

Redes Neurais Artificiais para Controle de uma Planta de Nível

Isabele Moraes Costa , Luana Lyra de Almeida , Stella Neves Duarte Lisboa e
Fábio Meneghetti Ugulino de Araújo

Resumo—Este trabalho pretende mostrar a utilização de Redes Neurais Artificiais para o controle de uma planta de nível. A idéia é substituir controladores PID já existentes por redes neurais artificiais que, inicialmente, copiem a dinâmica dos mesmos. Os resultados apresentados mostram o desempenho dos controladores neurais quando aplicados à planta simulada e à planta real.

Index Terms—Controle Neural, *Backpropagation*, Controle de Nível.

I. INTRODUÇÃO

A utilização de métodos de controle clássico é uma área de pesquisa já consolidada, e constitui uma boa opção no controle de sistemas simples e com especificações de desempenho menos rígidas. Entretanto, em algumas situações, ela pode não ser uma alternativa satisfatória por alguns motivos. No caso dos sistemas não-lineares, as técnicas de controle clássico utilizadas baseiam-se em modelos linearizados dos sistemas físicos, o que pode causar a perda de informações úteis. Logo, torna-se muito difícil a obtenção de um modelo preciso, que reflita a dinâmica do sistema de forma fiel. Dinâmica esta, que é pouco conhecida, ou acaba sendo modelada por equações muito complexas, que tornam muito difícil a tarefa de controle.

Neste contexto, a aplicação de técnicas de inteligência artificial no controle de sistemas não-lineares tem sido muito bem aceita entre os pesquisadores. Este trabalho trata especificamente da utilização de técnicas baseadas em Redes Neurais Artificiais (RNA).

A característica mais importante das RNAs está em sua habilidade de aproximar funções [1]. Em outras palavras, dada uma certa função desconhecida, a qual se deseja aproximar, a rede tem seus parâmetros ajustados de forma a produzir a mesma resposta em relação à função, para entradas semelhantes, como mostrado na Figura 1.

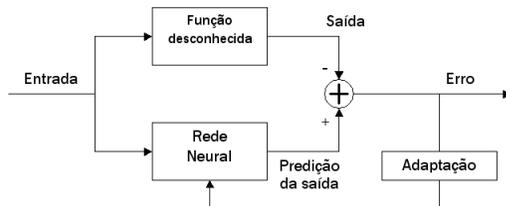


Figura 1. RNA como aproximadora de funções

Com isso, as redes neurais têm sido aplicadas com sucesso tanto na identificação (modelagem) de sistemas

Departamento de Engenharia de Computação e Automação (DCA), Universidade Federal do Rio Grande do Norte, Natal-RN, Brasil. emails: {isabele, luana, stella, meneghet}@dca.ufrn.br

não-lineares quanto no projeto de controladores para este tipo de sistemas ([2] e [3]). Elas podem ajustar seus parâmetros (aprender) através da apresentação de exemplos que mostrem o padrão de comportamento desejado.

No caso da identificação, a RNA é treinada para aprender a dinâmica do sistema que se almeja controlar. Ela seria treinada através da observação do comportamento entrada-saída da planta, recebendo a mesma entrada aplicada a ela. A saída desejada para a rede corresponderia à saída fornecida pela planta [4].

A RNA também poderia ser treinada para representar o comportamento inverso do sistema a ser controlado, ou seja, neste caso a rede seria utilizada para implementar o próprio controlador. A entrada para a rede, neste caso, seria a saída da planta, e a saída desejada para a rede seria a entrada da planta, de forma a fazer um mapeamento inverso que pode ser utilizado para controle [4].

Uma outra abordagem para a utilização de redes neurais no controle de sistemas é treinar a rede para que ela seja capaz de copiar o comportamento de um controlador já existente para aquela planta. A saída desejada para a rede neural corresponderia à saída do controlador, como pode ser visto na Figura 2.

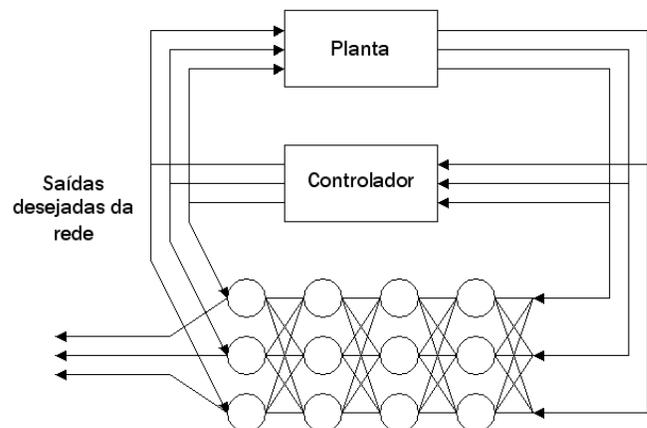


Figura 2. RNA copiando um controlador existente

Aparentemente, esta abordagem não apresenta vantagens, pois não haveriam razões para se utilizar uma rede neural quando já existe um controle capaz de executar sua tarefa. Porém, as vantagens apareceriam em duas situações: caso o controlador existente fosse impraticável, como por exemplo uma pessoa, ou caso a rede seja capaz de formar uma regra de controle eficiente com base em uma representação mais fácil de se obter do que a representação

do controlador existente [4],[5]. Além disto o controlador neural pode ser capaz de filtrar características não desejáveis dos controladores convencionais, que estão servindo de modelo, como por exemplo *overshoot*, oscilações do sinal de controle, entre outras.

Como visto, não há a dependência de uma teoria formal que descreva o processo, o que faz das redes neurais ferramentas potencialmente poderosas na solução de problemas envolvendo sistemas não-lineares.

A análise e o projeto de controladores neurais, entretanto, não é algo simples. Pelo fato de existir uma variedade imensa de arquiteturas, é muito difícil obter uma expressão analítica que defina uma arquitetura ótima para cada problema específico, apesar de existirem vários estudos nesta direção [6]. Estas definições acabam por ser feitas de forma empírica, através do teste de vários modelos com diferentes números de camadas e neurônios e escolhendo aquele que proporcione o melhor desempenho.

O objetivo deste trabalho é o desenvolvimento e implementação de um controlador neural capaz de copiar o comportamento de controladores PID de uma malha de controle de nível. Na seção 2 será feita uma descrição da planta e será apresentada a malha de controle a ser copiada. Na seção 3 serão detalhadas as atividades realizadas e na seção 4 serão mostrados seus respectivos resultados. Por fim, a conclusão apresentará algumas considerações finais sobre o desenvolvimento do trabalho.

II. DESCRIÇÃO DA PLANTA

A planta consiste de um módulo de dois tanques, contendo uma bomba e um recipiente d'água. Conforme mostrado na Figura 3, esta bomba alimenta o Tanque 1, e este, através de um orifício de saída localizado em sua base, alimenta o Tanque 2. Este último, por sua vez, também possui um orifício de saída, através do qual sua vazão de saída é direcionada de volta ao recipiente d'água.

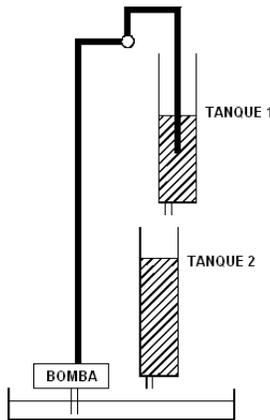


Figura 3. Módulo de dois tanques

O objetivo, neste caso, é controlar o nível da água contida no Tanque 2, através da aplicação de tensões adequadas à bomba.

O modelo matemático da planta descrita é encontrado no manual do fabricante [7], e é dado pelas Equações 1 e 2

dos níveis L_1 (tanque 1) e L_2 (tanque 2), respectivamente.

$$\dot{L}_1 = -\frac{a_1}{A_1} \sqrt{\frac{g}{2L_{10}}} L_1 + \frac{K_m}{A_1} V_p \quad (1)$$

$$\dot{L}_2 = -\frac{a_2}{A_2} \sqrt{\frac{g}{2L_{20}}} L_2 + \frac{a_1}{A_2} \sqrt{\frac{g}{2L_{10}}} L_1 \quad (2)$$

Na Tabela I, são mostrados os significados de cada uma das constantes utilizadas nas equações do modelo, juntamente com seus respectivos valores, também fornecidos pelo fabricante.

| Nome | Significado | Valor |
|---------------------|-------------------------|-------------------|
| K_m | cte. da bomba | $4.6(cm^3/s)/V$ |
| V_p | tensão aplicada à bomba | $-22 < V_p < 22$ |
| a_1 e a_2 | diam. orifício de saída | $0.17813919765cm$ |
| A_1 e A_2 | área do tanque | $15.5179cm^2$ |
| g | acel. gravidade | $980cm/s^2$ |
| L_{10} e L_{20} | pontos de linearização | $15cm$ |

TABLE I
PARÂMETROS DO MODELO DA PLANTA

Esse sistema de tanques acoplados, na configuração mostrada acima, pode utilizar um controle em cascata, com duas malhas de controle, conforme a Figura 4.

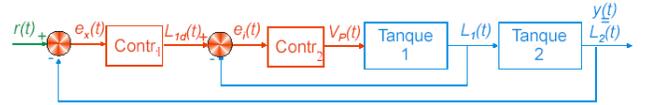


Figura 4. Esquema de controle para sistema de tanques

Ambos os controladores são PID's. Um conjunto de parâmetros, ajustado empiricamente, é mostrado na Tabela II.

| | Kp | Ki | Kd |
|------|----|------|-------|
| PID1 | 1 | 0.1 | 0.01 |
| PID2 | 2 | 0.05 | 0.005 |

TABLE II
GANHOS DOS CONTROLADORES PID

O objetivo é, então, a utilização de redes neurais artificiais, com *backpropagation* para o treinamento, para copiar a dinâmica do sistema de controle e posteriormente substituí-lo.

III. DESENVOLVIMENTO

A. Rede Neural Artificial Treinada com Dados Simulados

PRIMEIRAMENTE, a malha de controle contendo os dois PID's em cascata, juntamente com a planta de nível, foi implementada, utilizando-se a ferramenta Simulink, do Matlab. Em seguida, foi feita a simulação deste sistema, tendo como referência (nível desejado para o tanque 2) um ruído branco de banda limitada, variando

em torno de 15 centímetros, de forma a obter os conjuntos de dados para treinamento das redes neurais.

Para o treinamento das redes que copiarão a dinâmica de cada um dos PID's, e da rede que copiará a dinâmica dos dois PIDs simultaneamente, foram utilizados, de início, os seguintes parâmetros:

- PID1
 - Entradas: erro entre a referência e o nível do tanque 2, nível do tanque 1 e nível do tanque 2;
 - Saída desejada: nível do tanque 1 desejado (L_{1D});
- PID2
 - Entradas: erro entre L_{1D} e o nível do tanque 1, nível do tanque 1 e nível do tanque 2;
 - Saída desejada: sinal de controle (tensão na bomba);
- PID1+PID2
 - Entradas: erro entre a referência e o nível do tanque 2, nível do tanque 1 e nível do tanque 2;
 - Saída desejada: sinal de controle (tensão na bomba).

A partir do conjunto de dados, vários treinamentos, com várias arquiteturas, foram realizados. As arquiteturas que apresentaram os menores erros de convergência foram: RNA com uma camada escondida contendo 9 neurônios para o PID1 e RNA com uma camada escondida contendo 7 neurônios para o PID2. Foi feito também um treinamento de uma terceira rede neural para substituir os dois PIDs simultaneamente. Para esta rede, o menor erro de convergência, em torno de 10^{-5} , foi encontrado para uma arquitetura contendo duas camadas escondidas com 4 e 11 neurônios, respectivamente. Os resultados da implementação destas redes podem ser observados nas figuras 5 e 6.

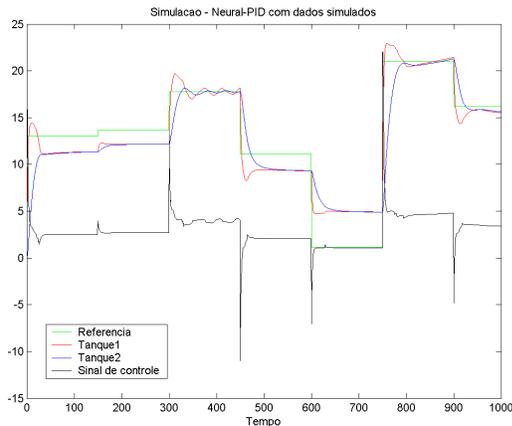


Figura 5. Simulação - RNA substituindo PID1

Como pôde ser visto, a rede neural que substituiu o PID2 comportou-se de modo satisfatório (Figura 6), com um bom tempo de estabilização (50 segundos), overshoot baixo (quase nulo) e erro de regime nulo. Já a rede neural que substituiu o PID1 não apresentou o comportamento esperado (Figura 5), já que o nível do tanque 2 se manteve com um erro de regime em torno de 3 centímetros para a maioria das referências. Por este motivo, o desempenho do sistema foi afetado quando os dois PIDs foram substituídos

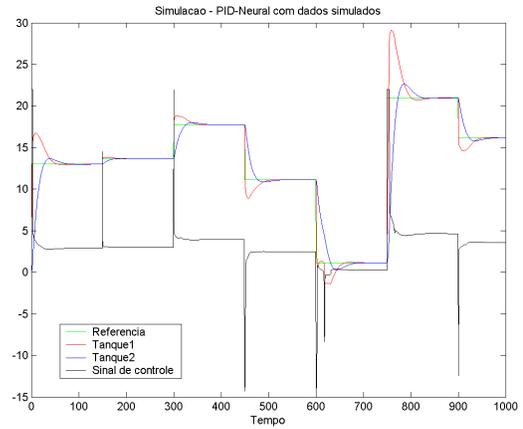


Figura 6. Simulação - RNA substituindo PID2

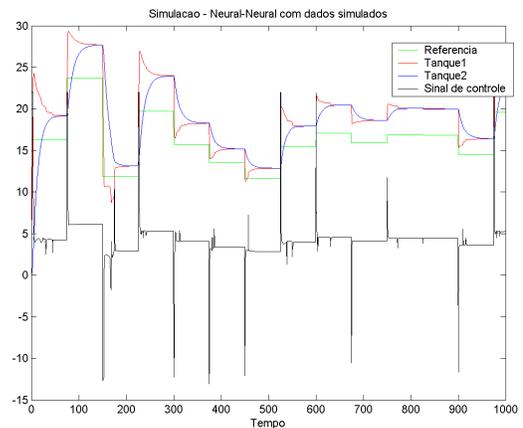


Figura 7. Simulação - RNAs substituindo cada PID simultaneamente

pelas duas RNAs (Figura 7), e a saída apresentou erro de regime (que chegou a atingir 5 centímetros para algumas referências).

A Figura 8, mostra o comportamento do sistema quando uma única rede neural substituiu os dois PIDs. Este controlador neural apresentou um bom desempenho, com um bom tempo de estabilização (40 segundos), overshoot quase nulo, porém com erro de regime variando entre 2 e 5 centímetros.

B. Rede Neural Artificial Treinada com Dados Reais

DEVIDO ao erro de regime encontrado na implementação das redes neurais cujo treinamento foi realizado com dados simulados, optou-se por uma estratégia diferente, a qual consistia no treinamento dessas redes neurais com dados capturados durante a execução dos dois PIDs na planta real. Porém, por fins de praticidade e precaução, foi decidido que os testes iniciais dos desempenhos das redes continuariam sendo feitos na planta simulada. Desta maneira, levaria-se menos tempo na realização de cada teste, e seriam evitados os riscos de danos à planta real (no caso de sinais fora dos limites permitidos).

Para formar o conjunto de dados tentou-se abranger a

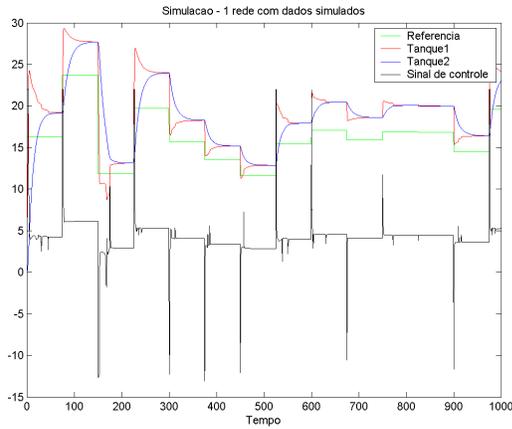


Figura 8. Simulação - RNA substituindo PID1 e PID2

maior quantidade de estados que o processo pudesse gerar. Esse conjunto de dados pode ser observado na Figura 9.

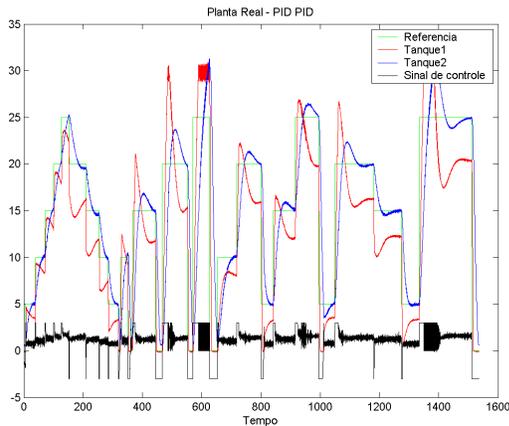


Figura 9. Conjunto de treinamento com dados reais - execução com controladores PID

Os parâmetros utilizados para o treinamento das RNAs que copiarão a dinâmica de cada um dos PIDs foram os mesmos utilizados na simulação anterior. O critério de decisão pela rede neural que melhor desempenhava o objetivo foi, também, o menor erro de convergência. No caso do PID1, a arquitetura da rede neural escolhida possuía 1 camada escondida com 15 neurônios, e no caso do PID2, 1 camada escondida com 11 neurônios. Ambas utilizaram a tangente sigmóide como função de ativação nas camadas escondidas e a função linear como função de ativação nas camadas de saída. Os erros de convergência encontrados nos treinamentos para ambas as redes foram da ordem de 10^{-5} .

Os pesos sinápticos resultantes do treinamento foram implementados em uma rotina no Matlab que promovia a substituição dos PIDs por essas redes neurais. Os resultados dessas substituições podem ser observados nas Figuras 10 e 11.

Como pôde ser visto, a rede neural que substituiu o PID2 comportou-se de modo satisfatório, com um bom tempo de

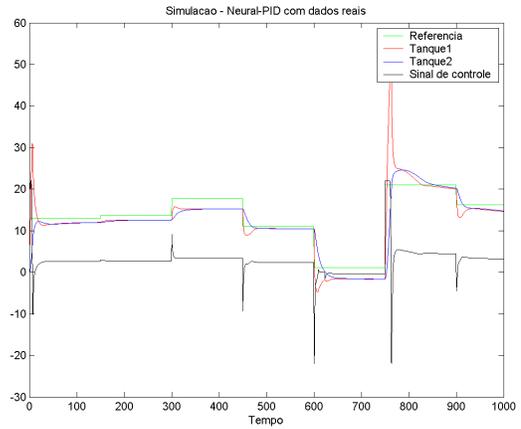


Figura 10. RNA treinada com dados reais substituindo PID1

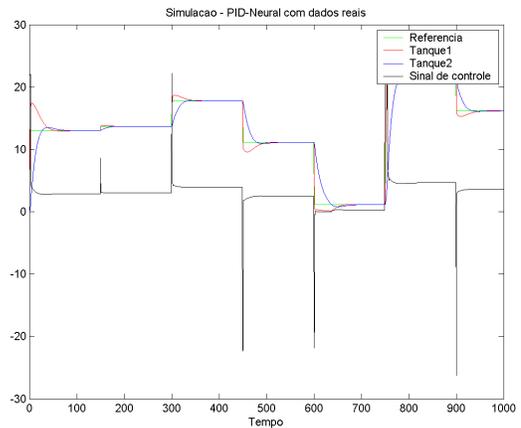


Figura 11. RNA treinada com dados reais substituindo PID2

estabilização (50 segundos), overshoot baixo (quase nulo) e erro de regime nulo. Já a rede neural que substituiu o PID1, apesar de ter mostrado um resultado melhor do que a rede neural treinada com dados simulados para este mesmo PID, não apresentou o comportamento esperado, já que o nível do tanque 2 se manteve com um erro de regime em torno de 1 centímetro para a maioria das referências.

Substituindo os dois PIDs pelas duas redes neurais devidamente treinadas, o sistema apresentou uma resposta semelhante aos testes anteriores de mesmo propósito, uma vez que a saída apresentou oscilações e erro de regime, como mostra a Figura 12.

Partindo para o treinamento de uma única rede neural com a intenção de substituir a dinâmica dos dois PIDs, a arquitetura que apresentou menor erro de convergência possuía 2 camadas escondidas, onde na primeira foram utilizados 5 neurônios e na segunda 11 neurônios.

Na Figura 13, observa-se o comportamento do sistema com a substituição dos dois PIDs por essa única rede neural. Os resultados apresentados não mostraram-se satisfatórios já que ocorreu um erro de regime na saída.

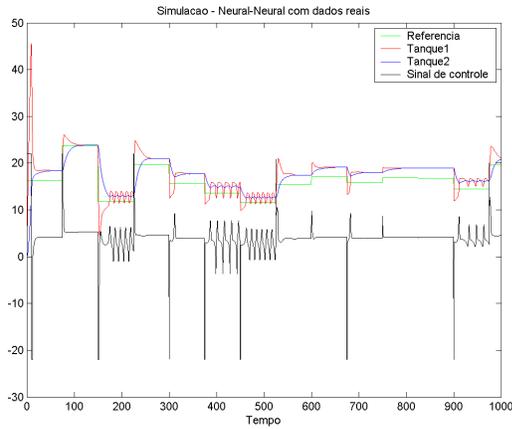


Figura 12. RNAs treinadas com dados reais substituindo cada PID

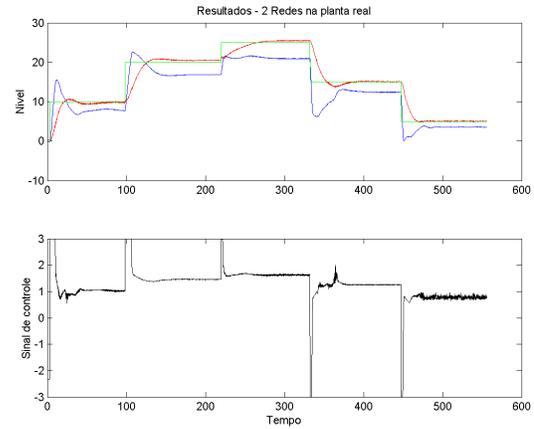


Figura 14. Planta real - RNAs treinadas com dados reais substituindo cada PID

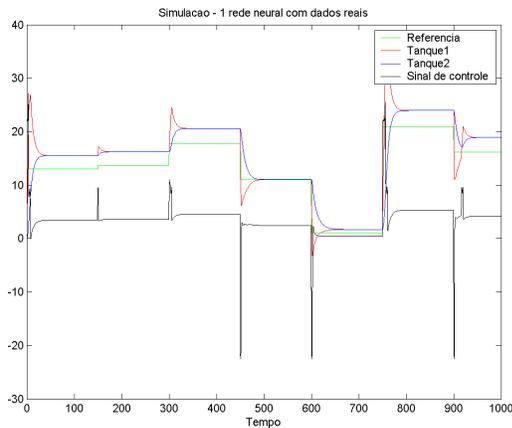


Figura 13. RNA treinada com dados reais substituindo os 2 PIDs

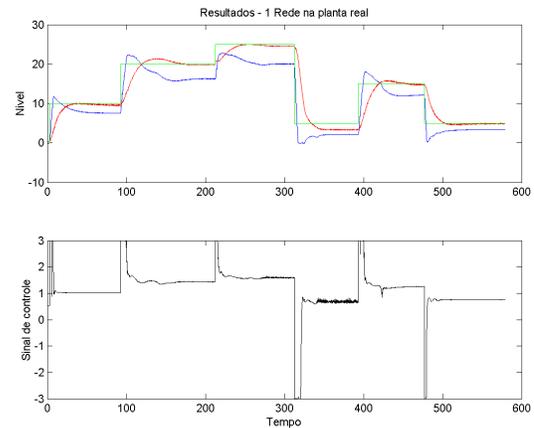


Figura 15. Planta real - RNA treinada com dados reais substituindo os 2 PIDs

IV. RESULTADOS FINAIS

COMPARANDO-SE os resultados das diversas simulações, tanto com RNAs treinadas usando-se dados obtidos via simulação, quanto com RNAs treinadas a partir de dados coletados na planta real, concluiu-se que algumas características insatisfatórias dos resultados das simulações estariam associadas a ganhos e dinâmicas não modeladas. Mesmo assim, como o sinal de controle apresentou-se relativamente suave e dentro de limites aceitáveis, em todas as simulações, partiu-se para a implementação dos controladores obtidos, diretamente na planta real.

A implementação das redes neurais substituindo cada PID, na planta real, resultou em um controle satisfatório onde o tempo de estabilização foi de aproximadamente 40 segundos, overshoot e erro de regime praticamente nulos, como pode ser visto na Figura 14.

A implementação da rede neural substituindo os dois PIDs simultaneamente, mostrada na Figura 15, também apresentou um ótimo desempenho, com características similares à saída das duas redes porém com a vantagem de gerar um sinal de controle menos oscilatório para as referências mais baixas. Esta diferença de desempenhos entre os controladores aplicados à planta simulada e à planta real

deve-se, provavelmente, a ganhos e dinâmicas não modeladas, como já citado.

Por fim, foi feito um estudo comparativo dos resultados obtidos. Todas as configurações implementadas foram testadas para uma mesma situação, isto é, a planta iniciaria sua operação com ambos os tanques vazios, e o tanque 2 teria como referência o nível de 10 centímetros. As figuras 16 e 17 mostram estes resultados, relativos ao nível do tanque 2 e ao sinal de controle, respectivamente. Quanto ao desempenho geral, nota-se que o controlador PID possui um transitório suave, com pouco overshoot. Além disso, seu erro em regime é nulo, ao contrário dos controladores neurais, que apresentaram uma pequena diferença (em torno de 0.5 cm) em relação nível desejado.

É possível observar que os controladores neurais mostraram-se melhores do que o controlador PID no que diz respeito aos sinais de controle. Comparados ao sinal fornecido pelo controlador PID, os sinais dos controladores neurais apresentaram-se bem menos oscilatórios. Este fator faz com que os atuadores sejam poupados durante seu funcionamento, e conseqüentemente contribui para a vida útil dos mesmos.

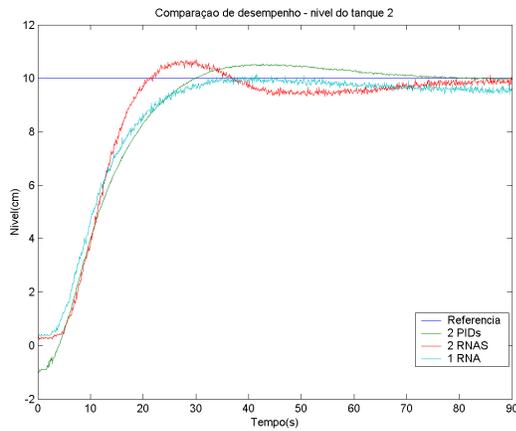


Figura 16. Comparação de desempenho - nível do tanque 2

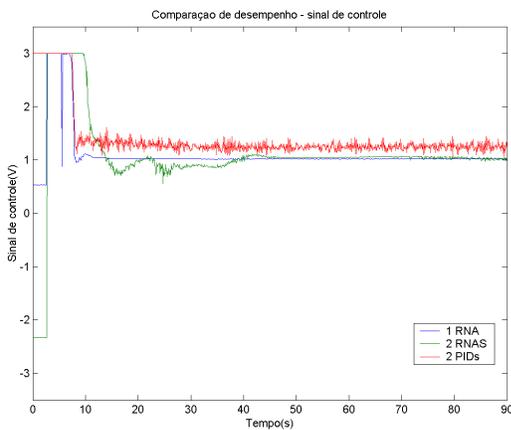


Figura 17. Comparação de desempenho - sinal de controle

V. CONCLUSÕES

NESTE trabalho, foi realizado um estudo sobre controladores neurais, através da aplicação dos mesmos a uma planta de nível, em substituição aos dois controladores PID já existentes.

Em uma primeira etapa, cada PID foi substituído por uma rede neural, e posteriormente os dois PIDs foram substituídos por uma única rede. Para cada configuração, foram feitas simulações de diversas arquiteturas de RNAs, treinadas com conjuntos de dados extraídos tanto da planta real quanto da sua simulação através do Simulink/Matlab. Os resultados obtidos mostraram que as redes neurais foram capazes de controlar a planta, e apresentaram algumas vantagens, em relação aos PIDs a partir dos quais foram copiadas.

REFERÊNCIAS

- [1] Simon Haykin, *Redes Neurais: princípios e prática*, Bookman, 2001.
- [2] K. S. Narendra and K. Parthasarathy, *Identification and Control of Dynamical Systems Using Neural Networks*, IEEE Transactions on Neural Networks, vol.1 issue 1, March, 1990 .
- [3] K. S. Narendra, *Neural Networks for Control: Theory and Practice*, Proceedings of the IEEE, vol. 84, issue 10, pp. 1385-1406, October, 1996 .

- [4] W. T. Miller, R. Sutton and P. J. Werbos , *Neural Networks for Control*, The MIT Press, 1995.
- [5] B. Widrow and F. W. Smith , *Pattern Recognizing Control Systems*, Computer and Information Sciences (COINS) Proceedings, Washington D. C. , Spartan Books, 1964.
- [6] D. C. Psychogios and L. H. Ungar, *SVD-NET: an algorithm that automatically selects network structure*, IEEE Transactions on Neural Networks, vol.5 issue 3, pp. 513-515, May, 1994.
- [7] *Coupled Water Tanks Experiments*, Quanser Consulting.