

CONTROLE PREDITIVO BASEADO EM UM MODELO NEURAL APLICADO A UM SISTEMA NÃO-LINEAR DE TANQUES ACOPLADOS

URIEL I. O. DA CRUZ*, TITO L. M. SANTOS*, ACBAL R. A. ACHY[†], CRISTIANE C. PAIM*

**Universidade Federal da Bahia
R. Aristides Novis, N.02, Federação
Salvador, Bahia, Brasil*

*†Universidade Federal do Recôncavo da Bahia
Rua Rui Barbosa, N.710, Centro
Cruz das Almas, Bahia, Brasil*

Emails: u.i.o.cruz@gmail.com, tlsantos@ufba.br, acbal.achy@gmail.com, cpaim@ufba.br

Abstract— This paper presents a model predictive control (MPC) strategy based in a neural network model. The proposed strategy gather several elements of others nonlinear MPC techniques to simplify modelling and implementation algorithms. The control algorithm is tested in an experimental multivariable and nonlinear level control plataforma in order to evaluate set-point tracking and disturbance rejection behavior performance.

Keywords— Intelligent control systems, artificial intelligence techniques in control systems, predictive control, coupled nonlinear tanks system, neural networks

Resumo— Neste artigo apresenta-se uma estratégia de controle preditivo baseado em modelo obtido através de uma rede neural. A estratégia proposta reúne elementos diversas técnicas de controle preditivo não-linear com o objetivo de simplificar o procedimento de modelagem e de implementação do algoritmo de controle. O algoritmo de controle é testado experimentalmente em uma plataforma multivariável não-linear de controle de nível com vistas a avaliar seu desempenho tanto para o caso servo como para o caso regulador.

Keywords— Sistemas de controle inteligentes, Técnicas de inteligência artificial em controle, Controle preditivo, Sistema Não-linear de Tanques Acoplados, rede neurais

1 Introdução

O controle de sistemas industriais complexos com especificações e critérios de qualidade seletivos, baixo desperdícios e custos, tem levado a uma crescente demanda por estratégias de controle capazes de operar eficientemente sobre essas condições. Dentro deste contexto, os problemas de controle não-linear têm se destacado na medida em que as técnicas lineares de modelagem e controle podem levar a um desempenho insatisfatório sob determinadas condições (Findeisen and Allgöwer, 2002). Estratégias de Controle Preditivo Baseado em Modelo¹ vêm ampliando o rol de aplicações por tratar de maneira natural de aspectos práticos como restrições e não-linearidades (Camacho and Bordons, 1998).

A evolução das ferramentas de otimização e das técnicas de controle preditivo linear têm permitido a execução de algoritmos de controle em intervalos de tempo cada vez menores (Wang and Boyd, 2010). Já para sistemas não-lineares, o problema de otimização não é convexo, o que aumenta a complexidade computacional do algoritmo de otimização (Findeisen and Allgöwer, 2002). Neste caso, é necessário recorrer a estratégias de controle não-linear que utilizam horizonte de predição e de controle mais curtos (Findeisen and Allgöwer, 2002) ou recorrer a técnica de aproximam o problema de otimização não-

linear para um problema convexo do tipo programação quadrática²(Lawrynczuk, 2011). Em grande parte das aplicações práticas, costuma-se recorrer a tipos variados de aproximações, obtendo soluções sub-ótimas, mas que têm apresentado um bom desempenho (Åkesson and Toivonen, 2006; Lawrynczuk, 2008; Plucenio et al., 2007; Bravo and Normey-Rico, 2009; Lawrynczuk, 2011).

Tanto o processo de identificação, quanto as técnicas de controle preditivo para sistemas lineares, já atingiram um nível de maturidade considerável(Ljung, 2010; Findeisen and Allgöwer, 2002). Por outro lado, o problema de modelagem de sistemas não-lineares ainda apresenta diversas questões em aberto (Ljung, 2010). As propriedades de aproximação de funções das redes neurais as habilitam como poderosas ferramentas para a descrição de modelos dinâmicos não-lineares (Åkesson and Toivonen, 2006).

Neste trabalho apresenta-se uma estratégia de controle preditivo baseado num modelo obtido a partir de uma rede neural, a qual reúne elementos simplificadores de outras técnicas de controle preditivo não-linear. Esta técnica divide a predição do comportamento futuro da saída do modelo em duas parcelas, uma linear, que é uma função afim das ações de controle futuras, e outra não-linear, que independe das ações de controle futuras. Esta aproximação tem o objetivo de tornar o problema

¹Do inglês MPC.

²Do inglês QP

convexo, semelhante ao MPC linear (Åkesson and Toivonen, 2006; Lawrynczuk, 2008; Plucenio et al., 2007). O principal objetivo desta estratégia é obter uma técnica de controle avançado para sistemas não-lineares com restrições, que possa ser implementada de forma simples e eficiente, tanto do ponto de vista computacional, quanto de desempenho do sistema de controle. A implementação, os testes e a avaliação dos resultados foram realizados utilizando plataforma multivariável de controle de nível composta por uma planta didática de vasos comunicantes com diferentes geometrias.

A apresentação do trabalho está dividida da seguinte maneira: na Seção 2 são apresentados os aspectos teóricos relacionados ao modelos considerados; na Seção 3 propõe-se o algoritmo de controle preditivo e na Seção 4 apresenta-se o sistema de tanques acoplados. Os resultados experimentais e os comentários finais são expostos nas Seções 5 e 6 respectivamente.

2 Fundamentação teórica

Neste trabalho considera-se um sistema não-linear invariante no tempo como segue:

$$\begin{aligned} x_{k+1} &= f(x_k, u_k) + w_k \\ y_k &= h(x_k) + v_k \end{aligned} \quad (1)$$

sendo $x_k \in \mathbb{R}^n$ o vetor de estados no instante k , $u_k \in \mathbb{R}^m$ o sinal de controle, $y_k \in \mathbb{R}^p$ o sinal de saída, $w_k \in \mathbb{R}^n$ uma perturbação aditiva nos estados e $v_k \in \mathbb{R}^p$ uma perturbação aditiva na saída. Assume-se que o sistema é sujeito a restrições nos estados e na entrada $x_k \in X \subset \mathbb{R}^n$, $u_k \in U \subset \mathbb{R}^m$.

No caso nominal, com vistas a modelar o comportamento dinâmico descrito na Eq. (1), utiliza-se uma rede neural recorrente (Grancharova et al., 2010) representada como segue:

$$\begin{aligned} z_k &= [y_k, y_{k-1}, \dots, y_{k-l_y}, u_k, u_{k-1}, \dots, u_{k-l_u}] \\ \bar{y}_{k+1} &= g(z_k, \theta) = g_{rn}(z_k) \end{aligned} \quad (2)$$

sendo z_k o vetor de regressores relativo ao instante k , l_y e l_u as ordens de regressão, θ os parâmetros da rede (pesos sinápticos). Deve-se notar que $g(\cdot, \cdot)$ é a função que realiza o mapeamento da rede neural e a mesma pode ser representada diretamente por $g_{rn}(\cdot)$, na medida em que os pesos sinápticos devem ser fixados após o treinamento uma determinada rede.

Devido a presença de incertezas, ruído, perturbações constantes e o próprio erro de modelagem, necessariamente existirá uma diferença entre o valores de saída, determinado pela rede neural, \bar{y}_{k+1} , e o valor real, y_{k+1} . Esta diferença pode ser corrigida através de um sinal de erro dado por $e_k = y_{k+1} - \bar{y}_{k+1}$, o que resulta numa descrição

como segue:

$$\begin{aligned} z_k &= [y_k, y_{k-1}, \dots, y_{k-l_y}, u_k, u_{k-1}, \dots, u_{k-l_u}] \\ y_{k+1} &= g_{rn}(z_k) + e_k. \end{aligned} \quad (3)$$

Deve-se ressaltar que o erro de predição de um passo adiante, e_k , é desconhecido no instante k , de maneira que a equação (3) não pode ser utilizada para fins de predição. Por outro lado, é possível calcular e_{k-1} , pois $e_{k-1} = y_k - g_{rn}(z_{k-1})$, erro este que pode ser utilizado para fins de predição. Em decorrência da presença de dinâmicas não modeladas e ruído de altas frequências, é importante utilizar um filtro passa-baixas com ganho unitário para atenuar o efeito indesejado de componentes de altas frequências. Em geral, um filtro passa-baixas de primeira ordem já apresenta bons resultados (Limon et al., 2010):

$$\xi_k = \alpha \xi_{k-1} + (1 - \alpha) e_{k-1}$$

sendo α o parâmetro de sintonia com $1 > \alpha > 0$.

Finalmente, o modelo neural de predição considerado no presente trabalho é dado por

$$\begin{aligned} z_k &= [y_k, y_{k-1}, \dots, y_{k-l_y}, u_k, u_{k-1}, \dots, u_{k-l_u}] \\ \hat{y}_{k+1|k} &= g_{rn}(z_k) + \xi_k. \end{aligned} \quad (4)$$

sendo $\hat{y}_{k+1|k}$ a predição obtida para y_{k+1} dadas as informações do instante k . Para modelar perturbações constantes em um dado instante k , considera-se $\xi_k = \xi_{k+j}$, $j > 0$. As predições $\hat{y}_{k+j|k}$ podem ser obtidas de forma recursiva a partir da Eq. (4).

3 Controlador proposto

Nesta seção será apresentado um controlador preditivo sub-ótimo baseado em um modelo neural (Lawrynczuk, 2008; Lawrynczuk, 2011). A técnica recai num problema de otimização convexo tipo QP com um desempenho que se aproxima aos resultados obtidos com programação não-linear (Plucenio et al., 2007).

Para tanto, considera-se um problema de otimização comum às técnicas de controle preditivo dado por:

$$\min_{\mathbf{U}_k} \sum_{j=1}^N \|\hat{y}_{k+j|k} - r_{k+j|k}\|_Q + \sum_{j=0}^{N_u-1} \|\Delta u_{k+j|k}\|_R$$

s.a.

$$y_{\min} \leq \hat{y}_{k+j|k} \leq y_{\max}, \quad 1 \leq j \leq N,$$

$$u_{\min} \leq u_{k+j|k} \leq u_{\max}, \quad 0 \leq j \leq N_u - 1.$$

sendo $r_{k+j|k} \in \mathbb{R}^p$ o vetor de referência futura, $\Delta u_{k+j|k} = u_{k+j|k} - u_{k+j-1|k}$ o incremento do sinal de controle, R a matriz de ponderação do sinal de controle³, Q a matriz de ponderação do erro e

³Neste trabalho, considera-se a notação padrão, $\|u\|_R \triangleq u' R u$.

$\mathbf{U}_k = [\Delta u'_{k|k} \ \Delta u'_{k+1|k} \ \dots \ \Delta u'_{k+N_u-1|k}]'$ o vetor de seqüência de incrementos de controle futuros.

Para que o problema de otimização seja convexo, é necessário descrever o vetor de saídas previstas, $\hat{\mathbf{Y}}_{k|k} = [\hat{y}'_{k+1|k} \ \hat{y}'_{k+2|k} \ \dots \ \hat{y}'_{k+N|k}]'$, como uma função afim da seqüência de controles futuros \mathbf{U}_k conforme descrito a abaixo:

$$\hat{\mathbf{Y}}_{k|k} = \tilde{\mathbf{Y}}_k + \mathbf{G}(\mathbf{k})\mathbf{U}_k$$

A rigor, por se tratar de um sistema não-linear, não se pode dividir a resposta em uma parcela livre e outra forçada, pois o princípio da superposição não é válido. No entanto, para este tipo de algoritmo, o processo de convexificação do problema de otimização advém de uma aproximação linear do sistema não-linear a cada instante k . Deste modo, costuma-se chamar o vetor $\tilde{\mathbf{Y}}_k$ de resposta livre e a parcela $\hat{\mathbf{Y}}_{f,k} = \mathbf{G}(\mathbf{k})\mathbf{U}_k$ de resposta forçada (Plucenio et al., 2007; Lawrynczuk, 2008; Lawrynczuk, 2011).

3.1 Respostas livre e forçada

A resposta livre pode ser interpretada como a evolução das saídas previstas dado que os incrementos de controle são nulos. Neste caso, ela pode ser obtida recursivamente a partir da Eq. (4), utilizando a regra indicada a seguir:

$$\begin{aligned} \tilde{z}_{k+j} &= [\tilde{y}_{k+j}, \dots, \tilde{y}_{k+j-l_y}, \tilde{u}_{k+j}, \dots, \tilde{u}_{k+j-l_u}] \\ \tilde{y}_{k+j+1|k} &= g_{rn}(\tilde{z}_{k+j}) + \xi_k. \end{aligned} \quad (5)$$

com $\tilde{u}_{k+i} = u_{k+i}$, se $i < 0$; $\tilde{u}_{k+i} = u_{k-1}$, se $i \geq 0$; $\tilde{y}_{k+i} = y_{k+i}$, se $i \leq 0$; $\tilde{y}_{k+i} = \tilde{y}_{k+i|k}$, se $i > 0$. Desta maneira, é possível obter o vetor de resposta livre dado por $\tilde{\mathbf{Y}}_{k|k} = [\tilde{y}'_{k+1|k} \ \tilde{y}'_{k+2|k} \ \dots \ \tilde{y}'_{k+N|k}]'$. Na prática, esta predição pode ser realizada diretamente em ambiente de simulação, mantendo a ação de controle mais atual, u_{k-1} , inalterada.

Diferentemente da resposta livre, na qual deseja-se descobrir o vetor $\tilde{\mathbf{Y}}_{k|k}$, no caso da resposta forçada é necessário conhecer a matriz $\mathbf{G}(\mathbf{k})$ que permitirá realizar as predições em função da seqüência de controle futuros que é a variável de otimização. Para tanto, é possível obter um modelo linear a cada ponto e posteriormente realizar um procedimento para cálculo da matriz $\mathbf{G}(\mathbf{k})$ baseado em técnicas de controladores lineares (Lawrynczuk, 2008; Lawrynczuk, 2011) ou pode-se recorrer a procedimentos numéricos para realização da aproximação linear (Plucenio et al., 2007). Optou-se pelo procedimento numérico devido à simplicidade de implementação e dos bons resultados já obtidos (Plucenio et al., 2007).

Considere uma seqüência futura qualquer, \mathbf{U}_k , a ser aplicada no modelo não-linear. A evolução das saídas previstas é determinada por:

$$\begin{aligned} \hat{z}_{k+j} &= [\hat{y}_{k+j}, \dots, \hat{y}_{k+j-l_y}, \hat{u}_{k+j}, \dots, \hat{u}_{k+j-l_u}] \\ \hat{y}_{k+j+1|k} &= g_{rn}(\hat{z}_{k+j}) + \xi_k. \end{aligned} \quad (6)$$

com $\hat{u}_{k+i} = u_{k+i}$, se $i < 0$; $\hat{u}_{k+i} = \hat{u}_{k+i-1} + \Delta u_{k+i}$, se $i \geq 0$; $\hat{y}_{k+i} = y_{k+i}$, se $i \leq 0$; $\hat{y}_{k+i} = \hat{y}_{k+i|k}$, se $i > 0$. Desta maneira, é possível obter o vetor de resposta livre dado por $\hat{\mathbf{Y}}_{k|k} = [\hat{y}'_{k+1|k} \ \hat{y}'_{k+2|k} \ \dots \ \hat{y}'_{k+N|k}]'$. Esta predição também pode ser realizada diretamente em ambiente de simulação, adicionando os incrementos de controle Δu_{k+i} a cada instante. Deve-se enfatizar que \mathbf{U}_k pode ser uma seqüência de controle qualquer. No caso de sistemas lineares, utiliza-se um degrau unitário na técnica DMC⁴. Para sistemas não-lineares, quanto menor a amplitude do desta seqüência, melhor a aproximação linear em torno do ponto atual. Por outro lado, em sistemas reais, devido a presença de ruído, este sinal não pode ser muito pequeno para que não se reduza a relação sinal ruído substancialmente.

Assim, pode-se notar a relação a seguir:

$$\mathbf{G}(\mathbf{k})\mathbf{U}_k = \hat{\mathbf{Y}}_{k|k} - \tilde{\mathbf{Y}}_k$$

sendo $\mathbf{G}(\mathbf{k})$ uma matriz a ser determinada a cada instante k . Esta matriz tem dimensão $N \cdot p \times N_u \cdot m$, o que nos leva a um problema linear com infinitas soluções, pois o mesmo possui $N \cdot p$ equações e $N \cdot p \cdot N_u \cdot m$ incógnitas. Neste caso, pode-se optar por diversas soluções. Por simplicidade de apresentação, sem perda de generalidade, apresenta-se o caso monovariável $m = p = 1$. Uma das soluções mais intuitivas decorre de uma aproximação discretizada do Jacobiano de $\hat{\mathbf{Y}}_{k|k} - \tilde{\mathbf{Y}}_k$ com relação a \mathbf{U}_k . Esta abordagem é parecida com a abordagem do PNMPC⁵ (Plucenio et al., 2007) sendo dada por

$$\mathbf{G}(\mathbf{k}) = \begin{bmatrix} g_{11}(k) & 0 & 0 & \dots & 0 \\ g_{21}(k) & g_{22}(k) & 0 & \dots & 0 \\ g_{31}(k) & g_{32}(k) & g_{33}(k) & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ g_{N1}(k) & g_{N2}(k) & g_{N3}(k) & \dots & g_{NN_u}(k) \end{bmatrix}$$

com

$$g_{i1}(k) = \frac{\hat{y}_{k+j|k} - \tilde{y}_{k+j|k}}{\Delta u_{k|k}}$$

e

$$g_{ij}(k) = \frac{\hat{y}_{k+i|k} - \hat{y}_{k+i-1|k}}{\Delta u_{k+j-1|k}}, \quad i \geq 2.$$

Para este caso, $\Delta u_{k+j-1|k} \neq 0, \forall j \geq 0$. No caso multivariável, basta concatenar as submatrizes $G(k)_{ij}, i = 1 \dots p, j = 1 \dots m$.

Outra possibilidade, baseada na resposta ao degrau do DMC, consiste em utilizar uma aproximação linear mais simples como segue

$$\mathbf{G}(\mathbf{k}) = \begin{bmatrix} g_1(k) & 0 & \dots & 0 \\ g_2(k) & g_1(k) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_N(k) & g_{N-1}(k) & \dots & g_{N-N_u+1}(k) \end{bmatrix}$$

⁴Do inglês *Dynamic Matrix Control*

⁵Do inglês *Practical Non-Linear Model Predictive Control*

com $\Delta u_{k+j|k} = 0$, $j \geq 1$ e o elemento g_j dado por:

$$g_j(k) = \frac{\hat{y}_{k+j|k} - \tilde{y}_{k+j|k}}{\Delta u_{k|k}}.$$

Este tipo de aproximação é mais pobre no que diz respeito à captação das características não-lineares. No entanto, a escolha de $\Delta u_{k|k}$ não precisa ser muito rigorosa, pois basta que $\Delta u_{k|k}$ seja suficientemente pequeno para que $\hat{y}_{k+j|k}$ não se afaste muito do ponto de operação, o que é mais simples do que no caso anterior. Como dito anteriormente, se $\Delta u_{k+j|k}$ assumir valores da ordem do ruído de medição, o seu efeito será comparável ao de ξ_k , o que requer uma sintonia mais rigorosa do filtro passa-baixas. Por outro lado, a sintonia do filtro passa-baixas, afeta a rejeição de perturbações constantes. Assim, $\mathbf{G}(\mathbf{k})\mathbf{U}_k$ pode ser calculado de várias maneiras, dependendo essencialmente do grau de não-linearidade do sistema, o que não está no escopo deste trabalho.

O algoritmo proposto faz uso de elementos bem conhecidos da literatura de controle preditivo para sistemas não-lineares, a saber: modelo baseado em uma rede neural recursiva (Lawrynczuk, 2008; Lawrynczuk, 2011), obtenção da matriz de resposta forçada obtido através de aproximação numérica (Plucenio et al., 2007) e modelo de perturbações constantes com estimador de perturbações similar ao DMC. A combinação destas técnicas permite aplicar uma técnica de controle preditivo para sistemas não lineares que é simples no que diz respeito à modelagem, à sua implementação, bem como ao entendimento do seu funcionamento.

4 Sistema de tanques acoplados

O controle de nível em tanques é um tipo de problema comumente encontrado, tanto no ramo acadêmico (Johansson, 2000), quanto no industrial (Campos and Teixeira, 2006). A plataforma multivariável controle de nível, utilizada neste trabalho, pode ser dividida em quatro partes principais: estrutura física de acomodação dos tanques, sistema hidráulico da coluna, sistema elétrico e Interface Homem Máquina (IHM). Na Figura 1 é mostrado o kit didático multivariável em questão. O algoritmo de controle é implementado num Computador Pessoal convencional que se comunica com um Controlador Lógico Programável, o qual é responsável pelo envio do sinal de controle aos atuadores. Este sistema de tanques é interessante do ponto de vista didático, pois a geometria da sua seção transversal não é constante, criando uma não-linearidade dinâmica.

Por simplicidade, supõe-se dois tanques acoplados com escoamento laminar nas saídas dos tanques, de maneira que se assume que as vazões de saída e de transmissão são proporcionais ao



Figura 1: Kit didático do sistema multivariável desenvolvido no laboratório da UFBA.

nível. Neste caso, um modelo fenomenológico simplificado é dado por

$$\begin{aligned} \dot{h}_1(t) &= \frac{1}{A_1(h_1(t))} [u_1(t) - c_1 h_1(t) - c_t (h_1(t) - h_2(t))] \\ \dot{h}_2(t) &= \frac{1}{A_2(h_2(t))} [u_2(t) - c_2 h_2(t) + c_t (h_1(t) - h_2(t))] \end{aligned}$$

sendo c_1 , c_2 e c_3 constantes, $u_1(t)$ e $u_2(t)$ as vazões de entrada, $h_1(t)$ e $h_2(t)$ os respectivos valores de nível e $A_1(\cdot)$ e $A_2(\cdot)$ as áreas das seções transversais em função do nível. Assim, pode-se observar que a simples dependência das áreas $A_1(\cdot)$ e $A_2(\cdot)$ com seus respectivos níveis provocam um comportamento não-linear. Adicionalmente, sabe-se que em função do regime de escoamento, a relação das vazões de saída com o nível podem ser aproximados por uma função que depende da raiz quadrada do nível. Devido à limitação do tanque pulmão, são utilizados apenas dois tanques. Neste caso, são utilizados os tanques 2 e 3, os quais apresentam o comportamento não-linear mais acentuado.

Foram aplicados degraus de amplitudes distintas para os tanques em questão e observou-se que a constante de tempo do tanque 2 pode variar entre 26s e 45s, ao passo que a constante de tempo do tanque 3 pode variar entre 20s e 42s. Para fins de identificação e controle, utiliza-se um período de amostragem $T_a = 2s$. Por se tratar de um sistema de segunda ordem, optou-se por utilizar uma rede neural com um atraso na entrada, $l_u = 1$, e dois na saída, $l_y = 2$, e uma camada escondida. A função de ativação das camadas escondidas é do tipo sigmóide e a camada de saída apresenta uma função linear. Após diversos testes, observou-se que uma rede cinco neurônios na camada escondida apresentava um bom desempenho com um grau moderado de complexidade. No procedimento de treinamento utilizou-se o algoritmo Levenberg-Marquardt com minimização do erro médio quadrático. As redes foram excitadas com um sinal do tipo Pseudo-Aleatório de

Múltiplos Níveis com um período mínimo de 10s e um período máximo de 180s com um intervalo de 3500s para treinamento (1750 pontos) e 900s para validação. As saídas utilizadas para validação são apresentadas na Fig. 2, sendo definidos os valores de 15 e 15,5 cm da régua milimetrada como os pontos de operação dos tanques 2 e 3 respectivamente, o que corresponde à aproximadamente 20 cm da base do tanque. Para atingir este valor, é necessário utilizar aproximadamente 60% da vazão nominal. Arbitrou-se o ponto de operação como nível 0 cm.

5 Resultados Experimentais

Nesta seção serão apresentados os resultados experimentais obtidos no kit didático de controle de nível apresentado na Seção 4. O principal objetivo é avaliar o comportamento do algoritmo frente a aspectos práticos como dinâmicas não modeladas e ruído de medição.

Os parâmetros de sintonia escolhidos são $Q = 1$, $R = 0,5$, $N = 40$, $N_u = 10$ e $\alpha = 0.7$. $N = 40$ e $N_u = 10$ correspondem a intervalos de 80s e 20s respectivamente, o que permite considerar praticamente todo o comportamento dinâmico de malha fechada para $Q = 1$ e $R = 0.5$. Para cálculo do $\mathbf{G}(\mathbf{k})$, utilizou-se a técnica mais simples com $\Delta u_{k|k} = 1$. Com o intuito de ilustrar a importância de se considerar restrições em determinados sistemas de controle, inicialmente realiza-se uma comparação entre o algoritmo proposto com restrições na variável manipulada⁶ e o algoritmo sem restrições na MV, no qual utiliza-se uma saturação forçada. A vazão dos tanques deve ser superior a 0% e inferior a 100% e os resultados em malha aberta e em malha fechada são apresentados na Fig. 3. Para o caso sem restrições, observa-se o efeito de acúmulo da ação integral (efeito *wind-up*) devido a saturação forçada. Conforme esperado, este efeito indesejado eleva o tempo resposta, o sobressinal e o esforço de controle, o que ilustra a importância de se considerar restrições na MV. Ainda neste teste, pode-se observar que o controlador com restrições apresenta um tempo de acomodação de 2% da ordem de 40s, que é menos da metade do tempo de acomodação de malha aberta, mesmo com a presença de restrições na MV. O caso servo para seguimento de referência para o tanque 3 é apresentado na Figura 4. Este teste é útil para indicar o efeito do acoplamento na medida em que a MV do tanque 2 deve ser alterada, a despeito da mudança de referência ser imposta apenas ao tanque 2.

Posteriormente, com o intuito de avaliar o desempenho regulador, utilizou-se uma terceira mangueira/bomba para inserir uma perturbação de 10% no tanque 2 em 45s e a mesma foi retirada num segundo momento, em torno de 85s.

⁶Do inglês *Manipulated Variable* (MV)

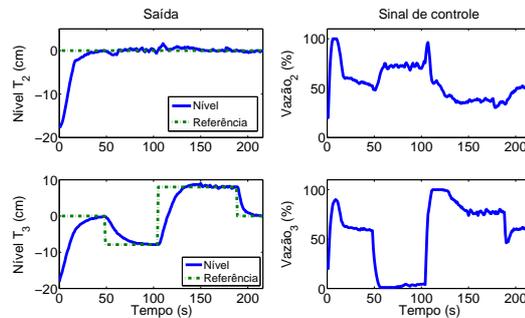


Figura 4: Resposta do sistema em malha fechada - caso servo.

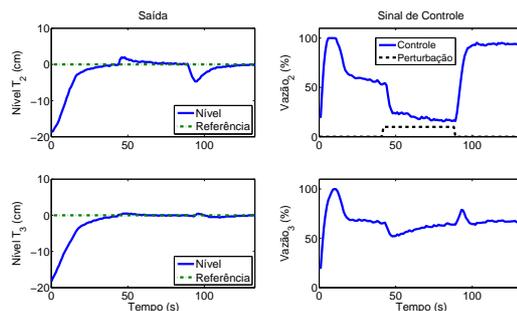


Figura 5: Resposta do sistema em malha fechada - caso regulador.

Conforme esperado, o sistema rejeitou a perturbação e o tempo necessário para rejeita-lá também é da ordem de 40s indicando que a técnica proposta rejeita perturbações constantes de maneira eficiente. No entanto, o elemento mais relevante deste teste advém do fato da MV ter alterações maiores do que 10%. Além disso, ao se retirar a perturbação, o valor da MV foi a um patamar muito acima do observado pré-inserção de perturbação. Obviamente este fato é inesperado, caracterizando alguma alteração das condições de operação/regime de escoamento. Apesar deste fato, o sistema de malha fechada se comportou bem, rejeitando a perturbação num intervalo de tempo relativamente curto se comparado ao tempo de resposta de malha aberta.

6 Conclusões

Neste trabalho foi proposto um algoritmo de controle preditivo para sistemas não-lineares baseado em um modelo formado por uma rede neural. O processo de concepção e implementação do algoritmo é simples, similar a uma estratégia de controle preditivo linear com adaptação do cálculo da resposta livre. A técnica foi testada em um sistema de tanques interconectados com seção transversal variável, apresentando bons resultados do ponto de vista servo e regulador.

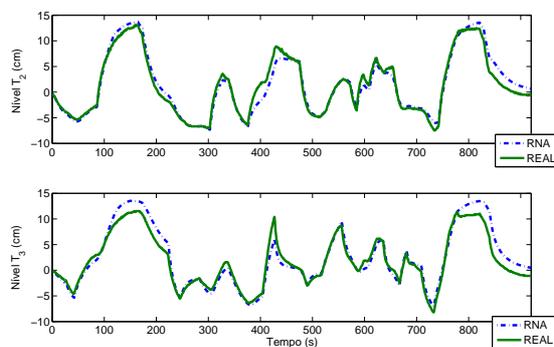


Figura 2: Comparação das respostas para validação da rede neural.

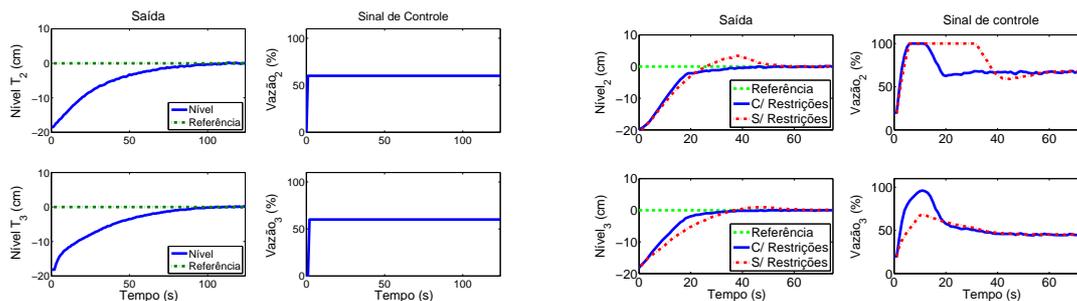


Figura 3: Resposta do sistema em malha aberta (direita) e em malha fechada (esquerda).

Referências

- Bravo, C. O. A. and Normey-Rico, J. E. (2009). Controle de plantas não-lineares utilizando control preditivo linear baseado em modelos locais, *Sba: Controle & Automação Sociedade Brasileira de Automatica* **20**: 465 – 481.
- Camacho, E. and Bordons, C. (1998). *Model Predictive Control*, Springer-Verlag, New York.
- Campos, M. C. M. M. and Teixeira, H. C. G. (2006). *Controles Típicos de Equipamentos e Processos Industriais*, Edgard Blücher.
- Findeisen, R. and Allgöwer, F. (2002). An introduction to nonlinear model predictive control, *21st Benelux Meeting on Systems and Control*, Vol. 11.
- Grancharova, A., Kocijan, J. and Johansen, T. A. (2010). Dual-mode explicit output-feedback predictive control based on neural network models, *8th IFAC Symposium on Nonlinear Control Systems*.
- Johansson, K. (2000). The quadruple-tank process: a multivariable laboratory process with an adjustable zero, *IEEE transaction on control systems technology* **8**(3): 456–465.
- Lawrynczuk, M. (2008). Modelling and nonlinear predictive control of a yeast fermentation biochemical reactor using neural networks, *Chemical Engineering Journal* **145**(2): 290 – 307.
- Lawrynczuk, M. (2011). Accuracy and computational efficiency of suboptimal nonlinear predictive control based on neural models, *Applied Soft Computing* **11**(2): 2202 – 2215.
- Limon, D., Alvarado, I., Alamo, T. and Camacho, E. (2010). Robust tube-based MPC for tracking of constrained linear systems with additive disturbances, *Journal of Process Control* **20**(3): 248 – 260.
- Ljung, L. (2010). Perspectives on system identification, *Annual Reviews in Control* **34**(1): 1 – 12.
- Plucenio, A., Pagano, D., Bruciapaglia, A. and Normey-Rico, J. (2007). A practical approach to predictive control for nonlinear processes nonlinear control systems, *7th IFAC Symposium on Nonlinear Control Systems*, Vol. 7.
- Wang, Y. and Boyd, S. (2010). Fast model predictive control using online optimization, *Control Systems Technology, IEEE Transactions on* **18**(2): 267–278.
- Åkesson, B. M. and Toivonen, H. T. (2006). A neural network model predictive controller, *Journal of Process Control* **16**(9): 937 – 946.