

IMPLEMENTAÇÃO DA TÉCNICA DE CONTROLE NEURAL ADAPTATIVO HÍBRIDO INDIRETO NUMA MALHA DE VAZÃO DAS PLANTAS DE REGENERAÇÃO DE ÁCIDO CLORÍDRICO DA USIMINAS¹

*Ricardo Feichas Santos²
Marcelo Vieira Corrêa³
Roselito de Albuquerque Teixeira³*

Resumo

Este trabalho apresenta a implementação do Controlador Neural Adaptativo Híbrido Indireto como opção ao controlador PID convencional em processos onde o procedimento de sintonia e re-sintonia são críticos. Em muitos casos a implementação de controladores PID resolve os problemas, no entanto, esta solução necessita de constante acompanhamento para a manutenção do desempenho do controlador, o que nem sempre ocorre. A busca por alternativas de controle menos dependentes de sintonias pode exercer importante papel em malhas de controle industrial. Esta estratégia foi avaliada em uma malha de controle de vazão das plantas de regeneração de ácido clorídrico da Usiminas, em Ipatinga. A implementação do novo esquema de controle otimizou o desempenho da malha propiciando independência de novos ajustes, redução do tempo de subida e redução da variabilidade em regime permanente.

Palavras-chave: Controle neural; Controle adaptativo; Regeneração de ácido clorídrico.

IMPLEMENTATION OF THE NEURAL ADAPTIVE HYBRID INDIRECT CONTROL TECHNIQUE IN A FLOW CONTROL LOOP OF THE HYDROCHLORIC ACID REGENERATION PLANT OF USIMINAS

Abstract

This paper presents the implementation of the Neural Adaptive Hybrid Indirect Controller as an option to the conventional PID in cases where the procedure of tuning and re-tuning are critical. In many cases the implementation of PID controllers solve the problems, however, this solution requires constant monitoring to maintain the controller performance, which does not occur. The search for alternatives less dependents on tunings may have an important role in industrial control loops. This strategy was evaluated in a flow control loop of the hydrochloric acid regeneration plant of Usiminas, Ipatinga. The implementation of the new control scheme optimized the performance of the control loop and provided independence of new arrangements, reducing the rise time and variability in the steady state.

Key words: Neural control; Adaptive control; Hydrochloric acid regeneration.

¹ *Contribuição técnica ao 14º Seminário de Automação de Processos, 6 a 8 de outubro de 2010, Belo Horizonte, MG.*

² *Analista de Automação, Gerência de Automação da Usiminas, Ipatinga, MG.*

³ *Professor Dr., Programa de Pós-Graduação em Engenharia, Unileste, Coronel Fabriciano, MG*

1 INTRODUÇÃO

Este trabalho apresenta um estudo da utilização de redes neurais na implementação de uma estratégia de controle adaptativo e foi baseado nos artigos de Maitelli e Gabriel Filho.^(1,2) O primeiro artigo apresenta as informações básicas para a implementação da técnica denominada Controle Neural Adaptativo Híbrido Indireto. O segundo apresenta um estudo de estabilidade e robustez da técnica. Este é um assunto que, apesar do crescente volume de trabalhos publicados ultimamente, conforme citado por Widrow e Walach,⁽³⁾ ainda não se vê muitas aplicações na indústria brasileira. Este fato já era esperado visto que nem a aplicação de redes neurais estáticas tem tantas implementações, apesar do crescimento de sua utilização nos últimos anos, como em Ribeiro⁽⁴⁾ e Takahashi.⁽⁵⁾ A técnica de controle proposta por Maitelli⁽¹⁾ é uma alternativa para processos onde a sintonia e re-sintonia de malhas se torna um procedimento crítico. Visando sua implementação em processos com esta característica, o objetivo deste estudo foi avaliar o funcionamento desta num sistema industrial real: uma malha de controle de vazão de uma das plantas de regeneração de ácido clorídrico da Usiminas, em Ipatinga. Como o objetivo foi apenas avaliar o funcionamento do esquema de controle, a escolha desta malha se deu por esta pertencer a um sistema com pequeno risco operacional e por possuir um sistema de automação moderno que possibilita o fácil acesso à leitura e à escrita das variáveis do processo.

Para a estratégia de controle estudada foram encontrados registros de sua implementação apenas em sistemas simulados e em plantas piloto. Desta forma, a principal contribuição deste trabalho foi sua implementação em uma planta industrial real.

2 MATERIAL E MÉTODOS

2.1 O Esquema de Controle

Pode-se observar na Figura 1 o diagrama esquemático do controlador neural proposto por Maitelli e tem construção similar ao que foi proposto por Adetona.⁽⁶⁾ As duas propostas se diferenciam basicamente pela forma com que chegaram à lei de controle e no tipo de rede neural utilizada. No trabalho de Adetona foi utilizada uma rede neural do tipo RBF (*Radial Basis Function*), enquanto que no trabalho de Maitelli foi utilizada uma rede neural do tipo MLP (*Multi Layer Perceptron*).

O esquema é denominado Neural porque utiliza redes neurais em sua estrutura. Adaptativo porque realiza treinamento *online* da rede. Híbrido porque utiliza-se uma lei de controle além das redes neurais. Indireto porque após o treinamento da rede neural, seus pesos sinápticos não podem ser utilizados diretamente na lei de controle, uma fase intermediária de cálculos é utilizada para a determinação do Jacobiano estimado.

A estratégia de controle baseia-se na obtenção do modelo da planta numa dada região de operação através do identificador neural (com τ atrasos da entrada e τ atrasos da saída da planta). Com o modelo obtido são extraídos os pesos W da rede neural com o intuito de se obter o Jacobiano estimado \hat{J} e, com base nele e na saída estimada \hat{y} do identificador, ajustar o próximo sinal de controle u de forma que a saída da planta y convirja para o sinal de referência y_r .

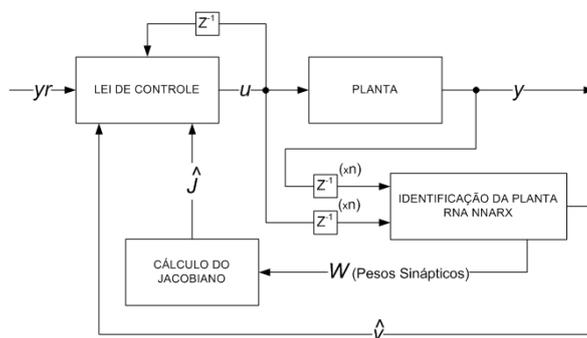


Figura 1. Esquema de controle neural adaptativo híbrido indireto.

2.2 O Identificador Neural

Um sistema dinâmico é aquele que permite descrever sua saída atual com base em suas entradas e saídas passadas, ou seja, sua memória. Identificar um sistema dinâmico significa gerar um modelo com base nesta memória. Para realizar este trabalho, as redes neurais foram utilizadas em sua forma recorrente. O esquema geral deste tipo de arquitetura pode ser visto na Figura 2. Para este trabalho n_y e n_u assumem valores iguais, conforme representado pela letra n na Figura 1.

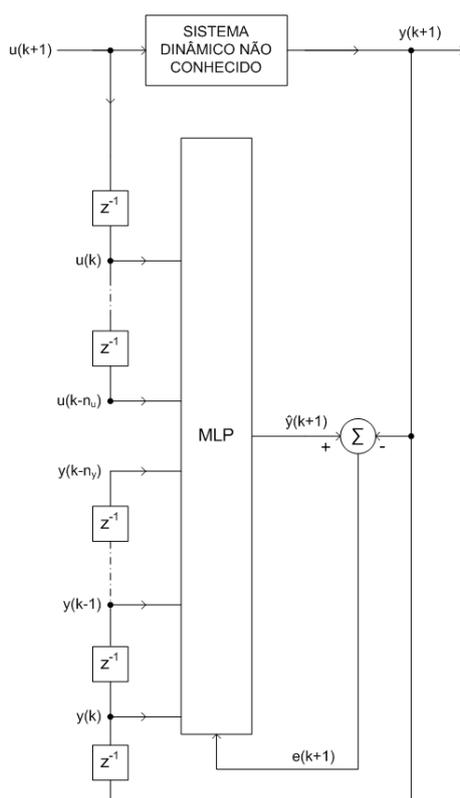


Figura 2. Esquema de rede neural recorrente para identificação de sistemas.

Conforme informado na seção 2.1, o treinamento é realizado *online* e apenas numa região de operação, ou seja, a cada nova etapa de treinamento são utilizados os

dados de uma janela de tempo definida, por exemplo, os últimos 5 minutos. A partir deste modelo obtido com a rede neural são extraídos os pesos sinápticos para obtenção do Jacobiano.

Antes do fechamento da malha pelo controlador neural adaptativo é proposta uma fase de pré-treinamento. Durante esta etapa inicial, o identificador neural apenas coleta os dados da planta, controlada pelo PID (Controlador Proporcional Integral Derivativo) original, sem calcular o sinal de controle (Figura 3). A cada nova amostragem de dados o identificador é re-treinado. Sua saída então é acompanhada e comparada com o valor real da planta. Quando o valor da saída da rede neural convergir para a saída real, considera-se que a rede aprendeu o sistema e que a partir deste momento a malha pode ser fechada pelo novo controlador (Figura 1).

A rede neural utilizada foi configurada com função de ativação tangente hiperbólica na camada escondida e função de ativação linear no neurônio de saída. Esta arquitetura tem como característica a capacidade de aproximar qualquer função matemática contínua.

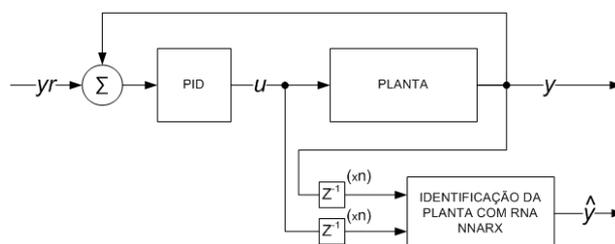


Figura 3. Fase de pré-treinamento do identificador neural.

2.3 Cálculo do Jacobiano

Após o treinamento da rede neural, os seus pesos sinápticos são utilizados para a estimação do Jacobiano. O desenvolvimento para a obtenção da expressão utilizada para o cálculo do Jacobiano estimado pode ser visto a seguir, conforme apresentado por Schnitman e Fontes.⁽⁸⁾

Considere a Figura 4, que representa a estrutura geral da rede neural proposta, sendo:

- W_1 → Matriz de pesos entre a entrada e a camada escondida
- W_2 → Matriz de pesos entre a camada escondida e o neurônio de saída
- S → Função de ativação da camada escondida
- b_i → Termos de polarização dos neurônios da camada escondida
- b_s → Termo de polarização do neurônio da saída
- N → Número de neurônios da camada escondida
- X_i → Resultado do campo local induzido para o i-ésimo neurônio
- n_y → Número de atrasos da saída
- n_u → Número de atrasos da entrada
- d → Tempo morto

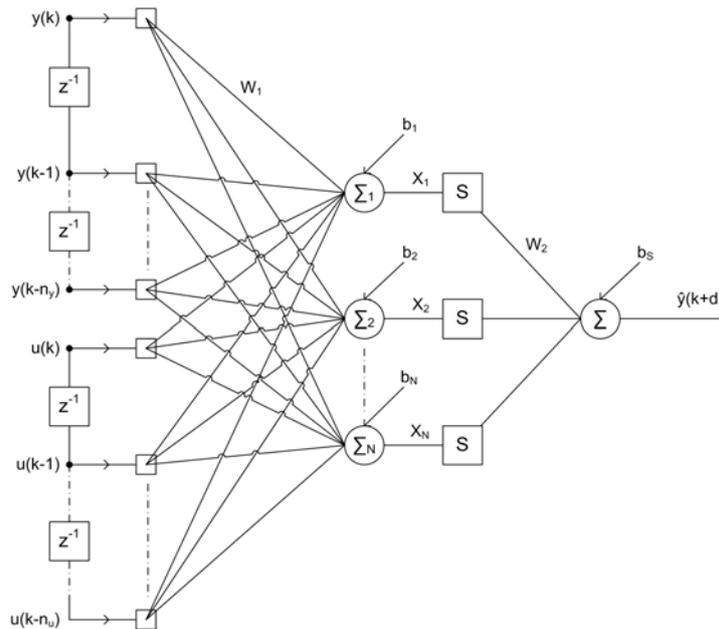


Figura 4. Esquema da rede neural utilizada para a identificação online da planta.

A expressão que representa a saída da rede é dada por:

$$\hat{y}(k+d) = b_s + \sum_{i=1}^N W_2(1,i)S(X_i) \quad (1)$$

sendo,

$$X_i = b(1,i) + \sum_{j=1}^{n_y} W_1(1,j)y(k-j+1) + \sum_{j=1}^{n_u} W_1(1,n_y+j)u(k-j+1) \quad (2)$$

Baseado na equação (1), o Jacobiano pode ser escrito como:

$$\frac{\partial \hat{y}(k+d)}{\partial u(k)} = \sum_{i=1}^N W_2(1,i)S'(X_i) \frac{\partial X_i}{\partial u(k)} \quad (3)$$

sendo S' ,

$$S' = \frac{dS}{dX_i} = (1 - \tanh^2(X_i)) \quad (4)$$

e,

$$\frac{\partial X_i}{\partial u(k)} = W_1(1,n_y+1) \quad (5)$$

Substituindo (5) em (3),

$$\frac{\partial \hat{y}(k+d)}{\partial u(k)} = \sum_{i=1}^N W_2(1,i)S'(X_i)W_1(1,n_y+1) \quad (6)$$

A equação (6) é utilizada para a estimação do Jacobiano com base nos pesos sinápticos da rede neural.

2.4 A Lei de Controle

Conforme mostrado por Maitelli e Rezende,⁽⁷⁾ a lei de controle utilizada está baseada na avaliação da taxa de variação da saída $\mathbf{y}(k+d)$ com relação à entrada da planta $\mathbf{u}(k)$, o Jacobiano, representado na equação (7), sendo d o atraso de transporte da planta.

$$\mathbf{J}(k+d) = \frac{\partial \mathbf{y}(k+d)}{\partial \mathbf{u}(k)} \quad (7)$$

Analogamente, com base na saída estimada $\hat{\mathbf{y}}$ do identificador, o Jacobiano estimado $\hat{\mathbf{J}}$ é dado por:

$$\hat{\mathbf{J}}(k+d) = \frac{\partial \hat{\mathbf{y}}(k+d)}{\partial \mathbf{u}(k)}, \quad (8)$$

Tomando a aproximação da derivada, segue:

$$\hat{\mathbf{J}}(k+d) = \frac{\partial \hat{\mathbf{y}}(k+d)}{\partial \mathbf{u}(k)} \cong \frac{\Delta \hat{\mathbf{y}}(k+d)}{\Delta \mathbf{u}(k)} \quad (9)$$

$$\frac{\Delta \hat{\mathbf{y}}(k+d)}{\Delta \mathbf{u}(k)} = \frac{\hat{\mathbf{y}}(k+d) - \hat{\mathbf{y}}(k+d-1)}{\mathbf{u}(k) - \mathbf{u}(k-1)} \quad (10)$$

Substituindo (10) em (9):

$$\hat{\mathbf{J}}(k+d) = \frac{\hat{\mathbf{y}}(k+d) - \hat{\mathbf{y}}(k+d-1)}{\mathbf{u}(k) - \mathbf{u}(k-1)} \quad (11)$$

Utiliza-se então a expressão (11) para determinação do próximo sinal de controle. No momento do cálculo da nova ação de controle, são conhecidos o último sinal de controle $\mathbf{u}(k-1)$, a última saída estimada $\hat{\mathbf{y}}(k+d-1)$, o último Jacobiano estimado $\hat{\mathbf{J}}(k+d-1)$ e o valor de referência desejado $\mathbf{y}_{ref}(k+d)$. Substituindo em (11), segue:

$$\hat{\mathbf{J}}(k+d-1) = \frac{\mathbf{y}_{ref}(k+d) - \hat{\mathbf{y}}(k+d-1)}{\mathbf{u}(k) - \mathbf{u}(k-1)} \quad (12)$$

Isolando $\mathbf{u}(k)$ na equação (12) chega-se à equação (13) que representa a lei de controle utilizada na estratégia implementada neste trabalho.

$$\mathbf{u}(k) = \mathbf{u}(k-1) + \frac{\mathbf{y}_{ref}(k+d) - \hat{\mathbf{y}}(k+d-1)}{\hat{\mathbf{J}}(k+d-1)} \quad (13)$$

Conforme foi demonstrado, a rede neural é utilizada para estimar a saída da planta e o Jacobiano, utilizando-os na equação (13) para obtenção do novo sinal de controle.

2.5 Algoritmo para implementação do esquema de controle

Após a fase de pré-treinamento, proposta neste trabalho e comentada na seção 2.2, estando a rede neural validada, a malha de controle pode ser fechada através do identificador neural, ou seja, sua saída e o Jacobiano estimado são utilizados na lei de controle para o cálculo de um novo sinal de controle que será aplicado na planta. O algoritmo para implementação do esquema, em português estruturado, é visto a seguir. O segundo laço “Enquanto” foi originalmente proposto por Maitelli.⁽¹⁾

Ajuste de parâmetros iniciais:

fim_ControlNeural == **Falso**;

fim_PreTreinamento == **Falso**;

Enquanto *fim_PreTreinamento* ≠ **Verdadeiro** **Faça**

Lê entrada e saída da planta;

Treina rede neural;

Fim_Enquanto

Enquanto *fim_ControlNeural* ≠ **Verdadeiro** **Faça**

Lê entrada e saída da planta;

Treina rede neural;

Calcula a saída rede neural;

Extrai pesos sinápticos;

Calcula o Jacobiano;

Aplica a lei de controle e calcula o novo sinal de controle;

Verifica limites para o sinal de controle;

Aplica o novo sinal de controle;

Fim_Enquanto

2.6 O Processo de Regeneração de Ácido Clorídrico

O ácido clorídrico (HCl) é utilizado nas indústrias siderúrgicas em suas linhas de decapagem. Estas linhas são responsáveis pela remoção da camada de óxidos superficial (carepa) das bobinas a quente e adequação da sua superfície para processos posteriores. Após o processo de decapagem, o ácido utilizado no processo é desviado para o processo de regeneração de ácido clorídrico. O ácido regenerado volta para o processo de decapagem mantendo o ciclo, assim evitando problemas ambientais com o seu descarte e diminuindo custos com menor aquisição de ácido novo. Outro produto da regeneração do ácido é o óxido de ferro.

O processo de regeneração de ácido clorídrico, descrito por Adham e Lee,⁽⁹⁾ consiste basicamente em alimentar um reator (Figura 5) com o produto descartado da decapagem. Este reator é também chamado de *Roaster* e trabalha com temperaturas entre 600°C e 900°C. A alimentação é feita em forma de *spray* com o objetivo de diminuir suas partículas e facilitar a evaporação. Em poucos segundos são produzidos ácido clorídrico gasoso e óxido de ferro sólido. O gás gerado no reator sai pelo topo e o óxido de ferro é depositado na parte de baixo do reator (Figura 5). Ao sair pelo topo do reator, o gás passa por um ciclone que garante a separação e recuperação de partículas de óxido que retornam para o reator. O gás passa ainda por um pré-concentrador, reduzindo sua temperatura e eliminando os últimos traços de óxido de

ferro. Em seguida este gás é lavado com água em uma coluna de absorção onde o ácido clorídrico é recuperado em sua forma líquida, sendo retirado na parte inferior (Figura 6).

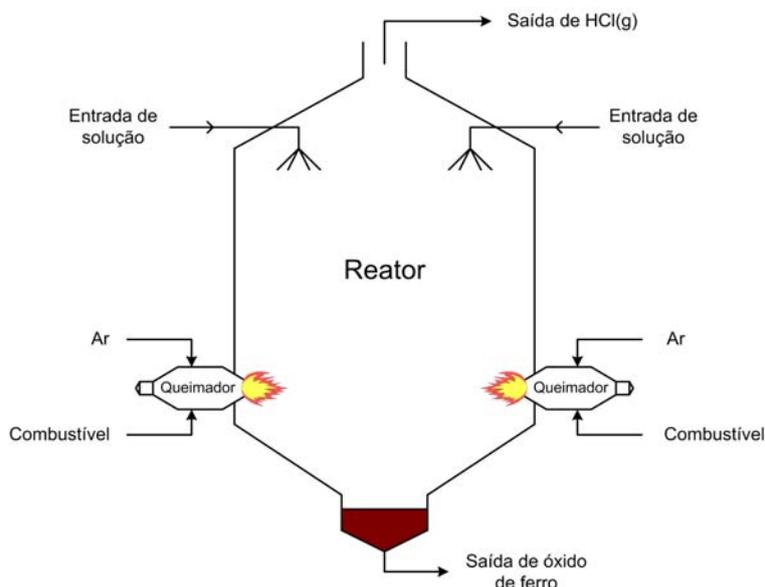


Figura 5. Representação do Reator do processo de regeneração de ácido clorídrico.

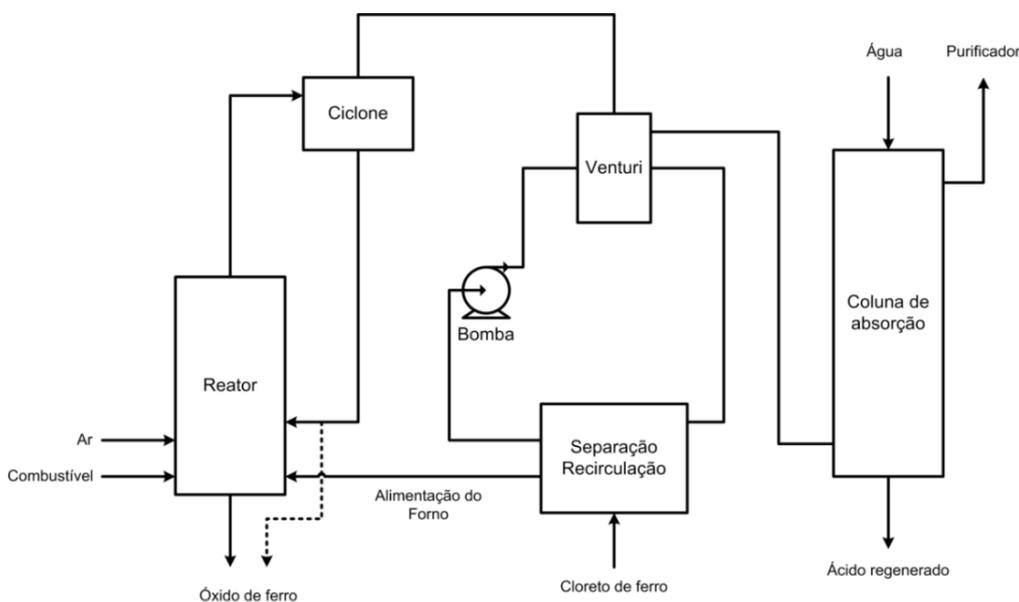


Figura 6. Diagrama esquemático do processo de regeneração de ácido clorídrico.

2.7 Aplicação do Esquema de Controle Neural no Controle da Vazão de Água da Coluna de Lavagem

O esquema de controle avaliado neste trabalho foi implementado no controle de vazão de água da coluna de lavagem do ácido gasoso. Esta planta é controlada por um

sistema dedicado. Para implementar a estratégia de controle neural adaptativa proposta, foi utilizado o protocolo de comunicação OPC (*OLE for Process Control*). O CS3000 trabalhou como um OPCServer e, como OPCClient, foi utilizado o Matlab instalado em um *notebook*, onde foi executado o esquema de controle.

Optou-se por esta arquitetura devido a sua facilidade de implementação, visto que o programa em código Matlab utilizado para os testes simulados no notebook foi reaproveitado.

No aplicativo do sistema dedicado foi implementada uma chave seletora onde foi possível selecionar se o programa estaria trabalhando com o controlador original PID ou com o controlador adaptativo neural rodando no notebook (Figura 7), facilitando desta forma os testes e a continuidade operacional quando o notebook era retirado do esquema.

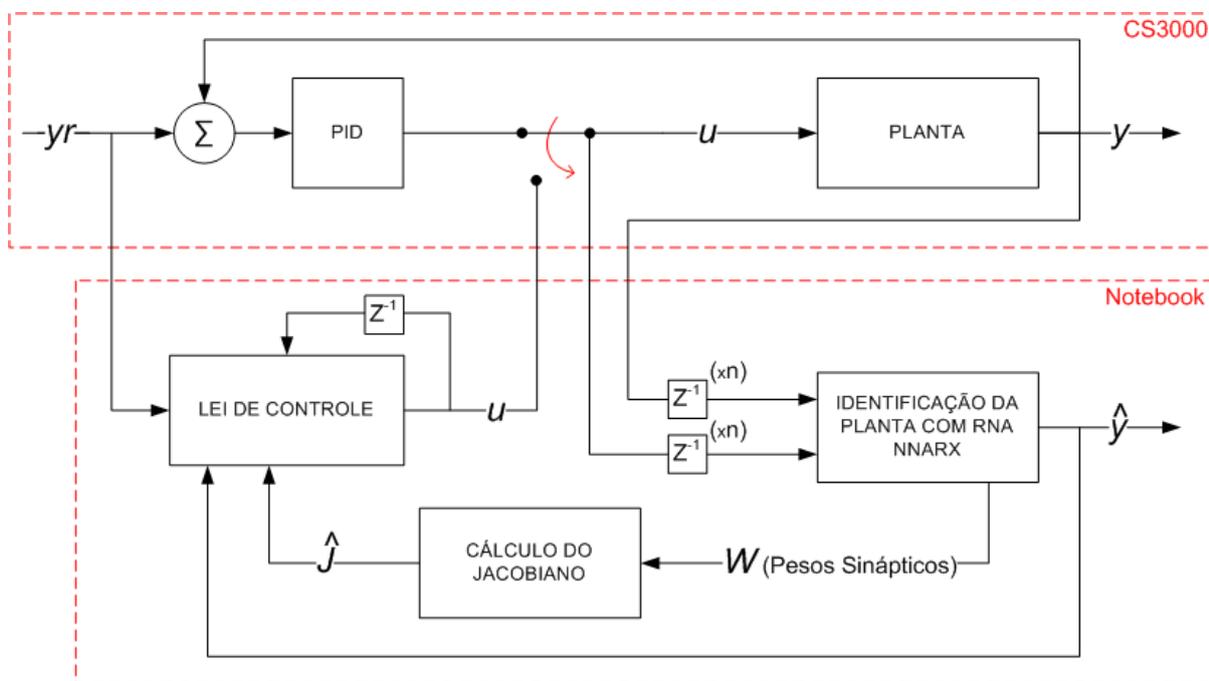


Figura 7. Arquitetura de controle implementada.

3 RESULTADOS

Com o objetivo de auxiliar na análise do resultado para o controlador neural adaptativo estudado, foi realizada a coleta de dados para os dois tipos de controladores utilizando-se o mesmo sinal de referência. Os resultados podem ser vistos na Figura 8.

Para implementação do controlador neural adaptativo não foi realizada nenhuma coleta de dados da planta para verificação dos parâmetros a serem ajustados no esquema de controle como: número de atrasos na entrada do identificador neural, número de neurônios da camada escondida e tamanho da janela de treinamento. Todos estes parâmetros foram definidos empiricamente, com base nos resultados alcançados em simulações e nos resultados do controlador original. Não foi possível a realização

desta análise prévia devido à indisponibilidade da planta durante o período de realização dos testes.

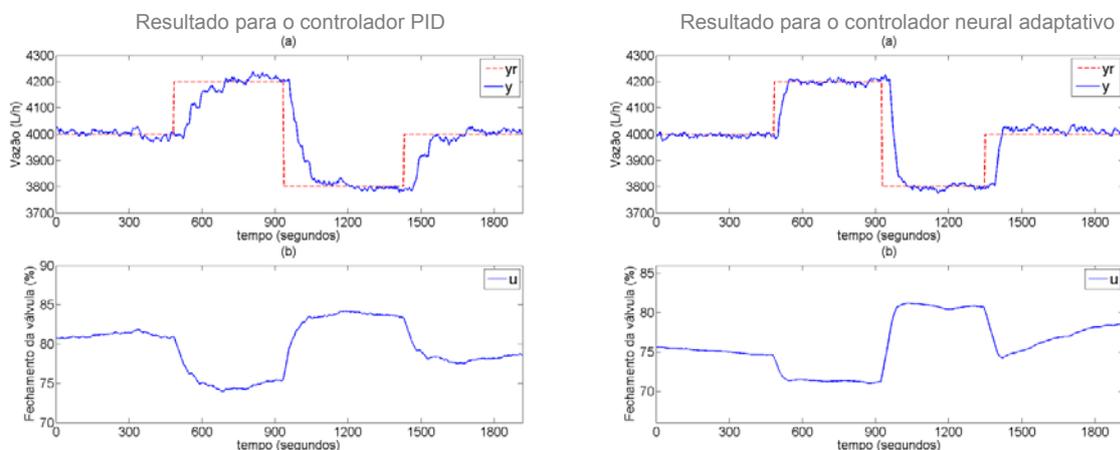


Figura 8. Resultados para os dois controladores. (a) Linha contínua: Sinal de vazão de água da coluna. Linha tracejada: Sinal de referência. (b) Sinal de controle (100% - valor de abertura da válvula)

A estratégia de controle foi implementada com os seguintes parâmetros: número de neurônios na camada escondida = 3; número de atrasos de entrada e saída = 2; tamanho da janela de treinamento = 10 amostras; tempo de amostragem = 3 segundos; tempo morto = 1 amostra.

Para o número de neurônios na camada escondida foi definido um número pequeno devido à baixa complexidade do sistema. O número de amostras na janela de treinamento e o número de atrasos da entrada e saída da planta também foram definidos com o mesmo critério. O tempo morto foi escolhido igual a 1 devido ao sistema não apresentar atraso de transporte. A atuação no ajuste de abertura da válvula tem efeito imediato na vazão de água da coluna.

Uma inspeção visual nos dados apresentados na Figura 8 (esquerda) mostra que, durante o tempo de subida, têm-se de 60 a 80 amostras. Valor muito maior do que o geralmente indicado na literatura.^(10,11) Além disso, testes realizados no processo com o tempo de amostragem de 1 segundo não tiveram bons resultados para o controlador neural. Assim, optou-se empiricamente em alterar o tempo de amostragem para 3 segundos.

4 DISCUSSÃO

O principal objetivo deste trabalho foi a avaliação do controlador neural e não a comparação entre os dois tipos de controladores. Para efeito de comparação o controlador PID deveria ter sido analisado e ajustado para sua melhor condição, o que não foi feito. Apesar disso, a comparação é inevitável, já que o controlador neural está sendo avaliado no lugar do controlador PID.

O controlador neural adaptativo estudado apresentou uma diferença significativa para o tempo de subida e uma menor variabilidade da saída em regime permanente. Para a transição do *setpoint* de 4.000 [l/h] para 4.200 [l/h] o tempo de subida para o controlador PID foi de 3,5 minutos, enquanto que para o controlador neural adaptativo foi de 1 minuto. De forma a complementar a análise, foram comparados também os

índices IAE (*Integral Absolute Error*) para os dois controladores. O controlador PID apresentou $IAE = 2,66 \times 10^4$, enquanto que o controlador neural adaptativo apresentou $IAE = 1,84 \times 10^4$, uma diferença considerável de 44%, devido principalmente ao menor tempo de subida.

5 CONCLUSÃO

Apresentou-se neste trabalho a aplicação de um esquema de controle neural adaptativo. O objetivo de avaliar uma técnica de controle que possibilite a isenção do trabalho de sintonia e re-sintonia foi atingido. Conforme mostrado na seção 3, não foi utilizado nenhum procedimento ou ferramenta para definição dos parâmetros do esquema de controle, os mesmos foram definidos apenas com a observação do processo e do controlador original. Pelo resultado alcançado do esquema na sintonia inicial, acredita-se também que variações da planta (desgaste de válvulas e bombas, entupimento de tubulações etc) seriam incorporadas pela estratégia evitando o trabalho de re-sintonia.

Além de evitar o esforço de sintonia do controlador, o resultado apresentado pelo esquema de controle estudado foi superior ao apresentado pelo controlador original. O novo controlador apresentou melhores resultados para o tempo de subida e para a variabilidade em regime permanente. Poderia ter sido encontrada uma sintonia para o PID que alcançasse resultados próximos, porém seria necessário este esforço de re-sintonia, que foi evitado pelo controlador proposto.

Ressalva-se que, dependendo da complexidade do processo, de suas dinâmicas, a determinação dos parâmetros do identificador neural pode exigir maior tempo. Este seria o ponto mais crítico.

Agradecimentos

À DEUS primeiramente. Aos operadores da planta pela participação ativa durante os testes. Ao pessoal da Instrumentação da Usiminas pela realização das modificações necessárias no sistema de sua responsabilidade. Aos meus colegas de escritório pela compreensão de minha ausência das atividades de rotina durante a realização deste trabalho. À FAPEMIG, CNPq e Usiminas.

REFERÊNCIAS

- 1 MAITELLI, A. L.; GABRIEL FILHO, O. G. Controlador híbrido indireto baseado em redes neurais - parte I: Desenvolvimento e implementação. VI Simpósio Brasileiro de Automação Inteligente - SBAI. Bauru: [s.n.]. 2003. p. 183-188.
- 2 MAITELLI, A. L.; GABRIEL FILHO, O. G. Controlador híbrido indireto baseado em redes neurais - parte II: estabilidade e robustez. VI Simpósio Brasileiro de Automação Inteligente - SBAI. Bauru: [s.n.]. 2003. p. 1067-1072.
- 3 WIDROW, B.; WALACH, E. Adaptive Inverse Control: A Signal Processing Approach. IEEE Press, 2008.
- 4 RIBEIRO, R. N. Utilização de redes neurais artificiais e tecnologia ft-nir para predição do número kappa em um processo kraft de cozimento de madeira em indústria de celulose. Coronel Fabriciano: Centro Universitário do Leste de Minas Gerais - UNILESTE, 2007. Dissertação de Mestrado - Programa de Pós-Graduação em Engenharia.

- 5 TAKAHASHI, H. J. Predição de propriedades mecânicas de aços de alta resistência microligados utilizando técnicas de inteligência computacional. Coronel Fabriciano: Centro Universitário do Leste de Minas Gerais - UNILESTE, 2006. Dissertação de Mestrado - Programa de Pós-Graduação em Engenharia.
- 6 ADETONA, O.; SATHANANTHAN, S.; KEEL, L. H. Robust nonlinear adaptive control using neural networks. Proceedings of the American Control Conference, Arlington, 25-27 junho 2001. 3884-3889.
- 7 MAITELLI, A. L.; DE REZENDE, J. A. D. Um neurocontrolador com treinamento em. Anais do V Simpósio Brasileiro de Automação Inteligente - SBAI. Canela: [s.n.]. 2001. p. 1-6.
- 8 SCHNITMAN, L.; FONTES, D. B. The basic ideas of neural predictive control. Proceedings of the 7th Mediterranean Conference on Control and Automation. Haifa, Israel: [s.n.]. 1999. p. 497-510.
- 9 ADHAM, K.; LEE, C. Minimizing fuel costs during thermal regeneration of the hydrochloric acid lixiviant. Disponível em:
<http://www.hatch.ca/Non_Ferrous/articles/minimizing_fuelcost.pdf>. Acesso em: 24 maio 2009.
- 10 CLARKE, D. W.; MOHTADI, C.; TUFFS, P. S. Generalized predictive control - part II: Extensions and interpretations. Automatica - Journal of the International Federation of Automatic Control, 1987. 149-160.
- 11 JI, K.; JONG KIM, W. Optimal bandwidth allocation and qos-adaptive control co-design for networked control systems. International Journal of Control - Automation and Systems, 2008. 596-606.