

CONTROLE NEURAL DO TIPO PD2 APLICADO A UM MANIPULADOR ROBÓTICO DE DOIS GRAUS DE LIBERDADE

Thyago L. de Vasconcelos Lima¹, Isaac Soares de Freitas², José Bezerra de Menezes Filho¹, Carlos Alberto Nóbrega Sobrinho¹, Jobson Francisco da Silva¹, Élidea Fernanda Xavier Júlio³

¹Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, Av. Primeiro de Maio, 720, Jaguaribe, João Pessoa, Paraíba

²Laboratório de Máquinas e Acionamentos Elétricos, CT, Universidade Federal da Paraíba Campus 1- João Pessoa, Paraíba

³Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal da Paraíba, Campus I - João Pessoa, PB

thyagolvasconcelos@gmail.com, isaac@ct.ufpb.br, jose.menezes@ifpb.edu.br, nobregasobrinho.ca@gmail.com,

jobsonfsilva@gmail.com, elida_xnet@yahoo.com.br

Resumo – O presente trabalho apresenta a aplicação de um controlador neural do tipo PD2 em um manipulador robótico de dois graus de liberdade. O manipulador utilizado na pesquisa foi construído utilizando juntas rotativas, acionadas por motores de indução trifásicos. O robô desenvolvido permite a movimentação em uma área espacial equivalente a um quarto de esfera. A avaliação do desempenho geral do sistema de controle é feita com base na resposta ao acompanhamento de trajetória (sinais senoidais) e na resposta de posicionamento (sinais tipo degrau).

Palavras-Chave – Controle de Posição, Redes Neurais, Manipulador Robótico

1 Introdução

Nas décadas de 50 e 60 os robôs industriais foram introduzidos com a finalidade de substituir o homem na execução de tarefas repetitivas e/ou perigosas, visando uma melhoria na qualidade, aumento da produtividade e redução dos custos de produção. Algumas das tarefas mais comuns às quais os robôs se destinam são: transporte e manejo de materiais [1], montagem e manufatura [2], soldagem [3], pintura [4].

No final da década de cinquenta foi desenvolvido o que se pode chamar de primeiro robô automático, um conceito de J. K. Devol, chamado Unimate [5], instalado na Ford no ano de 1961. A partir de então, a robótica não parou de se desenvolver de maneira acelerada, ao ponto de existirem estudos com robôs que imitam movimentos humanos [6] e robôs para aplicações domésticas [7].

Na Figura 1 é representado o arquétipo do robô manipulador, inspirado no braço humano. Através da programação dos três ângulos do braço (α , β , γ) e da aplicação do comando adequado aos motores das três articulações, é possível levar o atuador a um dado ponto dentro dos limites espaciais de trabalho. De forma análoga, pode-se programar os três ângulos (ψ , θ , ϕ) e comandar os acionadores do pulso para levar o elemento presente na extremidade do braço a tomar a orientação desejada com base na tarefa a ser realizada [5].

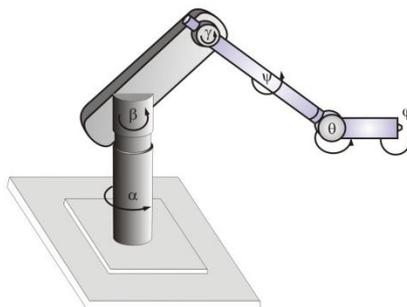


Figura 1 - Manipulador robótico de seis graus de liberdade (Adaptado de [5]).

O maciço investimento em robôs industriais no processo produtivo observado nas últimas décadas deve-se principalmente às crescentes necessidades impostas pelo mercado de se obter sistemas de produção cada vez mais automatizados e dinâmicos [8]. A partir da segunda metade do século passado, com o crescente avanço da automação industrial, tem sido cada vez maior a atenção dispensada ao controle automático de sistemas dinâmicos. Durante esse período, várias técnicas de controle têm sido desenvolvidas, como controle robusto, controle ótimo, controle adaptativo, controle não linear, controle inteligente.

Como alternativa ao controle convencional, nos tempos atuais, utilizam-se controles inteligentes, consistindo basicamente de três abordagens: sistemas especialistas baseados em conhecimento, controle por lógica fuzzy e controle por redes neurais [9].

Denomina-se Rede Neural Artificial (RNA) um processador paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso, assemelhando-se ao cérebro humano nos seguintes aspectos [10]:

- O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;
- Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizados para armazenar o conhecimento adquirido.

Na literatura, são encontrados inúmeros trabalhos com aplicação de redes neurais, seja na robótica ([11], [12], [18]), na medicina ([13]) ou no ramo automotivo ([14]).

O objetivo do presente trabalho é apresentar o desenvolvimento de um manipulador robótico, assim como realizar seu controle de posição e acompanhamento de trajetória por meio da aplicação de redes neurais. A estrutura de controle utiliza Redes Neurais Artificiais (RNA) com atualização de pesos sinápticos através do mecanismo de retropropagação e emula um controlador PD2, que é utilizado em sistemas que têm dois pólos dominantes e apresenta comportamento integral (um terceiro pólo igual a 1).

2 Descrição do Sistema

Para a realização da pesquisa foi construído um manipulador robótico de dois graus de liberdade, representado na Figura 2. A construção se justifica pelo fato de robôs para fins didáticos serem limitados para modificações, visto que os softwares de controle empregados em tais plataformas são proprietários, não permitindo acesso ao código inserido em bibliotecas previamente compiladas, bem como seu hardware não apresenta documentação acerca do circuito de controle [15]. Durante a elaboração do projeto do manipulador foram empregados materiais de baixo custo, como alumínio e aço 1020.

Tanto a base como o braço são acionados por motores de indução trifásicos de 220V, 60 Hz de 0.33 Cv, comandados por inversores de frequência. Ambos os motores são acoplados a eixos sem-fim, que por sua vez transmitem movimento à base e ao braço através de engrenagens. A velocidade de rotação e o sentido de giro do eixo dos motores são controlados por meio de sinais de controles neurais enviados aos inversores de frequência. O deslocamento angular total do braço é de 100° e o da base é de 120° e para a proteção do sistema são utilizadas chaves fim de curso.

O controle de posição do sistema foi implementado em malha fechada. Os controladores neurais foram desenvolvidos no ambiente de programação LabVIEW®, residente em um microcomputador Core2Duo 2,5 GHZ equipado com uma interface de aquisição de dados tipo NI-DAQ6008 da National Instruments®.

Como transdutores de posição foram utilizados potenciômetros multivoltas (dez voltas) acoplados aos eixos dos motores por engrenagens, que fornecem sinais de resposta proporcionais ao número de voltas de seus cursores. Os transdutores potenciométricos apresentam resistência elétrica de 10 kΩ ±10%, são alimentados com uma tensão fixa de 10 V e o terminal de saída está conectado ao canal de entrada analógica da placa de aquisição de dados.

As Equações (1) e (2), obtidas a partir de dados experimentais, representam uma função linear que relaciona os valores de tensão com os valores do deslocamento angular da base e do braço, respectivamente:

$$\theta_{base} = \frac{-120 \times V + 407,4}{5,43} \quad (1)$$

$$\theta_{braço} = \frac{-100 \times V + 507}{4,45} \quad (2)$$

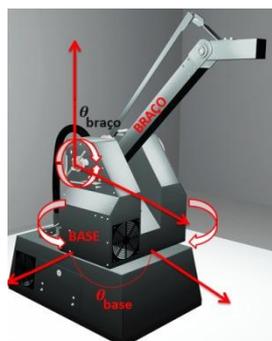


Figura 2– Representação do manipulador robótico utilizado na pesquisa

O diagrama esquemático do sistema de controle do braço e da base do manipulador robótico é mostrado na Figura 3.

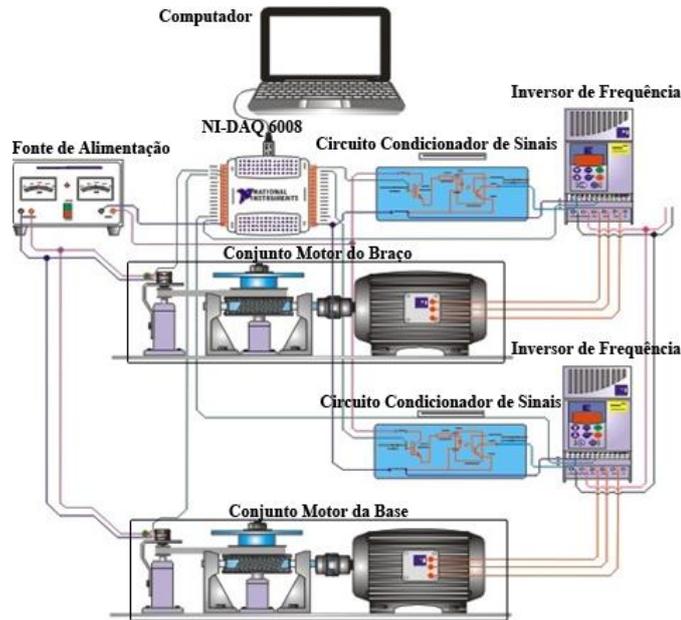


Figura 3 – Diagrama esquemático do sistema de controle.

3 Identificação do Sistema e Projeto dos Controladores Neurais

3.1 Identificação das funções de transferência discretas do manipulador robótico

O sistema foi simulado no ambiente Matlab® para obtenção dos pesos sinápticos iniciais das Redes Neurais Artificiais. Para tal, foram obtidas funções de transferência advindas da identificação do sistema, realizada a partir dos dados de entrada e de saída da planta, coletados de um ensaio em que foram aplicados sinais de excitação do tipo onda quadrada com amplitudes e larguras pré-determinadas. Para se obter as funções de transferência do sistema utilizou-se o “Toolbox” de identificação do Matlab®, aplicando-se o modelo BJ (Box Jenkins Model). O procedimento de identificação foi realizado várias vezes, até a obtenção de um modelo que apresentasse respostas com maior semelhança com os dados experimentais.

Nas Equações (3) e (4) são mostrados os modelos na forma de função de transferência no modo discreto do manipulador robótico para a base e o braço, respectivamente:

$$\frac{Y_{base}(z)}{U_{base}(z)} = \frac{0.03018z^2 - 0.06349z + 0.05471}{z^3 - 1.321z^2 + 0.03939z + 0.2818} \quad (3)$$

$$\frac{Y_{braço}(z)}{U_{braço}(z)} = \frac{0.01147z^2 - 0.020891z + 0.01141}{z^4 - 2.697z^3 + 2.426z^2 - 0.729z} \quad (4)$$

Onde:

Y_{base} : posição angular da base;

$Y_{braço}$: posição angular do braço;

U_{base} : sinal de controle da base;

$U_{braço}$: sinal de controle do braço;

Para validação dos modelos adotados, os modelos e o sistema foram submetidos à uma mesma excitação e suas respostas foram comparadas. As curvas de resposta simulada e experimental são mostradas nas Figuras 4.a e 4.b.

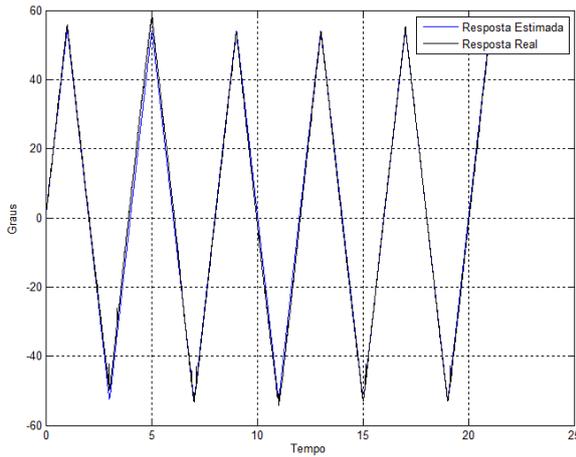


Figura 4.a – Curvas de Resposta Experimental e Simulada do Sistema – Braço.

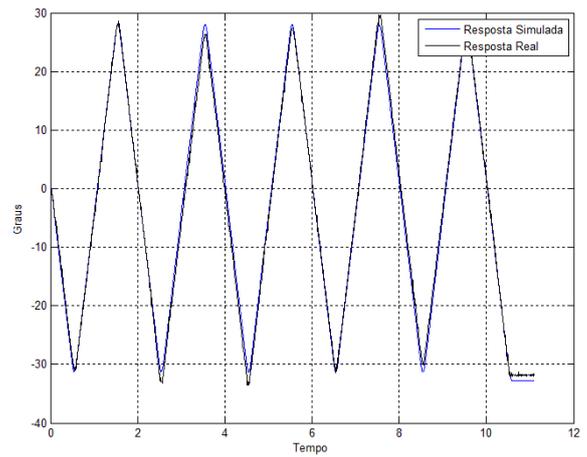


Figura 4.b – Curvas de Resposta Experimental e Simulada do Sistema – Base.

3.2 Projeto do Controlador Neural

Para o projeto dos controladores foram utilizadas Redes Neurais de Multicamada (RNMC) do tipo direto. Sua arquitetura consiste de três camadas: uma camada de entrada com quatro neurônios, uma camada oculta com dez neurônios e uma camada de saída com apenas um neurônio, a qual fornece o sinal de controle para os inversores de frequência. A Rede Neural foi testada com valores de 6, 8 e 10 neurônios na camada oculta, sendo a arquitetura com 10 neurônios a que apresentou melhores resultados. Os neurônios da camada de entrada têm a função apenas de ligação. Desse modo, as quatro ligações entre os neurônios de entrada e os neurônios da camada intermediária ocorrem através de 40 pesos sinápticos, obtendo-se, portanto, uma matriz com 10 linhas e 4 colunas denominada Win. Já as ligações entre os neurônios da camada intermediária e os neurônios da camada de saída ocorrem através de 10 pesos sinápticos, obtendo-se uma matriz de pesos contendo 10 linhas e 1 coluna, denominada Whide. A Figura 5 mostra o detalhe interno da Rede Neural Artificial utilizada nesta pesquisa.

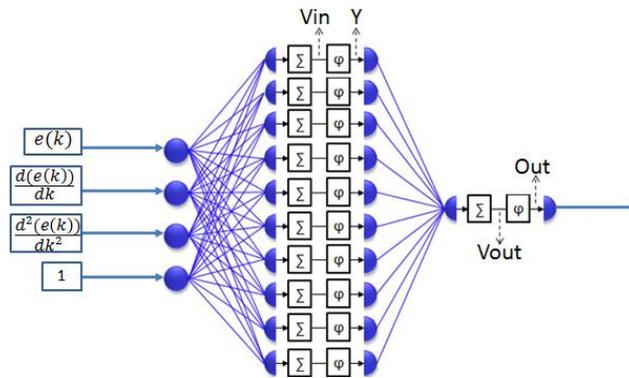


Figura 5 – Detalhe interno da Rede Neural utilizada como controlador.

Os sinais da primeira camada, ou seja, os sinais da camada de entrada, são determinados a partir de uma analogia com o controlador PD2 (Proporcional Derivativo Duplo), descrito em [16]. Essa estrutura é derivada de um controlador PD, ao qual é adicionada uma componente proporcional à derivada do sinal do erro de posição. A equação discreta do controlador PD2 é dada por:

$$u(k) = kp \times e(k) + kd \times \frac{d(e(k))}{dk} + kd_2 \times \frac{d^2(e(k))}{dk^2} = kp \times e(k) + kd \times (e(k) - e(k-1)) + kd_2 \times (e(k) - 2 \times e(k-1) + e(k-2)) \quad (5)$$

onde:

- $u(k)$: valor da saída discreta do controlador;
- kp : ganho proporcional do controlador;
- kd : Ganho aplicado à derivada do sinal de erro;

kd_2 : Ganho aplicado à derivada segunda do sinal de erro;

$e(k)$: erro no instante de amostragem k;

$e(k - 1)$: erro no instante de amostragem k-1;

$e(k - 2)$: erro no instante de amostragem k-2.

A opção pela utilização de um controlador neural que emula um controlador PD2 se deveu ao fato de que para implementação deste último controlador ter-se-ia a necessidade de se utilizar uma função de transferência que representasse com uma boa aproximação o comportamento dinâmico do sistema controlado, de modo a serem computados os novos pólos dominantes que seriam impostos ao sistema e eliminados os pólos indesejáveis do sistema de malha fechada. Já para os controladores neurais necessitou-se apenas das funções de transferência descritas nas Equações (3) e (4) para a etapa de treinamento no modo simulado para obtenção dos pesos sinápticos iniciais, não se exigindo que estas últimas equações representem com muita precisão as dinâmicas das juntas controladas do manipulador.

Dessa forma, a matriz I_n , matriz das entradas do sistema, é constituída do erro, da derivada primeira do erro, da derivada segunda do erro e do bias que assume valor 1. A Figura 6 ilustra o controlador neural aplicado no manipulador robótico.

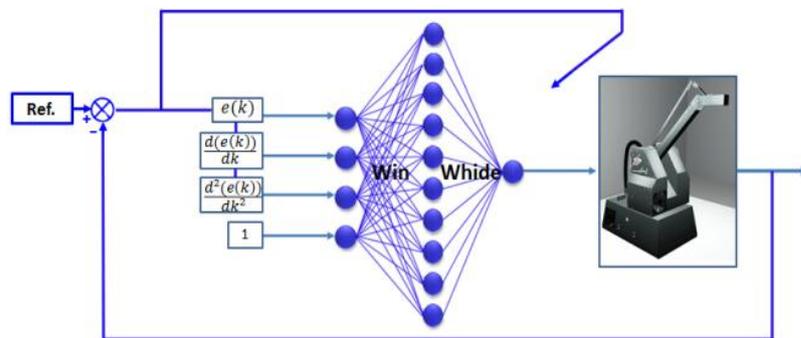


Figura 6– Controlador Neural aplicado ao manipulador.

Para cada neurônio da camada oculta são totalizados todos os produtos entre os pesos sinápticos W_{in} e matriz de entradas I_n e o somatório desses produtos resulta na função dada por:

$$V_{in} = W_{in} \times I_n \quad (6)$$

A função de ativação dos neurônios da camada oculta é do tipo tangente hiperbólica. Desta forma, obtém-se o sinal funcional do neurônio oculto, para $i = 1, 2, \dots, 10$, dado por:

$$Y_{(i \times 1)} = \varphi = \text{Tanh}(v_{in}(i)) \quad (7)$$

Aplicando-se a matriz W_{hide} ao vetor $Y_{(ix1)}$ obtém-se o sinal de entrada do neurônio da camada de saída:

$$v_{out} = W_{hide}^T \times Y \quad (8)$$

Finalmente, a obtenção do sinal de controle que é enviado ao inversor de frequência é mostrado pela Equação (9).

$$out = \text{Tanh}(v_{out}) \quad (9)$$

3.2.1 Algoritmo de retropropagação

Na retropropagação, todos os pesos da rede são ajustados. A retropropagação é iniciada pelo gradiente local da camada de saída (∇_{out}), mostrado na Eq. (1), que é definido como o produto de três componentes: a derivada da função de transferência do neurônio de saída, o erro de posição no instante k ($e(k)$), que é obtido a partir da diferença entre o sinal de referência de posição angular do tipo degrau e o sinal referente à posição angular medida no instante de tempo de amostragem e o Jacobiano da planta controlada (J).

$$\nabla_{out} = e(k) \times J \times \frac{d(\text{Tanh}(v_{out}))}{dk} \quad (10)$$

O valor do Jacobiano foi considerado igual à matriz identidade de ordem 1 (1x1), com a finalidade de simplificar o esforço computacional por parte da rede neural. Como os resultados experimentais foram satisfatórios, tal consideração foi mantida. De posse da Equação (10), são calculadas as variações dos pesos (whide), que ligam a camada de saída com a camada oculta, dadas pela Equação (11):

$$\Delta_{hide} = \eta \times \nabla_{out} \times Y \quad (11)$$

Onde η é o fator de convergência do algoritmo. Os pesos sinápticos (whide) são dados pela Equação (12):

$$W_{hide} = W_{hide} + \Delta_{hide} \quad (12)$$

A modificação dos pesos sinápticos entre a camada de entrada e a camada oculta é iniciada com o cálculo dos gradientes locais de cada neurônio da camada oculta dado pela Equação (13):

$$\nabla_{in} = \text{whid}_{(k1)} \times \nabla_{out} \times \frac{\partial(\text{Tanh}\{g(y)\})}{\partial y_{k1}} \quad (13)$$

onde: $k = 1, 2, \dots, 10$.

Obtidos os valores da Equação (13), a variação dos pesos entre a camada de entrada e camada oculta (win) é calculada de acordo com a Equação (14):

$$\Delta_{in} = \eta \times \nabla_{in} \times I_n^T \quad (14)$$

Finalmente é calculada a modificação dos pesos sinápticos, que ligam cada neurônio de entrada com os neurônios da camada oculta, de acordo com a Equação (15):

$$W_{in} = W_{in} + \Delta_{in} \quad (15)$$

4 Resultados Experimentais

4.1 Ensaios de acionamento com excitações do tipo degrau

Na base foi aplicado um degrau de referência de 98.1°, provocando um deslocamento de grande amplitude, variando a posição da base de -56.26° para a posição de 41.84°. No gráfico das Figuras 7.a, encontram-se as curvas de resposta da base e da referência.

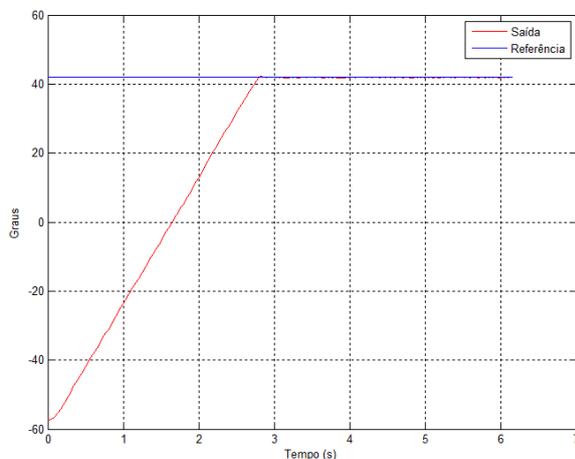


Figura 7.a – Curva de resposta ao degrau – Base

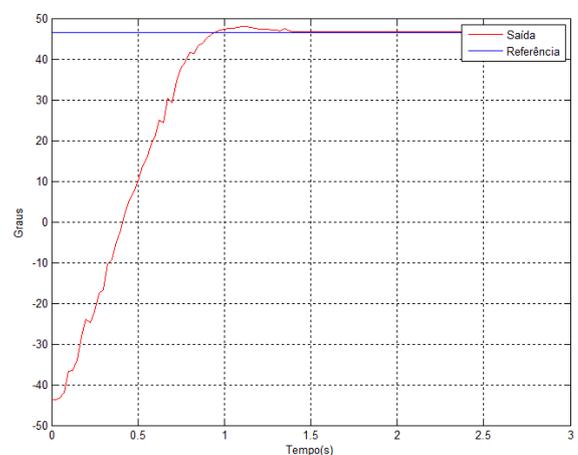


Figura 7.b – Curva de resposta ao degrau – Braço

Já para o braço, foi aplicado um degrau que resultou em um deslocamento angular total de 90.23° (da posição -43.71° para a posição 46.52°). Na Figura 7.b são mostradas as curvas de resposta do braço e da referência imposta.

A análise das Figuras 7.a e 7.b permite obter os tempos de assentamento T_s , e os percentuais de ultrapassagem UP e de erro de regime permanente ess , definidos conforme [17]. Esses dados constam na Tabela (1).

Tabela 1—Índices de desempenho experimentais extraídos das curvas de resposta do manipulador robótico.

| Valor Medido | Figura7.a | Figura7.b |
|--------------|---------------------|---------------------|
| | Sinal de Referência | Sinal de Referência |
| | 41.84° | 46.52° |
| T_s (s) | 2,776 | 1,2 |
| UP (%) | 0.88 | 2,83 |
| ess (%) | 0 | 0,34 |

Pela análise da Tabela 1, observa-se um comportamento satisfatório do sistema ao ser submetido à entrada do tipo degrau. Os resultados obtidos demonstram que o controlador neural apresentou erro de regime permanente apenas para o braço e ultrapassagem percentual máxima de 2,83 %, também para o braço.

Estes resultados indicam uma necessidade de melhor sintonia do controlador do braço, que pode ser realizada por meio de ajuste no fator de convergência ou na taxa de aprendizagem da Rede Neural Controladora.

4.2 Ensaios de acionamento com excitações do tipo seno e cosseno

Para avaliar o desempenho do controlador neural quanto ao acompanhamento de trajetória, foram impostas referências do tipo senoidal com período $T=160s$ e amplitudes de 44.9° e $56,7^\circ$, para o braço e a base respectivamente. Tais sinais foram aplicados simultaneamente e defasados de 90° entre si.

Nos gráficos do seno e do cosseno, é possível observar um bom desempenho nos acompanhamentos das saídas às trajetórias das referências. Todos os ensaios foram realizados na bancada experimental apresentada nas Figuras 9.a e 9.b.

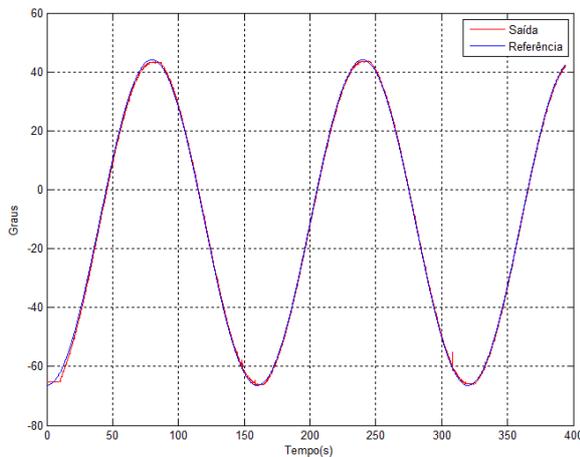


Figura 8.a – Curvas de resposta e de referência Cossenoidal da base

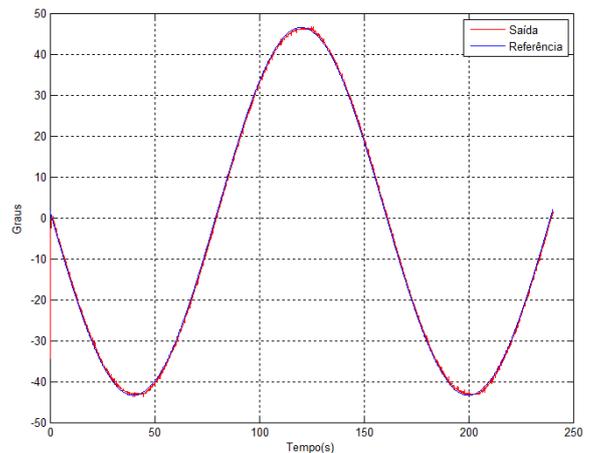


Figura 8.b - Curvas de resposta e de referência senoidal do braço.



Figura 9.a – Vista lateral da bancada experimental utilizada na pesquisa



Figura 9.b - Vista frontal da bancada experimental utilizada na pesquisa

5 Conclusões

Neste trabalho apresentou-se o desenvolvimento e controle por redes neurais de um manipulador robótico de dois graus de liberdade, acionado por motores de indução trifásicos. Acionamentos para realizar o controle de posição e de acompanhamento de trajetória foram realizados para avaliar o desempenho da estratégia de controle. Nos dois tipos de ensaios realizados, o sistema apresentou um bom desempenho. Observa-se que a rede neural multicamadas, emulando um controlador do tipo PD2ecom aprendizado realizado através da técnica de retropropagação do erro, respondeu de maneira positiva ao que se esperava de um manipulador robótico acionado por motores de indução trifásicos. Por fim, o manipulador robótico construído para a realização das pesquisas ofereceu suporte para superação de obstáculos financeiros e de falta de documentação, proporcionando a realização não só do presente trabalho, mas de outros que se encontram em desenvolvimento.

6 Referências

- [1] M. Endo, K. Hirose, Y. Hirata, K. Kosuge, T. Kanbayashi, M. Oomoto, K. Akune, H. Arai, H. Shinoduka, K. Suzuki, A car transportation system by multiple mobile robots – iCART, **IEEE/RSJ International Conference on Intelligent Robots and Systems**, (2008), 2795-2801
- [2] M. Fei, Z. Haiou, W. Guilan, Application of Industrial robot in rapid prototype manufacturing technology, **2nd International Conference on Industrial Mechatronics and Automation**, vol. 1 (2010), 218-220.
- [3] H. B. Chen, T. Lin, S. B. Chen, J. F. Wang, J. Q. Jia, H. Zhang, Adaptive control on wire feeding in robot arc welding system, **IEEE Conference on Robotics, Automation and Mechatronics**, (2008), pp.: 119-122.
- [4] J.-P. Gazeau, A. Eon, S. Zeghloul, M. Arsicault, New Printing Robot for High-Resolution Pictures on Three- Dimensional Wide Surfaces, **IEEE Transactions on Industrial Electronics**, vol. 58, issue 2, (2011), 384-391.
- [5] G. Giralt, A robótica, **Biblioteca Básica de Ciência e Cultura, Instituto Piaget**, (1997).
- [6] D. Komagome, M. Suzuki, T. Ono, S. Yamada, RobotMeme – A proposal of Human-Robot Mimetic Mutual Adaptation, **The 16th IEEE International Symposium on Robot and Human interactive Communication**, (2007), 427-432.
- [7] D. Wang, J. Leung, A. P. Kurian, H.-J. Kim, Yoon, A Deconvolutive Neural Network for Speech Classification With Applications to Home Service Robot, **IEEE Transactions on Instrumentation and Measurement**, vol. 59, issue 12, (2010), 3237-3243.
- [8] V. R. Romano, Robótica Industrial, 1^a Edição, **Ed. Edgard Blücher LTDA**, (2002).
- [9] P. N. Paraskevopoulos, Digital Control Systems, 1^a Edition, **Prentice Hall**, (1995).
- [10] S. Haykin, Redes Neurais, Princípios e Prática, Tradução de Paulo Martins Engel, 2^a Edição, **Editores Bookman**, (2001).
- [11] J. Zhao-Hui, T. Ishida, Trajectory Tracking Control of Industrial Robot Manipulators Using a Neural Network Controller, **IEEE International Conference on Systems, Man and Cybernetics**, (2007), 2390-2395.
- [12] Y. Zhao, C. C. Cheah, Neural Network Control of Multifingered Robot Hands Using Visual Feedback, **IEEE International Transactions on Neural Networks**, vol. 20, issue 5, (2009), 758-767.
- [13] H. Yan, Y. Jiang, J. Zheng, C. Peng, Q. Li, A Multilayer Perceptron-based Medical Decision Support System for Heart Disease Diagnosis, **Expert Systems with Applications**, vol. 30, issue 2, (2006), 272-281.
- [14] A. V. Ortega, I. N. Silva, Neural Network Model for Designing Automotive Devices Using SMS LED, **International Journal of Automotive Technology**, vol. 9, issue 2, (2008), 203-210.
- [15] A. A. D. Medeiros, G. S. Santiago, Desenvolvimento de um Braço Manipulador Didático de Baixo Custo Controlado por Computador, **SPET 1998 – IV Simpósio em Pesquisa e Extensão em Tecnologia**, (1998).
- [16] H. Buhler, RéglagesÉchantillonnés, **Ed. Lausanne e SuissePresses, PolytechniquesRomandes**, (1982).
- [17] K. Ogata, Engenharia de Controle Moderno, 4^a Edição, **Prentice Hall**, (2003)
- [18] G. Pessin, F. Osório, S. Musse, V. Nonnemacher, S. S. Ferreira, Utilizando Redes Neurais Artificiais no Controle de Robôs Móveis Aplicados ao Combate de Incêndios Florestais, **Anais do XVI SEMINCO**, (2007), 19-30.