R_x} \right) \quad (23)$$

onde:

\hat{V} - Vetor de posição da ferramenta de trabalho da mesa X Y.

$\|\hat{V}\|$ - Módulo do vetor de posição da ferramenta de trabalho.

$\angle \hat{V}$ - Ângulo do vetor de posição da ferramenta de trabalho.

V_x - Componente no eixo X do vetor de posição da ferramenta de trabalho

V_y - Componente no eixo Y do vetor de posição da ferramenta de trabalho.

\hat{R} - Vetor de posição de referência da ferramenta de trabalho da mesa X Y.

$\|\hat{R}\|$ - Módulo do vetor de posição de referência da ferramenta de trabalho.

$\angle \hat{R}$ - Ângulo do vetor de posição de referência da ferramenta de trabalho.

R_x - Componente no eixo X do vetor de posição da referência da ferramenta de trabalho.

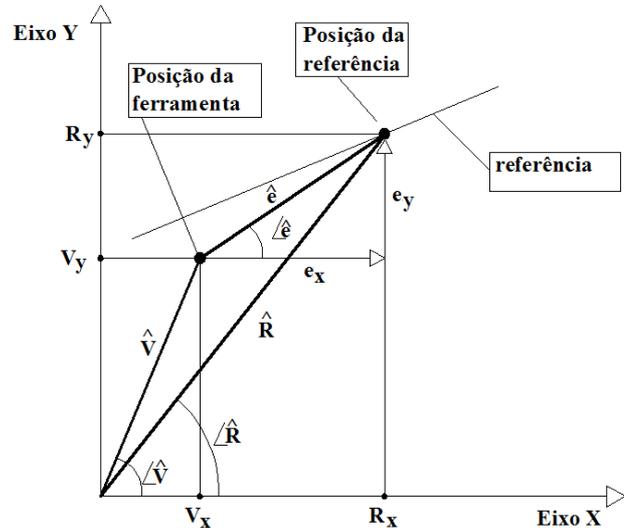


Figura 23: Vetores de referência atual e de erro utilizados no controle vetorial neural.

R_y - Componente no eixo Y do vetor de posição da referência da ferramenta de trabalho.

A diferença entre o vetor de posição da referência e o vetor de posição da mesa, define um erro vetorial, conforme a Equação (24).

$$\hat{e} = (\hat{R} - \hat{V}) = \|\hat{e}\| \angle \hat{e} \quad (24)$$

onde:

\hat{e} - Vetor erro de posição.

$\|\hat{e}\|$ - Módulo do vetor erro de posição.

$\angle \hat{e}$ - Ângulo do vetor erro de posição.

A Figura 23 mostra os vetores de posição da referência, de posição atual e de erro de posição no plano de trabalho da mesa X Y. São mostrados, também, os ângulos de cada vetor.

O módulo do vetor erro de posição é utilizado como sinal de entrada na rede neural, juntamente com seus valores armazenados em dois instantes de amostragem imediatamente anteriores e com o módulo do sinal de referência, obtido do bloco “Determinação de módulo e ângulo”, o qual processa o sinal do bloco “Conversor Retangular-polar”. Este último bloco tem a função de converter os sinais R_x e R_y que são as referências de posição para as bases X e Y da mesa de coordenadas controlada no modo vetorial.

O vetor erro de posição é utilizado para treinamento dos pesos sinápticos da rede neural no algoritmo de retropropaga-

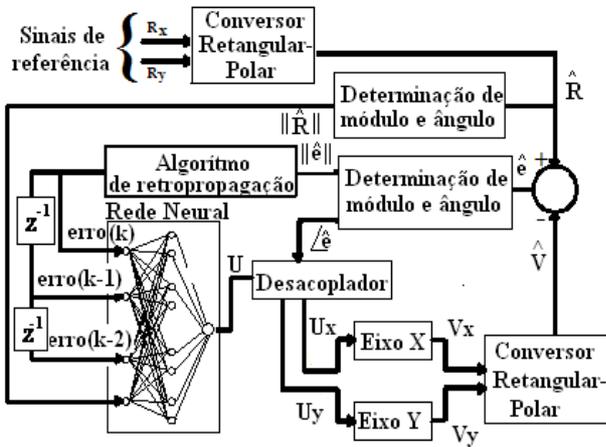


Figura 24: Diagrama de blocos do controlador vetorial neural.

ção. Na Figura 24 é mostrado o diagrama de blocos do controle vetorial neural da mesa de coordenadas XY utilizando uma rede neural adaptativa.

O sinal resultante do processamento da rede neural é decomposto em duas componente, U_x e U_y , que são aplicadas, após ajustes devido à diferença de simetria entre os sistemas das bases, respectivamente, no motor que aciona o eixo X, de acordo com a Equação (25) e no motor que aciona o eixo Y, de acordo com a Equação (26).

$$U_x = \|\hat{U}\| \cos(\angle \hat{e}) \quad (25)$$

$$U_y = \|\hat{U}\| \text{sen}(\angle \hat{e}) \quad (26)$$

Ao serem acionados com os sinais U_x e U_y , os motores acoplados aos eixos X e Y, através dos fusos trapezoidais, promovem um deslocamento linear em suas respectivas bases, cujas posições são então fornecidas pelos detectores de posição. Os sinais destes detectores, V_x e V_y , são convertidos em valores vetoriais por meio das Equações (19 e 20).

De acordo com Haykin (2001) uma das abordagens para determinação do Jacobiano da planta, para retropropagação do erro, em um controlador neural, é a aprendizagem direta, no qual pode-se aproximar as derivadas parciais pelos seus sinais individuais, ficando seus valores absolutos distribuídos nos parâmetros livres do controlador neural. Desse modo, como o interesse é manter o módulo do vetor em um determinado valor, o sinal da derivada do valor controlado (módulo do vetor) em relação ao sinal de controle é positivo.

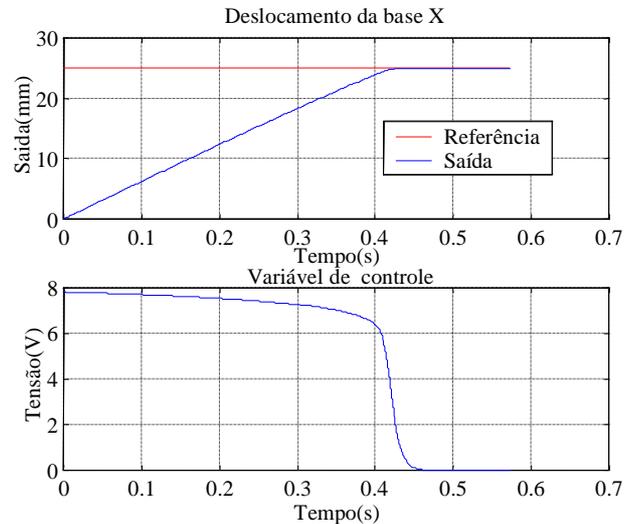


Figura 25: Curvas de resposta simuladas da base X para um sinal de referência degrau com controlador vetorial neural.

4.1 Simulação do Controle Vetorial Neural

O controlador vetorial neural foi acionado em um programa de simulação que implementa o controle mostrado na Figura 24. As equações discretas que representam as funções de transferência das bases X e Y da mesa de coordenadas são dadas pelas Equações (14) e (15), respectivamente, para as bases X e Y. Estas equações são as mesmas utilizadas no programa de simulação do controle por redes neurais independentes.

Como a rede neural é utilizada neste controlador em uma configuração diferente da apresentada para o caso de controladores neurais independentes, torna-se necessário a aprendizagem dos pesos sinápticos w e wh a partir de novos valores aleatórios, já que esta estrutura de controle não possui relação com a das redes neurais independentes.

Para o acionamento da rede neural, como controlador de posição, no modo vetorial, o esquema da Figura 24 foi modificado, estabelecendo o valor zero no sinal de entrada correspondente ao valor modular da referência, ficando, portanto, o módulo do erro de posição e seus valores armazenados em instantes de amostragem anteriores como entradas para a rede neural. Nas Figuras 25 e 26 são mostrados os sinais de referência, de deslocamento e da variável de controle para as bases X e Y da simulação realizada.

A Tabela 3 mostra os sobre-sinais máximos e os erros de regime permanente obtidos, para as bases X e Y, em modo simulado.

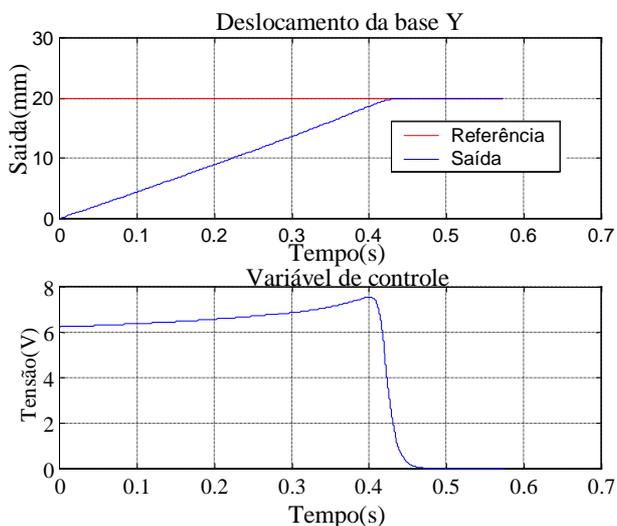


Figura 26: Curvas de resposta simuladas da base Y para um sinal de referência degrau com controlador vetorial neural.

Tabela 3: Valores dos índices obtidos do controlador vetorial neural para um degrau de entrada.

Valor medido	base X	base Y
Sobre-sinal máximo (%)	0,0	0,0
Erro de regime permanente (%)	0,0	0,0

Em seguida, foi realizada a simulação com referências senoidais para as bases X e Y, utilizando o controlador mostrado no diagrama de blocos da Figura 24. Para este tipo de acionamento, novamente os pesos sinápticos foram treinados, iniciando o processo com os pesos obtidos de modo aleatório no programa MATLAB®.

Na Figura 27 são mostrados os resultados de simulação da mesa de coordenadas XY, para cada base, com a rede neural atuando como controlador vetorial neural e na Figura 28 a composição dos dois sinais das bases.

A Tabela 4 mostra os sobre-sinais máximos e os erros de regime permanente obtidos, para as bases X e Y, em modo simulado, com sinais de entrada senoidais.

4.2 Implementação experimental do Controle Vetorial Neural

A RNMC foi implementada no ambiente LabVIEW® utilizando um tempo de amostragem de 5ms. Os pesos sinápticos da camada oculta (win) e da camada de saída (whid), obtidos das simulações apresentadas nas seções anteriores que foram armazenados em um arquivo de dados do programa

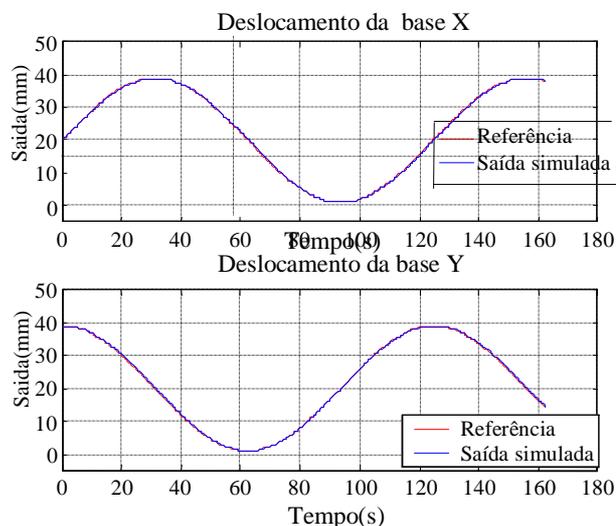


Figura 27: Curvas de resposta simuladas das bases X e Y para entradas de referência senoidais com controlador vetorial neural.

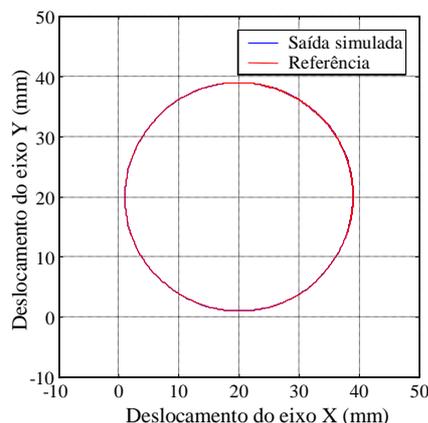


Figura 28: Sinais de referência e de saída simulados das bases X e Y com controlador vetorial neural.

MATLAB®, foram utilizados no acionamento experimental.

Foram realizados os acionamentos em controle de posição e

Tabela 4: Valores de erros percentuais simulados dos controladores no modo vetorial e independentes.

Valor medido	base X	base Y
Erro máximo do controle vetorial (%)	0,6	1,1
Erro máximo dos controladores independentes (%)	1,1	1,7

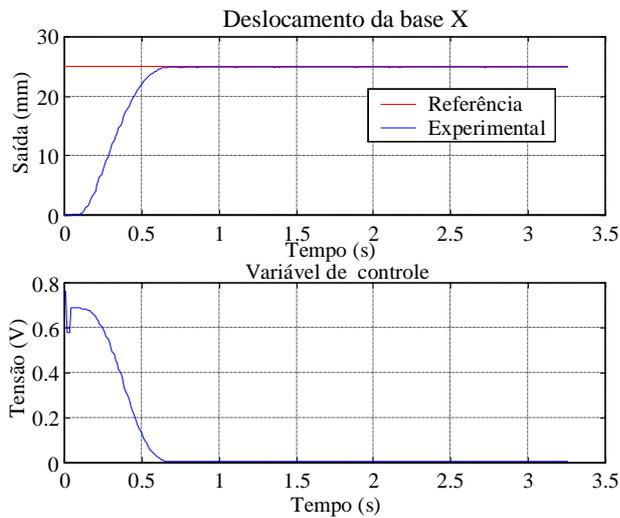


Figura 29: Curvas de resposta experimental da base X com controle vetorial neural para um sinal de referência degrau.

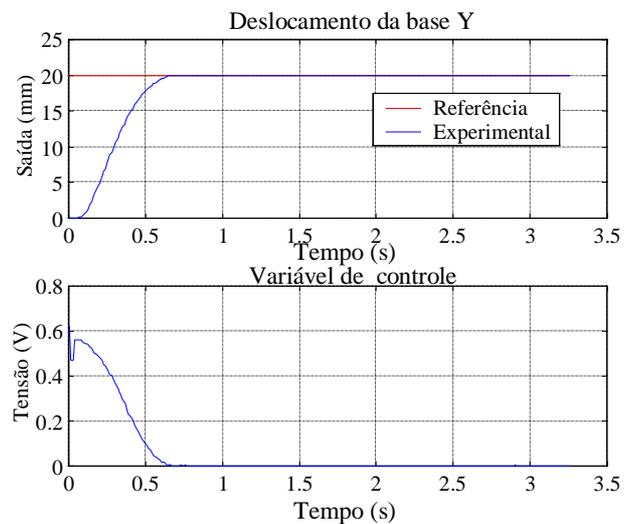


Figura 30: Curvas de resposta experimental da base Y com controle vetorial neural para um sinal de referência degrau.

seguimento de trajetória. Para o controle de posição, a mesa de coordenadas XY foi inicialmente acionada por sinais de referência do tipo degrau e em seguida por sinais contínuos e variáveis no tempo.

O sistema foi acionado utilizando como referência um degrau de 25 mm para a base X e de 20 mm para a base Y.

As Figuras 29 e 30 mostram as curvas de resposta experimental para as bases X e Y, respectivamente.

A Tabela 5 mostra os valores dos índices observados no acionamento experimental da mesa de coordenadas XY.

Na segunda etapa do acionamento do controlador vetorial neural, a referência utilizada foi uma seqüência de degraus de amplitudes distintas. Este acionamento teve como objetivo de verificar o comportamento do controlador com posições distintas de referência.

A Figura 31 apresenta as curvas de resposta experimental para a base X e na Figura 32, para a base Y.

Observou-se um pequeno sobre-sinal para a base Y na etapa de acionamento na transição da posição de 20 mm para 30 mm.

Tabela 5: Valores experimentais dos índices, do controle vetorial neural, para um sinal de referência degrau.

Valor medido	base X	base Y
Sobre-sinal (%)	0,0	0,0
Erro de regime permanente (%)	1,2	1,0

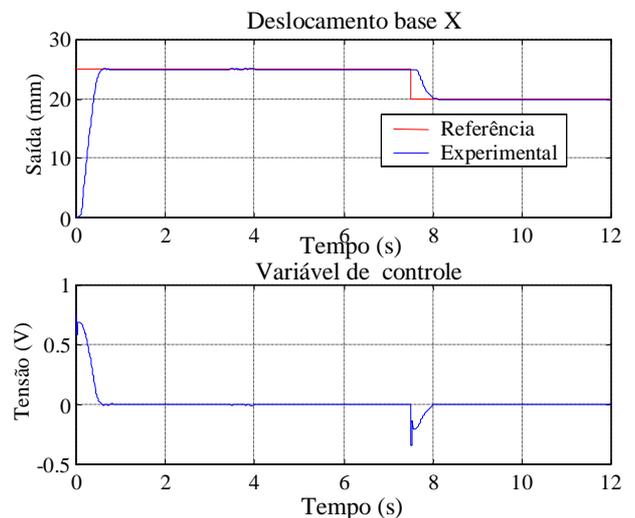


Figura 31: Curvas de resposta experimental da base X com controle vetorial neural para referências variáveis.

A Tabela 6 mostra os valores dos índices observados no acionamento experimental para valores de referência variáveis com o controlador vetorial neural.

Tabela 6: Valores experimentais do controle vetorial neural de posição para entradas variáveis

Valor medido	base X	base Y
Sobre-sinal máximo (%)	0,5	3,0
Erro de regime permanente (%)	0,1	0,3

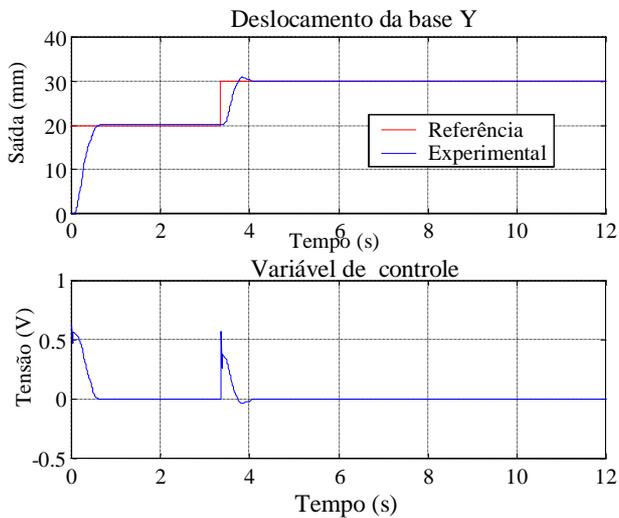


Figura 32: Curvas de resposta experimental da base Y com controle vetorial neural para referências variáveis.

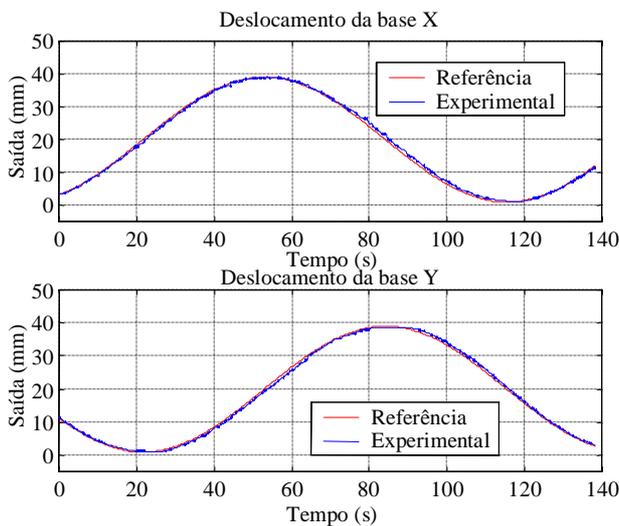


Figura 33: Curvas de resposta experimental para trajetórias senoidais das bases X e Y com controlador vetorial neural.

Em seguida o sistema foi acionado pelo controlador vetorial neural operando com sinais de referência dos tipo senoidal.

Na Figura 33 são mostradas as curvas de resposta experimentais para as bases X e Y com a rede neural atuando como controlador vetorial neural.

Na Figura 34 é mostrada a curva de resposta experimental resultante da composição dos dois sinais de referência senoidais.

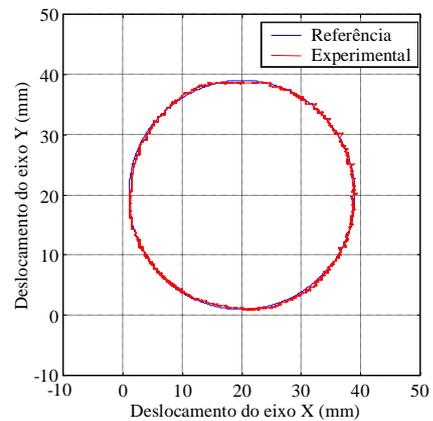


Figura 34: Curva de resposta experimental para sinais de referência senoidais, das bases X e Y com controladores neurais independentes.

5 COMENTÁRIOS E CONCLUSÕES

Neste trabalho foi apresentada uma nova estratégia de acionamento de uma mesa de coordenadas XY. A estrutura experimental utilizada consistiu de uma mesa de coordenadas, de dois graus de liberdade, acionada por dois motores de corrente contínua. O controle foi exercido por controladores implementados em um ambiente computacional que integra programas LabVIEW® e MATLAB® instalados em um microcomputador do tipo PC. Para a determinação das posições de ambos os eixos da mesa foram confeccionados circuitos detectores de posição conhecidos pela denominação de *encoders* que utilizam o microcontrolador PIC16F84 da Microship® como contador e um conversor digital para analógico de 8 bits. A proposta do acionamento foi denominado de controle vetorial neural de uma mesa de coordenadas X Y, que utiliza um controlador neural adaptativo direto para acionamento das bases da mesa de coordenadas. O índice de desempenho minimizado no funcionamento da rede neural é o módulo do erro medido entre o vetor de posição de referência, e o vetor de posição calculado a partir dos sinais de posição de cada mesa.

Através da pesquisa bibliográfica efetuada é possível se observar que as máquinas ferramentas, na qual se enquadra a mesa de coordenadas são acionadas por dois tipos principais de controladores, que são os controladores de trajetória independentes, operando em malhas-fechadas individuais para cada eixo de acionamento e os controladores de erro de contorno, que atuam em um valor calculado de erro de contorno conjuntamente com os controladores axiais. A proposta apresentada não se enquadra rigorosamente nesses dois tipos de controle, já que não atua individualmente nas bases como os controladores de trajetória independentes e não utiliza o cálculo de um erro de contorno como no caso dos controla-

dores de erro de contorno.

Para efeito de comparação, são também apresentados, os resultados simulados e experimentais do acionamento da mesa de coordenadas por meio de controladores neurais independentes para cada base. No caso do acionamento em controle de posição, os resultados obtidos nas simulações e experimentalmente, com ambos os controladores, não apresentaram sobre-sinal. No entanto, os erros de regime permanente no acionamento do controle vetorial foram abaixo dos observados para o caso dos controladores neurais independentes. Para o caso da imposição de uma trajetória de referência, do tipo senoidal, observou-se um desempenho superior do controlador proposto em relação aos controladores independentes ao se comparar os resultados das simulações, conforme mostrado na Tabela 4. No caso dos resultados experimentais, não foi possível se observar diferenças, já que os resultados obtidos foram contaminados por ruídos gerados pela resolução dos detectores de posição utilizados.

Como vantagem da utilização deste controlador, pode-se destacar o fato de atuar na posição final da mesa de coordenadas, mantendo o controle em ambos os eixos de deslocamento, diferentemente do que acontece com o controle de trajetória independente, que minimizam os erros individuais de cada eixo sem que haja uma interação entre os controladores individuais de cada eixo. Por outro lado, ressalva-se que a rede neural, por sua característica de algoritmo de aprendizagem, possui um tempo considerável de adaptação sempre que os sinais de referência mudam. Desse modo, caso a forma desejada em uma determinada operação mude de circular para um outro tipo, deve-se retrainar a rede para essa nova situação. Além disso, como a rede processa as informações a cada tempo de amostragem, no sentido direto e inverso, existe uma limitação em termos de frequência dos sinais de referência que deve ser considerada em seu acionamento.

REFERÊNCIAS

- Aguirre, L. A 2000. Introdução à Identificação de Sistemas: Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais. Ed. UFMG, Belo Horizonte - MG.
- Aguirre, L. A. e Correa, M. V 2004. Identificação Não-Linear Caixa Cinza: Uma Revisão e Novos Resultados. *Controle & Automação*, vol. 15, nº 2, pp. 109-126.
- Buhler, H 1982. *Réglages Échantillonnés*, Ed. Lausanne e Suisse Presses, Polytechniques Romandes.
- Dorf, R. C 2001. *Sistemas de Controle Moderno*. Ed. LTC, São Paulo-SP.
- Coelho, L. e Mariani, V 2006. Sistema Híbrido Neuro-Evolutivo Aplicado ao Controle de um Processo Multivariável. *Controle & Automação*, vol. 10, No 1, pp. 13-30.
- Erkorkmaz, K. and Altintas Y 2001. High Speed CNC System Design. art II: Modeling and Identification of Feed Drives. *International Journal of Machine Tools & Manufacture*, pp. 1487-1509.
- Erkorkmaz, K., Yeung, C. and Altintas, Y 2006. Virtual CNC System. Part II. High Speed Contouring Application. *International Journal of Machine Tools & Manufacture*, pp. 1121-1138.
- Haykin, S 2001. *Redes Neurais - Princípios e Prática*. Tradução de Paulo Martins Engel. Ed. Porto Alegre - RS - Brasil. Ed. Bookman.
- Jamaludin, Z., Brussel, H. V., Pipeleers, G. and Swevers, J 2008. Accurate Motion Control of xy High-Speed Linear Drives Using Friction Model Feedforward and Cutting Forces Estimation. *CIRP Annals - Manufacturing Technology*, Volume 57, Issue 1, pp. 403-406.
- Koren, Y 1978. *Design of Computer Control for Manufacturing System*. American Society of Mechanical Engineers, No 78 - USA.
- Lacerda, H. B., 1998. Um Controlador de Erros de Contorno para Máquinas CNC de Alta Velocidade. Tese de Doutorado, EEE-USP, São Carlos, Brasil.
- Liuzzo, S. and Tomei, P 2008. A Global Adaptive Learning Control for Robotic Manipulators. *Automática*. Elsevier. vol. 44, Issue 5, pp. 1379-1384
- Liu, Z. Z., Luo, F. L., and Rahman, M. A 2005. Robust and Precision Motion Control System of Linear-Motor Direct Drive for High-Speed X-Y Table Positioning Mechanism *Industrial Electronics*. *IEEE Transactions*, vol. 52, Issue 5, pp. 1357-1363.
- Ljung, L., 1987. *System Identification, Theory for the User*. Prentice-Hall, Inc. New Jersey - USA
- Menezes, J. B., Filho 2002. Projeto de Controlador por Retroalimentação de Estados Aplicada a um Sistema Eletromecânico de Posição. Dissertação de Mestrado. UFPB - Brasil.
- Nascimento, J. C. L. e Yoneyama, T 2000. *Inteligência Artificial em Controle e Automação*. São Paulo, Brasil. Editora Edgard Blucher.
- Peng, C. and Chen, L 2007. Biaxial Contouring Control With Friction Dynamics Using a Contour Index Approach. *International Journal of Machine Tools & Manufacture* vol. 47, Issue 10, August 2007, pp. 1542-1555.

- Riul, J. A 2000. Controladores Neurais e Híbrido Aplicados em uma Carga Acionada por um Atuador Hidráulico. Tese de Doutorado, UFPB - Brasil
- Ramesh, R., Mannan, M.A. and Poo, A.N 2005. Tracking and Contour Error Control in CNC Servo Systems. International Journal of Machine Tools and Manufacture, pp. 301– 326.
- Tasinaffo, P. M. and Neto, A. R 2007. Predictive Control With Mean Derivative Based Neural Euler Integrator Dynamic Model. Controle & Automação, vol. 18, n° 1, pp. 94-105.
- Tan, K.K., Huang, S.Y., Lim, S.Y., Leow, Y.P. and Liaw, H. C 2006. Geometrical Error Modeling and Compensation Using Neural Networks. IEEE Transactions on systems, Man, and Cybernetics, vol 36, n° 6, pp. 797-809.
- Tomizuka, M. and Tsao T. C 1987. Adaptive Zero Phase Error Tracking Algorithm for Digital Control. Journal of Dynamics Systems, Measurements and Control Transaction of the ASME, vol. 109, pp. 349-354.
- Tomizuka, M., 1987. Zero Phase Error Tracking Algorithm for Digital Control. Journal of System Measurement and Control, vol. 109, pp. 65-68. USA