



## 4º Exercício

### Controle NARMA-L2 de Processo de Nível

O objetivo deste experimento é simular um controlador neural NARMA-L2 para um processo de nível de líquidos de 2<sup>a</sup> ordem. A vantagem deste controlador em relação aos controladores lineares é que é possível obter, aproximadamente, a mesma dinâmica (tempo de subida/descida, sobresinal/subsinal e erro em regime permanente) em toda a faixa de operação do processo. Esta técnica de controle também é conhecida por “linearização por realimentação” e fornece, considerando-se a saturação do atuador, a resposta mais rápida possível. Uma escolha inadequada dos parâmetros de projeto leva a chaveamentos freqüentes do sinal de controle (“chattering”).

#### 1 – Introdução – O processo de nível

Processos de nível de líquido aparecem freqüentemente na indústria (e.g., refinarias, usinas de álcool, indústria de alimentos). Em várias situações o líquido depois de processado é passado de um tanque para outro tanque adjacente. Neste experimento utilizaremos o modelo simplificado do processo de 2<sup>a</sup> ordem, Figura 1. A figura 2 mostra o modelo de simulação não linear. A raiz quadrada do nível h2 e da diferença de níveis (h1-h2), a função módulo e a saturação do atuador e dos níveis h1 e h2 são características não lineares. Ver roteiro LabCDin4\_EE\_nivel.pdf, para mais detalhes.

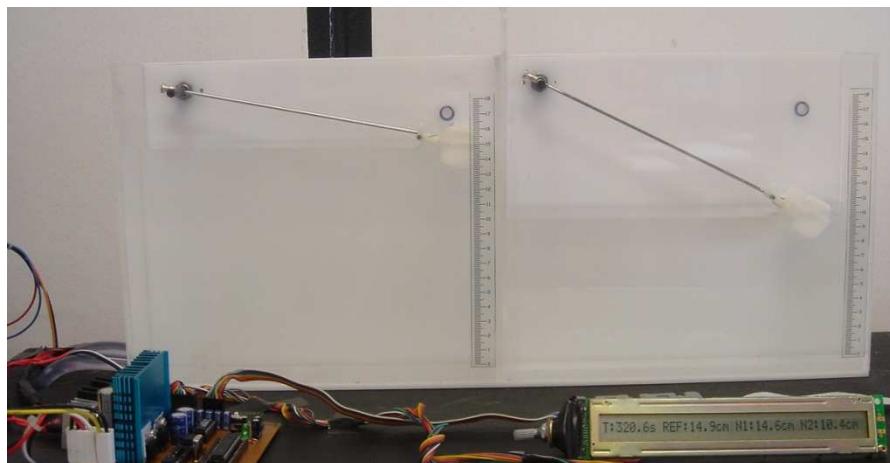


Figura 1 – Processo de nível de líquidos de 2<sup>a</sup> ordem.

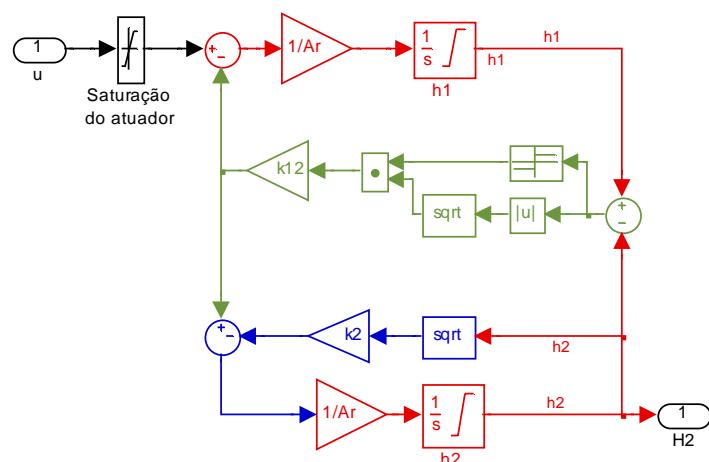


Figura 2 – Modelo não-linear do processo de nível de líquidos de 2<sup>a</sup> ordem.



## 2 – Controle NARMA-L2 (Feedback Linearization)

Um dos modelos mais utilizados para modelar sistemas não-lineares é o modelo discreto NARMA (Non-Linear Auto Regressive Moving Average):

$$y(k+d) = N[y(k), y(k-1), \dots, y(k-n+1), u(k), u(k-1), \dots, u(k-n+1)] \quad (1)$$

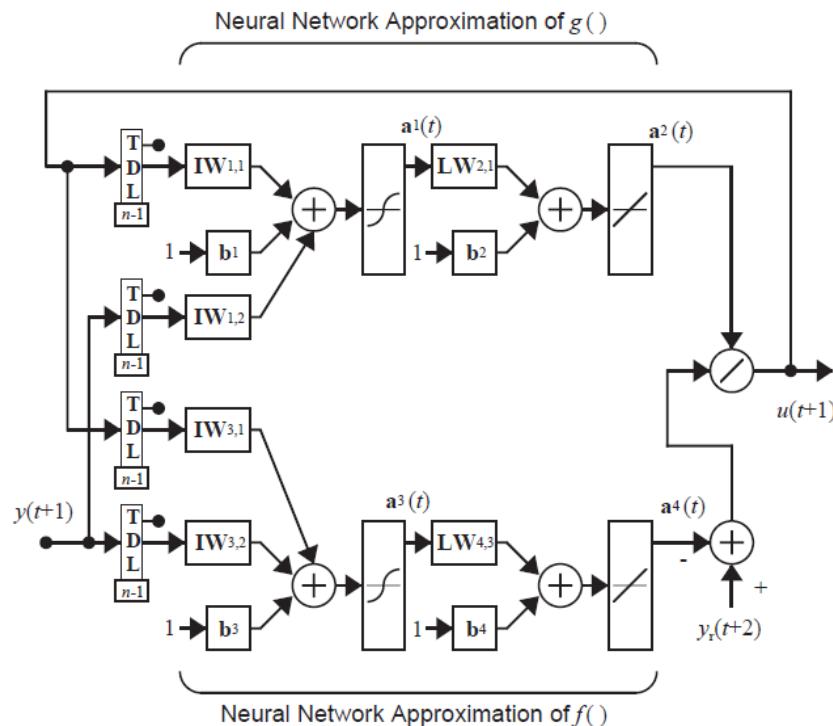
onde  $u(k)$  é o sinal de entrada,  $y(k)$  é o sinal de saída do sistema e  $d$  é o atraso. A utilização deste modelo em uma RNA para minimizar o erro quadrático médio (norma L2) é, geralmente, muito lenta. Narendra e Mukhopahayay, (Adaptive Control Using Neural Networks and Approximate Models. IEEE Transactions on Neural Networks, Vol. 8, No 3, May 1997, pp. 475-485), propuseram um controlador utilizando o seguinte modelo NARMA-L2 aproximado:

$$\begin{aligned} y(k+d) &= f[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)] \\ &\quad + g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)] \cdot u(k) \end{aligned} \quad (2)$$

Neste modelo o próximo sinal de controle  $u(k)$  não aparece nas funções não lineares e pode ser facilmente resolvido. Considerando um sinal de referência a ser seguido  $y_r(k+d) \equiv y(k+d)$ , temos a lei de controle NARMA-L2:

$$\begin{aligned} u(k) &= y_r(k+d) - f[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)] \\ &\quad - g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)] \end{aligned} \quad (3)$$

Redes neurais MLP com linhas de atraso (TDL – Time Delay Lines) implementam as funções  $f(\cdot)$  e  $g(\cdot)$  no bloco “NARMA-L2 Controller”, conforme pode ser visto na figura 3.



**Figura 3** – Modelo NARMA-L2 utilizando Redes Neurais Perceptron Multicamadas e TDLs.

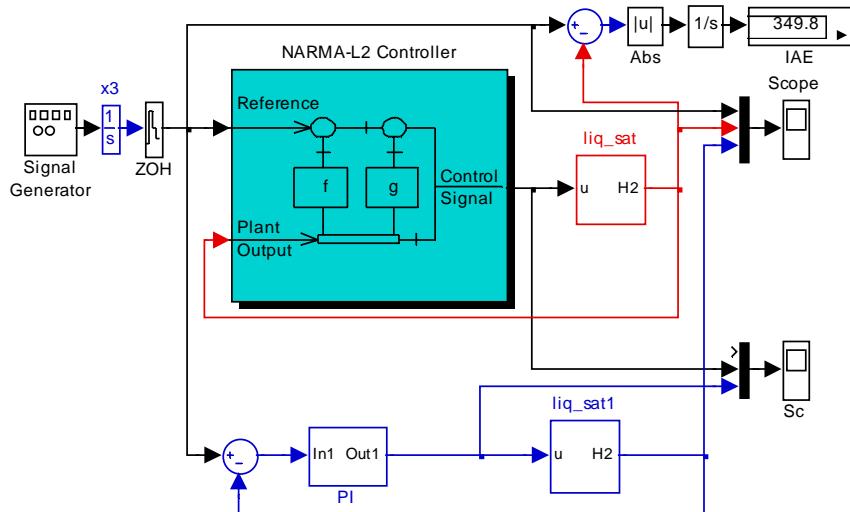
Esta técnica de controle **identifica** numa primeira fase o modelo não linear do processo, segundo a equação (2). Para tanto faz-se necessário **simular** o processo a ser controlado produzindo o conjunto de treinamento da RNA:

**Pattern** =  $[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)]$ , **Target** =  $[y(k+d)]$ ,  $k = 1, 2, \dots, N$ ;  $N$  amostras.



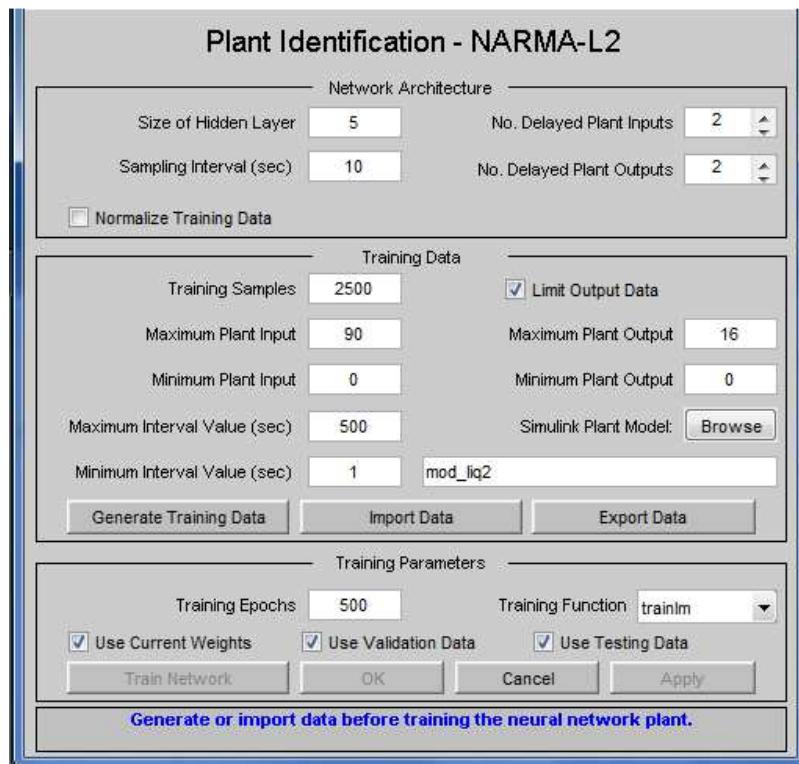
### 3 – Controle NARMA-L2 do processo de nível

A toolbox de redes neurais artificiais do MatLab implementa o controlador NARMA-L2, que será aqui utilizada para controlar o processo de nível de líquidos de 2<sup>a</sup> ordem, ver figura 4. Para efeito de comparação dos controladores implementa-se o critério IAE, *Integral of Absolute Error* e também um controlador linear PI.



**Figura 4** – Processo de nível de líquidos de 2<sup>a</sup> ordem.

A figura 5 mostra a GUI “NARMA-L2” que permite tanto simular o processo (etapa mais demorada) como modelar o processo através de uma rede neural MLP. O botão “Apply” atribui os pesos aos neurônios correspondentes do controlador NARMA-L2, ver equação (3) e figura 3.



**Figura 5** – Parâmetros típicos NARMA-L2 para o processo de nível de líquidos de 2<sup>a</sup> ordem.

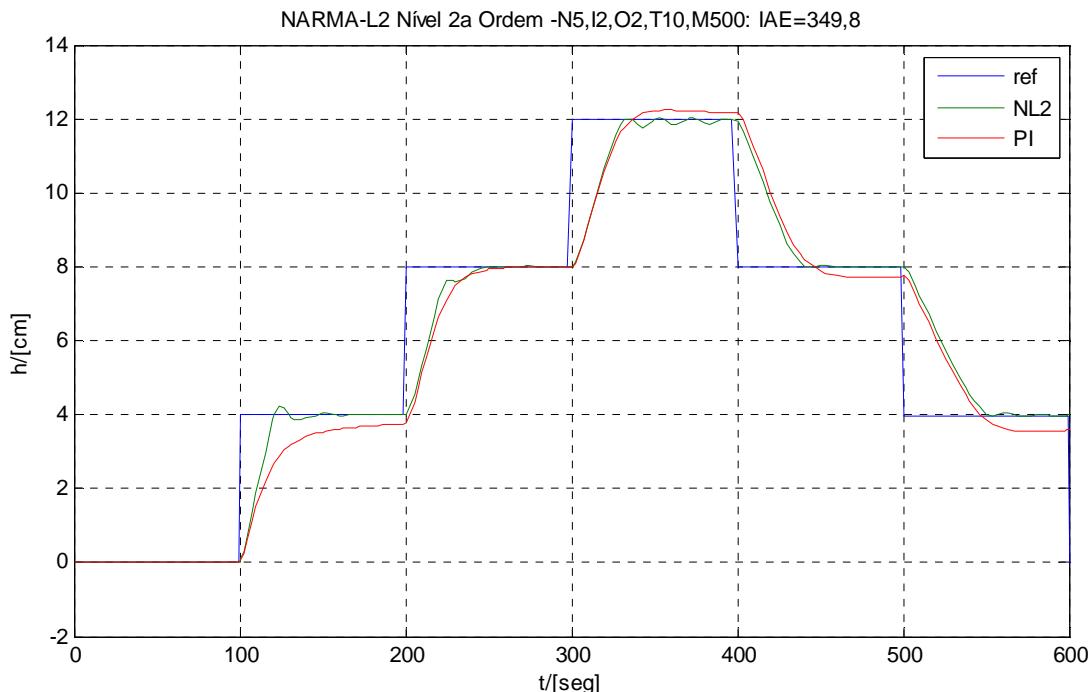


## 4 – Procedimento

O controlador NARMA-L2 tem diversos parâmetros de projeto. O propósito deste experimento é identificar a configuração de parâmetros que minimiza o critério IAE, *Integral of Absolute Error*, variando-se os parâmetros da tabela 1. A figura 6 apresenta uma curva típica obtida com o controlador NARMA-L2.

Tabela 1 – Faixa de parâmetros para o controlador NARMA-L2.

# de neurônios	1 a 20
# de entradas defasadas	1 a 4
# de saídas defasadas	1 a 8
Período de amostragem (seg)	1 a 10
Intervalo Máximo (seg)	100 a 500



**Figura 6** – Resultado típico do controlador NARMA-L2 para o processo de nível de líquidos de 2<sup>a</sup> ordem.

## 5 – Relatório

- Incluir todos os cálculos e considerações que nortearam a escolha dos parâmetros.
- Incluir as simulações realizadas de forma compacta (agrupar variações do mesmo parâmetro).
- Discorrer sobre a “melhor” escolha de cada parâmetro.
- Com a experiência adquirida se o problema fosse agora controlar um processo de nível de 4<sup>a</sup> ordem, quais seriam sugestões “expert” para os parâmetros da tabela 1?