

Self-tuning of a Neuro-Adaptive PID Controller for a SCARA Robot Based on Neural Network

E. O. Freire, F. G. Rossomando and C. M. Soria

Abstract— In this paper a MIMO (Multiple-Input-Multiple-Output) adaptive neural PID (AN-PID) controller that can be applied to a nonlinear dynamics is proposed, and its use is shown in the control of a SCARA robot for two degrees of freedom. The AN-PID controller, including a neural network of the dynamic perceptron type, is designed. The proposed controller uses a RBF network to identify the model and back propagates the control error to the AN-PID controller, unlike other controllers, that use direct methods to back propagate such error. With these properties, an AN-PID controller corrects the tracking errors due to the uncertainties and variations in the robot arm dynamics. It is robust and with adaptive capacity in order to achieve a suitable control performance. Experimental results on the SCARA robot were obtained to illustrate the effectiveness of the proposed control strategy, including comparison with a classical PID. By using Lyapunov's discrete-time theory, it was demonstrated that the control error is semi-global uniformly ultimate bounded (SGUUB).

Keywords— MIMO systems, neural networks, nonlinear control, adaptive control.

I. INTRODUÇÃO

OS CONTROLADORES PID (proporcional, integral e derivativo) são amplamente aplicados em processos industriais, sistemas automáticos e robótica, pois são robustos e simples de implementar. Mas os controladores PID têm algumas desvantagens; por exemplo, é difícil ajustar os parâmetros de controle (os ganhos proporcional, integral e derivativo) em sistemas não invariantes no tempo. Além disso, controladores PID não são recomendáveis para sistemas complexos ou quando incertezas podem levar a não-linearidades no processo [1][2][3][4].

Em um esforço para contornar esses problemas, são descritas na literatura diversas abordagens baseadas em controladores PID, como controladores PID baseados em RNA's (Redes Neurais Artificiais) e controladores PID *fuzzy*, por exemplo, bem como técnicas de otimização baseadas em enxames de partículas, algoritmos genéticos e colônias de formigas para controladores PID, dentre outros [5][6].

Nesse trabalho é apresentado o desenvolvimento matemático de um controlador PID neuro-adaptativo MIMO (do inglês *Multiple Input, Multiple Output*), com identificação neural indireta usando uma rede neural RBF (do inglês *Radial Basis Function*), ambos completamente projetados no domínio

de tempo discreto, de forma que sua implementação reduz os problemas produzidos pelos projetos de automação e controle desenhados no domínio de tempo contínuo com posterior discretização.

A abordagem proposta é semelhante à que é apresentada em [7], onde é introduzido um controlador PID neural aplicado a robôs móveis. Em [7], são apresentados resultados experimentais que confirmam o funcionamento do método de controle proposto, entretanto, a análise de estabilidade pode ser melhorada se forem considerados os ganhos do PID na função candidata de Lyapunov, o que é feito neste trabalho.

O projeto apresentado neste artigo visa ajustar os parâmetros de um controlador PID sem conhecer previamente o modelo do processo que se deseja controlar, que neste caso é um robô SCARA Bosch SR-800. A configuração SCARA (do inglês *Selective Compliant Articulated Robot for Assembly*) é um robô cujas duas primeiras juntas são de rotação e a terceira junta é prismática, e que é muito utilizado em tarefas de montagem na indústria, principalmente em montagens de placas de circuito impresso. Neste trabalho, só é considerado o controle das duas juntas de rotação.

Os parâmetros dinâmicos do robô podem variar por conta de fatores como atrito, variação de massa, deslizamento, etc. Além disso, o robô possui uma dinâmica não-linear. Para poder lidar com tais questões, o controlador PID neuro-adaptativo MIMO (que a partir desse ponto será designado pela sigla AN-PID) proposto neste trabalho é capaz de compensar a dinâmica não-linear do robô e de reduzir o efeito das incertezas associadas ao modelo do manipulador robótico, bem como das perturbações causadas pelo ambiente de operação. Assim, o controlador apresentado dispensa a necessidade de um modelo exato do robô e garante um desempenho robusto, mesmo na presença de incertezas e perturbações na dinâmica do processo.

O método de controle apresentado possui as seguintes vantagens:

- (i) Pode ser aplicado a qualquer sistema com múltiplas entradas e múltiplas saídas (sistemas MIMO), como é o caso do robô SCARA considerado neste trabalho;
- (ii) O modelo exato do sistema não precisa ser conhecido;
- (iii) O modelo dinâmico é identificado *on-line*;
- (iv) O projeto do controlador AN-PID é simples e baseada em uma topologia de RNA dinâmica;
- (v) A identificação do modelo dinâmico e a implementação do controlador AN-PID é realizada diretamente no domínio discreto de tempo, facilitando a sua programação em computadores e outros equipamentos digitais e evitando os problemas de estabilidade causados pela implementação direta em tempo discreto de controladores originalmente projetados em tempo contínuo.

E. O. Freire, Universidade Federal de Sergipe (UFS), São Cristóvão-SE – Brasil, efreire@ufs.br.

F. G. Rossomando, Instituto de Automatica – Conicet - Universidad Nacional de San Juan (UNSJ-Conicet), Capital, San Juan, Argentina, frosoma@inaut.unsj.edu.ar.

C. M. Soria, Instituto de Automatica – Conicet - Universidad Nacional de San Juan (UNSJ-Conicet), Capital, San Juan, Argentina, csoria@inaut.unsj.edu.ar.

Corresponding author: Eduardo Oliveira Freire

- (vi) A análise de estabilidade foi realizada no domínio de tempo discreto (tanto para o modelo obtido pelo identificador neural, quanto para o controlador AN-PID), e é apresentada neste trabalho, visando suprir uma deficiência existente na literatura da área.

Este artigo está organizado da seguinte maneira: na Seção II são apresentados trabalhos correlatos, na Seção III é apresentada uma visão geral do robô e de seu modelo dinâmico. O controlador AN-PID com identificação neural indireta da dinâmica do robô e sua análise de estabilidade são estudados nas seções IV, V e VI. Os resultados obtidos experimentalmente são apresentados na Seção VII, e as conclusões, na Seção VIII, seguidas das referências bibliográficas citadas neste trabalho.

II. TRABALHOS CORRELATOS

Os trabalhos [5] e [6] são sobre controladores PID aplicados a processos na indústria e braços robóticos, respectivamente. Ambos clamam que a dinâmica do processo e do manipulador robótico, respectivamente, são desconhecidos, e portanto a aplicação de técnicas de controle PID pode consistir na melhor opção, pois não é necessário nenhum conhecimento prévio, além de seus parâmetros poderem ser ajustados com simplicidade e de forma separada.

Em [8], é apresentada uma estratégia de controle semelhante a PID baseada em RNA's, que é aplicável a uma classe de problemas de controle não-linear frequentemente encontrados em controle de processos industriais e de aplicações tecnológicas. Os resultados obtidos experimentalmente demonstram a efetividade do método de controle. Neste trabalho, não é apresentada prova de estabilidade da abordagem proposta, que também não possui nenhuma propriedade adaptativa.

Em [9] é apresentada uma nova técnica de controle que utiliza neurônios auto-sintonizados para encontrar os parâmetros de ganho de um controlador PID multivariado. As leis de adaptação utilizam um método indireto de retro-propagação de erro para ajustar os ganhos, que são sintonizados *on-line*. Os resultados das simulações apresentadas foram obtidos para sistemas lineares apenas.

Em [10] é proposto um novo método para ajustar os coeficientes dos controladores de lógica *fuzzy* (FLC, do inglês *fuzzy logic controller*) tipo PID. O novo método, ajusta o fator de escala de entrada correspondente ao coeficiente derivativo e o fator de escala de saída correspondente ao coeficiente integral do FLC tipo PID usando um mecanismo de inferência *fuzzy on-line*. Os resultados das simulações apresentados mostram a robustez e efetividade do algoritmo de auto-sintonia proposto. As simulações foram feitas em um sistema de segunda ordem com parâmetros variáveis e atraso de tempo.

O trabalho apresentado em [11] consiste no estudo da regulação assintótica global de manipuladores robóticos sob restrições de entrada, com/sem medições de velocidade. No trabalho, é mostrado que sistemas robóticos sujeitos a entradas limitadas podem ser assintoticamente globalmente estabilizados através de um controle PID saturado, de acordo com o método direto de Lyapunov e com o princípio de invariância de LaSalle. A efetividade da abordagem proposta

foi demonstrada por simulações.

Em [12] foi desenvolvido um algoritmo de aprendizagem PID robusto ótimo, no qual os parâmetros ótimos de aprendizagem podem ser encontrados utilizando técnicas de otimização de desigualdade de matrizes lineares. Para demonstrar a efetividade do algoritmo proposto, foi realizada uma análise teórica e simulações.

Em [13] é apresentada uma combinação de um controlador PID linear industrial e compensação neural. Com essa combinação, o PID neural não necessita que os ganhos proporcional e integral sejam elevados para garantir a estabilidade assintótica. Essas condições resultam em métodos de seleção explícitos para os parâmetros do controlador PID linear. O trabalho apresenta um estudo experimental em um exoesqueleto de membro superior.

Em [14] é mostrado, via simulação, que um robô SCARA tipo DDR (do inglês *Direct Drive Robot*) pode ser controlado com sucesso por um controlador adaptativo simples com dois graus de liberdade. A arquitetura de controle é baseada em um modelo linear e sua implementação é relativamente simples. O ângulo da junta foi capaz de rastrear o percurso de referência adequadamente, e o efeito da perturbação de entrada constante pôde ser suprimido por meio da alteração da propriedade de rejeição de perturbações, ajustando o ganho integral.

Em [15], é apresentado o projeto de um controlador PID baseado no Controle de Modelo Interno (IMC, do inglês *Internal Model Control*) para um robô SCARA com dois elos. Um filtro passa-baixa IMC adequado deve ser selecionado para que o controlador PID possa ser derivado aplicando expansão da série de MacLaurin ao controlador IMC em um laço de controle de realimentação geral. Os resultados das simulações mostrados nesse trabalho confirmam que controladores PID projetados pelo método proposto podem controlar as posições angulares do robô SCARA com precisão, sem erro de regime permanente.

O trabalho apresentado em [16] mostra uma modelagem abrangente e a identificação do modelo de um robô SCARA industrial desenvolvida para incluir a dinâmica do servo atuador. As cinemáticas direta e inversa do manipulador foram analisadas, e os autores utilizaram mecânica Lagrangiana para derivar as equações de movimento. Um controlador PD tradicional foi testado superpondo os resultados com um controlador baseado em RNA no que concerne à obtenção de um controle preciso das características de posição e movimento. Cada junta é tratada individualmente para alcançar o posicionamento ótimo do efetuador final. O modelo da RNA é treinado para atingir posicionamento preciso e minimizar os deslocamentos das juntas. São apresentados resultados de simulações mostram que o sistema de controle proposto apresenta resultados acetáveis, mas, nenhuma análise de estabilidade é apresentada.

Em [17] são apresentados os resultados de dois experimentos que demonstram que os parâmetros do controlador PD adaptativo com atrito dinâmico podem diminuir os erros em estado permanente de forma mais eficiente do que os parâmetros em um controlador PD com atrito estático.

No trabalho de Proano et al. [18], é apresentada uma abordagem geral na qual o modelo exato do robô é substituído por um modelo de ordem reduzida obtido utilizando a

abordagem *black-box* na implementação da estratégia de Controle de Modo Deslizante. O controlador projetado tem seus parâmetros sintonizados com base na utilização de uma superfície tipo PID, o que simplifica a implementação e evita o uso do modelo completo do robô. Os resultados experimentais apresentado mostram que o método de controle apresentado funciona adequadamente.

Em Orrante et al. [19], é apresentado um novo procedimento de sintonia para garantir a estabilidade exponencial semi-global para o controle PID clássico de robôs rígidos. Esse procedimento de sintonia é projetado para ser usado no domínio de tempo contínuo, e a análise de estabilidade demonstra uma convergência exponencial.

III. MODELAGEM DO ROBÔ TIPO SCARA

Uma vez que o robô será comandado por um controlador AN-PID no plano de movimento horizontal, será considerado apenas o modelo dinâmico das duas primeiras juntas (de revolução) do robô (Fig. 1).




Figura 1. Robô SCARA representado no plano X-Y.

A equação que representa o espaço de juntas para um robô com $n = 4$ graus de liberdade foi obtida em [20]. Adaptando para o caso deste trabalho, onde $n = 2$, tem-se que:

$$\mathbf{M}(\mathbf{q})\ddot{\mathbf{q}} + \mathbf{C}(\mathbf{q}, \dot{\mathbf{q}})\dot{\mathbf{q}} + \mathbf{f}(\dot{\mathbf{q}}) = \boldsymbol{\tau} \quad (1)$$

Onde:

$\mathbf{q} \in \mathcal{R}^{(2 \times 1)}$ é um vetor de coordenadas generalizadas (posições de juntas), $\mathbf{q} = [q_1, q_2]^T$;

$\mathbf{M}(\mathbf{q}) \in \mathcal{R}^{(2 \times 2)}$ é uma matriz denominada de matriz de massa do manipulador, contendo as funções de energia cinética do manipulador;

$\mathbf{C}(\mathbf{q}, \dot{\mathbf{q}}) \in \mathcal{R}^{(2 \times 2)}$ é uma matriz que representa os torques decorrentes das forças centrífuga e Coriolis;

$\mathbf{f}(\dot{\mathbf{q}}) \in \mathcal{R}^{(2 \times 1)}$ é um vetor que representa os efeitos do atrito quando o manipulador está se movendo em seu espaço de trabalho;

$\boldsymbol{\tau} \in \mathcal{R}^{(2 \times 1)}$ é o vetor de torques dos atuadores das juntas.

Os parâmetros do robô SCARA Bosch SR-800 são dados por:

$$\begin{aligned} \mathbf{M}(\mathbf{q}) &= \begin{bmatrix} 1,7277 + 0,1908\cos(q_2) & 0,0918 + 0,0954\cos(q_2) \\ 0,3340 + 0,3418\cos(q_2) & 0,918 \end{bmatrix} \\ \mathbf{C}(\mathbf{q}, \dot{\mathbf{q}}) &= \begin{bmatrix} 31,8192 - 0,0954\sin(q_2)(\dot{q}_2) & -0,0954\sin(q_2)(\dot{q}_2 + \dot{q}_1) \\ 0,3340 + 0,3418\sin(q_2)(\dot{q}_2) & 12,5783 \end{bmatrix} \\ \mathbf{f}(\dot{\mathbf{q}}) &= \begin{bmatrix} 1,0256\text{sign}(\dot{q}_2) \\ 1,7842\text{sign}(\dot{q}_2) \end{bmatrix} \end{aligned} \quad (2)$$

O modelo dinâmico não-linear de um manipulador (1), é usado para calcular as entradas de torque de controle,

$$\hat{\mathbf{M}}(\mathbf{q})\ddot{\mathbf{q}} + \hat{\mathbf{C}}(\mathbf{q}, \dot{\mathbf{q}})\dot{\mathbf{q}} + \hat{\mathbf{f}}(\dot{\mathbf{q}}) = \boldsymbol{\tau} + \boldsymbol{\delta}(\mathbf{q}) \quad (3)$$

Onde os valores de $\hat{\mathbf{M}}(\mathbf{q})\ddot{\mathbf{q}}$, $\hat{\mathbf{C}}(\mathbf{q}, \dot{\mathbf{q}})$, $\hat{\mathbf{f}}(\dot{\mathbf{q}})$ são estimativas dos parâmetros reais e $\boldsymbol{\delta}(\mathbf{q})$ são as incertezas dependentes do tempo desconhecidas. A partir de (2), $\mathbf{M}(\mathbf{q})$ é uma matriz definida positiva, e se for possível demonstrar que $\det(\mathbf{M}(\mathbf{q})) \neq 0$, então $\mathbf{M}(\mathbf{q})$ também será uma matriz inversível.

Suposição 1: O vetor função de incertezas $\boldsymbol{\delta}(\mathbf{q})$ é limitado por uma constante $\|\boldsymbol{\delta}(\mathbf{q})\| \leq \boldsymbol{\delta}_{Max}$.

Para obter um modelo dinâmico discreto no tempo foi usada uma discretização direta com $\dot{q}_i = \frac{q_i(k) - q_i(k-1)}{T_0}$ e $\ddot{q}_i = \frac{q_i(k+1) - 2q_i(k) + q_i(k-1)}{T_0^2}$, onde $T_0 = 1$ ms é o período de amostragem e k é o tempo discreto.

$$\begin{pmatrix} \mathbf{q}(k) \\ \mathbf{q}(k+1) \end{pmatrix} = - \begin{pmatrix} \mathbf{0} \\ \boldsymbol{\Psi}(k) \end{pmatrix} \hat{\mathbf{f}}(\dot{\mathbf{q}}) + \begin{pmatrix} \mathbf{0} & \mathbf{I} \\ -\boldsymbol{\alpha}(k) & -\boldsymbol{\beta}(k) \end{pmatrix} \begin{pmatrix} \mathbf{q}(k-1) \\ \mathbf{q}(k) \end{pmatrix} + \dots \quad (4)$$

$$\begin{pmatrix} \mathbf{0} \\ \boldsymbol{\Psi}(k) \end{pmatrix} \boldsymbol{\tau}(k) + \begin{pmatrix} \mathbf{0} \\ \boldsymbol{\Psi}(k) \end{pmatrix} \boldsymbol{\delta}(k)$$

Onde os parâmetros da matriz são definidos por:

$$\begin{aligned} \boldsymbol{\beta}(\mathbf{q}(k), \mathbf{q}(k-1)) &= \hat{\mathbf{M}}^{-1}(\mathbf{q})\hat{\mathbf{C}}(\mathbf{q}(k), \mathbf{q}(k-1))T_0 - 2\mathbf{I} \\ \boldsymbol{\alpha}(\mathbf{q}(k), \mathbf{q}(k-1)) &= \mathbf{I} - \hat{\mathbf{M}}^{-1}(\mathbf{q})\hat{\mathbf{C}}(\mathbf{q}(k), \mathbf{q}(k-1))T_0 \\ \boldsymbol{\Psi}(\mathbf{q}(k)) &= \hat{\mathbf{M}}^{-1}(\mathbf{q}(k))T_0^2 \end{aligned} \quad (5)$$

Rearranjando (4), obtém-se:

$$\mathbf{q}(k+1) = \mathbf{F}(\mathbf{q}(k)) + \mathbf{G}(\mathbf{q}(k))\boldsymbol{\tau}(k) + \boldsymbol{\Delta}(k) \quad (6)$$

Onde:

$$\mathbf{F}(\mathbf{q}(k)) = \boldsymbol{\Psi}(\mathbf{q}(k))\hat{\mathbf{f}}(\dot{\mathbf{q}}(k)) - \boldsymbol{\alpha}(k)\mathbf{q}(k-1) - \boldsymbol{\beta}(k)\mathbf{q}(k) \quad (7)$$

$$\begin{aligned} \mathbf{G}(\mathbf{q}(k)) &= \boldsymbol{\Psi}(\mathbf{q}(k)) \\ \boldsymbol{\Delta}(k) &= \boldsymbol{\Psi}(\mathbf{q}(k))\boldsymbol{\delta}(k) \end{aligned} \quad (8)$$

IV. IDENTIFICAÇÃO COM RNA'S DO ROBÔ TIPO SCARA BOSH SR-800

A técnica de controle apresentada neste trabalho necessita conhecer a dinâmica do robô para retropropagar o erro de controle a partir da saída para o controlador. Mas esta dinâmica é desconhecida ou variável, portanto é necessário identificar a dinâmica do processo a ser controlado.

Neste sentido, será desenvolvida uma rede RBF para identificar o modelo do robô. Também é importante demonstrar a estabilidade da rede RBF adaptativa, pois seus parâmetros neurais estão envolvidos na aprendizagem dos parâmetros do controlador. O erro de identificação do modelo é definido da seguinte forma:

$$\mathbf{q}_m(k) = \mathbf{q}(k) - \hat{\mathbf{q}}(k) = \begin{pmatrix} q_1(k) - \hat{q}_1(k) \\ q_2(k) - \hat{q}_2(k) \end{pmatrix} \quad (9)$$

O robô possui uma dinâmica não-linear, definida na eq. (6), e pode ser representada por uma RNA definida por:

$$\mathbf{q}(k+1) = \boldsymbol{\theta}_f^T \boldsymbol{\xi}(\zeta(k)) + \boldsymbol{\theta}_g^T \sum_{j=1}^2 (\boldsymbol{\xi}_j(\zeta(k))\tau_j) + \boldsymbol{\theta}_\Delta^T \boldsymbol{\chi}(v(k)) + \boldsymbol{\varepsilon} \quad (10)$$

Em (10), o índice j representa o j -ésimo vetor coluna $\boldsymbol{\xi}(\zeta(k))$ e o j -ésimo elemento de $\boldsymbol{\tau}$, e onde $\boldsymbol{\theta}_f^* \in \mathfrak{R}^{(m \times 2)}$ é o vetor de parâmetros ótimos que representa a função $\mathbf{F}(\mathbf{q}(k), \mathbf{q}(k-1))$, $\boldsymbol{\theta}_g^* \in \mathfrak{R}^{(m \times 2)}$ e $\boldsymbol{\theta}_\Delta^* \in \mathfrak{R}^{(m \times 2)}$ são vetores de parâmetros ótimos das funções $\mathbf{G}(\mathbf{q})$ e Δ da eq. (6), respectivamente. A função $\boldsymbol{\xi} \in \mathfrak{R}^{(m \times 1)}$ é uma RBF relacionada com os pesos $\boldsymbol{\theta}_f^*$ e $\boldsymbol{\theta}_g^*$; $\boldsymbol{\chi} \in \mathfrak{R}^{(m \times 1)}$ é uma RBF relacionada com o vetor de pesos $\boldsymbol{\theta}_\Delta^*$, e $\boldsymbol{\varepsilon} \in \mathfrak{R}^{(2 \times 1)}$ é o menor erro de aproximação com relação ao sistema dinâmico, onde m é o número de neurônios, sendo:

$$\begin{aligned} \boldsymbol{\varepsilon}_f(k) &= [\mathbf{F}(\mathbf{q}(k)) - \boldsymbol{\theta}_f^T \boldsymbol{\xi}(\zeta(k))] \\ \boldsymbol{\varepsilon}_g(k) &= [\mathbf{G}(\mathbf{q}(k)) - \boldsymbol{\theta}_g^T \sum_{j=1}^2 (\boldsymbol{\xi}_j(\zeta(k))\tau_j)] \\ \boldsymbol{\varepsilon}_\Delta(k) &= [\Delta(k) - \boldsymbol{\theta}_\Delta^T \boldsymbol{\chi}(v(k))] \\ \boldsymbol{\varepsilon}(k) &= \boldsymbol{\varepsilon}_f(k) + \boldsymbol{\varepsilon}_g(k) + \boldsymbol{\varepsilon}_\Delta(k) \end{aligned} \quad (11)$$

Uma vez que o vetor de parâmetros ótimos é desconhecido, é necessário estimar seus valores. Uma função de estimativa baseada em (4) é definida como:

$$\hat{\mathbf{q}}(k+1) = \hat{\boldsymbol{\theta}}_f^T \boldsymbol{\xi}(\zeta(k)) + \hat{\boldsymbol{\theta}}_g^T \sum_{j=1}^2 (\boldsymbol{\xi}_j(\zeta(k))\tau_j) + \hat{\boldsymbol{\theta}}_\Delta^T \boldsymbol{\chi}(v(k)) \quad (12)$$

A partir de (9), (10) e (11), o erro de identificação pode ser descrito por:

$$\mathbf{e}_m(k+1) = \hat{\boldsymbol{\theta}}_f^T \boldsymbol{\xi}(\zeta(k)) + \hat{\boldsymbol{\theta}}_g^T \sum_{j=1}^2 (\boldsymbol{\xi}_j(\zeta(k))\tau_j) + \hat{\boldsymbol{\theta}}_\Delta^T \boldsymbol{\chi}(v(k)) + \boldsymbol{\varepsilon} \quad (13)$$

Onde $\boldsymbol{\xi}$ e $\boldsymbol{\chi}$ são as funções de ativação de cada neurônio na camada escondida, $\hat{\boldsymbol{\theta}}_f(k) = (\boldsymbol{\theta}_f^* - \hat{\boldsymbol{\theta}}_f(k))$; $\hat{\boldsymbol{\theta}}_g(k) = (\boldsymbol{\theta}_g^* - \hat{\boldsymbol{\theta}}_g(k))$; e $\hat{\boldsymbol{\theta}}_\Delta(k) = (\boldsymbol{\theta}_\Delta^* - \hat{\boldsymbol{\theta}}_\Delta(k))$ são os erros de aproximação dos pesos do identificador neural.

$$\xi_i(\zeta(k)) = e^{-\left(\frac{\|\zeta(k) - \mathbf{c}_i\|^2}{2\sigma_i^2}\right)} \quad (14)$$

$$\chi_i(\mathbf{v}(k)) = e^{-\left(\frac{\|\mathbf{v}(k) - \mathbf{c}_i\|^2}{2\sigma_i^2}\right)} \quad (15)$$

Onde i é o i -ésimo neurônio da camada oculta, \mathbf{c}_i é a posição central do i -ésimo neurônio, e σ_i é o fator de largura (igual a um neste caso) da função gaussiana. Os vetores ζ e \mathbf{v} são regressores do modelo neural, definidos como:

$$\zeta(k) = [\hat{\mathbf{q}}(k), \hat{\mathbf{q}}(k-1), \hat{\mathbf{q}}(k-2), \boldsymbol{\tau}(k), \mathbf{q}_{ref}(k+1)] \quad (16)$$

$$\mathbf{v}(k) = [\mathbf{e}_m(k), \mathbf{e}_m(k-1), \mathbf{e}_m(k-2), \boldsymbol{\tau}(k), \mathbf{q}_{ref}(k+1)] \quad (17)$$

Suposição 2: O erro de aproximação ótimo $\boldsymbol{\varepsilon}$ é limitado por uma constante $\|\boldsymbol{\varepsilon}\| \leq \bar{\boldsymbol{\varepsilon}}$.

Suposição 3: Os torques da ação de controle $\boldsymbol{\tau}(k)$ são limitados ao valor máximo de entrada possível $\tau_i(k) \leq \tau_{iMax}$ para prevenir possíveis danos ao robô.

Suposição 4: Os vetores de erro dos pesos neurais são limitados. Então existem as constantes $\kappa_f, \kappa_g, \kappa_\Delta > 0$ que podem ser expressas como:

$$\|\hat{\boldsymbol{\theta}}_{fi}\| \leq \kappa_f \quad \|\hat{\boldsymbol{\theta}}_{gi}\| \leq \kappa_g \quad \|\hat{\boldsymbol{\theta}}_{\Delta i}\| \leq \kappa_\Delta$$

Teorema: Considerando o sistema não-linear definido pela eq. (4), o qual pode ser aproximado pela RNA definida em (12) usando uma lei de ajuste neural definida por:

$$\Delta \hat{\boldsymbol{\theta}}_{fi} = -\gamma_1 e_{mi} \boldsymbol{\xi}(\zeta(k)) \quad (18)$$

$$\Delta \hat{\boldsymbol{\theta}}_{gi} = -\gamma_2 e_{mi} \sum_{j=1}^2 (\boldsymbol{\xi}_j(\zeta(k))\tau_j) \quad (19)$$

$$\Delta \hat{\boldsymbol{\theta}}_{\Delta i} = -\gamma_3 e_{mi} \boldsymbol{\chi}(v(k)) \quad (20)$$

Prova: Definindo uma função candidata de Laypunov, com V_m sendo uma função definida positiva expressa por:

$$V_m(k) = \sum_{i=1}^2 [e_{mi}^2(k) + \gamma_1^{-1} \hat{\boldsymbol{\theta}}_{fi}^T(k-1) \hat{\boldsymbol{\theta}}_{fi}(k-1) + \gamma_2^{-1} \hat{\boldsymbol{\theta}}_{gi}^T(k-1) \hat{\boldsymbol{\theta}}_{gi}(k-1) + \gamma_3^{-1} \hat{\boldsymbol{\theta}}_{\Delta i}^T(k-1) \hat{\boldsymbol{\theta}}_{\Delta i}(k-1)] \quad (21)$$

Considerando a diferença no tempo discreto ΔV_m como:

$$\begin{aligned} \Delta V_m(k) &= \sum_{i=1}^2 [e_{mi}^2(k+1) - e_{mi}^2(k) + \gamma_1^{-1} (\hat{\boldsymbol{\theta}}_{fi}^T(k) \hat{\boldsymbol{\theta}}_{fi}(k) - \\ &\hat{\boldsymbol{\theta}}_{fi}^T(k-1) \hat{\boldsymbol{\theta}}_{fi}(k-1)) + \gamma_2^{-1} (\hat{\boldsymbol{\theta}}_{gi}^T(k) \hat{\boldsymbol{\theta}}_{gi}(k) - \hat{\boldsymbol{\theta}}_{gi}^T(k-1) \hat{\boldsymbol{\theta}}_{gi}(k-1)) + \gamma_3^{-1} (\hat{\boldsymbol{\theta}}_{\Delta i}^T(k) \hat{\boldsymbol{\theta}}_{\Delta i}(k) - \hat{\boldsymbol{\theta}}_{\Delta i}^T(k-1) \hat{\boldsymbol{\theta}}_{\Delta i}(k-1))] \end{aligned} \quad (22)$$

Definindo $\Delta \boldsymbol{\theta}_{fi}$, $\Delta \boldsymbol{\theta}_{gi}$ e $\Delta \boldsymbol{\theta}_{\Delta i}$ como:

$$\begin{aligned} \Delta \boldsymbol{\theta}_{fi} &= \gamma_1^{-1} (\hat{\boldsymbol{\theta}}_{fi}^T(k) \hat{\boldsymbol{\theta}}_{fi}(k) - \hat{\boldsymbol{\theta}}_{fi}^T(k-1) \hat{\boldsymbol{\theta}}_{fi}(k-1)) \\ \Delta \boldsymbol{\theta}_{gi} &= \gamma_2^{-1} (\hat{\boldsymbol{\theta}}_{gi}^T(k) \hat{\boldsymbol{\theta}}_{gi}(k) - \hat{\boldsymbol{\theta}}_{gi}^T(k-1) \hat{\boldsymbol{\theta}}_{gi}(k-1)) \\ \Delta \boldsymbol{\theta}_{\Delta i} &= \gamma_3^{-1} (\hat{\boldsymbol{\theta}}_{\Delta i}^T(k) \hat{\boldsymbol{\theta}}_{\Delta i}(k) - \hat{\boldsymbol{\theta}}_{\Delta i}^T(k-1) \hat{\boldsymbol{\theta}}_{\Delta i}(k-1)) \end{aligned} \quad (23)$$

Então, rearranjando (22) e considerando a diferença do erro $\Delta \mathbf{e}_m(k) = \mathbf{e}_m(k+1) - \mathbf{e}_m(k)$, obtém-se a seguinte equação:

$$\begin{aligned} \Delta V_m(k) &= \sum_{i=1}^2 [e_{mi}^2(k+1) - e_{mi}^2(k) + \Delta \boldsymbol{\theta}_{fi} + \Delta \boldsymbol{\theta}_{gi} + \Delta \boldsymbol{\theta}_{\Delta i}] = \\ &\sum_{i=1}^2 [(e_{mi}(k) + \Delta e_{mi}(k))^2 - e_{mi}^2(k) + \Delta \boldsymbol{\theta}_{fi} + \Delta \boldsymbol{\theta}_{gi} + \Delta \boldsymbol{\theta}_{\Delta i}] = \\ &\sum_{i=1}^2 [(2e_{mi}(k) \Delta e_{mi}(k) + \Delta e_{mi}^2(k)) + \Delta \boldsymbol{\theta}_{fi} + \Delta \boldsymbol{\theta}_{gi} + \Delta \boldsymbol{\theta}_{\Delta i}] \end{aligned} \quad (24)$$

Em seguida, substituindo (13) em (24), ΔV_m é escrita como:

$$\begin{aligned} \Delta V_m(k) &= \sum_{i=1}^2 \left[(2e_{mi}(k)(e_{mi}(k+1) - e_{mi}(k)) + \Delta e_{mi}^2(k)) + \Delta \boldsymbol{\theta}_{fi} + \Delta \boldsymbol{\theta}_{gi} + \Delta \boldsymbol{\theta}_{\Delta i} \right] = \sum_{i=1}^2 \left[(2e_{mi}(k) \hat{\boldsymbol{\theta}}_{fi}^T \boldsymbol{\xi}(\zeta(k)) + \right. \\ &2e_{mi}(k) \hat{\boldsymbol{\theta}}_g^T \sum_{j=1}^2 (\boldsymbol{\xi}_j(\zeta(k))\tau_j) + 2e_{mi}(k) \hat{\boldsymbol{\theta}}_\Delta^T \boldsymbol{\chi}(v(k)) + \\ &\left. 2e_{mi}(k) \boldsymbol{\varepsilon} - 2e_{mi}^2(k) + \Delta e_{mi}^2(k)) + \Delta \boldsymbol{\theta}_{fi} + \Delta \boldsymbol{\theta}_{gi} + \Delta \boldsymbol{\theta}_{\Delta i} \right] \end{aligned} \quad (25)$$

de (23), e reescrevendo $\Delta \boldsymbol{\theta}_{fi}$, obtém-se:

$$\begin{aligned} \Delta \boldsymbol{\theta}_{fi} &= \gamma_1^{-1} (\hat{\boldsymbol{\theta}}_{fi}^T(k) \hat{\boldsymbol{\theta}}_{fi}(k) - [\hat{\boldsymbol{\theta}}_{fi}(k) - \Delta \hat{\boldsymbol{\theta}}_{fi}(k)] [\hat{\boldsymbol{\theta}}_{fi}(k) - \\ &\Delta \hat{\boldsymbol{\theta}}_{fi}(k)]^T) = 2\gamma_1^{-1} (\hat{\boldsymbol{\theta}}_{fi}^T(k) \Delta \hat{\boldsymbol{\theta}}_{fi}(k)) - \gamma_1^{-1} (\Delta \hat{\boldsymbol{\theta}}_{fi}^T(k) \Delta \hat{\boldsymbol{\theta}}_{fi}(k)) \end{aligned} \quad (26)$$

Fazendo a mesma análise para $\Delta\theta_{gi}$ e $\Delta\theta_{\Delta i}$, podem ser escritas como:

$$\Delta\theta_{gi} = 2\gamma_2^{-1} \left(\tilde{\theta}_{gi}^T(k) \Delta\tilde{\theta}_{gi}(k) \right) - \gamma_2^{-1} \left(\Delta\tilde{\theta}_{gi}^T(k) \Delta\tilde{\theta}_{gi}(k) \right) \quad (27)$$

$$\Delta\theta_{\Delta i} = 2\gamma_3^{-1} \left(\tilde{\theta}_{\Delta i}^T(k) \Delta\tilde{\theta}_{\Delta i}(k) \right) - \gamma_3^{-1} \left(\Delta\tilde{\theta}_{\Delta i}^T(k) \Delta\tilde{\theta}_{\Delta i}(k) \right) \quad (28)$$

Então, (26), (27) e (28) são substituídas em (25) onde reorganizando os termos obtém-se a seguinte equação:

$$\begin{aligned} \Delta V_m(k) = & \sum_{i=1}^2 \left[-2e_{mi}^2(k) + \Delta e_{mi}^2(k) + 2e_{mi}(k)\epsilon + \right. \\ & 2\tilde{\theta}_f^T \left(e_{mi}(k) \xi(\zeta(k)) + \gamma_1^{-1} \Delta\tilde{\theta}_{fi}(k) \right) - \gamma_1^{-1} \left(\Delta\tilde{\theta}_{fi}^T(k) \Delta\tilde{\theta}_{fi}(k) \right) + \\ & 2\tilde{\theta}_g^T \left(e_{mi}(k) \sum_{j=1}^2 (\xi_j(\zeta(k)) \tau_j) + \gamma_2^{-1} \Delta\tilde{\theta}_{gi}(k) \right) - \\ & \gamma_2^{-1} \left(\Delta\tilde{\theta}_{gi}^T(k) \Delta\tilde{\theta}_{gi}(k) \right) + 2\tilde{\theta}_\chi^T \left(e_{mi}(k) \chi(v(k)) - \right. \\ & \left. \gamma_3^{-1} \Delta\tilde{\theta}_{\Delta i}(k) \right) - \gamma_3^{-1} \left(\Delta\tilde{\theta}_{\Delta i}^T(k) \Delta\tilde{\theta}_{\Delta i}(k) \right) \left. \right] \quad (29) \end{aligned}$$

Substituindo as leis de ajuste (18), (19) e (20) com $\Delta\tilde{\theta}_{fi}$, $\Delta\tilde{\theta}_{gi}$ e $\Delta\tilde{\theta}_{\Delta i}$ em (29), ΔV_m é representado por:

$$\begin{aligned} \Delta V_m(k) = & \sum_{i=1}^2 \left[-2e_{mi}^2(k) + \Delta e_{mi}^2(k) + 2e_{mi}(k)\epsilon - \right. \\ & \gamma_1^{-1} \left(\Delta\tilde{\theta}_{fi}^T(k) \Delta\tilde{\theta}_{fi}(k) \right) - \gamma_2^{-1} \left(\Delta\tilde{\theta}_{gi}^T(k) \Delta\tilde{\theta}_{gi}(k) \right) - \\ & \left. \gamma_3^{-1} \left(\Delta\tilde{\theta}_{\Delta i}^T(k) \Delta\tilde{\theta}_{\Delta i}(k) \right) \right] \quad (30) \end{aligned}$$

A maioria dos termos de (30) são negativos, com a exceção de Δe_{mi} . Este incremento do erro do modelo pode ser aproximado pela seguinte equação:

$$\begin{aligned} \Delta e_{mi}(k) = & \left(\frac{\partial e_{mi}(k+1)}{\partial \hat{\theta}_{fi}(k)} \right)^T \Delta \hat{\theta}_{fi}(k) + \left(\frac{\partial e_{mi}(k+1)}{\partial \hat{\theta}_{gi}(k)} \right)^T \Delta \hat{\theta}_{gi}(k) + \\ & \left(\frac{\partial e_{mi}(k+1)}{\partial \hat{\theta}_{\Delta i}(k)} \right)^T \Delta \hat{\theta}_{\Delta i}(k) \quad (31) \end{aligned}$$

A derivada parcial do erro do modelo depende apenas dos pesos da RNA e pode ser reescrita como:

$$\begin{aligned} \Delta e_{mi}(k) = & - \left(\frac{\partial \hat{q}_i(k+1)}{\partial \hat{\theta}_{fi}(k)} \right)^T \Delta \hat{\theta}_{fi}(k) - \left(\frac{\partial \hat{q}_i(k+1)}{\partial \hat{\theta}_{gi}(k)} \right)^T \Delta \hat{\theta}_{gi}(k) - \\ & \left(\frac{\partial \hat{q}_i(k+1)}{\partial \hat{\theta}_{\Delta i}(k)} \right)^T \Delta \hat{\theta}_{\Delta i}(k) \quad (32) \end{aligned}$$

Os valores dos pesos são modificados de acordo com as equações (18), (19) e (20); e considera-se que θ_f^* , θ_g^* e θ_{Δ}^* são vetores de pesos constantes ideais só para propósitos analíticos. Então, reorganizando $\Delta\tilde{\theta}_{fi}(k)$, obtém-se:

$$\begin{aligned} \Delta\tilde{\theta}_{fi}(k) = & \tilde{\theta}_{fi}(k) - \tilde{\theta}_{fi}(k-1) = (\hat{\theta}_{fi}(k) - \theta_f^*) - (\hat{\theta}_{fi}(k-1) - \theta_f^*) \\ \theta_f^* = & \hat{\theta}_{fi}(k) - \tilde{\theta}_{fi}(k-1) = \Delta\tilde{\theta}_{fi}(k) \quad (33) \end{aligned}$$

Fazendo a mesma análise para $\Delta\tilde{\theta}_{gi}(k)$ e $\Delta\tilde{\theta}_{\Delta i}(k)$, obtém-se:

$$\Delta\tilde{\theta}_{gi}(k) = \Delta\hat{\theta}_{gi}(k), \Delta\tilde{\theta}_{\Delta i}(k) = \Delta\hat{\theta}_{\Delta i}(k) \quad (34)$$

A eq. (32) pode ser reescrita como:

$$\begin{aligned} \Delta e_{mi}(k) = & \left(\frac{\partial \hat{q}_i(k+1)}{\partial \hat{\theta}_{fi}(k)} \right)^T \left(\gamma_1 e_{mi} \xi(\zeta(k)) \right) + \\ & \left(\frac{\partial \hat{q}_i(k+1)}{\partial \hat{\theta}_{gi}(k)} \right)^T \left(\gamma_2 e_{mi} \sum_{j=1}^2 (\xi_j(\zeta(k)) \tau_j) \right) + \\ & \left(\frac{\partial \hat{q}_i(k+1)}{\partial \hat{\theta}_{\Delta i}(k)} \right)^T \left(\gamma_3 e_{mi} \chi(v(k)) \right) \quad (35) \end{aligned}$$

Considerando os valores das derivadas parciais da RNA definida em (12) e substituindo-os em (35), obtém-se:

$$\begin{aligned} \Delta e_{mi}(k) = & \left(\gamma_1 e_{mi} \xi^T(\zeta(k)) \xi(\zeta(k)) \right) + \\ & \left(\gamma_2 e_{mi} \sum_{j=1}^2 \left(\xi^T(\zeta(k)) \xi(\zeta(k)) \right)_{ij} \tau_j^2 \right) + \\ & \left(\gamma_3 e_{mi} \chi^T(v(k)) \chi(v(k)) \right) \quad (36) \end{aligned}$$

O incremento no erro do modelo é definido como:

$$\Delta e_{mi}(k) \leq \gamma e_{mi} \quad (37)$$

onde:

$$\begin{aligned} \gamma = & \max \left(\gamma_1 \|\xi(\zeta(k))\|^2 + \gamma_2 \|\xi(\zeta(k))\|^2 \|\tau\|^2 + \gamma_3 \|\chi(v(k))\|^2 \right) \\ \gamma = & \max(\gamma_1 + \gamma_2 \tau_{max}^2 + \gamma_3) \quad (38) \end{aligned}$$

Sendo $\|\xi(\zeta(k))\|$ e $\|\chi(v(k))\| \leq 1$ funções limitadas. Os valores γ_1 , γ_2 , γ_3 , são fatores de aprendizagem da RNA ($0 < \gamma_{1,2,3} < 1$) e ser podem ser definidos arbitrariamente.

Substituindo o valor do incremento do erro do modelo na eq. (30), a diferença discreta de Lyapunov é definida como:

$$\begin{aligned} \Delta V_m(k) = & \sum_{i=1}^2 \left[-2e_{mi}^2(k)(2 - \gamma^2) + 2e_{mi}(k)\epsilon - \right. \\ & \gamma_1^{-1} \left(\Delta\tilde{\theta}_{fi}^T(k) \Delta\tilde{\theta}_{fi}(k) \right) - \gamma_2^{-1} \left(\Delta\tilde{\theta}_{gi}^T(k) \Delta\tilde{\theta}_{gi}(k) \right) - \\ & \left. \gamma_3^{-1} \left(\Delta\tilde{\theta}_{\Delta i}^T(k) \Delta\tilde{\theta}_{\Delta i}(k) \right) \right] \quad (39) \end{aligned}$$

Agora substituindo as regras de ajuste (18), (19) e (20) na eq. (39), equação pode ser escrita como:

$$\begin{aligned} \Delta V_m(k) = & \sum_{i=1}^2 \left[-2e_{mi}^2(k)(2 - \gamma^2) + 2e_{mi}(k)\epsilon - \right. \\ & \left(\gamma_1 e_{mi}^2 \xi^T(\zeta(k)) \xi(\zeta(k)) \right) - \left(\gamma_2 e_{mi}^2 \sum_{j=1}^2 \left(\xi^T(\zeta(k)) \xi(\zeta(k)) \right)_{ij} \tau_j^2 \right) - \\ & \left. \left(\gamma_3 e_{mi}^2 \chi^T(v(k)) \chi(v(k)) \right) \right] \quad (40) \end{aligned}$$

Aplicando a definição de norma na eq. (40) e considerando o valor de γ na eq. (38), a eq. (40) pode ser reescrita como:

$$\begin{aligned} \Delta V_m(k) \leq & \sum_{i=1}^2 \left[-|e_{mi}(k)|^2 (\gamma^2 - 2) + 2|e_{mi}(k)|\bar{\epsilon} - \right. \\ & \left. \left(\gamma_1 + \gamma_2 \tau_{max}^2 + \gamma_3 \right) |e_{mi}(k)| \right] = \sum_{i=1}^2 \left[-2|e_{mi}(k)|^2 (2 + \gamma^2) + \right. \\ & \left. 2|e_{mi}(k)|\bar{\epsilon} \right] \quad (41) \end{aligned}$$

Para que a eq. (41) seja convergente tem que ser menor que zero.

$$\Delta V_m(k) = \sum_{i=1}^2 \left[-2|e_{mi}(k)|^2 (2 + \gamma^2) + 2|e_{mi}(k)|\bar{\epsilon} \right] < 0 \quad (42)$$

Para tanto, se faz necessário que:

$$|e_{mi}(k)|^2 > \left(\frac{\bar{\epsilon}}{1 + \frac{y^2}{2}} \right) \quad (43)$$

A eq. (41) mostra que a identificação da dinâmica do robô é semi-globalmente uniformemente limitada (SGUUB, do inglês *semi-global uniformly ultimate boundedness*) e pode ser usada como retro propagação do erro de saída para sintonizar o controlador PID neuro-adaptativo, o qual será descrito na próxima seção.

V. O CONTROLADOR PID NEURO-ADAPTATIVO

O controlador PID neuro-adaptativo (AN-PID) recebe a diferença entre referências desejadas e posições angulares (q_1 e q_2) de saída, que são enviadas para os motores de posicionamento do robô, como mostrado na Fig. 2. Este vetor de erro de posições angulares de saída é definido como:

$$e(k) = \begin{pmatrix} e_1(k) \\ e_2(k) \end{pmatrix} \quad (44)$$

onde:

$$e_1(k) = (q_{1ref}(k+1) - q_1(k+1)) \quad e_2(k) = (q_{2ref}(k+1) - q_2(k+1))$$

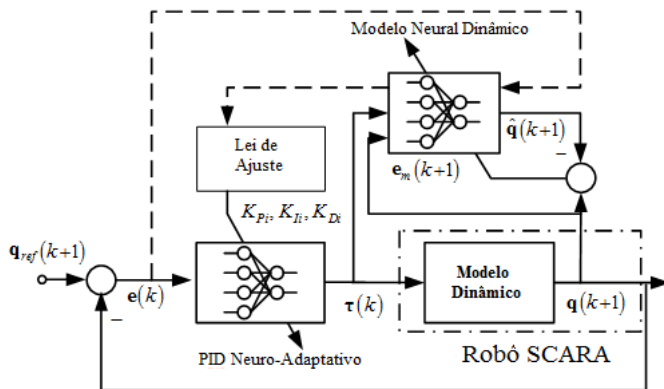


Figura 2. Arquitetura de Controle do robô SCARA.

O controlador PID clássico no tempo discreto é:

$$o_i(k) = K_{Pi}e_i(k) + K_{Ii} \sum_{j=1}^k e_i(j)T_0 + \frac{K_{Di}}{T_0}(e_i(k) - e_i(k-1)) \quad (45)$$

Onde o subíndice i indica as posições das juntas do robô SCARA.

Considerando a ação de controle no instante $(k-1)$, obtém-se:

$$o_i(k-1) = K_{Pi}e_i(k-1) + K_{Ii} \sum_{j=1}^{k-1} e_i(j)T_0 + \frac{K_{Di}}{T_0}(e_i(k-1) - e_i(k-2)) \quad (46)$$

Em seguida, tomando a diferença entre $o(k)$ e $o(k-1)$ de (45) e (46) respectivamente, o sinal $o(k)$ é dado por:

$$o_i(k) = o_i(k-1) + K_{Pi}(e_i(k) - e_i(k-1)) + K_{Ii}e_i(k)T_0 + \frac{K_{Di}}{T_0}(e_i(k) - 2e_i(k-1) + e_i(k-2)) \quad (47)$$

Para projetar o controlador PID desejado, é necessário obter uma função no momento $(k-1)$. O objetivo é conseguir um método baseado em auto-ajuste usado na teoria de redes neurais, no qual as saídas de posição angular (q_1 e q_2) do controlador PID possam acompanhar as referências desejadas.

Geralmente, a modificação dos parâmetros de um controlador PID é feita para obter um controle mais preciso. No entanto, o controlador PID clássico é limitado porque os ganhos K_{Di} , K_{Ii} , K_{Pi} são constantes. Isso significa que a saída de controle não tem propriedades adaptáveis. Um controle adaptativo inteligente deve ser usado para ajustar dinamicamente os parâmetros de controle a fim de minimizar o erro de posição angular. O controlador proposto pode resolver esses problemas, sendo os ganhos PID ajustados para minimizar o erro de posição angular sem ser afetado por não-linearidades do sistema.

Para representar um sistema baseado em um controlador PID neural é necessário definir uma função de ativação para cada ação do controlador PID. Portanto, uma função $\tanh(\cdot)$ é aplicada como uma saturação contínua, que é mostrada em (49). Assim, a saída do controlador é menor que o controle de ação máximo permitido, de acordo com a Suposição 3 da seção anterior:

$$|\tau_i| = \tau_{Max} \quad (48)$$

A principal vantagem do uso da função de ativação para cada neurônio é assegurar a estabilidade, como será comprovado na Seção VI.

Definição 1: A função de ativação $f(\cdot)$ é definida por:

$$f(o_i) = \tau_{Max} \tanh\left(\frac{o_i}{\tau_{Max}}\right) \quad (49)$$

Sendo o controlador definido em (45) expresso por:

$$o_i(k) = f(o_i(k-1)) + K_{Pi}f(e_i(k) - e_i(k-1)) + K_{Ii}f(e_i(k))T_0 + \frac{K_{Di}}{T_0}f(e_i(k) - 2e_i(k-1) + e_i(k-2)) \quad (50)$$

Onde a função de ativação de saída é uma função linear. O Controlador PID neuro-adaptativo (AN-PID) está ilustrado na Fig. 3.

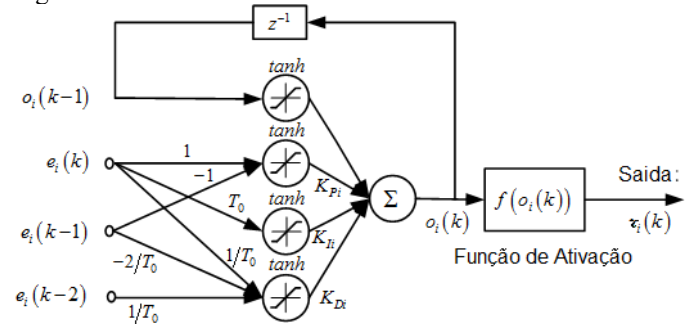


Figura 3. Arquitetura do controlador AN-PID.

A fim de assegurar a convergência e o desempenho da função de otimização, deve ser definido um índice que seja função dos erros de rastreamento de posição angular. Esse índice é definido como:

$$E(k) = \frac{1}{2} (\mathbf{e}^T(k) \mathbf{e}(k)) = \frac{1}{2} \sum_{i=1}^2 e_i^2(k) \quad (51)$$

Os ganhos K_{Di} , K_{Ii} , K_{Pi} para o controlador PID neural são ajustados usando o método gradiente descendente, semelhante aos pesos de uma RNA do tipo *perceptron*. As regras para atualizar os ganhos do controlador são:

$$\begin{pmatrix} K_{Pi}(k+1) \\ K_{Ii}(k+1) \\ K_{Di}(k+1) \end{pmatrix} = \begin{pmatrix} K_{Pi}(k) \\ K_{Ii}(k) \\ K_{Di}(k) \end{pmatrix} - \begin{pmatrix} \eta_{Pi} \partial E(k) / \partial K_{Pi} \\ \eta_{Ii} \partial E(k) / \partial K_{Ii} \\ \eta_{Di} \partial E(k) / \partial K_{Di} \end{pmatrix} \quad (52)$$

Onde os valores de $\eta_{Pi, Ii, Di}$ são fatores de aprendizado para o controlador PID neural. A partir de (52), usando a regra da cadeia, obtém-se as seguintes expressões:

$$\begin{aligned} \frac{\partial E(k)}{\partial K_{Pi}} &= \frac{\partial E(k)}{\partial q_i(k+1)} \frac{\partial q_i(k+1)}{\partial \tau_i(k)} \frac{\partial \tau_i(k)}{\partial o_i(k)} \frac{\partial o_i(k)}{\partial K_{Pi}} \\ \frac{\partial E(k)}{\partial K_{Ii}} &= \frac{\partial E(k)}{\partial q_i(k+1)} \frac{\partial q_i(k+1)}{\partial \tau_i(k)} \frac{\partial \tau_i(k)}{\partial o_i(k)} \frac{\partial o_i(k)}{\partial K_{Ii}} \\ \frac{\partial E(k)}{\partial K_{Di}} &= \frac{\partial E(k)}{\partial q_i(k+1)} \frac{\partial q_i(k+1)}{\partial \tau_i(k)} \frac{\partial \tau_i(k)}{\partial o_i(k)} \frac{\partial o_i(k)}{\partial K_{Di}} \end{aligned} \quad (53)$$

Os valores das derivadas parciais da regra da cadeia são:

$$\frac{\partial E(k)}{\partial q_i(k+1)} = -e_i(k) \quad (54)$$

Para $\partial q_i / \partial \tau_i$ a dinâmica é desconhecida e deve ser aproximada pela dinâmica identificada pela RNA definida em (12), obtendo $\partial \hat{q}_i / \partial \tau_i$.

$$\begin{aligned} \frac{\partial \hat{q}_i(k+1)}{\partial \tau_i(k)} &= \hat{\boldsymbol{\theta}}_{fi}^T \boldsymbol{\xi}(\zeta(k)) \left[(\zeta(k) - c_i) \frac{\partial \zeta^T(k)}{\partial \tau_i} \right] + \\ &\hat{\boldsymbol{\theta}}_{gi}^T \sum_{j=1}^2 (\boldsymbol{\xi}_j(\zeta(k)) \tau_j) \left[(\zeta(k) - c_i) \frac{\partial \zeta^T(k)}{\partial \tau_i} \right] + \\ &\hat{\boldsymbol{\theta}}_{gi}^T \sum_{j=1}^2 (\boldsymbol{\xi}_j(\zeta(k)) \tau_j) \frac{\partial \tau_i(k)}{\partial \tau_i} + \hat{\boldsymbol{\theta}}_{\Delta i}^T \boldsymbol{\chi}(v(k)) \left[(v(k) - c_i) \frac{\partial v^T(k)}{\partial \tau_i} \right] \end{aligned} \quad (55)$$

De (16) e (17), $\partial \zeta_i^T / \partial \tau_i$ e $\partial v_i^T / \partial \tau_i$ são $[0, 0, 0, 1, 0]^T$ e $[0, 0, 0, 1, 0]^T$, respectivamente. Como $q(k-2)$, $q(k-1)$, $q(k)$ e $q_{ref}(k)$ não são dependentes de $\tau(k)$, da mesma forma, $e(k-2)$, $e(k-1)$, $e(k)$ e $q_{ref}(k)$ também não são dependentes de $\tau(k)$.

A relação $\partial \tau_i / \partial o_i$ é a derivada da função de ativação $\tanh(\cdot)$. Esta derivada parcial só é válida dentro da zona linear da função, na qual a ação de controle não alcança valores que possam causar danos ou quebra da dinâmica do robô. Essa operação é calculada por:

$$\frac{\partial \tau_i(k)}{\partial o_i(k)} = \frac{\partial f(o_i(k))}{\partial o_i(k)} = \tau_{Max} \left[1 - \frac{f^2(o_i(k))}{\tau_{Max}^2} \right] \quad (56)$$

Considerando agora as derivadas parciais em relação aos ganhos do controlador, definidas como:

$$\begin{cases} \frac{\partial(o_i(k))}{\partial K_{Pi}} = f(e_i(k) - e_i(k-1)) \\ \frac{\partial(o_i(k))}{\partial K_{Ii}} = f(e_i(k)) \\ \frac{\partial(o_i(k))}{\partial K_{Di}} = f(e_i(k) - 2e_i(k-1) + e_i(k-2)) \end{cases} \quad (57)$$

Em seguida, as expressões obtidas de (52) são descritas como se segue:

$$\begin{aligned} K_{Pi}(k+1) &= K_{Pi}(k) - \eta_{Pi} e_i(k) \left(\frac{\partial \hat{q}_i(k+1)}{\partial \tau_i(k)} \right) \tau_{Max} \left[1 - \frac{f^2(o_i(k))}{\tau_{Max}^2} \right] \\ &\quad f(e_i(k) - e_i(k-1)) \\ K_{Ii}(k+1) &= K_{Ii}(k) - \eta_{Ii} e_i(k) \left(\frac{\partial \hat{q}_i(k+1)}{\partial \tau_i(k)} \right) \tau_{Max} \left[1 - \frac{f^2(o_i(k))}{\tau_{Max}^2} \right] \\ &\quad f(e_i(k)) \\ K_{Di}(k+1) &= K_{Di}(k) - \eta_{Di} e_i(k) \left(\frac{\partial \hat{q}_i(k+1)}{\partial \tau_i(k)} \right) \tau_{Max} \left[1 - \frac{f^2(o_i(k))}{\tau_{Max}^2} \right] \\ &\quad f(e_i(k) - 2e_i(k-1) + e_i(k-2)) \end{aligned} \quad (58)$$

A análise de estabilidade para esta técnica de controle é apresentada na próxima seção.

VI. CONVERGÊNCIA E ESTABILIDADE DO CONTROLADOR

Nesta seção será realizada a análise de estabilidade do novo Controlador PID neuro-adaptativo (AN-PID). Para tanto, é necessário iniciar fazendo a seguinte suposição:

Suposição 6: Definindo os parâmetros constantes ideais do controlador AN-PID como \mathbf{K}_θ^* , então o erro de estimação pode ser definido como:

$$\tilde{\mathbf{K}}_{\theta i}(k) = \mathbf{K}_{\theta i}(k) - \mathbf{K}_{\theta i}^* \quad (59)$$

Onde Ω_K e Ω_q são conjuntos compactos de limites adequados em $\mathbf{K}_{\theta i}(k)$ e \mathbf{q} , respectivamente, definidos como $\Omega_K = \{\|\tilde{\mathbf{K}}_{\theta i}\| \leq K_{max}\}$ e $\Omega_q = \{\|\mathbf{q}\| \leq Q\}$ onde K_{max} e Q são constantes positivas. Supõe-se que dentro do conjunto compacto Ω_q o erro de aproximação do controlador AN-PID é muito pequeno quando o vetor de parâmetros $\mathbf{K}_{\theta i}(k)$ é igual a algum vetor de parâmetros ótimo denotado por \mathbf{K}_{θ}^* .

Lema 1: a diferença do erro $\Delta e(k)$ no processo de aprendizagem é expressa por:

$$\Delta e_i(k) = \left(\frac{\partial e_i(k)}{\partial \mathbf{K}_{\theta i}} \right)^T \Delta \mathbf{K}_{\theta i}(k) = \frac{\partial e_i(k)}{\partial q_i(k+1)} \left(\frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta i}} \right)^T \Delta \mathbf{K}_{\theta i}(k) \quad (60)$$

Considerando as equações (53) e (54) e tomando $\bar{\eta} = \max(\eta_{Pi}, \eta_{Di}, \eta_{Ii})$:

$$\Delta \mathbf{K}_{\theta i}(k) = \bar{\eta} \frac{\partial e_i(k)}{\partial q_i(k+1)} \left(\frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta i}} \right) = -\bar{\eta} e_i(k) \left(\frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta i}} \right) \quad (61)$$

Substituindo (61) em (60):

$$\begin{aligned} \Delta e_i(k) &= \frac{\partial e_i(k)}{\partial q_i(k+1)} \left(\frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta i}} \right)^T \left(-\bar{\eta} e_i(k) \left(\frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta i}} \right) \right) \\ \Delta e_i(k) &\leq -\alpha_i e_i(k) \end{aligned} \quad (62)$$

Onde:

$$\left\| \frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \right\| = \left| \frac{\partial q_i(k+1)}{\partial \tau_i} \right| \left\| \frac{\partial \tau_i}{\partial \mathbf{o}_i} \right\| \left\| \frac{\partial \mathbf{o}_i}{\partial \mathbf{K}_{\theta_i}} \right\| \quad (63)$$

Conforme mostrado na Seção IV, a dinâmica desconhecida ($\partial q_i / \partial \tau_i$) foi identificada e pode ser aproximada por ($\partial \hat{q}_i / \partial \tau_i$), cuja estabilidade foi demonstrada em (41), portanto a norma de diferenças de ($\zeta(k) - \mathbf{c}_i$) e ($v(k) - \mathbf{c}_i$) são delimitadas por constantes positivas κ_1 e κ_2 respectivamente e as funções RBF $\xi(\zeta(k))$ e $\chi(v(k))$ também são limitadas (≤ 1). Além disso, considerando a Suposição 4, a norma da eq. (55) pode ser representada por:

$$\left| \frac{\partial q_i(k+1)}{\partial \tau_i(k)} \right| \approx \left| \frac{\partial \hat{q}_i(k+1)}{\partial \tau_i(k)} \right| \leq \bar{\theta}_f + \bar{\theta}_g |\tau_{Max}| \kappa_1 + \bar{\theta}_g + \bar{\theta}_\Delta \kappa_2 = \bar{\theta} \quad (64)$$

Considerando:

$$\begin{aligned} \left| \frac{\partial \tau_i}{\partial \mathbf{o}_i} \right| &= |f(\mathbf{o}_i)| = \tau_{Max} \left[1 - \frac{f^2(\mathbf{o}_i(k))}{\tau_{Max}^2} \right] \leq \tau_{Max} \\ \left\| \frac{\partial \mathbf{o}_i}{\partial \mathbf{K}_{\theta_i}} \right\| &= f(e_i(k)) + f(e_i(k) - e_i(k-1)) + \dots \\ &f(e_i(k) - 2e_i(k-1) + e_i(k-2)) \end{aligned} \quad (65)$$

E substituindo os valores de (64) e (65) na (63), sendo limitada pela constante:

$$\left\| \frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \right\| = \left| \frac{\partial q_i(k+1)}{\partial \tau_i} \right| \left\| \frac{\partial \tau_i}{\partial \mathbf{o}_i} \right\| \left\| \frac{\partial \mathbf{o}_i}{\partial \mathbf{K}_{\theta_i}} \right\| \leq 3\bar{\theta} \tau_{Max}^2 \quad (66)$$

$$\left| \frac{\partial e_i(k)}{\partial q_i(k+1)} \right| = 1 \quad (67)$$

Definindo α_i como:

$$\alpha_i \leq \max \left(\bar{\eta} \left| \frac{\partial e_i(k)}{\partial q_i(k+1)} \right| \left\| \frac{\partial \hat{q}_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \right\| \right) = 9\bar{\theta}^2 \tau_{Max}^4$$

Onde a eq. (62) pode ser reescrita como:

$$\Delta e_i(k) \leq -\alpha_i e_i(k) \quad (68)$$

Para a análise de estabilidade é preciso definir uma função candidata de Lyapunov que seja definida positiva no domínio de tempo discreto. Assim, considerando:

$$V(k) = \frac{1}{2} \sum_{i=1}^2 \left(e_i^2(k) + \tilde{\mathbf{K}}_{\theta_i}^T(k) \tilde{\mathbf{K}}_{\theta_i}(k) \right) \quad (69)$$

A diferença discreta da função candidata é calculada por:

$$\Delta V(k) = V(k+1) - V(k) = \frac{1}{2} \sum_{i=1}^2 \left(e_i^2(k+1) - e_i^2(k) + \tilde{\mathbf{K}}_{\theta_i}^T(k+1) \tilde{\mathbf{K}}_{\theta_i}(k+1) - \tilde{\mathbf{K}}_{\theta_i}^T(k) \tilde{\mathbf{K}}_{\theta_i}(k) \right) \quad (70)$$

A partir de (52) pode ser definido o produto entre $\mathbf{K}_{\theta_i}^T$ e \mathbf{K}_{θ_i} :

$$\begin{aligned} \tilde{\mathbf{K}}_{\theta_i}^T(k+1) \tilde{\mathbf{K}}_{\theta_i}(k+1) &= \left(\tilde{\mathbf{K}}_{\theta_i}(k) - \bar{\eta} e_i(k) \left(\frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \right)^T \right) \\ &\left(\tilde{\mathbf{K}}_{\theta_i}(k) - \bar{\eta} e_i(k) \left(\frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \right) \right) \\ \tilde{\mathbf{K}}_{\theta_i}^T(k+1) \tilde{\mathbf{K}}_{\theta_i}(k+1) - \tilde{\mathbf{K}}_{\theta_i}^T(k) \tilde{\mathbf{K}}_{\theta_i}(k) &= \\ -2\bar{\eta} e_i(k) \tilde{\mathbf{K}}_{\theta_i}^T(k) \frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} + e_i^2(k) \bar{\eta}^2 \left(\frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \right)^T \frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \end{aligned} \quad (71)$$

O valor de $e(k+1)$ pode ser obtido através da seguinte expressão:

$$e_i(k+1) = e_i(k) + \Delta e_i(k) \quad (72)$$

Substituindo (72) em $e^2(k+1)$ e calculando a diferença quadrática,

$$e_i^2(k+1) - e_i^2(k) = 2e_i(k) \Delta e_i(k) + \Delta e_i^2(k) \quad (73)$$

Onde:

$$\begin{aligned} \Delta V_i(k) &= V_i(k+1) - V_i(k) = 2e_i(k) \Delta e_i(k) + \\ \Delta e_i^2(k) - 2\bar{\eta} e_i(k) \tilde{\mathbf{K}}_{\theta_i}^T(k) \frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} + \\ e_i^2(k) \bar{\eta}^2 \left(\frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \right)^T \frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \end{aligned} \quad (74)$$

A partir do **Lema 1**, a eq. (74) pode ser reescrita como:

$$\begin{aligned} \Delta V_i(k) &= -2\alpha_i(k) e_i^2(k) + \alpha_i^2 e_i^2(k) - \\ 2\bar{\eta} e_i(k) \tilde{\mathbf{K}}_{\theta_i}^T(k) \frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} - e_i^2(k) \bar{\eta}^2 \left(\frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \right)^T \frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \end{aligned} \quad (75)$$

Aplicando a definição de norma na (75):

$$\begin{aligned} \Delta V_i(k) &\leq -2\alpha_i(k) |e_i(k)|^2 + \alpha_i^2 |e_i(k)|^2 - \\ 2\bar{\eta} |e_i(k)| \|\tilde{\mathbf{K}}_{\theta_i}(k)\| \left\| \frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \right\| - \bar{\eta}^2 |e_i(k)|^2 \left\| \frac{\partial q_i(k+1)}{\partial \mathbf{K}_{\theta_i}} \right\| \end{aligned} \quad (76)$$

E substituindo os valores de (66) em (76):

$$\begin{aligned} \Delta V_i(k) &\leq -2\alpha_i |e_i(k)|^2 + \alpha_i^2 |e_i(k)|^2 - \\ 6\bar{\eta} |e_i(k)| K_{Max} \bar{\theta} \tau_{Max}^2 - 9\bar{\eta}^2 |e_i(k)|^2 \bar{\theta}^2 \tau_{Max}^4 \end{aligned} \quad (77)$$

De (77), obtém-se:

$$\Delta V_i(k) \leq 0 \quad |e_i(k)| > \frac{6\bar{\eta} K_{Max} \bar{\theta} \tau_{Max}^2}{2\alpha_i - \alpha_i^2 + 9\bar{\eta}^2 \bar{\theta}^2 \tau_{Max}^4} \quad (78)$$

A partir de (78) obtém-se o limite de $V(k)$ que fixa o valor uniformemente finalmente limitado de $e_i(k)$. Os erros de (78) permitem estabelecer que os erros são delimitados pelo erro de aproximação do controlador AN-PID. Assim, verifica-se que o controlador proposto possui uma estabilidade SQUUB.

VII. RESULTADOS EXPERIMENTAIS E DISCUSSÃO

Nesta seção será descrito o robô industrial utilizado para testar

o controlador AN-PID proposto nas Seções III e IV. Para este fim, será utilizado um robô SCARA Bosch SR-800 (Fig. 4). O robô manipulador que será usado é controlado através de uma CPU Intel Dual Core, funcionando em uma frequência de 2,6 GHz com 4 GB de memória RAM e que utiliza sistema operacional Linux Debian e RTAI (*Real Time Application Interface*). A abordagem proposta neste trabalho é aplicada ao manipulador robótico pelo controle da unidade de potência, que aplica os torques calculados (ações de controle) às juntas do robô. Para fins de comparação de desempenho, além de utilizar o AN-PID aqui proposto para controlar do manipulador robótico, também foi aplicado um controlador PID tradicional ao mesmo robô.



Figura 4. Robô SCARA Bosch SR-800.

O controlador AN-PID foi iniciado com ganhos aleatórios e ajustado usando diferentes trajetórias. No experimento apresentado neste trabalho, os valores dos ganhos são ajustados *on-line* pelo algoritmo de aprendizado, avaliando sua evolução em função do tempo.

A trajetória de referência utilizada para testar os dois controladores tem a forma de um “8”. Na Fig. 5, são mostradas as ações de controle do controlador AN-PID. Além disso, a evolução dos ganhos de sintonização do controlador AN-PID é mostrada na Fig. 6.

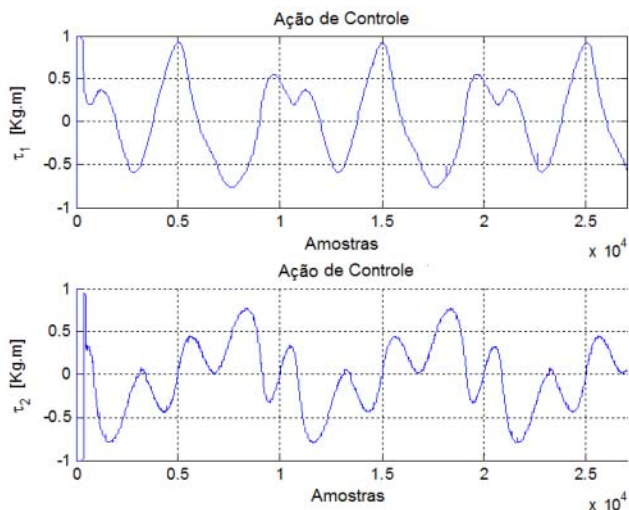


Figura 5. Ações de controle do controlador AN-PID.




Figura 6. Evolução dos ganhos do controlador AN-PID.

Na Fig. 7 são apresentados os sinais de referência da posição das juntas e a posição instantânea real das juntas do robô SCARA. As trajetórias desenhadas pelo robô SCARA usando cada um dos controladores são apresentadas na Fig. 8.

Na Fig. 9 é mostrada a norma quadrática dos erros de controle de ambos controladores. O maior erro foi obtido pelo controlador PID tradicional, que não tem qualquer adaptação *on-line*. Neste caso, o efeito das incertezas sobre o erro é claramente observado. Por outro lado, o menor erro foi obtido pelo controlador AN-PID aqui proposto, que diminui o erro causado pela estrutura não-modelada e por perturbações.




Figura 7. Valores de referência das posições das juntas e posições reais das juntas do robô SCARA.

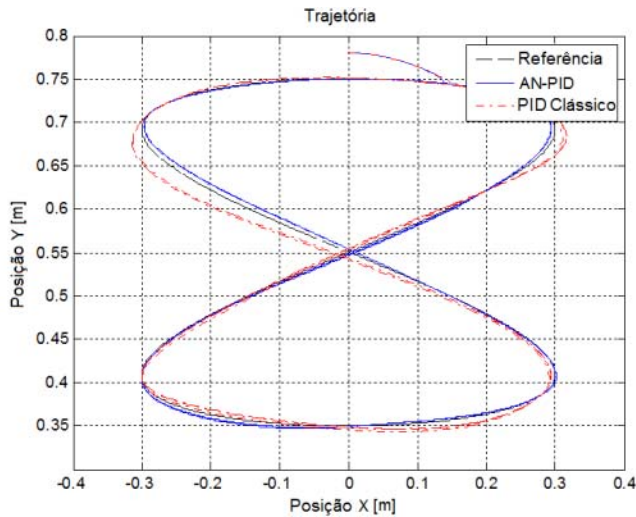


Figura 8. Trajetória seguida pelo robô usando o controlador AN-PID e usando o controlador PID tradicional.

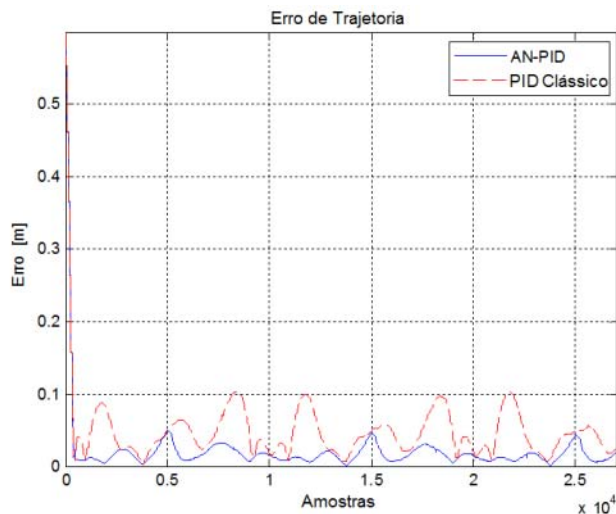


Figura 9. Erro quadrático da trajetória do robô. Robô com AN-PID e robô com PID estático tradicional.

Na Fig. 10, é feita uma comparação das posições angulares de saída entre a rede identificada pelo modelo neural dinâmico e a dinâmica real do robô SCARA. A análise da Fig. 10 evidencia que o modelo neural dinâmico identificado consiste em uma boa aproximação para a dinâmica real do robô.

O controlador AN-PID foi projetado para ser robusto em relação a erros de modelagem. A análise dos resultados obtidos mostra que de fato o controlador AN-PID é eficaz em rejeitar o efeito de distúrbios externos e não produz erros constantes causados por incertezas dos parâmetros. Porém, o controlador PID tradicional é vulnerável a mudanças no modelo dinâmico e incertezas, pois o mesmo foi projetado considerando um modelo linearizado da dinâmica do robô.

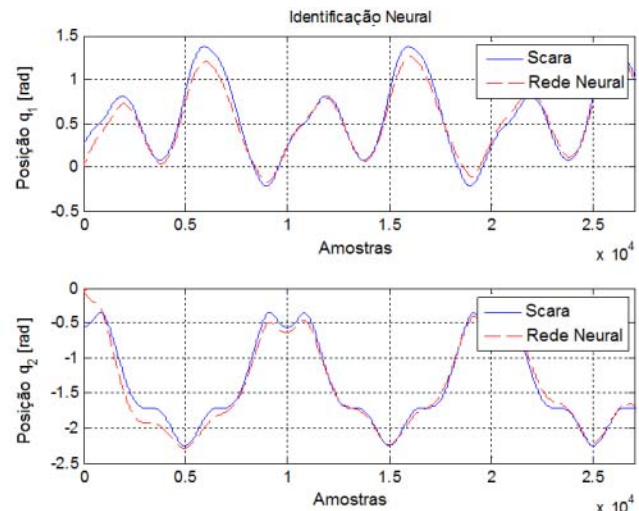


Figura 10. Comportamento do modelo dinâmico identificado do robô SCARA em comparação com a dinâmica real do robô.

A lei de controle aqui apresentada para não requer conhecimento acerca do modelo dinâmico do braço robótico. No entanto, sabe-se que a representação matemática de um modelo dinâmico não descreve com precisão o comportamento real. Os bons resultados obtidos, apesar destas não-linearidades e incertezas do modelo, juntamente com variações na dinâmica do robô, mostram o quão robusto é o controlador AN-PID proposto. Além disso, a estabilidade do sistema em malha fechada foi demonstrada analiticamente através da teoria da estabilidade discreta de Lyapunov.

A proposta de controle inteligente apresentada neste trabalho pode ser considerada como sendo uma solução geral para o controle de sistemas não-lineares, sobretudo para o caso de sistemas robóticos, quando a dinâmica é variável ou quando existem incertezas associadas ao modelo.

Este é um campo de pesquisa aberto para as questões de modelagem, estabilidade matemática, convergência e análise de robustez de sistemas de controle, e as pesquisas precisam continuar a avançar para projetar controladores cada vez mais precisos e eficientes.

VIII. CONCLUSÕES

O controlador PID neuro-adaptativo MIMO (AN-PID) proposto neste trabalho resolve o problema de ajuste dos ganhos proporcional, integral e derivativo dos controladores baseados na técnica PID. A técnica proposta pode atingir as propriedades dos controladores PID industriais sem a necessidade de ajuste *off-line* através das técnicas clássicas. O controlador proposto demonstrou que possui uma estabilidade semi-globalmente uniformemente limitada (SGUUB) e por ser projetado diretamente no tempo discreto, evita os problemas decorrentes da discretização de controladores inicialmente projetados no tempo contínuo.

Para retropropagar o erro, uma RNA (sintonizada *on-line*) foi usada para ajustar os ganhos do controlador. Devido à capacidade adaptável do controlador, ele é capaz de se ajustar a variações na dinâmica do robô.

Neste trabalho, o controlador AN-PID proposto foi aplicado num robô manipulador SCARA com dois graus de liberdade. Também foi utilizado um controlador PID

tradicional para controlar o mesmo robô, para fins de comparação com a abordagem proposta. Os resultados obtidos experimentalmente demonstraram o bom desempenho do controlador AN-PID, claramente superior ao desempenho do controlador PID tradicional, e evidenciaram a sua capacidade de adaptação às não-linearidades do robô SCARA, incertezas do modelo e perturbações.

Finalmente, a lei de controle proposta e a identificação do modelo pela RNA podem ser aplicadas em qualquer sistema com dinâmica desconhecida ou não-linearidades.

REFERÊNCIAS

- [1] Wei Lu and Jian Yang and Xiao Liu, "The PID Controller Based on the Artificial Neural Network and the Differential Evolution Algorithm", *Journal of Computers*, Academy Publisher, Vol. 7, N° 10, pp. 931-944, 2012.
- [2] Ching-hung Lee, "A Survey of PID Controller Design Based on Gain and Phase Margins", *International Journal of Computational Cognition*, Yang's Scientific Research Inst., Vol. 2, N° 10, pp. 200-204, 2004.
- [3] Indranil Pan, Saptarshi Das, Amitava Gupta, "Tuning of an optimal fuzzy PID controller with stochastic algorithms for networked control systems with random time delay", *ISA Transactions*, Elsevier, Vol. 50, N° 1, pp. 28 - 36, 2011.
- [4] Lluís Pacheco and Ningsu Luo, "Testing PID and MPC Performance for Mobile Robot Local Path-following", *International Journal of Advanced Robotic Systems*, v. 12, n. 11, p. 155, 2015.
- [5] M. A. Saldaña-O., L.E. Ramos-V., J. P. Ordaz-O, A. Garcia-Barrientos, I. Algreto-Badillo, Jean-Francois Balmat, and Frédéric Lafont. "A comparative study of the wavenet PID controllers for applications in non-linear systems", *Electrical Engineering, Computing Science and Automatic Control (CCE)*, pp. 1 - 6, 2015.
- [6] Rossomando, F.G. and Soria, C.M., "Design and Implementation of Adaptive Neural PID for Non Linear Dynamics in Mobile Robots", *Latin America Transactions, IEEE (Revista IEEE America Latina)*, Vol. 13, N° 4, pp. 913-918, 2015.
- [7] Rossomando, F.G. and Soria, C.M., "Identification and control of nonlinear dynamics of a mobile robot in discrete time using an adaptive technique based on neural PID", *Neural Computing and Applications*, Springer Netherlands, Vol. 26, N° 5, pp. 1179 - 1191, 2014.
- [8] T.H. Lee and P.K. Yue and K.K. Tan, "A neural-network-based model reference PID-like controller for process control", *Engineering Applications of Artificial Intelligence*, Elsevier, Vol. 7, N° 6, pp. 677 - 684, 1994.
- [9] Wei-Der Chang and Rey-Chue Hwang and Jer-Guang Hsieh, "A multivariable on-line adaptive PID controller using auto-tuning neurons", *Engineering Applications of Artificial Intelligence*, Elsevier, Vol. 16, N° 1, pp. 57 - 63, 2003.
- [10] Güzelkaya M., I. Eksin and E. Yesil, "Self-tuning of PID-type fuzzy logic controller coefficients via relative rate observer", *Engineering Applications of Artificial Intelligence*, Elsevier, Vol. 16, N° 3, pp. 227 - 237, 2003.
- [11] Yuxin Su and Müller, P.C. and Chunhong Zheng, "Global Asymptotic Saturated PID Control for Robot Manipulators", *Control Systems Technology*, Vol. 18, N° 6, pp. 1280-1288, 2010.
- [12] Xingjian Jing and Li Cheng, "An Optimal PID Control Algorithm for Training Feedforward Neural Networks", *Industrial Electronics, IEEE Transactions on, IEEE*, Vol. 60, N° 6, pp. 2273-2283, 2013.
- [13] Wen Yu and Rosen, J., "Neural PID Control of Robot Manipulators with Application to an Upper Limb Exoskeleton", *Cybernetics, IEEE Transactions on*, Vol. 43, N° 2, pp. 673-684, 2013.
- [14] Benjanarasuth, T. and Sowannee, N. and Naksuk, N., "Two-degree-of-freedom simple servo adaptive control for SCARA robot", *Control Automation and Systems (ICCAS)*, 2010 International Conference on, pp. 480-484, 2010.
- [15] Suvilath, S. and Khongsomboun, K. and Benjanarasuth, T. and Kominet, N., "IMC-based PID controllers design for a two-links SCARA robot", *TENCON 2011 - 2011 IEEE Region 10 Conference*, pp. 1030-1034, 2015.
- [16] Al-Khedher, M.A. and Alshamasin, M.S., "SCARA robot control using neural networks", *Intelligent and Advanced Systems (ICIAS)*, 2012 4th International Conference on, Vol.1, pp. 126-130, 2012.

- [17] Thanok, S., "Design of an adaptive PD controller with dynamic friction compensation for direct-drive SCARA robot", *Electrical Engineering Congress (IEECON)*, 2014 International, pp. 1-4, 2014.
- [18] P. Proaño and L. Capito and A. Rosales and O. Camacho, "Sliding Mode Control: Implementation Like PID for Trajectory-Tracking for Mobile Robots", *Computer Aided System Engineering (APCASE)*, 2015 Asia-Pacific Conference on, pp. 220-225, 2015.
- [19] Jorge Orrante-Sakanassi, Victor M. Hernandez Guzman and Victor Santibanez. "New tuning conditions for semiglobal exponential stability of the classical PID regulator for rigid robots." *International Journal of Advanced Robotic Systems*, v. 12, n. 10, p. 143, 2015.
- [20] Claudio Urrea and John Kern. "Modeling, simulation and control of a redundant SCARA-type manipulator robot." *International Journal of Advanced Robotic Systems*, v. 9, n. 2, p. 58, 2012.



Eduardo Oliveira Freire tem doutorado em engenharia elétrica pela Universidade Federal do Espírito Santo, Brasil. Atualmente é professor associado do Departamento de Engenharia Elétrica da Universidade Federal de Sergipe (UFS), Brasil, onde é coordenador do Programa de Pós-Graduação em Engenharia Elétrica.



Francisco G. Rossomando trabalhou entre 2002 e 2006 no seu doutorado na Universidade Federal do Espírito Santo, Brasil. Atualmente é pesquisador do Conselho Nacional para Pesquisa Científica e Técnica da Argentina (CONICET), no Instituto de Automática (INAUT) da Universidade Nacional de San Juan (UNSJ), Argentina.



Carlos M. Soria é graduado em engenharia elétrica pela Universidade Nacional de Tucuman, Argentina, em 1996. Em Março de 2005 obteve seu doutorado em Engenharia de Sistemas de Controle no Instituto de Automática (INAUT) da Universidade Nacional de San Juan (UNSJ).