

Rodrigo Cáo Pires

Identificação do modelo do processo em malha fechada com
controlador MPC

Dissertação apresentada à Escola
Politécnica da Universidade de São
Paulo para a obtenção do título de
mestre em Engenharia

São Paulo
2009

FICHA CATALOGRÁFICA

Pires, Rodrigo Cáo

**Identificação do modelo do processo em malha fechada
com controlador MPC / R.C. Pires. -- São Paulo, 2009.
88 p.**

**Dissertação (Mestrado) - Escola Politécnica da Universidade
de São Paulo. Departamento de Engenharia Química.**

**1. Controle preditivo 2. Controle de processos 3. Controla-
dores programáveis I. Universidade de São Paulo. Escola Poli-
técnica. Departamento de Engenharia Química II. t.**

AGRADECIMENTOS

Ao Professor Doutor Darci Odloak, pela orientação, experiência e criatividade sem o quais este trabalho não seria possível.

Ao Laboratório de Simulação e Controle de Processos da Escola Politécnica e as pessoas que lá trabalhavam e indiretamente contribuíram com o trabalho.

À Petrobras que sempre investe em pesquisas na área de controle avançado e no início pude participar de um projeto de desenvolvimento que me deu experiência pra concluir este trabalho.

À Escola Politécnica e à Universidade de São Paulo por sempre apoiar e desenvolver a pós-graduação no Brasil.

À minha família que me apoiou em todos os momentos.

RESUMO

Este trabalho visa o desenvolvimento de uma metodologia para a re-identificação do modelo usado em controladores preditivos (MPC) desenvolvidos em uma estrutura em duas camadas: uma camada estática que calcula os “targets” para as variáveis manipuladas e uma dinâmica que implementa os “targets” para as entradas. Espera-se que esse procedimento de re-identificação seja acionado sempre que for observada uma significativa degradação do modelo de controle do processo. Neste trabalho assume-se que a re-identificação do modelo deve ser realizada em malha fechada. No método aqui proposto, admite-se que o código fonte do programa do controlador preditivo não está disponível, e conseqüentemente, o método proposto não deve requerer qualquer modificação no código fonte. No método aqui proposto, o sinal de excitação é introduzido através dos coeficientes da função objetivo da camada estática que calcula os “targets” para as entradas. O método proposto é testado por simulação em dois processos diferentes. O primeiro processo é uma coluna de destilação para a qual estão disponíveis vários modelos lineares obtidos em diferentes condições operacionais. O segundo processo aqui estudado é um reator químico não linear que deve ser representado localmente por um modelo linear.

Palavras chaves: Controle preditivo baseado em modelo, Identificação de sistemas, Controle de Processos

ABSTRACT

This work aims at the development of a methodology to the re-identification of the model to be used in a MPC, which is developed in a two layers structure: a target calculation layer and a dynamic layer where the targets to the inputs are implemented. It is expected that the re-identification procedure should be started whenever it is observed a significant degradation of the process model. Here, it is assumed that the model re-identification is to be performed in closed-loop. In the method proposed here, it is assumed that the source code of the MPC controller is not available, and consequently, the proposed method should not require any modification the source code. In the method proposed here, the excitation signal is introduced through the coefficients of the objective function of the target calculation layer. The proposed method is tested by simulation in two different processes. The first one is a distillation column where several linear models obtained at different operating conditions are available. The second process studied here is a nonlinear chemical reactor that is locally represented by a linear model.

Key words: MPC control, System Identification, Process Control

SUMÁRIO

INTRODUÇÃO.....	7
REVISÃO DA LITERATURA	8
OBJETIVO	11
1 O Problema de Controle	12
1.1 Camada Dinâmica do MPC	13
1.2 Camada Estática do MPC	24
2 Técnicas de Identificação do modelo para o MPC	26
2.1 Descrição do Sinal de Teste adotado	31
2.2 Identificação do modelo usado pelo MPC.....	33
2.3 Sinal persistentemente excitante.....	36
2.3.1 Sinal Persistentemente excitante para modelos lineares.....	38
3 Exemplo de aplicação do método proposto	42
3.1 Descrição do sistema	42
3.2 Sinal de excitação	47
4 Procedimento de Identificação	51
4.1 Identificação da coluna despropanizadora usando o método de excitação proposto.....	52
4.2 Identificação usando sinal excitação nos “targets” das entradas.....	63
5 Identificação de um sistema não-linear	72
6 Conclusão e Recomendações	82
REFERÊNCIAS BIBLIOGRÁFICAS	84

INTRODUÇÃO

MPC (“Model Predictive Control”) refere-se a uma classe de algoritmos de controle que utilizam um modelo do processo para prever a resposta futura desse processo. A cada instante de amostragem, o controlador MPC otimiza o comportamento futuro da planta calculando uma seqüência de valores de entrada que devem ser aplicados ao processo. Desses, o primeiro é aplicado ao processo e no próximo instante de amostragem os cálculos são repetidos partindo do valor atual do estado do processo. Inicialmente o MPC foi desenvolvido para aplicação em refinarias de petróleo, mas atualmente, há mais de 4500 aplicações de controle avançado tipo MPC reportadas em várias áreas da indústria de processos (Qin e Badgwell, 2003).

O projeto de um controlador preditivo, tradicionalmente consiste em definir inicialmente os objetivos de controle e as restrições do processo, além da escolha das variáveis manipuladas, controladas e perturbações. Uma vez definidas as funções de controle, identifica-se o modelo do processo em um determinado ponto de operação. A seguir, constrói-se o controlador configurando e customizando a sua programação. Em seguida, sintoniza-se o controlador através da simulação e finalmente interliga-se o mesmo aos controladores PID do processo, através de um sistema digital normalmente um SDCD (Sistema Digital de Controle Distribuído).

Um controlador bem projetado vai funcionar bem por vários anos, mas em um grande número de casos, o MPC mostra uma deterioração de seu desempenho ao longo do tempo. As causas da queda de desempenho estão normalmente associadas a alterações no modelo que o MPC usa para fazer a predição das saídas do processo e calcular as entradas. Mudanças no modelo podem estar associadas às alterações nas condições dos equipamentos, como incrustações nos trocadores de calor, perda de eficiência nos pratos de uma coluna de destilação, etc. Essas alterações podem ocorrer na escala de tempo de semanas ou meses. Porém, em alguns processos, podem ocorrer freqüentes alterações nas condições operacionais o que torna a representação da planta pelo modelo usado no MPC inadequada. Alterações no ponto de operação de um processo podem resultar, por exemplo, de mudanças na vazão de carga. Também podem resultar de variações na composição da alimentação do processo ou na especificação do produto que está sendo fabricado. Essas mudanças ocorrem em uma escala de tempo de dias ou até de horas.

REVISÃO DA LITERATURA

Há exemplos de casos estudados na literatura como em Almeida Neto (1999) sobre a dificuldade de manter os produtos de uma torre desbutanizadora de unidade de destilação de petróleo nas especificações desejadas. Essa coluna tem que produzir gasolina e GLP especificados apesar do sistema mudar frequentemente de ponto de operação devido à variação na percentagem de GLP na carga (nafta instável). Isso faz com que o controlador desta torre tenha uma grande dificuldade em operar com uma performance aceitável. Almeida Neto (1999) inicialmente produziu modelos estacionários da coluna através de um simulador rigoroso e avaliou as propriedades da matriz de ganhos, propriedades essas ligadas às características de interações entre as variáveis, condicionamento e sinal do ganho do processo. Em seguida, ele obteve modelos dinâmicos lineares locais através de um simulador dinâmico rigoroso, construiu um novo sistema de controle baseado em vários modelos e avaliou o comportamento, estabilidade e desempenho do controlador em diversas condições do processo. O novo controlador mostrou um desempenho bastante robusto em relação às variações do modelo da coluna, entretanto, o controlador produzido apresentou um esforço computacional bastante superior ao MPC convencional.

Outro exemplo estudado na literatura é apresentado por Porfírio (2001) que, usando o mesmo método, estudou o controle de uma coluna despropanizadora industrial, na qual controladores multivariáveis tradicionais apresentavam grande dificuldade em manter os produtos dentro das especificações, pois, o processo apresentava comportamento bastante não-linear ao longo de toda sua região de operação. Com o objetivo de estudar os limites do sistema quanto à sua capacidade de controle construíram-se também modelos estáticos e dinâmicos lineares locais.

Uma forma de se obter um modelo linear do processo, tal que esse modelo possa ser usado no controlador MPC, é através de técnicas de identificação de sistemas (Ljung, 1999). O estudo dessas técnicas de identificação de sistemas tem sido uma das áreas de pesquisa mais ativas nos últimos 30 anos. Como resultado, inúmeras técnicas foram desenvolvidas as quais podem, em geral, ser classificadas em métodos do erro da predição, “prediction error methods” (PEM) (Ljung, 1999), métodos das variáveis instrumentais, “instrumental variable methods” (IVM) (Söderström e Stoica, 1983), métodos em subespaço de estados, “subspace identification methods” (SIM) (Van Overschee e De Moor, 1996) e métodos de correlação e análise espectral (Jenkins e Watts, 1968). Apesar da necessidade urgente de ferramentas efetivas e eficientes, o PEM, embora chamado ‘convencional’, é o mais usado na geração de

modelos para controle de processos. A maioria dos algoritmos PEM é baseada na minimização do erro de predição *um passo à frente*, os quais geram modelos que não necessariamente fornecem boas predições *k-passos à frente*, que são necessárias na síntese da lei de controle do MPC. Para controladores MPC industriais usa-se, em geral, um modelo tipo caixa-preta (Zhu, 2000) obtido a partir de testes experimentais onde se coletam as entradas (variáveis manipuladas) e saídas (variáveis controladas) do processo.

A identificação de um modelo com várias entradas e várias saídas, Multiple Input Multiple Output (MIMO), é normalmente feita a partir de um estado estacionário a partir do qual o processo é excitado através das entradas em malha aberta. Essa excitação pode ser feita simultaneamente em todas as entradas ou seqüencialmente considerando uma entrada de cada vez. Nesta última estratégia, as entradas, ou variáveis manipuladas, são perturbadas individualmente, mantendo as outras manipuladas nos seus estados estacionários. Esse enfoque leva à identificação de modelos com uma entrada e uma saída, Single Input Single Output (SISO). Portanto, esse método tem a vantagem de observar e produzir a resposta de cada par (entrada x saída) individualmente, porém sua desvantagem é o alto tempo de execução. No teste simultâneo, todas as entradas são perturbadas ao mesmo tempo levando a uma identificação MIMO ou várias entradas para única saída, Multiple Input Single Output (MISO). A vantagem de uma identificação MIMO é que eventuais interações entre as saídas são levadas em conta no desenvolvimento do modelo. No caso de sistemas MIMO, freqüentemente, adota-se o teorema da superposição o que equivale a considerar que é possível a combinação dos modelos SISO para a obtenção (aproximada) de um modelo MIMO. Esta hipótese considera que o sistema é linear, e, é importante notar que quando um modelo MIMO obtido a partir da combinação de modelos SISO é usado para controle, pequenos erros nos modelos individuais podem causar uma significativa degradação do desempenho e instabilidade do sistema.

A excitação das entradas tem que ser informativa o suficiente para uma boa estimativa da direcionalidade do ganho do processo (Waller e Waller, 1995), além de conter energia suficiente para excitar o processo na faixa de freqüências de interesse para o controle. Observe-se que o teste em malha aberta pode forçar o processo para um ponto fora da região normal de operação do processo. Isso pode tornar necessária a introdução de ações corretivas, durante a identificação, para manter as especificações de qualidade dos produtos, ou por segurança em processos instáveis, não-lineares ou com características integradoras. Nesse caso, a identificação denomina-se do tipo malha fechada e novas técnicas de identificação com essa filosofia têm-se mostrado uma ferramenta adequada para

identificação de modelos para controle (Landau, 2001), porque o controlador tende a reduzir os efeitos dos distúrbios introduzidos para excitar o processo e manter o mesmo dentro da faixa de operação desejada.

Poucas aplicações industriais de identificação em malha fechada têm sido reportadas na literatura. Dessas aplicações, Aling e Heintze (1992) usam esse tipo de identificação em uma caldeira industrial e Östring et al. (2003) consideram o caso de identificação do modelo de um robô industrial. Entretanto, nenhum desses casos considera o sistema sendo controlado por um MPC com restrições.

OBJETIVO

Assim, pelo discutido anteriormente, conclui-se que a identificação torna-se muitas vezes necessária para a manutenção do bom desempenho do controlador. É preciso, portanto, buscar meios de facilitar a identificação e validação de novos modelos de processos que estão operando com controladores MPC. Assim, o objetivo principal deste trabalho é propor um procedimento automático de excitação de um processo em malha fechada com o controlador MPC e o procedimento de identificação de um novo modelo a ser usado no controlador. Assume-se que durante o procedimento de excitação, o controlador opere com um modelo desatualizado, que resulta em um desempenho sub-ótimo, mas que ainda permite uma razoável estabilização do processo. O método proposto é testado para dois sistemas da indústria de processos. O primeiro processo é uma coluna de destilação para a qual dispõe-se de um conjunto de modelos lineares correspondentes a diferentes pontos de operação. Nos testes realizados, considera-se que o modelo usado pelo MPC não é o modelo real do processo e o objetivo da re-identificação é obter o modelo real. O segundo processo é um reator de polimerização cujo modelo real é não linear, mas o controlador MPC é baseado em um modelo linear que aproxima o modelo real em um dado estado estacionário. Nesse caso o procedimento de re-identificação do modelo linear é necessário quando o processo muda de estado estacionário.

1 O Problema de Controle

Os controladores MPC estudados na literatura (Maciejowski, 2002, Qin e Badgwell, 2003) tem como objetivo manter a saída do processo em setpoints bem definidos. Embora não conste explicitamente na literatura, os pacotes comerciais de controle MPC usados na indústria são todos projetados em duas camadas, sendo uma camada de controle dinâmico e outra camada de otimização estática. Na camada superior, ou camada estática do controlador, a cada instante de amostragem, um algoritmo de otimização calcula um conjunto de valores ótimos estacionários para as variáveis manipuladas e para as variáveis controladas. Esse problema de otimização considera restrições nas entradas e saídas no estado estacionário. Tais valores ótimos são enviados à camada dinâmica do MPC para sua implementação levando em conta as restrições operacionais dinâmicas. Assim, o problema de controle pode ser subdividido em dois sub-problemas conforme mostrado na Figura 1.1.

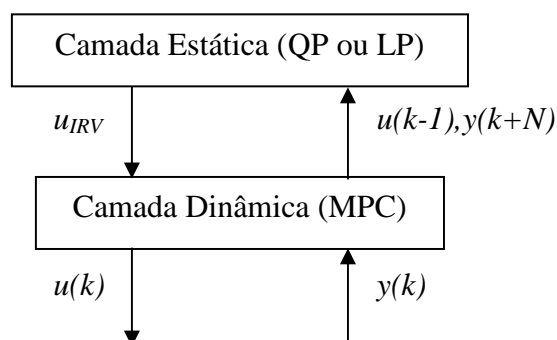


Figura 1.1: Estrutura dos pacotes MPC

Na camada estática de controle calculam-se os valores ótimos das variáveis do processo no estado estacionário u_{IRV} através de uma programação quadrática (QP) ou programação linear (LP) com dados da última ação de controle implementada no processo $u(k-1)$, a previsão da saída no estado estacionário $y(k+N)$ e o modelo estático do processo. Na camada dinâmica, que caracteriza o controlador MPC, resolve-se um problema de controle que considera a leitura das variáveis controladas $y(k)$ do processo obtidas pela camada de controle regulatório e o modelo dinâmico do processo. Após a solução do problema de controle por programação linear (LP) ou programação quadrática (QP), o MPC envia o valor das entradas $u(k)$ para que o controle regulatório aplique as mesmas ao processo.

1.1 Camada Dinâmica do MPC

O termo controle preditivo, Model Predictive Control (MPC), se refere a uma classe de algoritmos de controle que considera a resposta futura do processo através de um modelo do mesmo. A cada instante de amostragem, o controlador resolve um problema de otimização em malha aberta que inclui restrições e envolve o cálculo da trajetória futura das saídas e entradas do processo a partir do estado atual. O resultado da otimização gera uma seqüência de controle que é aplicada de acordo com a filosofia de controle de horizonte móvel (Receding Horizon Control, RHC¹) produzindo um controlador com as características de realimentação desejadas.

As idéias do MPC tiveram início a partir de 1960 (García et al., 1989), porém, o interesse nesse campo começou a crescer a partir de 1980, depois dos trabalhos publicados sobre o MPHC (Model Predictive Heuristic Control) e o DMC (Dynamic Matrix Control), e particularmente, depois do QDMC (Quadratic Dynamic Matrix Control), que ficaram muito populares nas indústrias de refino de petróleo e petroquímica e em estações de força. Desde essa época, têm surgido novas variantes de MPC, tais como: MAC, IMC, GPC, MOOCA, HIECON, PFC, OPC, PCT e RMPCT (Qin e Badgwell, 2003). Apesar das várias siglas e abreviações introduzidas, não existem muitas diferenças entre esses vários algoritmos. Tipicamente, esses algoritmos podem diferir no tipo de modelo do processo usado, na modelagem das perturbações e, eventualmente, nas características de adaptação. Descrições interessantes dessas tecnologias podem ser vistas em García et al. (1989), Morari et al. (1999), Rawlings (2000), Qin e Badgwell (2003) e Camacho e Bordons (2004).

Atualmente, MPC é a técnica de controle avançado mais amplamente usada na indústria de processos. No entanto, apesar do aparecimento incipiente de algoritmos MPC não-lineares (NMPC), a geração corrente de algoritmos MPC comercialmente disponíveis são baseados em modelos lineares (LMPC, ou simplesmente MPC). Na Petrobras, o algoritmo MPC mais usado é o MPC linear, Linear Dynamic Matrix Control (LDMC), conforme apresentado por Morshedi et al. (1985). Para calcular a lei de controle, a camada dinâmica do MPC convencional leva em conta as seguintes informações:

- trajetória predita das variáveis controladas (usando um modelo do processo) ao longo do horizonte de controle da saída.

¹ Conforme o MPC é conhecido na área da Engenharia Elétrica (Eaton e Rawlings, 1992).

- valores desejados ótimos (ou faixas) para as variáveis controladas e manipuladas, valores esses obtidos na camada de otimização estática.
- restrições nos valores máximos e mínimos variáveis manipuladas, bem como na variação máxima dessas variáveis. Em alguns MPCs comerciais, também são incluídas restrições nos valores máximos e mínimos das variáveis controladas. Como essas restrições precisam ser incluídas como “soft constraints” para evitar situações em que o problema de controle se torne inviável, muitos controladores comerciais não incluem explicitamente essas restrições.

Basicamente, um MPC deve calcular os valores das variáveis manipuladas (ações de controle) que minimizem a diferença entre os valores preditos e desejados das variáveis controladas, sujeitas às restrições impostas nas variáveis manipuladas. Ou seja, um controlador MPC, como descrito neste trabalho, tenta levar as variáveis manipuladas para seus valores ótimos desejados sem desrespeitar as restrições nessas variáveis manipuladas e mantendo as variáveis controladas dentro das faixas de operação adequadas. Essa atuação do algoritmo MPC é resumida na função objetivo quadrática definida na eq. 1.1.1.

$$\begin{aligned}
 \min_{\Delta u(k), \dots, \Delta u(k+m-1)} J_k = & \sum_{i=1}^p \left[(r(k+i) - \hat{y}(k+i))^T Q(k+i) (r(k+i) - \hat{y}(k+i)) \right] + \\
 & \sum_{j=0}^{m-1} \Delta u(k+j)^T R \Delta u(k+j) + \\
 & \left[(u(k-1) + \sum_{j=k}^{k+m-1} \Delta u(j) - u_{IRV})^T R_u \cdot (u(k-1) + \sum_{j=k}^{k+m-1} \Delta u(j) - u_{IRV}) \right]
 \end{aligned} \tag{1.1.1}$$

Onde:

- $\hat{y}(k+i) \in \mathbb{R}^{ny}$ é o valor predito das variáveis controladas no instante $k+i$ considerando as ações de controle futuras e a correção retroalimentada da última leitura da saída da planta. O cálculo da predição é feito no instante k .
- k é o instante de tempo presente;
- $\Delta u(k+j) = u(k+j) - u(k+j-1)$ é o incremento nas entradas e $u(k+j) \in \mathbb{R}^{nu}$;
- nu e ny são respectivamente o número de variáveis manipuladas e controladas do processo;

- os parâmetros p e m são respectivamente os horizontes de predição e controle;
- $Q \in \mathbb{R}^{n_y \times n_y}$, $R \in \mathbb{R}^{n_u \times n_u}$ e $R_u \in \mathbb{R}^{n_u \times n_u}$ são respectivamente a matriz de pesos das variáveis controladas, a matriz de fatores de atenuação das variáveis manipuladas e a matriz de pesos para conduzir as variáveis manipuladas para seus respectivos valores ótimos u_{IRV} , todas positivas semidefinidas;
- $r(k+i) \in \mathbb{R}^{n_y}$ é o valor do setpoint das variáveis controladas no instante $k+i$;
- Neste trabalho os valores de Q e $r(k+i)$ não são fixos, pois como se verá adiante, no caso prático, há somente que manter as saídas dentro das faixas adequadas.

As variáveis de busca que minimizam a função objetivo 1.1.1 estão sujeitas às restrições 1.1.2 e 1.1.3 descritas abaixo.

$$-\Delta u^{\max} \leq \Delta u(k+j) \leq \Delta u^{\max} \quad (1.1.2)$$

$$j = 0, 1, 2, \dots, m-1$$

$$u^{\min} \leq u(k-1) + \sum_{j=0}^i \Delta u(k+j) \leq u^{\max} \quad (1.1.3)$$

$$j = 0, 1, 2, \dots, m-1$$

Na literatura de controle MPC, tal como Maciejowski (2002), nota-se que na função objetivo usual não há o último termo da eq. 1.1.1, porque assume-se que o problema de controle é simplesmente levar as variáveis controladas para seus respectivos setpoints $r(k+i)$, previamente conhecidos e fixos. Na eq. 1.1.1 o último termo é incluído para tentar levar as variáveis manipuladas para seus valores ótimos calculados na camada de otimização estacionária do controlador, respeitando as faixas de operação das variáveis controladas. Portanto, este controlador tem por objetivo calcular a melhor seqüência de controle para alcançar o valor ótimo u_{IRV} calculado pela camada estática, mantendo as variáveis controladas em suas faixas operacionais. As faixas de operação (ou zonas) são intervalos de valores mínimos e máximos que as variáveis controladas podem assumir. Os valores numéricos da matriz Q e o vetor $r(k+i)$ implementam o controle por faixas das saídas no controlador de acordo com os valores de $\bar{y}(k+i)$, predições das saídas do controlador considerando apenas o movimento até $u(k-1)$. O valor de $r(k+i)$ é definido em

função de $\bar{y}(k+i)$ em relação aos limites superiores e inferiores que as variáveis de controle podem assumir. Podem ocorrer três casos:

- Se $\bar{y}(k+i) \geq y^{\max}$, a saída tende a extrapolar o limite superior, portanto o objetivo é trazê-la para o valor máximo da sua faixa operacional. Neste caso é adotado $r(k+i) = y^{\max}$, e o peso $Q(k+i)$ correspondente a esta variável toma o valor adotado como parâmetro de sintonia do controlador.
- Se $\bar{y}(k+i) \leq y^{\min}$, a saída tende a extrapolar seu limite inferior, portanto o objetivo é trazê-la para o valor mínimo da sua faixa operacional. Logo é adotado $r(k+i) = y^{\min}$, e o peso $Q(k+i)$ desta saída toma o mesmo valor do caso anterior.
- Se $y^{\min} \leq \bar{y}(k+i) \leq y^{\max}$, a saída pode ser ignorada (liberada ou removida dos cálculos de controle) no instante $k+i$. Portanto, o peso $Q(k+i)$ desta saída deve ser zero. O valor de $r(k+i)$, para o instante correspondente k , assume um valor qualquer (p. ex.: $r(k+i) = \bar{y}(k+i)$).

Essa estratégia permite que o controlador tenha graus de liberdade suficientes para controlar um número de saídas maior que o número de entradas e ainda levar algumas entradas para os seus valores ótimos.

Para resolver o problema de controle com um algoritmo de programação linear ou quadrática, convém colocar a função objetivo na forma vetorial. Assim, a eq. 1.1.1 pode ser reescrita da seguinte forma:

$$\min_{\Delta u} J = \begin{bmatrix} r(k+1) - \hat{y}(k+1) \\ r(k+2) - \hat{y}(k+2) \\ \vdots \\ r(k+p) - \hat{y}(k+p) \end{bmatrix}^T \tilde{Q} \begin{bmatrix} r(k+1) - \hat{y}(k+1) \\ r(k+2) - \hat{y}(k+2) \\ \vdots \\ r(k+p) - \hat{y}(k+p) \end{bmatrix} + \Delta u^T \tilde{R} \Delta u +$$

(1.1.4)

$$\begin{bmatrix} \begin{bmatrix} u(k-1) \\ u(k-1) \\ \vdots \\ u(k-1) \end{bmatrix} - \begin{bmatrix} u_{IRV} \\ u_{IRV} \\ \vdots \\ u_{IRV} \end{bmatrix} + N\Delta u \\ \tilde{R}_u \begin{bmatrix} u(k-1) \\ u(k-1) \\ \vdots \\ u(k-1) \end{bmatrix} - \begin{bmatrix} u_{IRV} \\ u_{IRV} \\ \vdots \\ u_{IRV} \end{bmatrix} + N\Delta u \end{bmatrix}^T$$

A função objetivo 1.1.4 é colocada em função do vetor $\Delta u \in \mathbb{R}^{m \cdot nu}$ onde nu é o número de entradas, e tal que o vetor Δu das ações de controle é definido como:

$$\Delta u = \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \vdots \\ \Delta u(k+m-1) \end{bmatrix}$$

Na equação 1.1.4 foi usada a matriz peso $\tilde{Q} \in \mathbb{R}^{p \cdot ny \times p \cdot ny}$ que é definida como:

$$\tilde{Q} = \begin{bmatrix} \overbrace{Q(1) \quad \cdots \quad 0 \quad \cdots \quad 0}^{p \times ny} \\ \vdots \quad \ddots \quad \vdots \quad \ddots \quad \vdots \\ 0 \quad \cdots \quad Q(i) \quad \cdots \quad 0 \\ \vdots \quad \ddots \quad \vdots \quad \ddots \quad \vdots \\ 0 \quad \cdots \quad 0 \quad \cdots \quad Q(p) \end{bmatrix}$$

A matriz dos fatores de atenuação das variáveis manipuladas $\tilde{R} \in \mathbb{R}^{m \cdot nu \times m \cdot nu}$ é definida como:

$$\tilde{R} = \overbrace{\begin{bmatrix} R & \cdots & 0 & \cdots & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ 0 & \cdots & R & \cdots & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ 0 & \cdots & 0 & \cdots & R \end{bmatrix}}^{m \times nu}$$

A matriz de pesos $R_u \in \mathbb{R}^{m \, nu \times m \, nu}$ é definida de tal forma que o controlador conduza as variáveis manipuladas para seus valores ótimos no estado estacionário apenas no instante m . Isso é feito para desacoplar a parte dinâmica (controle das saídas) da otimização das entradas e tem a seguinte forma:

$$\tilde{R}_u = \overbrace{\begin{bmatrix} 0 & \cdots & 0 & \cdots & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ 0 & \cdots & 0 & \cdots & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ 0 & \cdots & 0 & \cdots & R_u \end{bmatrix}}^{m \times nu}$$

Há também na eq. 1.1.4 a matriz $N \in \mathbb{R}^{m \, nu \times m \, nu}$ definida 1.1.5 que fornece a somatória dos movimentos das variáveis manipuladas para que se obtenha seus futuros valores calculados.

$$N = \overbrace{\begin{bmatrix} I_{nu} & \cdots & 0 & \cdots & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ I_{nu} & \cdots & I_{nu} & \cdots & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ I_{nu} & \cdots & I_{nu} & \cdots & I_{nu} \end{bmatrix}}^{m \times nu} \quad (1.1.5)$$

A prova de 1.1.5 é demonstrada pela seqüência de somas a seguir:

$$\begin{aligned}
u(k) &= u(k-1) + \Delta u(k) \\
u(k+1) &= u(k-1) + \Delta u(k) + \Delta u(k+1) \\
&\vdots \\
u(k+m-1) &= u(k-1) + \Delta u(k) + \dots + \Delta u(k+m-1)
\end{aligned}$$

Portanto:

$$u = \begin{bmatrix} u(k-1) \\ \vdots \\ u(k-1) \end{bmatrix} + N\Delta u$$

As predições das variáveis controladas são alteradas pelas ações de controle que serão aplicadas em instantes futuros. Nos controladores preditivos normalmente consideram que serão aplicadas várias ações de controle, o que fornece um maior número de graus de liberdade para o controlador. Quando o número de ações de controle calculadas é aumentado, permite-se ao controlador distribuir de forma mais conveniente suas ações. Desta forma quando são aplicadas m ações de controle, obtém-se a seguinte seqüência de predições:

$$\begin{aligned}
\hat{y}(k+1) &= \bar{y}(k+1) + S(1)\Delta u(k) \\
\hat{y}(k+2) &= \bar{y}(k+2) + S(2)\Delta u(k) + S(1)\Delta u(k+1) \\
&\vdots \\
\hat{y}(k+m) &= \bar{y}(k+m) + S(m)\Delta u(k) + S(m-1)\Delta u(k+1) + \dots + S(1)\Delta u(k+m-1) \\
&\vdots \\
\hat{y}(k+p) &= \bar{y}(k+p) + S(p)\Delta u(k) + S(p-1)\Delta u(k+1) + \dots + S(p-m+1)\Delta u(k+m-1)
\end{aligned} \tag{1.1.6}$$

Portanto, define-se $\bar{y} \in \mathbb{R}^{ny,p}$ como o vetor predições da saída antes das ações de controle, e $\hat{y} \in \mathbb{R}^{ny,p}$, como vetor de predições da saída após as ações de controle. A matriz $S(i)$ contém os coeficientes da resposta ao degrau do sistema no instante i :

$$S(i) = \begin{bmatrix} S_{1,1}(i) & S_{1,2}(i) & \dots & S_{1,nu}(i) \\ S_{2,1}(i) & S_{2,2}(i) & \dots & S_{2,nu}(i) \\ \vdots & \vdots & \ddots & \vdots \\ S_{ny,1}(i) & S_{ny,2}(i) & \dots & S_{ny,nu}(i) \end{bmatrix}$$

Então é possível equacionar 1.1.6 na forma vetorial como visto na eq. 1.1.7 usando a matriz auxiliar $S_m \in \mathbb{R}^{p.ny \times m.mu}$ definida como matriz dinâmica do sistema.

$$\hat{y} = \bar{y} + S_m \Delta u \quad (1.1.7)$$

$$S_m = \begin{bmatrix} S(1) & 0 & \cdots & \overbrace{0}^m & 0 \\ S(2) & S(1) & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ S(m-1) & S(m-2) & \cdots & S(1) & 0 \\ S(m) & S(m-1) & \cdots & S(2) & S(1) \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ S(p) & S(p-1) & \cdots & S(p-m-1) & S(p-m+1) \end{bmatrix}$$

Diante das incertezas em relação aos modelos da planta e perturbações não medidas, é necessário acrescentar um termo de correção das variáveis controladas. Além do efeito das ações de controle, calculados na eq. 1.1.7, é necessário corrigir as predições através da leitura das variáveis controladas. A predição dessas variáveis no instante atual deveria corresponder aos valores lidos das variáveis controladas $y(k)$ se o modelo fosse perfeito e não houvesse perturbações. Entretanto, isso não ocorre e neste caso define-se a correção $w(k)$ na eq. 1.1.8.

$$w(k) = y(k) - \bar{y}(k) \quad (1.1.8)$$

Tal que $\bar{y}(k)$ é a predição da saída no instante atual feita no instante anterior $k-1$. Da correção das demais predições advém seguinte vetor:

$$\begin{bmatrix} y^c(k+1) \\ y^c(k+2) \\ \vdots \\ y^c(k+p) \end{bmatrix} = \begin{bmatrix} \bar{y}(k+1) \\ \bar{y}(k+2) \\ \vdots \\ \bar{y}(k+p) \end{bmatrix}_k + \begin{bmatrix} w(k) \\ w(k) \\ \vdots \\ w(k) \end{bmatrix}$$

$$\begin{bmatrix} \bar{y}(k+1) \\ \bar{y}(k+2) \\ \bar{y}(k+3) \\ \vdots \\ \bar{y}(k+N) \end{bmatrix}_k = \begin{bmatrix} 0 & I_{n_y} & 0 & \cdots & 0 \\ 0 & 0 & I_{n_y} & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \cdots & I_{n_y} \\ 0 & 0 & 0 & \cdots & I_{n_y} \end{bmatrix} \begin{bmatrix} y^c(k) \\ y^c(k+1) \\ y^c(k+2) \\ \vdots \\ y^c(k+N-1) \end{bmatrix}_{k-1}$$

$$\bar{y} = My^c$$

O conhecimento da matriz dinâmica permite expressar o vetor de erros $\hat{\varepsilon}$ nas predições corrigidas em função do vetor de erros ε nas predições não corrigidas pelas ações de controle.

$$\hat{\varepsilon} = \begin{bmatrix} r - \hat{y}(k+1) \\ r - \hat{y}(k+2) \\ \vdots \\ r - \hat{y}(k+p) \end{bmatrix} = \begin{bmatrix} r - \bar{y}(k+1) \\ r - \bar{y}(k+2) \\ \vdots \\ r - \bar{y}(k+p) \end{bmatrix} - S_m \cdot \Delta u \quad (1.1.9)$$

$$\hat{\varepsilon} = \varepsilon - S_m \cdot \Delta u$$

Daí, a função objetivo do problema de controle pode ser escrita da seguinte forma:

$$\begin{aligned} \min_{\Delta u} J = & \Delta u^T S_m^T \tilde{Q} S_m \Delta u + \varepsilon^T \tilde{Q} S_m \Delta u + \Delta u^T S_m^T \tilde{Q} \varepsilon + \varepsilon^T \tilde{Q} \varepsilon + \Delta u^T \tilde{R} \Delta u + \\ & + \Delta u^T N^T \tilde{R}_u N \Delta u + \Delta u^T N^T \tilde{R}_u \Delta u_d + \Delta u_d^T \tilde{R}_u N \Delta u + \Delta u_d^T \tilde{R}_u \Delta u_d \end{aligned} \quad (1.1.10)$$

Na eq. 1.1.10, o vetor de predições do erro ε foi definido na eq. 1.1.9 e o vetor Δu_d é definido a seguir:

$$\Delta u_d = \begin{bmatrix} u(k-1) \\ u(k-1) \\ \vdots \\ u(k-1) \end{bmatrix} - \begin{bmatrix} u_{IRV} \\ u_{IRV} \\ \vdots \\ u_{IRV} \end{bmatrix}$$

Onde $u(k-1)$ corresponde a última ação de controle implementada no processo.

Como cada termo da eq. 1.1.10 é um escalar, é fácil ver que são válidas as seguintes identidades:

$$\begin{aligned}\varepsilon^T \tilde{Q} S_m \Delta u &= \Delta u^T S_m^T \tilde{Q} \varepsilon \\ \Delta u^T N^T \tilde{R}_u \Delta u_d &= \Delta u_d^T \tilde{R}_u N \Delta u\end{aligned}$$

Portanto, a função objetivo do problema de controle pode ser colocada na forma abaixo.

$$\min_{\Delta u} J = \Delta u^T H \Delta u + 2c_t \Delta u + c \quad (1.1.11)$$

Onde a matriz H é proveniente dos termos da eq. 1.1.10 com dependência quadrática em relação a Δu e pode ser representada pela equação 1.1.12 abaixo.

$$H = S_m^T \tilde{Q} S_m + \tilde{R} + N^T \tilde{R}_u N \quad (1.1.12)$$

O vetor c_t resulta dos termos de dependência linear em relação a Δu e pode ser representado pela equação 1.1.13.

$$c_t = (S_m^T \tilde{Q} \varepsilon + N^T \tilde{R}_u \Delta u_d) \quad (1.1.13)$$

Finalmente, o escalar c contém os termos constantes em relação a Δu , e portanto não influi na minimização de J na eq. 1.1.11.

Através do conceito de derivada demonstra-se facilmente que o mínimo analítico de J pode ser resolvido por:

$$\frac{\partial J}{\partial \Delta u} = 2H \Delta u + 2c_t = 0 \quad (1.1.14)$$

Porém, se a equação 1.1.14 for resolvida em termos de Δu , o resultado não necessariamente irá respeitar as restrições em u e Δu . Assim, uma forma de minimizar J e

resolver o problema do MPC respeitando as restrições é transformá-lo em um problema clássico de programação linear como se vê a seguir (Sotomayor et al., 2006a). Considera-se inicialmente o vetor $\rho = H \cdot \Delta u + c_i$ tal que $\rho \in \mathbb{R}^{m \cdot nu}$. Então é possível definir como objetivo para o MPC:

$$\min_{\Delta u} \sum_{i=1}^{m \cdot nu} v_i |\rho_i|$$

Onde v_i é um fator de ponderação que normalmente é adotado igual à unidade.

Esta função objetivo está sujeita ao conjunto de restrições lineares nas variáveis manipuladas Δu como visto nas equações de 1.1.15 a 1.1.17. Para caracterizar esse problema como um problema de programação linear define-se $\rho_i = x_i - z_i$ tal que $x_i, z_i \geq 0$. O problema de controle assumirá então a seguinte forma.

$$\min_{\Delta u} \sum_{i=1}^{m \cdot nu} v_i (x_i - z_i)$$

Sujeita a:

$$\begin{bmatrix} x_1 - z_1 \\ x_2 - z_2 \\ \vdots \\ x_{m \cdot nu} - z_{m \cdot nu} \end{bmatrix} = (S_m^T \tilde{Q} S_m + \tilde{R}^T + N^T \tilde{R}_u N) \cdot \Delta u - (S_m^T \tilde{Q} \varepsilon + N^T \tilde{R}_u \Delta u_d)$$

$$-\Delta u^{\max} \leq \Delta u(k+j) \leq \Delta u^{\max} \quad (1.1.15)$$

$$u^{\min} \leq u(k-1) + \sum_{j=0}^i \Delta u(k+j) \leq u^{\max} \quad (1.1.16)$$

$$i = 0, 1, 2, \dots, m-1$$

$$x(i), z(i) \geq 0 \quad i = 1 \dots m \cdot nu \quad (1.1.17)$$

A solução desse problema de otimização pode ser obtida usando os pacotes de programação linear disponíveis comercialmente.

1.2 Camada Estática do MPC

A camada estática do MPC soluciona a cada instante de amostragem um problema de programação quadrática (QP) com restrições, usando um modelo do processo em estado estacionário e informações vindas do controlador MPC. Dependendo da existência ou não de um otimizador rigoroso da operação do processo, a camada estática do controlador pode ter objetivos diferentes. Caso exista a otimização rigorosa em tempo real, a camada estática tem como objetivo compatibilizar os “targets” calculados pelo otimizador com as restrições dinâmicas das entradas e saídas do processo. Nesse caso, a função objetivo da camada de otimização simplesmente minimiza a distância entre os targets produzidos pelo otimizador rigoroso e os “targets” possíveis de serem implementados pelo controlador. Quando o otimizador não é rigoroso, que é o caso mais geral, então a função da camada estática é levar o sistema para um conjunto de restrições que definem um ponto ótimo aproximado. O uso dos valores preditos em estado estacionário de cada variável controlada permite que a camada estática do MPC forneça uma solução ótima em estado estacionário para o controlador antes que o processo tenha alcançado tal condição. No entanto, esta técnica tem a desvantagem que não pode otimizar a planta durante transitórios, tais como os produzidos por perturbações ou mudanças no regime operacional (Bezerra et al., 1999). Mas, a camada estática tende a mostrar certo grau de robustez e também fornece ao controlador desempenho livre de off-sets (nas variáveis controladas e manipuladas) independente dos pesos na função objetivo do MPC. O resultado dos cálculos é o valor ótimo do estado estacionário para as variáveis manipuladas u_{IRV} .

A função objetivo dessa camada é definida na eq. 1.2.1.

$$\min_{\Delta u_{IRV}} J_e = \Delta u_{IRV}^T W_1 \Delta u_{IRV} - W_2^T \Delta u_{IRV} + \delta^T \tilde{M} \delta \quad (1.2.1)$$

Onde:

- $\Delta u_{IRV} \in \mathbb{R}^{nu.m}$ corresponde à variação total nas variáveis manipuladas, do último valor implementado no processo $u^{(k-1)}$ até o valor ótimo;
- $W_1 \in \mathbb{R}^{nu \times nu}$ é uma matriz de pesos que visa evitar soluções que levem a ações muito bruscas de controle;
- $W_2 \in \mathbb{R}^{nu}$ é um vetor de pesos econômicos;

- $\delta \in \mathbb{R}^{ny}$ é um vetor de variáveis de folga (“slack”), ele garante que o problema seja sempre viável;
- $\tilde{M} \in \mathbb{R}^{ny \times ny}$ é uma matriz de pesos suficientemente grande, no mínimo 100 vezes os pesos econômicos, como verificado experimentalmente.

A função objetivo J_e está sujeita às restrições apresentadas nas equações 1.2.2 e 1.2.3.

$$u^{\min} \leq u(k-1) + \Delta u_{IRV} \leq u^{\max} \quad (1.2.2)$$

$$y^{\min} \leq y_{ss} + \delta \leq y^{\max} \quad (1.2.3)$$

Onde:

- y_{ss} é a predição da saída no estado estacionário ótimo que pode ser calculada por $y_{ss} = \bar{y}(k+n) + K\Delta u_{IRV}$ onde $\bar{y}(k+n)$ é a predição do estado estacionário atingido no instante n calculado pela camada dinâmica no instante $k-1$ e por fim K é a matriz de ganhos estáticos do processo;
- n é o horizonte de estabilização do sistema.

O problema de otimização é colocado na forma de programação quadrática, pois a programação quadrática afasta soluções numéricas com respostas degeneradas, ou seja, soluções ao longo da face do polígono de domínio das soluções formado pelas restrições à solução do problema linear e reduz o número de chaveamentos de u_{IRV} (saltos de uma intersecção para a outra do polígono de domínio da solução).

2 Técnicas de Identificação do modelo para o MPC

Como mencionado anteriormente, os controladores MPC incorporam um modelo explícito do processo, isso motiva o estudo de técnicas para obtenção desses modelos conhecidas como técnicas de identificação de sistemas.

Estimativas indicam que o desenvolvimento de um modelo do processo pode corresponder a até 90% do custo total, em tempo e dinheiro, da implantação de um projeto típico de MPC (Andersen e Kümmel, 1992). Usualmente, um modelo MIMO (Multiple Input Multiple Output) do processo é desenvolvido a partir de uma série de experimentos em malha-aberta durante a fase inicial do projeto do MPC. Na prática industrial, é comum aplicar-se individualmente um degrau numa variável manipulada (fixando as outras manipuladas nos seus estados estacionários) para, depois de um pré-tratamento e análise das respostas, identificar modelos simples SISO ou diretamente determinar os coeficientes da resposta ao degrau para serem usados no controlador MPC (modelo de convolução). Esta técnica assume que o sistema é linear e que o teorema da superposição é válido sendo, portanto, possível a combinação dos modelos SISO para a obtenção aproximada de um modelo MIMO.

De acordo com Kalra e Georgakis (1996), o teste de resposta ao degrau pode não conter suficiente excitação para identificar o caráter dinâmico do processo em frequências de interesse para controle em malha fechada. O teste de resposta ao degrau pode também não conter boas informações para identificar o caráter multivariável e interativo do processo (Zhu, 2003) e tende a perturbar somente as direções de maior ganho (Li e Lee, 1996).

Segundo Li e Lee (1996), a predição baseada em um modelo MIMO obtido pela combinação de modelos SISO pode ser extremamente pobre porque num processo altamente interativo, a direcionalidade² do ganho do processo pode fazer com que as saídas exibam forte correlação, chegando mesmo ao extremo da co-linearidade, o que pode levar a problemas tais como relação sinal/ruído pobre, grande “bias” nas direções de menores ganhos e condicionamento numérico elevado (Morari e Lee, 1999).

No teste simultâneo em malha aberta, todas as entradas são perturbadas ao mesmo tempo, levando a uma identificação MISO ou MIMO. A vantagem de uma identificação

² A direcionalidade do ganho refere-se à dependência do ganho do processo à direção da saída e à direção da entrada. A sua presença reflete uma planta com um número de condicionamento elevado o que a torna difícil de controlar (Waller e Waller, 1995). Usando o conceito de direcionalidade do ganho, Koung e MacGregor (1993) projetaram seqüências de entrada que provêm igual excitação nas direções de maior e menor ganho; e Zhan et al. (2006) formularam sinais de entrada ótimos para sistemas MIMO com restrições.

MIMO é que as interações entre as saídas são levadas em conta no desenvolvimento do modelo. No entanto, resulta frequentemente num problema de otimização não-convexa e mal-condicionada com possíveis mínimos locais (Li e Lee, 1996).

No entanto, seja qual for o teste usado e embora ambos possam ser aplicados de forma automática, o sinal de teste³ pode forçar o processo para fora da região normal de operação (principalmente se o sistema for não-linear, instável ou contiver características integradoras) de tal forma que o uso de ações corretivas tornam-se necessárias, ou seja, o uso de identificação em malha fechada. Em contrapartida, os sinais de entrada têm que ser informativos⁴ de modo a se obter uma boa estimativa da direcionalidade do ganho (Andersen e Kümmel, 1992; Li e Lee, 1996). Em outras palavras, a entrada deve conter suficiente energia na faixa de frequências de interesse, a fim de garantir a identificabilidade do processo. De fato, bons modelos na faixa de frequências baixas e médias são importantes para controle MPC (Gopaluni et al., 2003).

Embora sejam baseados em modelos LTI (Linear Time Invariant), os controladores MPC industriais têm características não-lineares e variantes no tempo, ou seja, não têm uma estrutura definida porque restrições são ativadas e desativadas ao longo do tempo.

As técnicas de identificação em malha fechada podem ser classificadas em três tipos (Ljung, 1999) dependendo da natureza do controlador e as suposições a respeito do modelo do ruído:

- O método direto que ignora a presença do controlador e usa sinais de entrada e saída do processo como se faz em malha aberta. Ele fornece consistência e precisão ótimas desde que o modelo contenha o sistema real. Esse método requer um modelo adequado do ruído para evitar “bias” no modelo da planta.
- O método indireto que introduz sinais (distúrbios) através do setpoint e usa a saída do processo em malha fechada. Esse método requer o conhecimento da estrutura do controlador, logo não funciona para controladores não lineares resultantes de restrições ativas. Nesse caso, não é necessário conhecer a representação perfeita do modelo do ruído.
- O método conjunto que usa os sinais de entrada e saída como sendo as saídas de um sistema aumentado cujas entradas são o setpoint e o ruído. Esse modelo

³ Normalmente, quando em malha aberta, o sinal de teste é a própria entrada do processo.

⁴ Isto significa que para a operação em malha aberta, a entrada tem que ter característica de excitação persistente (“persistently exciting”, PE) de uma certa ordem (Åström e Eykhoff, 1971).

permite realizar a identificação não só dos modelos da planta e ruído, como também do controlador.

Para o controlador utilizado neste trabalho, o melhor método a ser usado é o método direto, pois a forma de controle das saídas por faixas reduz o efeito da realimentação nas entradas possibilitando um maior sucesso da identificação direta. É imprescindível notar que para este trabalho o controle PID, ou controle regulatório, é considerado como parte do processo, referindo-se a controle como controle avançado.

A presença do controlador tem uma vantagem adicional se o processo é mal-condicionado, como é o caso de colunas de destilação de alta pureza em que as variáveis controladas apresentam forte correlação: no controle deste tipo de processo é importante identificar modelos que tenham uma boa estimativa das direções de menor ganho e, para isto, é vital que as variáveis manipuladas exibam certa correlação entre si, o que é criado naturalmente pela realimentação (Koung e MacGregor, 1993; Zhu, 2003). No entanto, esta correlação-cruzada entre si das variáveis manipuladas, unidas à significativa correlação-cruzada entre as variáveis manipuladas e controladas torna-se o problema fundamental da identificação em malha fechada, as quais podem introduzir “bias” nas estimativas devido à realimentação. “Bias” são erros sistemáticos originados de erros de modelagem e variância (ou erros randômicos) relacionada à presença de ruídos. Em malha fechada, a inerente redução na excitação pode levar a uma relação entre sinal e ruído pobre, o que pode influenciar no aumento da variância. Apesar dessas desvantagens, a identificação em malha fechada está recebendo muita atenção nos últimos anos e está sendo considerada como uma alternativa que pode ser usada para restabelecer o desempenho do controlador quando existem erros entre a planta e o modelo que forem significativos.

De modo a garantir a identificabilidade do processo, é necessário perturbar o sistema com um sinal persistentemente excitante. Dependendo da forma com que esta perturbação é feita, é possível identificar um sistema em malha fechada com aplicação de excitação externa ou interna. No caso de excitação externa o sinal persistentemente excitante é adicionado diretamente às variáveis manipuladas (Celaya et al., 2004; Kline et al., 2006), ou no “setpoint” das variáveis controladas⁵ (Doma et al., 1996; Amjad e Al-Duwaish, 2003), até mesmo em ambas (Zhu e Butoyi, 2002) como observa-se na Figura 2.1.

⁵ A aplicação do sinal persistentemente excitante no “setpoint” pode ser realizada quando o controlador é quadrado e, pelo menos, razoavelmente bem ajustado (Doma et al., 1996).

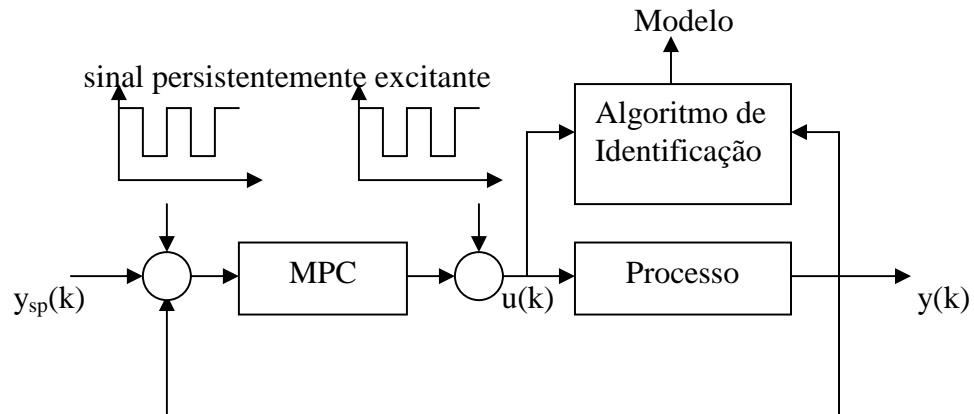


Figura 2.1: Sinal persistentemente excitante para identificação

A desvantagem de aplicar uma excitação externa é a falta de uma forma sistemática de projetar o sinal de teste, o que pode resultar em excessiva ou insuficiente excitação para o sistema. Entretanto, a introdução de uma excitação interna no controlador MPC, significa alterar o código fonte do MPC que normalmente não é possível, pois o mesmo em geral é propriedade de um licenciador. Porém, no caso do MPC de duas camadas, será emulada a excitação interna introduzindo o sinal persistentemente excitante na camada estática do controlador, em sua função objetivo na eq. 2.0.1 por meio dos coeficientes econômicos W_2 .

$$\min_{\Delta u_{IRV}} J = \Delta u_{IRV}^T W_1 \Delta u_{IRV} - W_2^T \Delta u_{IRV} + \delta^T \tilde{M} \delta \quad (2.0.1)$$

↑
sinal persistentemente excitante

Esta forma de excitar o sistema é considerada um método de aplicação de uma excitação interna, pois o sinal persistentemente excitante não é aplicado diretamente nos “targets” das variáveis manipuladas como em Sagias e Nikolaou (2001), mas sim nos seus respectivos coeficientes econômicos (Sotomayor e Odloak, 2006b).

O sinal chega indiretamente até a camada dinâmica do MPC, por meio do valor ótimo do estado estacionário como nota-se na eq. 2.0.2.

$$\begin{aligned}
& \min_{\Delta u(k), \dots, \Delta u(k+m-1)} J_k = \sum_{i=1}^p \left[(r - \hat{y}(k+i))^T q(k+i) (r - \hat{y}(k+i)) \right] + \\
& \sum_{j=0}^{m-1} \Delta u(k+j)^T r(k+j) \Delta u(k+j) + \\
& + \left[(u(k-1) + \sum_{j=k}^{k+m-1} \Delta u(j) - u_{IRV})^T r_u \cdot (u(k-1) + \sum_{j=k}^{k+m-1} \Delta u(j) - u_{IRV}) \right]
\end{aligned} \tag{2.0.2}$$

↑
↑
sinal
sinal

No caso de aplicação de excitação interna, é necessário lembrar que em malha fechada, a característica persistentemente excitante da entrada do processo é que garante a identificabilidade do modelo e não a excitação persistente do sinal de teste.

No caso de identificação de um novo modelo para o MPC, deve-se lembrar que:

- A identificação será realizada em operação normal da planta, portanto, deverá ser realizada automaticamente sem a assistência permanente de um engenheiro de controle;
- As restrições nas entradas (valores máximos e mínimos e incremento máximo) devem ser respeitadas durante o teste;
- As saídas controladas devem ser mantidas dentro de suas faixas de tal forma que a qualidade dos produtos não seja afetada pelo teste;
- A ocorrência do teste de identificação não deve necessitar de uma atenção especial pelos operadores do processo, pois o mesmo pode se estender por muitas horas ou dias.

O que nos leva a concluir uma proposta de identificação em malha fechada sempre que for preciso re-identificar o modelo do processo, porque respeita restrições, não altera a qualidade dos produtos e dispensa atenção especial por parte da equipe de operação.

2.1 Descrição do Sinal de Teste adotado

O sinal de teste corresponde ao distúrbio que é introduzido no processo no sentido de excitar todos os modos dinâmicos do mesmo e possibilitar a identificação do modelo correspondente. O projeto desse sinal desempenha um papel importante na excitação do processo e identificação do modelo, constituindo-se em uma área de interesse de muitos pesquisadores. Sinais de teste são amplamente usados na identificação de sistemas e podem ser classificados em duas grandes categorias. A primeira categoria é a de sinais otimizados, os quais são projetados para terem um espectro de potência específico, e.g. sinais multi-seno, sinais binários de intervalo discreto e sinais multi-harmônico, multi-nível. A segunda categoria de sinais de teste inclui o GBN (Generalized Binary Noise), tem um espectro de potência fixo para uma mesma frequência de excitação. Um caso particular e conhecido deste último são os PRBS (“pseudo-random binary signals”).

No caso da re-identificação do modelo de um processo em malha fechada com o MPC pode ser usado um sinal tipo GBN, e o foco deste trabalho estará neste tipo de sinal, pois será usado no método proposto. Um sinal persistentemente excitante do tipo GBN produz valores que alternam entre a e $-a$ os coeficientes W_2 da função objetivo da camada estática do MPC. Espera-se que essa variação faça com que a camada estática do MPC varie os valores desejados das entradas do MPC, e conseqüentemente, o MPC varie as entradas reais o suficiente para que o algoritmo do modelo identificador consiga distingui-las em relação aos ruídos.

No sinal persistentemente excitante do tipo GBN, em um instante de chaveamento t cada evento ocorre com a probabilidade P definida na eq. 2.1.1.

$$\begin{aligned} P[u(t) = -u(t-1)] &= p_{sw} \\ P[u(t) = u(t-1)] &= 1 - p_{sw} \end{aligned} \tag{2.1.1}$$

onde p_{sw} é probabilidade de chaveamento.

Portanto, considerando por exemplo que $W_2(t) = -a$ é o valor inicial desse parâmetro e γ uma variável de valores randômicos uniformemente distribuídos no intervalo $[0,1]$, daí segue-se a seguinte estratégia:

- se o valor de γ é menor que p_{sw} , a variável $W_2(t+1)$ troca de sinal assumindo valor a , ou seja, $W_2(t+1)$ vale $W_2(t)$ multiplicada por -1 ;
- se o valor randômico de γ é maior que p_{sw} , $W_2(t+1)$ mantêm o mesmo sinal de $W_2(t)$.

Como a distribuição do tempo de chaveamento de cada evento é independente do parâmetro p_{sw} , a média do sinal é zero.

T_{\min} foi definido como o tempo mínimo de chaveamento ou o tempo mínimo em que se mantém o sinal constante até um novo chaveamento. Também foi definido T_{sw} como o tempo transcorrido entre dois chaveamentos. Daí, o tempo médio $\mu(T_{sw})$ de chaveamento é representado por

$$\mu(T_{sw}) = \frac{T_{\min}}{P_{sw}} \quad (2.1.2)$$

Observando a eq. 2.1.2, nota-se que para a probabilidade de chaveamento p_{sw} adequada é preciso escolher um valor médio $\mu(T_{sw})$ que permita o processo gerar um espectro do sinal de entrada no processo com energia suficiente na faixa de frequências de interesse para o controle. Na literatura (Zhu, 2001), esse valor é relacionado com o valor máximo de estabilização ao degrau T_{ss} em cada saída do processo conforme mostrado na eq. 2.1.3:

$$\mu(T_{sw}) = \frac{T_{ss}}{n} \quad (2.1.3)$$

Onde:

- T_{ss} é o tempo que o processo leva para atingir o estado estacionário, portanto esse valor é fixo para cada processo. Esse valor é calculado como o tempo necessário para atingir 95% do valor final no estado estacionário.
- n é um parâmetro escolhido para se obter o sinal de excitação que seja mais adequado para solucionar o problema de identificação do processo.

2.2 Identificação do modelo usado pelo MPC

Pelo que foi visto nas seções 1.1 e 1.2 anteriormente, fica claro que o desempenho do algoritmo de controle MPC é altamente dependente da qualidade do modelo do processo. Isso porque, nessa estratégia de controle o modelo é usado para:

- prever o comportamento futuro das saídas num horizonte relativamente longo;
- levar em conta todas as características significativas da dinâmica do processo no cálculo da lei de controle.

Isso motiva o estudo dos modelos usados na identificação de sistemas, pois se o modelo do processo é de má qualidade, as previsões serão pobres resultando num controle pobre. Portanto, a fidelidade do modelo é um fator importante no desempenho dos controladores MPC. Embora os processos industriais sejam, em geral, não-lineares e de ordem relativamente elevada, a estrutura dos modelos usados na literatura para aproximar estes processos é quase sempre de ordem reduzida. Por exemplo, o modelo apresentado na eq. 2.2.1 é um modelo do tipo output-error (OE) de ordem 2, que serviu para o uso neste trabalho, sendo o escolhido por desempenho em testes frente a outras estruturas.

$$G(q) = \frac{B(q)}{F(q)} = \frac{b_1 q^{-1} + b_2 q^{-2}}{1 + f_1 q^{-1} + f_2 q^{-2}} \quad (2.2.1)$$

Os parâmetros $\tilde{\theta} = [\tilde{f}_1, \tilde{f}_2, \tilde{b}_1, \tilde{b}_2]^T$ estimados para o modelo na eq. 2.2.1 são definidos de forma a minimizar o erro $\varepsilon_{oe}(t)$ na eq. 2.2.2 entre a resposta do processo $y(t)$ e a resposta do modelo estimado $\tilde{y}(t)$.

$$\begin{aligned} \varepsilon_{oe}(t) &= y(t) - \tilde{y}(t) \\ y(t) &= \frac{B(q)}{F(q)} u(t) + v(t) \\ \tilde{y}(t) &= \frac{\tilde{B}(q)}{\tilde{F}(q)} u(t) \end{aligned} \quad (2.2.2)$$

O erro da leitura da saída do processo $v(t)$ é assumido como um ruído branco, portanto o valor de $\tilde{y}(t)$ é obtido pela seqüência Z^N de entradas e respectivas saídas lidas na planta.

$$Z^N := (y(1), u(1); \dots; y(N), u(N))$$

Os parâmetros são obtidos com o método de ajuste do OE minimizando a função perda definida na eq. 2.2.3.

$$V_{oe} = \frac{1}{N-n} \sum_{t=n+1}^N \varepsilon_{oe}(t)^2 \quad (2.2.3)$$

Nota-se que $\varepsilon_{oe}(t)$ não é linear em relação aos parâmetros de $\tilde{F}(q)$ e em consequência dessas não-linearidades, não há solução analítica para o problema que tem que ser resolvido através de um algoritmo numérico. Logo, problemas de não convergência e mínimo local podem ocorrer.

Por definição o erro sistemático é escrito como $\Delta G(q)$, que é a diferença entre o modelo real $G(q)$ e o modelo estimado $\tilde{G}(q)$ na eq. 2.2.4.

$$\Delta G(q) = G(q) - \tilde{G}(q) \quad (2.2.4)$$

Assim, é fácil ver que o erro $\varepsilon_{oe}(t)$ definido na eq. 2.2.2 é função da entrada $u(t)$ e do ruído branco na leitura da saída $v(t)$ como pode ser visto na eq. 2.2.5.

$$y(t) - \tilde{y}(t) = \Delta G(q)u(t) + v(t) \quad (2.2.5)$$

A função perda definida na eq. 2.2.3 é semelhante a um cálculo de covariância, usando a identidade 2.2.5 para $N \rightarrow \infty$, é possível desenvolver a função perda conforme se vê na eq. 2.2.6.

$$\begin{aligned} V_{oe}^N &= \sigma^2(\varepsilon_{oe}) = \sigma^2[\Delta G(q)u(t) + v(t)]^2 \Rightarrow \\ V_{oe}^N &= [\Delta G(q)]^2 \sigma^2[u^2(t)] + 2\Delta G(q)\sigma^2[u(t)v(t)] + \sigma^2[v^2(t)] \end{aligned} \quad (2.2.6)$$

Se for válida a hipótese de que o ruído branco $v(t)$ não é significativamente realimentado nas ações de controle porque é adotado o controle por faixas das saídas e porque neste controlador tem-se um desacoplamento entre a parte dinâmica, que controla as saídas, e a otimização estática das entradas, então, pode-se aproximar por zero o penúltimo termo da eq. 2.2.6 devido à baixa correlação entre estas variáveis. Já a covariância de $v(t)$ deve ser muito pequena se comparada ao antepenúltimo termo da eq. 2.2.6. Se $V_{oe}^N \rightarrow 0$ quando $N \rightarrow \infty$, conseqüentemente tem-se que:

$$V_{oe}^N \rightarrow 0 \Rightarrow [\Delta G(q)]^2 \rightarrow 0$$

Que é equivalente ao modelo estimado $\tilde{G}(q)$ tender ao modelo real $G(q)$ quando N tende ao infinito:

$$N \rightarrow \infty \Rightarrow \tilde{G}(q) \rightarrow G(q)$$

Como os modelos usados para identificação correspondem a modelos dinâmicos lineares que descrevem as variações das saídas em função das variações nas entradas em torno de um ponto de operação, para uma correta identificação é preciso eliminar o ponto de operação, ou seja, subtrair os dados de suas médias.

$$\begin{aligned} y'(t) &= y(t) - \mu(y) \\ u'(t) &= u(t) - \mu(u) \end{aligned}$$

Além disso, para identificação do modelo é conveniente trabalhar com os dados normalizados:

$$\begin{aligned} y''(t) &= \frac{y(t) - \mu(y)}{\sigma(y)} \\ u''(t) &= \frac{u(t) - \mu(u)}{\sigma(u)} \end{aligned}$$

Onde $\sigma(y(t)) = \sqrt{E[y(t) - \mu(y)]^2}$, $\sigma(u(t)) = \sqrt{E[u(t) - \mu(u)]^2}$, tal que o operador E representa a esperança estatística.

Na prática as rotinas de OE são pacotes comerciais computacionais que buscam os valores para os parâmetros $\tilde{\theta} = [\tilde{f}_1, \tilde{f}_2, \tilde{b}_1, \tilde{b}_2]^T$ que minimizem o valor da função objetivo V_{oe}^N .

2.3 Sinal persistentemente excitante

Para uma identificação confiável do processo, a entrada tem que ter característica de sinal persistente excitante de certa ordem M (Åström e Eykhoff, 1971). A interpretação no domínio da frequência de um sinal PE de ordem M , é que o espectro do sinal não é zero em no mínimo M frequências no intervalo $[-\pi, \pi]$, (Söderström e Stoica, 1989; Ljung, 1999). Sinais com característica persistentemente excitante podem ser, por exemplo, do tipo GBN (“generalized binary noise”, Tulleken (1990)) e IRS (“inverse repeat sequence”, Srinivasan et al., (1999)). Para discutir alguns detalhes sobre as características dos sinais persistentemente excitantes foi considerado inicialmente o modelo de convolução.

$$y(t) = \sum_{k=0}^{\infty} h(k)u(t-k) + v(t) \quad (2.3.1)$$

Onde:

- $h(k)$ é o coeficiente da resposta ao impulso no instante k ;
- $v(t)$ é o termo de distúrbio.

Assuma agora que a entrada seja um processo estocástico estacionário independente do distúrbio. Neste caso é fácil provar que:

$$r_{yu}(\tau) = \sum_{k=0}^{\infty} h(k)r_u(\tau-k) \quad (2.3.2)$$

Onde as funções de covariância podem ser estimadas por:

$$\hat{r}_{yu}(\tau) = \frac{1}{N} \sum_{t=1-\min(\tau,0)}^{N-\max(\tau,0)} y(t+\tau)u(t) \quad \tau = 0, \pm 1, \pm 2, \dots \quad (2.3.3)$$

$$\hat{r}_u(\tau) = \frac{1}{N} \sum_{t=1}^{N-\tau} u(t-\tau)u(t) \quad \hat{r}_u(-\tau) = \hat{r}_u(\tau) \quad \tau = 0, 1, 2, \dots$$

Daí, um valor estimado da função de resposta ao impulso $h(k)$ pode ser obtido pela solução da eq. 2.3.4.

$$\hat{r}_{yu}(\tau) = \sum_{k=0}^{\infty} h(k)\hat{r}_u(\tau - k) \quad (2.3.4)$$

Porém, nesse caso o modelo do sistema linear a ser obtido apresenta dimensão infinita. O problema pode ser simplificado considerando um ruído branco na entrada, o que nos leva a conhecer a priori que $r_u(\tau) = 0$ para todo $\tau \neq 0$. Portanto, para este caso tem-se $h(k) = r_{yu}(k)/r_u(0)$. Pode-se simplificar o problema truncando a função peso $h(k)$ tal que esta assuma valores nulos para $k \geq M$. Esse modelo é chamado FIR – finite impulse response – e M é escolhido como o tempo de estabilização do sistema. Reescrevendo a eq. 2.3.4:

$$\hat{r}_{yu}(\tau) = \sum_{k=0}^{M-1} h(k)\hat{r}_u(\tau - k) \quad (2.3.5)$$

Escrevendo a equação acima para $\tau = 0, 1, \dots, M-1$, o seguinte sistema de equações é obtido.

$$\begin{pmatrix} \hat{r}_{yu}(0) \\ \vdots \\ \hat{r}_{yu}(M-1) \end{pmatrix} = \begin{pmatrix} \hat{r}_u(0) & \cdots & \hat{r}_u(M-1) \\ \vdots & \ddots & \vdots \\ \hat{r}_u(M-1) & \cdots & \hat{r}_u(0) \end{pmatrix} \begin{pmatrix} h(0) \\ \vdots \\ h(M-1) \end{pmatrix} \quad (2.3.6)$$

Os coeficientes $h(k)$ para $k = 0, 1, \dots, M-1$ podem ser determinados como solução do sistema 2.3.6 acima. Para que haja uma solução única para o sistema, a matriz de covariâncias r_u não pode ser singular. Assim, pode-se definir o conceito de excitação persistente:

Por definição um sinal é dito persistentemente excitante de ordem n se:

i. Existir o limite:

$$r_u(\tau) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{t=1}^N u(t+\tau)u^T(t)$$

ii. A seguinte matriz é positiva definida.

$$R_u(n) = \begin{pmatrix} \hat{r}_u(0) & \hat{r}_u(1) & \cdots & \hat{r}_u(n-1) \\ \hat{r}_u(-1) & \hat{r}_u(0) & \ddots & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ \hat{r}_u(1-n) & \cdots & \cdots & \hat{r}_u(0) \end{pmatrix}$$

Pela definição, se o sinal $u(k)$ é ergódico, então $r_u(\tau)$, na condição (i) é a função autocorrelação e $R_u(n)$ na condição (ii) é a matriz de covariâncias. É óbvio que $\det(R_u(n)) > 0$ é condição necessária para que $u(k)$ seja persistentemente excitante de ordem n .

No domínio de frequência, o sinal persistentemente excitante de ordem n é equivalente a requerer que o espectro do sinal seja diferente de zero em pelo menos n pontos.

Usando o procedimento de excitação descrito anteriormente para o caso do MPC, conclui-se que é preciso verificar se as entradas do processo são persistentemente excitantes e têm energia suficiente para excitar a dinâmica do processo permitindo uma boa identificação.

2.3.1 Sinal Persistentemente excitante para modelos lineares

A necessidade do sinal de excitação ser persistentemente excitante foi introduzida na seção anterior no caso da estimação da função peso de modelos FIR. Pode-se verificar agora como a propriedade de sinal ser persistentemente excitante pode ser caracterizada em modelos lineares de ordem n . Para tal, pode-se reescrever a eq. 2.3.1 da forma:

$$A(q)y(t) = B(q)u(t) + v(t) \Rightarrow$$

$$(1 + a_1q^{-1} + a_2q^{-2} + \dots + a_{na}q^{-na})y(t) = (b_1q^{-1} + b_2q^{-2} + \dots + b_{nb}q^{-nb})u(t) + v(t)$$

Daí, pode-se definir:

$$\varphi(t)^T = [-y(t-1) \ \dots \ -y(t-n_a) \ u(t-1) \ \dots \ u(t-n_b)]$$

$$\theta^T = [a_1 \ \dots \ a_{na} \ b_1 \ \dots \ b_{nb}]$$

Conseqüentemente, o modelo linear pode então ser escrito da seguinte forma:

$$y(t) = \varphi(t)^T \theta + v(t)$$

Da mesma forma que para o modelo de resposta ao impulso, a existência de solução do método dos mínimos quadrados para estimar $\hat{\theta}$ torna-se assintoticamente equivalente a não singularidade da matriz covariância definida como:

$$R = E\varphi(t)\varphi(t)^T$$

Onde E é o operador esperança.

Como se mostrará a seguir, a condição $R > 0$ está diretamente relacionada à propriedade do sinal de entrada $u(t)$ ser persistentemente excitante. Para tal foram considerados separadamente dois casos distintos: a saída livre de ruído ($v(t) = 0$) e a saída com presença deste ($v(t) \neq 0$):

i. Para $v(t) = 0$ é possível escrever.

$$\varphi(t) = \begin{matrix} na \\ \left\{ \begin{matrix} -b_1 & \dots & -b_{nb} & 0 \\ & \ddots & \ddots & \\ 0 & -b_1 & \dots & -b_{nb} \\ a_1 & \dots & a_{na} & 0 \end{matrix} \right. \\ nb \\ \left\{ \begin{matrix} & & & \\ & \ddots & \ddots & \\ 0 & a_1 & \dots & a_{na} \end{matrix} \right. \end{matrix} \begin{pmatrix} \frac{1}{A(q)}u(t-1) \\ \vdots \\ \frac{1}{A(q)}u(t-na-nb) \end{pmatrix} \equiv \mathfrak{Z}(-B, A)\tilde{\varphi}(t)$$

A matriz $\mathfrak{S}(-B, A)$ é definida como matriz de Sylvester associada aos polinômios $-B(z)$ e $A(z)$. Essa matriz será singular se $B(z)$ e $A(z)$ forem co-primos. Então.

$$R = \mathfrak{S}(-B, A)E\tilde{\varphi}(t)\tilde{\varphi}(t)^T\mathfrak{S}(-B, A)^T \equiv \mathfrak{S}(-B, A)\tilde{R}\mathfrak{S}(-B, A)^T$$

Portanto nota-se que:

$$\{R > 0\} \Leftrightarrow \{\mathfrak{S} \text{ não singular e } \tilde{R} > 0\}$$

A matriz \tilde{R} será positiva definida se e somente se $u(t)$ for persistentemente excitante de ordem $(na + nb)$. A propriedade acima pode ser escrita também da seguinte forma:

$$\{R > 0\} \Leftrightarrow \{ u(t) \text{ é persistentemente excitante e } A(z), B(z) \text{ são co-primos } \}$$

ii. Para o caso em que a saída contém ruído:

$$\bar{v}(t) = -\frac{1}{A(q)}v(t) \quad x(t) = \frac{B(q)}{A(q)}u(t)$$

Admitido que $Eu(t) \mathcal{V}(s) = 0$ para todo t e s . Daí, pode-se escrever:

$$\begin{aligned}
R = & E \begin{pmatrix} x(t-1) \\ \vdots \\ x(t-na) \\ u(t-1) \\ \vdots \\ u(t-nb) \end{pmatrix} \begin{pmatrix} x(t-1) & \cdots & x(t-na) & u(t-1) & \cdots & u(t-nb) \end{pmatrix} \\
& + E \begin{pmatrix} \bar{v}(t-1) \\ \vdots \\ \bar{v}(t-na) \\ 0 \\ \vdots \\ 0 \end{pmatrix} \begin{pmatrix} \bar{v}(t-1) & \cdots & \bar{v}(t-na) & 0 & \cdots & 0 \end{pmatrix} \\
R = & \begin{pmatrix} \tilde{A} & B \\ B^T & C \end{pmatrix} + \begin{pmatrix} \bar{A} & 0 \\ 0 & 0 \end{pmatrix}
\end{aligned}$$

Claramente a condição $C > 0$ é necessária para $R > 0$ e também suficiente se ocorrer também $A > 0$ ou $\bar{A} > 0$. Se $A > 0$, é possível provar que pelo Lema A.3 apresentado em Stoica & Söderström (1989):

$$\tilde{A} - BC^{-1}B^T \geq 0$$

$$\text{posto}(R) = nb + \text{posto}(\tilde{A} + \bar{A} - BC^{-1}B^T)$$

Portanto se $\bar{A} > 0$ conclui-se que $\text{posto}(\tilde{A} + \bar{A} - BC^{-1}B^T) = na$. Assim conclui-se que se $u(t)$ for persistentemente excitante de ordem nb , ou que $C > 0$, e o ruído $v(t)$ é tal que $\bar{A} > 0$, então $R > 0$ e o modelo linear é identificável. Entretanto, essa condição só é válida se há a certeza da existência do ruído branco. No caso geral, é necessário que garantir que $u(t)$ é persistentemente excitante de ordem $na + nb$ conforme em (i).

3 Exemplo de aplicação do método proposto

3.1 Descrição do sistema

O método para excitar e identificar processos em malha fechada com MPC aqui proposto é testado por simulação em um processo real da indústria de refino: uma coluna despropanizadora localizada na RPBC (Refinaria Presidente Bernardes Cubatão) pertencente à Petrobras.

A coluna despropanizadora é utilizada para a separação entre as correntes de propano e butano produzida da Unidade de Craqueamento Catalítico como observado na Figura 3.1. Na coluna despropanizadora, o propano é enviado para o pool de GLP (gás liquefeito de petróleo) e o butano é enviado para a unidade de gasolina de aviação (UGAV).

O controle regulatório existente na coluna despropanizadora é feito no SDCD (Sistema Digital de Controle Distribuído) e consiste nos seguintes controladores principais:

- controlador de vazão de carga - FC1 (variável manipulada do controlador de nível do vaso de carga - LC1);
- controlador de pressão da coluna - PC2 (controla a pressão no estágio 24 manipulando a vazão de retirada de propano no topo);
- controlador de nível de fundo - LC2 (manipula a vazão de retirada de butano no fundo da coluna);
- controlador da temperatura de fundo (manipula a entrada de fluido de aquecimento para o refeedor - FC3);
- controlador de vazão de refluxo - FC2 (há a possibilidade de ser cascadeado pelo controlador da temperatura do topo).

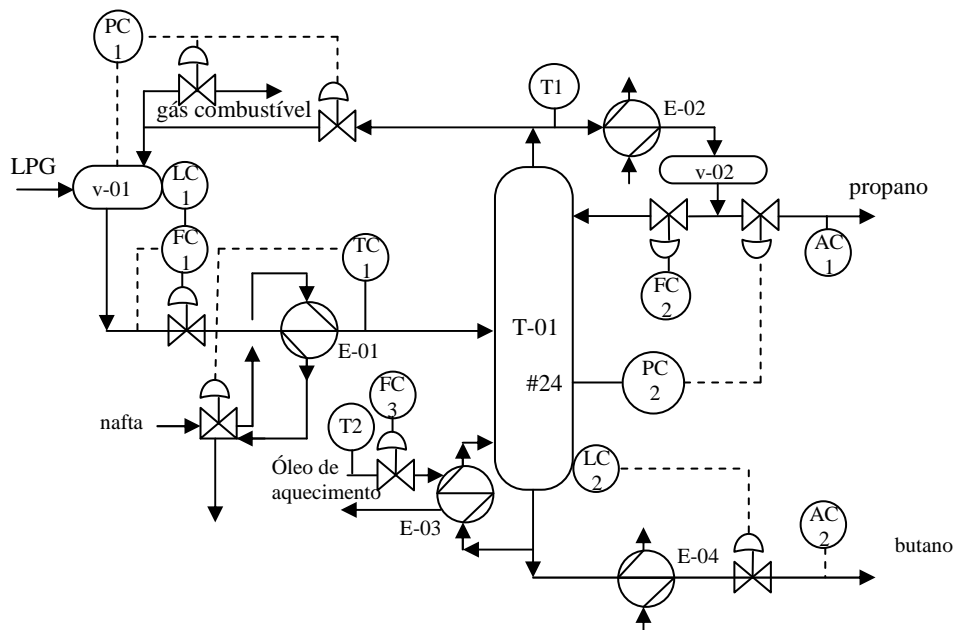


Figura 3.1: Malha de Controle de uma coluna despropanizadora industrial

No SDCD a atuação do operador para o controle da qualidade dos produtos é feita principalmente manipulando o setpoint do controlador da vazão de refluxo e o setpoint do controlador da temperatura de fundo da coluna.

O controlador preditivo instalado na coluna possui duas variáveis controladas (saídas):

- y_1 - Concentração de propano e mais leves na corrente de fundo composta principalmente por butano (obtido por inferência);
- y_2 - Temperatura de topo da coluna (T_{TOPO});

E duas variáveis manipuladas (entradas):

- u_1 - Setpoint da vazão de refluxo topo da coluna (V_{GOP});
- u_2 - Setpoint da vazão de fluido de aquecimento do refeedor (V_{RF}).

Devido à coluna comportar-se como um sistema não linear, o controlador MPC pode ter um desempenho deficiente, pois usa modelos lineares. Em Porfírio (2001), estuda-se o controle do processo usando um conjunto de modelos lineares, onde cada modelo corresponde a um possível ponto de operação. O controlador desenvolvido foi designado o MMPC (Multi Model Predictive Control). No MMPC, a seqüência de controle é computada

por um algoritmo de controle baseado em um problema de otimização min-max, em que a função custo de controle é minimizada para o pior modelo. A principal desvantagem deste tipo de controle é sua complexidade e alto tempo computacional.

No presente trabalho é usado o MPC convencional onde o modelo do processo usado pelo controlador é atualizado através do algoritmo proposto na seção 2.2.

Os modelos usados no MMPC (Multi Model Predictive Control), Porfírio (2001), foram obtidos experimentalmente ou pelo simulador dinâmico Hysys. Na figura 3.2 observam-se as respostas ao degrau unitário de cada um dos modelos aqui considerados. Cada curva tem uma cor e corresponde a um regime de operação da coluna despropanizadora. FD é o modelo mais provável, e os outros modelos possíveis são numerados de 1 a 5. Os vários pontos de operação deste sistema foram obtidos por alterações em variáveis que não fazem parte das variáveis medidas do controlador tais como vazão de carga e composição da carga.

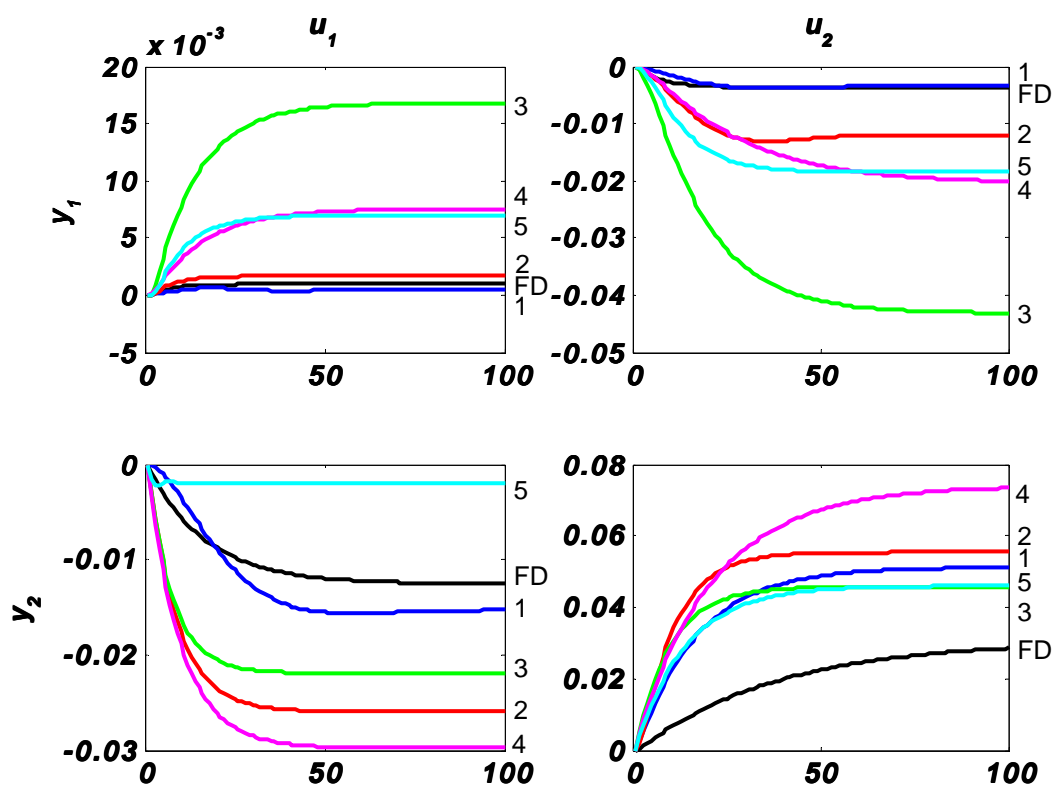


Figura 3.2: Resposta ao degrau - modelos: FD, 1, 2, 3, 4, 5

Na Tabela 3.1 estão listados os parâmetros desses modelos que se apresenta na forma da eq. 3.1.1.

$$G(s) = \frac{b_0 + b_1 s}{s^2 + a_1 s + a_0} e^{-\theta s} \quad (3.1.1)$$

Nessa tabela, são fornecidos os valores dos a_n e b_n correspondentes a cada modelo. Em todos os casos, assume-se que o tempo morto é previamente conhecido $\theta_{ij} = 1$ e que ele não varia com o tempo.

		entrada		V _{RF}		V _{GOP}	
saída		b_n/a_n	0	1	0	1	
FD	T _{TOPO}	b	-1,235E-03	-1,135E-03	2,000E-03	-3,000E-04	
		a	9,852E-02	1,638E+00	6,510E-02	2,430E+00	
	C3 ⁻	b	5,656E-04	-2,218E-04	-1,452E-03	7,413E-05	
		a	5,902E-01	3,495E+00	4,023E-01	2,699E+00	
1	T _{TOPO}	b	-1,116E-04	-8,730E-05	7,000E-03	1,300E-03	
		a	7,300E-03	1,317E-01	1,366E-01	2,261E+00	
	C3 ⁻	b	1,094E-05	4,227E-05	-3,824E-05	-1,206E-04	
		a	2,430E-02	1,090E-01	1,110E-02	1,342E-01	
2	T _{TOPO}	b	-6,300E-03	-3,400E-03	4,500E-03	2,000E-04	
		a	2,428E-01	2,072E+00	8,120E-02	8,352E-01	
	C3 ⁻	b	4,220E-04	-2,722E-04	-1,405E-04	-2,183E-04	
		a	2,525E-01	1,660E+00	1,170E-02	1,322E-01	
3	T _{TOPO}	b	-8,000E-04	-3,400E-03	8,900E-03	6,400E-03	
		a	3,650E-02	4,017E-01	1,946E-01	1,896E+00	
	C3 ⁻	b	1,532E-03	-8,600E-04	-7,811E-04	-3,770E-04	
		a	9,120E-02	1,191E+00	1,810E-02	3,402E-01	
4	T _{TOPO}	b	-2,500E-03	-3,900E-03	2,900E-03	5,500E-03	
		a	8,400E-02	8,868E-01	3,920E-02	8,602E-01	
	C3 ⁻	b	4,881E-04	-1,107E-04	-1,862E-04	-1,763E-04	
		a	6,460E-02	9,881E-01	9,100E-03	2,605E-01	
5	T _{TOPO}	b	-2,100E-03	-1,900E-03	8,100E-03	5,300E-03	
		a	1,107E+00	1,168E+00	1,761E-01	2,419E+00	
	C3 ⁻	b	5,647E-04	-3,596E-04	-4,780E-04	-1,427E-04	
		a	8,090E-02	8,165E-01	2,590E-02	3,417E-01	

Tabela 3.1: Modelos de resposta ao degrau

O estudo da aplicação do método de identificação proposto é feito por simulação usando o MATLABTM. A planta real é representada por um modelo em espaço de estados com tempo discreto definido na eq. 3.1.2. Esse modelo pode corresponder a qualquer um dos modelos representados na Tabela 3.1.

$$\begin{aligned}x(k+1) &= Ax(k) + B\Delta u(k) \\y(k) &= Cx(k)\end{aligned}\tag{3.1.2}$$

Onde A é a matriz de estados, B é a matriz de entradas e C é a matriz de saídas.

É importante mencionar que no controlador estudado, como ocorre em todos os pacotes comerciais, as variáveis do processo são normalizadas, visando a que o controlador trabalhe com variáveis de magnitude comparáveis. Para as entradas, faz-se a seguinte normalização:

$$u_j^{AD}(k) = \frac{u_j(k) - u_j^{\min}}{\text{range}_j} \quad j = 1, \dots, nu\tag{3.1.3}$$

Onde range_j é o intervalo máximo em que cada entrada u_j pode variar.

$$\text{range}_j = u_j^{\max} - u_j^{\min}$$

Esses intervalos entre u^{\max} e u^{\min} são definidos pelo operador.

Analogamente para cada saída, conforme mostrado na eq. 3.1.4 obtém-se a normalização usando o $Fator_{cv_i}$ que é o máximo produto do range_j de cada entrada j pelo correspondente ganho da saída do processo

$$Fator_{cv_i} = \max\left(|K_{i,j}(k)| \cdot \text{range}_j\right) \quad i = 1, \dots, ny$$

Conseqüentemente, a saída normalizada do processo é definida por:

$$y_i^{AD}(k) = \frac{y_i(k) - y_{i,\min}}{Fator_{cv_i}}\tag{3.1.4}$$

A adimensionalização dos ganhos usados tanto da matriz S_m quanto em K , descritas nas seções 1.1 e 1.2, são análogas e calculadas de acordo com a eq. 3.1.5 escrita abaixo:

$$K_{i,j}^{AD} = \frac{\text{range}_j}{Fator_{cv_i}} K_{i,j}\tag{3.1.5}$$

3.2 Sinal de excitação

Como visto anteriormente, para solucionar o problema de excitação da malha fechada com MPC e atender aos requisitos de continuidade operacional, é proposto o uso de uma excitação interna como descrito na seção 2.1, que altera os coeficientes econômicos das variáveis manipuladas dentro da camada estática com um sinal persistentemente excitante. O sinal deve ser projetado de forma independente para o coeficiente de cada variável manipulada com o objetivo de minimizar a correlação-cruzada entre elas, ou maximizar a ortogonalidade entre elas.

Essa proposta não muda o problema de otimização da camada estática do MPC, cuja solução ajusta os sinais, orientados à identificação, para as entradas do processo e mantendo as variáveis controladas em suas faixas. Desta forma, as exigências de identificabilidade são alcançadas, enquanto que a segurança do processo e as especificações da qualidade do produto são satisfeitas.

Sinais GBN são usados para excitar o processo inserindo esses sinais simultaneamente nas duas variáveis manipuladas visando a redução do tempo requerido para realizar a identificação⁶. Neste caso, é necessária especial atenção para evitar a correlação-cruzada entre as entradas, o que pode provocar “bias” no modelo. Foi usada a sugestão de Gaikwad e Rivera (1996) de versões defasadas do mesmo sinal GBN para evitar a correlação-cruzada num sistema com múltiplas entradas. No caso em estudo, a defasagem adotada foi de 200 min, que é aproximadamente o tempo de estabilização da coluna.

Ao longo deste trabalho assume-se que o tempo mínimo de chaveamento T_{min} , usado na Equação 2.1.2, obtido experimentalmente é fixo e igual a 5 períodos de amostragem, que no caso da despropanizadora é de 1 min.

As figuras 3.3 e 3.4 ilustram de que forma o parâmetro n do GBN, visto na eq. 2.1.3, influencia o sinal de excitação. Para o processo em estudo, o tempo de estabilização T_{ss} é aproximadamente igual a 170 min, e, como visto acima, o valor de T_{min} é fixado em 5 min. Daí, no primeiro caso usando um coeficiente $n = 2$, tem-se como consequência, o tempo médio de chaveamento $\mu(T_{sw_1}) = 85$ min e probabilidade $p_{sw_1} = 0.06$. É possível notar que o sinal de excitação correspondente à segunda entrada é igual ao da primeira, porém defasado para que as entradas não sejam correlacionadas.

⁶ Zhu et al. (1997), Zhu (1998) e Butoyi e Zhu (2001) reportam uma economia de 60-70% de tempo, comparado com o teste seqüencial.

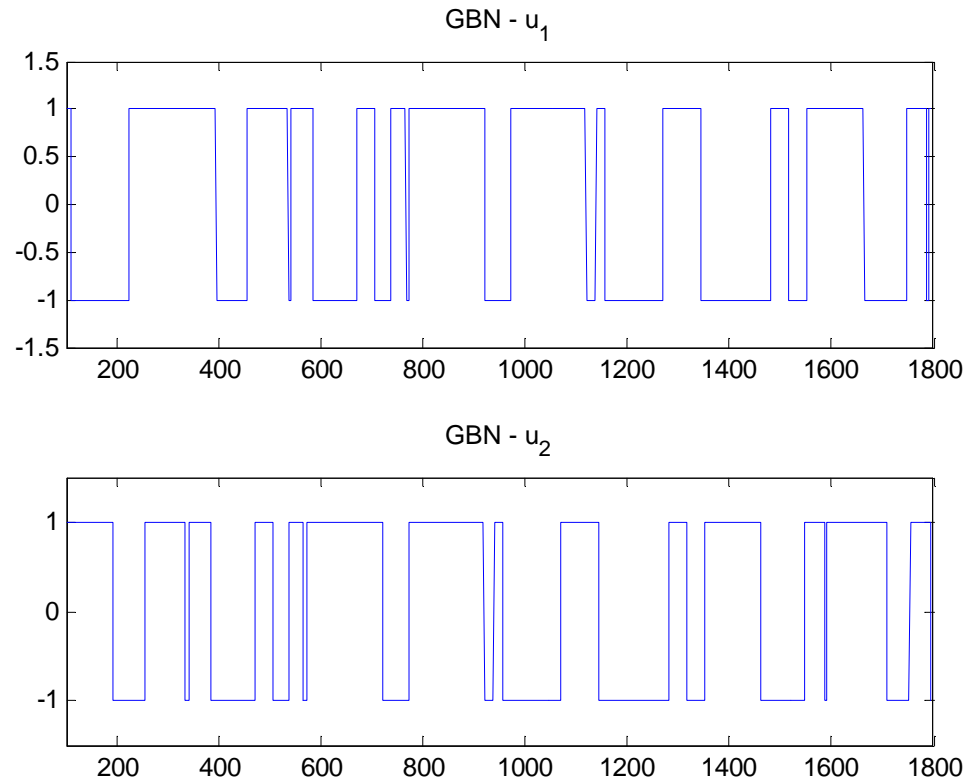


Figura 3.3: Sinal persistentemente excitante com $n=2$

Na Figura 3.4, há um outro sinal de excitação para o mesmo processo, logo os mesmos tempos de estabilização $T_{ss} = 170$ min e tempo mínimo de chaveamento $T_{min} = 5$ min são usados, porém neste caso é usado o coeficiente $n = 4$. Como resultado, o tempo médio de chaveamento é $\mu(T_{sw_I}) = 42.5$ min e probabilidade $p_{sw_I} = 0.12$. Observe-se que nesse caso o chaveamento é muito mais freqüente que no caso anterior.




Figura 3.4: Sinal persistentemente excitante com $n=4$

É importante observar que, durante a excitação, a saída do processo responde à dinâmica da planta, portanto o tempo de estabilização real não é conhecido. Daí, o tempo de estabilização usado na geração do sinal de excitação corresponde ao tempo de estabilização do modelo do controlador, que no caso de ser muito diferente da planta pode gerar problemas na identificação. No processo estudado, os tempos de estabilização dos possíveis modelos da coluna são próximos, conseqüentemente será gerada somente uma seqüência de excitação com um tempo de estabilização fixo em 170 min.

Depois de obtidas as respostas da planta ao sinal de excitação, para a identificação do modelo da coluna, neste trabalho, é usado o toolbox do Matlab⁷ CONTSID (Garnier e Mensler, 2000; Garnier et al., 2003; Garnier et al., 2006), que inclui métodos para estimar sistemas MISO descritos por várias funções de transferências com diferentes denominadores. Em especial, foi usada a rotina Continuous Output-Error (COE) que utiliza o algoritmo de programação não-linear Levenberg-Marquardt para minimização de V_{oe} definido na eq. 2.2.3, levando em conta, novamente, o conhecimento dos valores dos

⁷ Disponível em: <http://www.cran.uhp-nancy.fr/contsid>. A relevância dos métodos contidos neste toolbox foram recentemente demonstrados através de extensas simulações por Rao e Garnier (2004).

parâmetros do modelo usado no controlador, que são usados como solução inicial do problema de otimização, que calcula os parâmetros do modelo a ser identificado.

Por fim, para validar a qualidade do modelo obtido, os resultados do modelo identificado são comparados com dados obtidos do processo correspondentes às mesmas entradas resultantes da excitação persistente que foram usadas no procedimento de identificação. Esses dados podem ser os próprios dados usados na identificação do novo modelo ao que se denomina autovalidação ou através de dados independentes, sendo que neste caso o procedimento é denominado de validação cruzada. Os resultados desta comparação são introduzidos nas equações 3.2.1 e 3.2.2 e obtém-se um valor numérico que mostra o quanto o modelo identificado aproxima-se do modelo real:

$$FIT = 100 \frac{(1 - |y(t) - \tilde{y}(t)|)}{|y(t) - \mu(y)|} \quad (3.2.1)$$

$$RT_2 = 1 - \frac{\sigma^2(y(t) - \tilde{y}(t))}{\sigma^2(y(t) - \mu(y))} \quad (3.2.2)$$

Onde:

- μ é a esperança ou média;
- σ^2 é a esperança de segunda ordem ou variância;
- $y(t)$ é o vetor dos dados de saída da planta usados na validação;
- $\tilde{y}(t)$ é o vetor dos dados de saída obtidos pelo modelo usando as mesmas entradas dos dados de identificação.

Para os casos estudados obtém-se um bom modelo quando o FIT ultrapassa 80% ou RT_2 chega próximo a 0.98, enquanto bons resultados nestes parâmetros não são obtidos tem-se que realizar novas tentativas de identificação.

4 Procedimento de Identificação

O objetivo desta etapa é montar um simulador que represente a coluna despropanizadora representada pelos modelos mencionados na seção 3.1, em malha fechada com o esquema de controle que existe atualmente na unidade, que tem a estrutura mostrada no capítulo 1. Durante o teste, o modelo que representa a coluna real será chaveado para outro modelo possível e o algoritmo de identificação será usado para identificar o novo modelo. Isto significa prever possíveis alterações nos parâmetros desse modelo causadas por mudanças nas condições de operação do processo. Com base nessas informações é montado o simulador do sistema de controle atual usando a plataforma MATLABTM.

As condições iniciais do processo usadas na simulação e os parâmetros do controlador foram adotados como sendo os mesmos do controlador original da torre despropanizadora e se encontram no trabalho de mestrado de Porfírio (2001). Esses valores estão listados na Tabela 4.1.

variável	valor	definição
ny	2	número de saídas
nu	2	número de entradas
nsim	900	tempo de identificação
N	200	horizonte do modelo
p	60	horizonte de predição (otimização)
m	2	horizonte de controle
Ts	1	tempo de amostragem (min)
R	[3 3]'	peso das entradas
Q	[1.3 1.2]'	fator de atenuação das saídas
Ru	[10 10]'	peso dos targets
W2	[5000 -5000]'	peso econômico(GBN)
W1	[0.02 0.02]'	peso termo quadrático
umax	[3250 2000]'	valor máximo seguro das entradas
umin	[2800 1500]'	valor mínimo seguro das entradas
dumax	[10 10]'	variação máxima da saída no instante
y _{max}	[1.05 50]'	faixa máxima de variação das saídas
y _{min}	[0.85 48.5]'	faixa mínima de variação das saídas
u_0	[3160 1731]'	valor inicial das entradas
y_0	[0.88 49.34]'	valor inicial das saídas

Tabela 4.1: Parâmetros de sintonia do MPC da coluna despropanizadora

4.1 Identificação da coluna despropanizadora usando o método de excitação proposto

No caso simulado nesta seção, o MPC que controla a coluna despropanizadora será excitado através dos pesos da camada estática do MPC exatamente como foi mostrado na eq. 2.0.1, utilizando a função objetivo 1.2.1 com os parâmetros listados na Tabela 4.1. Como foi visto anteriormente, o problema resolvido nesta camada é o seguinte:

$$\min_{\Delta u_{IRV}} J_e = \Delta u_{IRV}^T W_1 \Delta u_{IRV} - W_2^T \Delta u_{IRV} + \delta^T \tilde{M} \delta$$

Sujeito a:

$$u^{\min} \leq u(k-1) + \Delta u_{IRV} \leq u^{\max}$$

$$y^{\min} \leq y_{ss} + \delta \leq y^{\max}$$

É considerado o caso em que o objetivo é identificar o modelo da coluna em malha fechada e o processo se comporta de acordo com o modelo 3, ver Figura 3.2, enquanto que o controlador usa o modelo FD para fazer as predições. Foi escolhido o modelo 3 por ter um comportamento do processo bem diferente do modelo FD usado no controle. Aparentemente, esse é o pior caso para o controle da coluna. É possível verificar a necessidade de uma re-identificação do modelo usado pelo controlador observando-se a oscilação na resposta da malha de controle quando o controlador leva as variáveis controladas aos setpoints impostos às saídas através do estreitamento das faixas. Na Figura 4.1.1, são representadas as respostas do sistema quando da introdução de degraus nos setpoints nos instantes 100 e 400 min.




Figura 4.1.1: Resposta ao degrau no setpoint das saídas do processo 3 controlado pelo modelo FD

Neste experimento foi usado sinal de excitação do tipo GBN, conforme apresentado na seção 2.1, com as seguintes características que constam na tabela abaixo. No caso foi utilizado $n=2$, devido aos resultados apresentados com este parâmetro serem melhores que os testes com $n=4$.

n	T_{ss_1}	T_{ss_2}	$\mu(T_{sw_1})$	$\mu(T_{sw_2})$	P_{sw_1}	P_{sw_2}
2	170	170	85	85	0.06	0.06

Tabela 4.2: Parâmetros do de excitação

Na Tabela 4.2 acima os índices 1 e 2 correspondem às entradas u_1 e u_2 respectivamente. A seqüência resultante desta configuração de parâmetros é representada na Figura 4.1.2.




Figura 4.1.2: Sinal de excitação do tipo GBN com $n=2$

Na Figura 4.1.3 observa-se o comportamento do processo quando da introdução do sinal de excitação descrita acima na camada estática do controlador MPC. Note no gráfico das entradas u_1 e u_2 que os valores das variáveis manipuladas (linhas contínuas) acompanham quase que perfeitamente o ponto ótimo de operação (linhas tracejadas que coincidem com as trajetórias das variáveis manipuladas) calculado pela camada de otimização estática (onde foi inserido o sinal de excitação do tipo GBN). Note que as saídas y_1 e y_2 descritas pelas linhas contínuas ao saírem da faixa de operação (linhas tracejadas) provocam atuação do controlador nas entradas u_1 e u_2 . Para uma boa identificação é importante que o processo oscile por longos períodos de tempo dentro da faixa que restringe sua operação, caso contrário haverá um excesso de atuação do controlador e conseqüentemente o efeito da realimentação tornará os dados inadequados sob o aspecto de identificação. Os fatores importantes na identificação são os valores de n e T_{sw} usados para gerar o sinal de excitação. Se seu produto for muito grande ocorrem mudanças muito bruscas nas entradas impossibilitando ao identificador observar a resposta em frequências baixas do espectro. Se esse produto for muito pequeno não se gerará excitação suficiente

para identificação. Feitos os cálculos descritos na seção 3.1 chega-se a conclusão que o sinal aplicado neste caso é persistentemente excitante (PE).




Figura 4.1.3: Comportamento do processo durante a identificação em malha fechada com excitação através dos targets: (...), targets, (—) resposta do sistema

Uma vez obtido o novo modelo do processo, compara-se a resposta ao degrau deste com as respostas do modelo usado no controlador e do modelo real do processo. Essas respostas podem ser vistas na Figura 4.1.4. A resposta do modelo usado no controlador é representada pela curva pontilhada enquanto que a resposta do modelo identificado é representada pela curva tracejada. Nota-se que o modelo identificado tende a ser melhor que o modelo usado no controle, mas ainda bem diferente do modelo real.

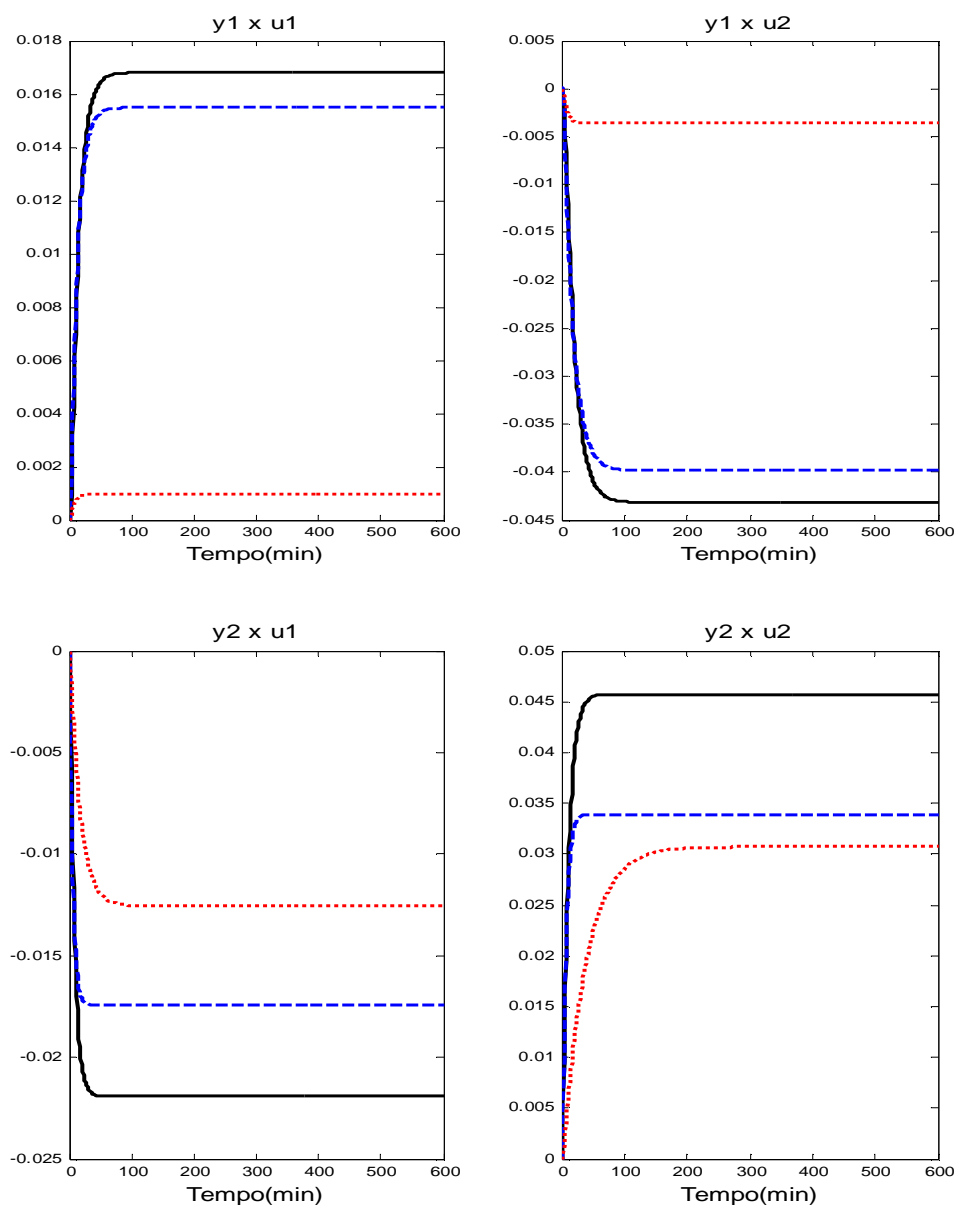


Figura 4.1.4: Resposta ao degrau dos modelos: modelo usado no controle (...), modelo identificado (---), processo (—)

Foi inserido o modelo real para fins demonstrativos, mas na prática, o modelo real é desconhecido e não é possível verificar o resultado da identificação pela comparação das respostas ao degrau. Assim, a validação do modelo obtido tem que ser feita usando um outro método. Por exemplo, pode-se fazer a validação do resultado como proposto por Ljung (1999) cruzando os dados das entradas e saídas do modelo e do processo real. A simulação da saída do modelo obtido na identificação para cada movimento das entradas teria que coincidir com o valor real da saída real, o que nunca ocorre devido às perturbações e não linearidades do processo. Porém, pode-se calcular uma correlação dos pontos obtidos que mostre o quão próximo o modelo identificado está do real. A validação pode ser feita

com dois tipos de dados vindos do processo. Os dados usados durante identificação dão origem a autovalidação e podem trazer bons resultados, porém não há confiança quanto à qualidade do modelo identificado, pois o modelo pode ter se adequado ao ruído estocástico.

A validação cruzada é uma opção mais realista que a autovalidação já que os dados usados na verificação são desconhecidos pelo identificador. Isso significa usar um novo conjunto de dados entrada x saída para testar o desempenho do modelo identificado. Porém a validação cruzada depende da disponibilidade de dados de entrada e saída gerados com sinal de excitação que não foram usados na identificação, o que aumenta o tempo da identificação e seus custos.

A validação cruzada do modelo obtido é mostrada na Figura 4.1.5, o FIT do modelo usado para descrever a saída 1 é de 50% enquanto que com o modelo originalmente usado no controlador é de apenas 23%. Analogamente, o valor de RT_2 subiu de 0.41 para 0.75.

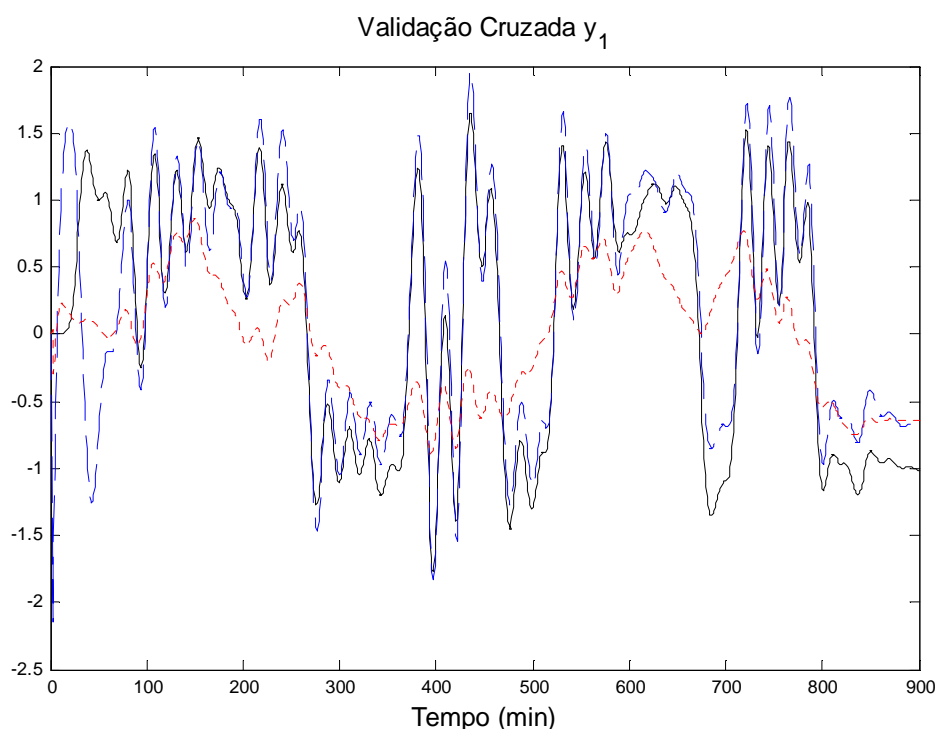


Figura 4.1.5: Validação cruzada para saída 1 do modelo usado no controle (...), modelo identificado (---) e processo(—)

A Figura 4.1.6 mostra os resultados da validação cruzada para a saída 2, que comparativamente apresentam resultados melhores que para saída 1. Isto está relacionado ao fato de a realimentação do movimento na saída 2 ser bem menor que a da saída 1, como pode ser observado na Figura 4.1.3. Como consequência, do modelo usado com controlador

para o modelo identificado, o FIT melhorou de 19% para 87% e RT_2 melhorou de 0.34 para 0.98.

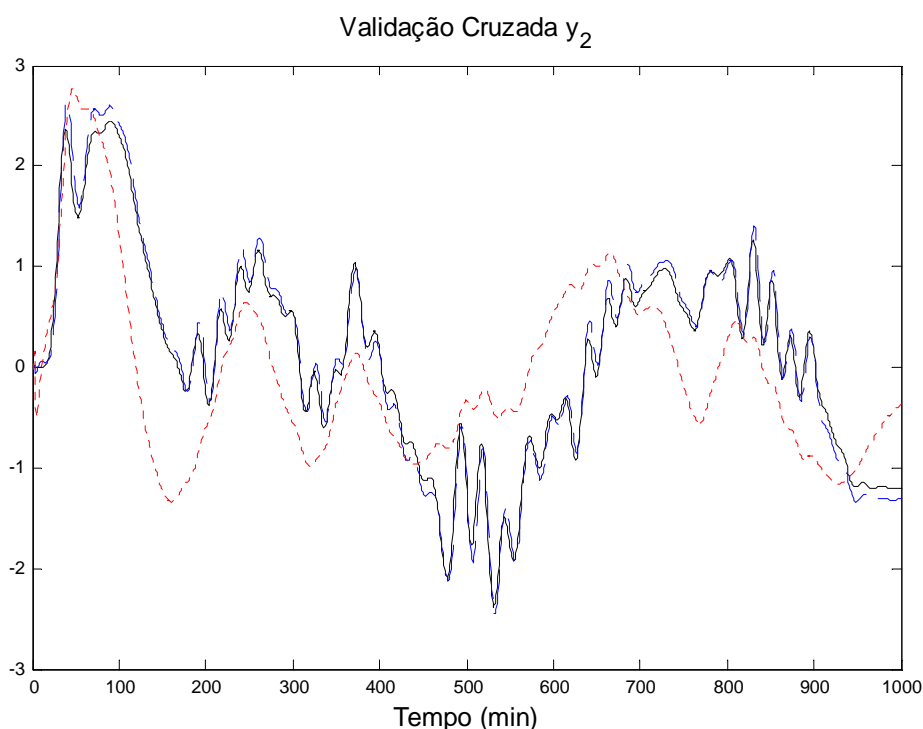


Figura 4.1.6: Validação cruzada para saída 2 do modelo usado no controle (...), modelo identificado (---) e processo(—)

Concluindo a análise, os resultados da validação cruzada e modelos de resposta ao degrau mostram que o modelo ainda pode não ser totalmente satisfatório para fins de controle e talvez fosse interessante melhorar o modelo ainda mais. Verifica-se a necessidade ou não de uma melhoria adicional no modelo identificado observando-se o comportamento do sistema em malha fechada com o MPC baseado no novo modelo. A Figura 4.1.7 mostra as respostas do sistema com esse controlador. Nessa figura são simuladas o mesmo estreitamento de faixa para gerar um setpoint, como usado caso da Figura 4.1.1. Observando essa figura, nota-se que o controlador usando o modelo identificado apresenta comportamento estável e muito melhor que no caso da Figura 4.1.1. Em termos práticos, o problema de re-identificação do modelo da despropanizadora poderia ser considerado resolvido.




Figura 4.1.7: Resposta ao degrau no setpoint das saídas do processo 3 usando no controle o modelo identificado

Entretanto é possível conseguir resultados ainda melhores repetindo-se o teste de re-identificação. Para melhorar o modelo identificado repete-se o teste de identificação, porém nesse novo teste, usando no controlador o novo modelo obtido na identificação anterior. Este procedimento pode ser considerado um procedimento de identificação recursiva.

Na Figura 4.1.8, observam-se as respostas do sistema ao sinal de excitação introduzido na camada de otimização do controlador.




Figura 4.1.8: Comportamento do processo durante a identificação em malha fechada com excitação através dos targets: (...)targets, (—) resposta do sistema

Apesar do sinal de excitação usado neste caso, ser a mesma sequência definida na Figura 4.1.2, o comportamento das entradas e saídas é diferente da observada na Figura 4.1.3 porque o controlador atua mais suavemente quando as variáveis controladas deixam as faixas de controle. Isto porque o controlador usa o modelo atualizado pela última identificação, portanto os erros de predição são menores. Isso leva a uma menor realimentação das saídas, o que proporciona uma melhor identificação neste teste.

Na Figura 4.1.9 estão os modelos de resposta ao degrau do novo modelo obtido com os dados resultantes do teste descrito na Figura 4.1.8. Também são mostrados o modelo usado no controlador e o modelo real. Observa-se que, aparentemente, os modelos vão se tornando mais próximos do modelo real à medida que o procedimento recursivo é aplicado.

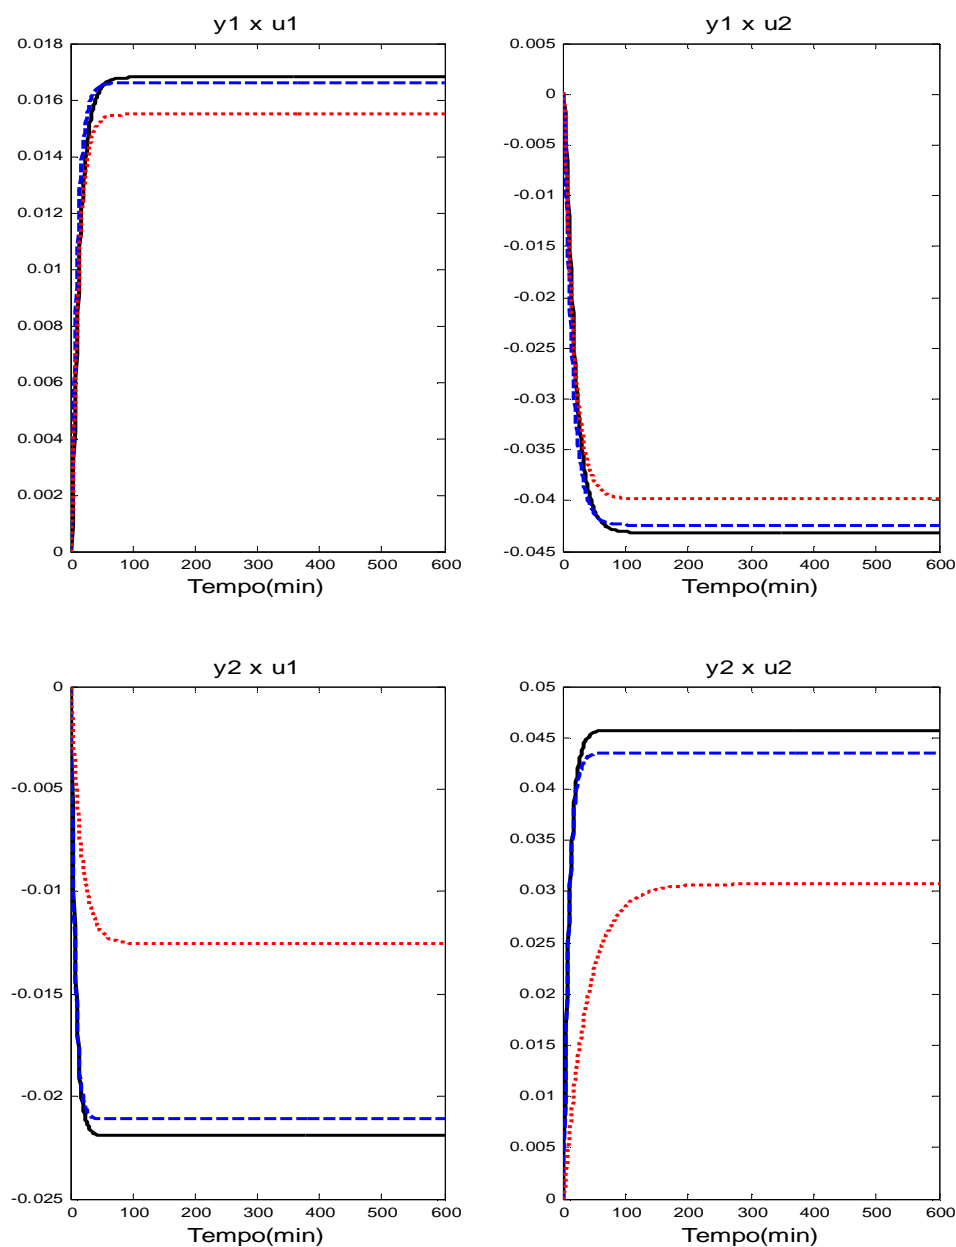


Figura 4.1.9: Resposta ao degrau dos modelos: modelo usado no controle (...), modelo identificado no processo recursivo (---), processo (—)

Na análise dos resultados da validação cruzada para o novo modelo, representada na Figura 4.1.10, o ajuste para a saída 1 (FIT 53% e $RT_2=0.78$) ainda não está tão bom quanto o ajuste para a saída 2 (FIT=92% e $RT_2=0.99$). Entretanto, esses números representam uma evolução do modelo identificado em relação ao anterior.

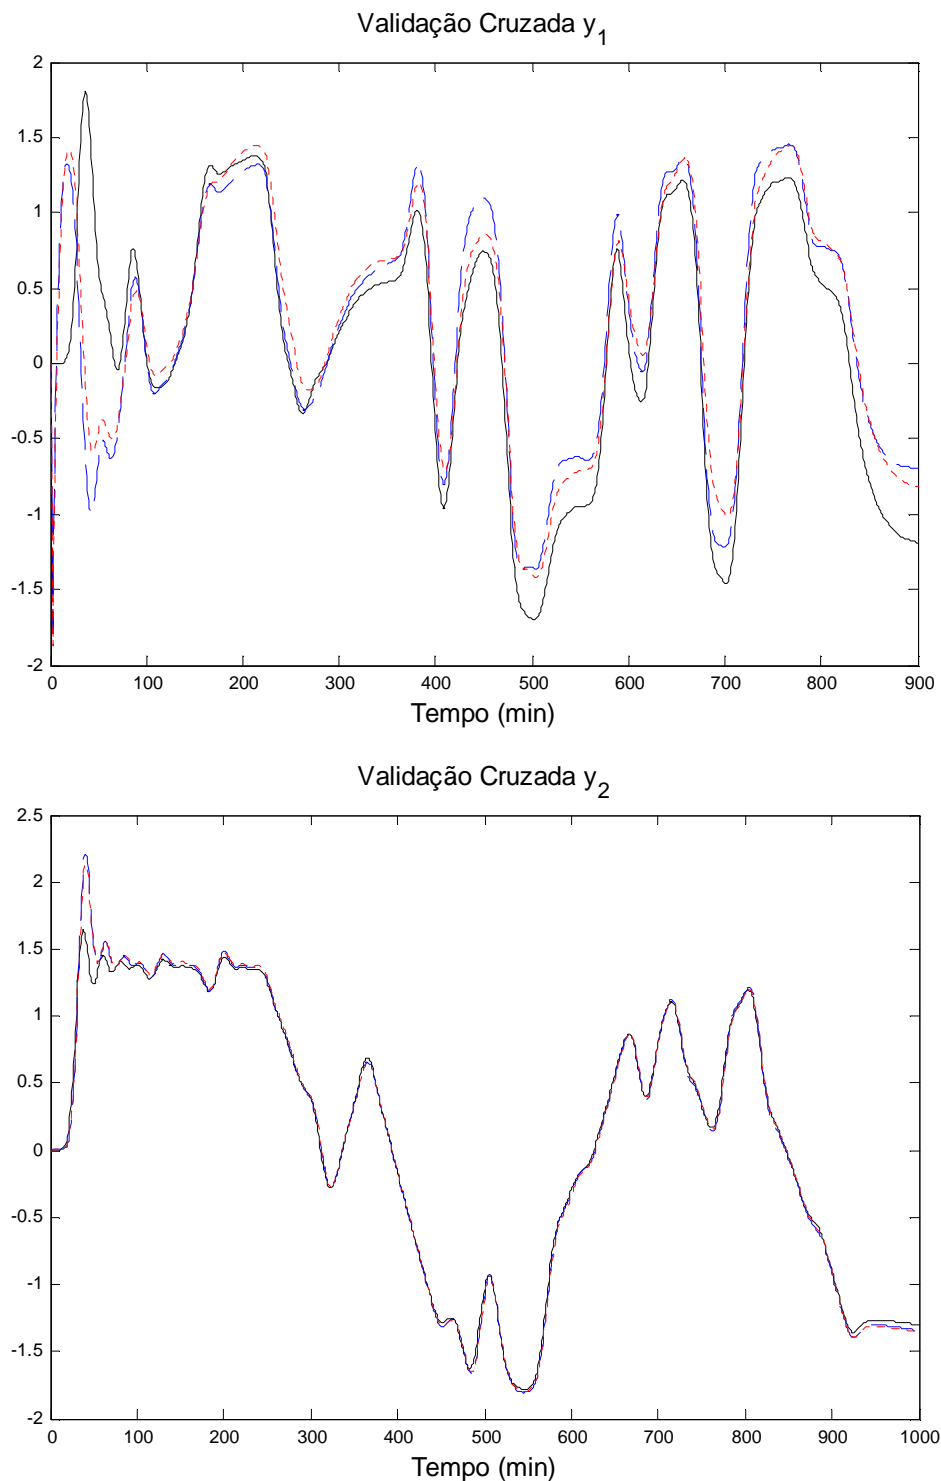


Figura 4.1.10: Validação cruzada para saídas do modelo usado no controle (...), modelo identificado (---) e processo(—)

A Figura 4.1.11 mostra o desempenho da despropanizadora em malha fechada com o MPC baseado no novo modelo em uma tentativa de impor setpoints às saídas. A nova identificação trouxe uma melhora no controle do sistema, retirando as oscilações, quando comparando a Figura 4.1.11 com as Figuras 4.1.1 e 4.1.7.

Esses resultados mostram que o procedimento de identificação em malha fechada do modelo MPC tem um bom potencial para ser aplicado na prática como alternativa ao controlador MMPC atualmente em operação na coluna.




Figura 4.1.11: Resposta ao degrau no setpoint das saídas do processo 3 usando no controle o modelo identificado

4.2 Identificação usando sinal excitação nos “targets” das entradas

Nesta seção, será testada uma forma alternativa de introduzir o sinal de excitação no controlador MPC de duas camadas. No método aqui proposto, a camada de otimização estática é modificada de tal forma que o sinal de excitação seja introduzido como “target” para a entrada. Esse tipo de modificação é também adotada por alguns MPCs que estão integrados com a otimização rigorosa da operação, que é normalmente realizada em uma camada superior na estrutura de controle da unidade. Essa camada de otimização trabalha com modelos estacionários rigorosos e como resultado enviam “targets” para as entradas e eventualmente saídas do processo. Esses “targets” externos são tratados pela camada de otimização estática do MPC para produzir os “targets” internos que são enviados para a

camada dinâmica do MPC. No método proposto a seguir, os “targets” são produzidos como sinais GBN que são projetados da mesma forma que nas seções anteriores. Assim, propõe-se que a camada de otimização do estado estacionário seja convertida no seguinte problema:

$$\min_{\Delta u_{IRV}} J_e = (\Delta u_{IRV} - [u_{exc} - u_{at}])^2 W_3 + \delta^2 W_4 \quad (4.2.1)$$

Sujeito a:

$$u^{\min} \leq u(k-1) + \Delta u_{IRV} \leq u^{\max} \quad (4.2.2)$$

$$y^{\min} \leq y_{ss} + \delta \leq y^{\max} \quad (4.2.3)$$

Onde u_{exc} é o vetor de valores desejados para as entradas definidos pela seqüência de excitação projetada externamente. O vetor de incrementos Δu_{IRV} é o vetor de incógnitas desse problema. Os “targets” enviados para a camada dinâmica do MPC são definidos pela equação:

$$u_{target} = u(k-1) + \Delta u_{IRV}$$

Os parâmetros da camada dinâmica do controlador são os mesmos usados no exemplo anterior. Além disso, usou-se $W_3 = I_{nu}$, onde I_{nu} representa a matriz identidade de dimensão nu , e $W_4 = 10^6$.

Na Figura 4.2.1, são mostrados os sinais u_{exc} introduzidos na camada estacionária do MPC de acordo com os parâmetros da Tabela 4.3.

N	T_{ss_1}	T_{ss_2}	$\mu(T_{sw_1})$	$\mu(T_{sw_2})$	p_{sw_1}	p_{sw_2}
2	170	170	85	85	0.06	0.06

Tabela 4.3: Parâmetros do de excitação

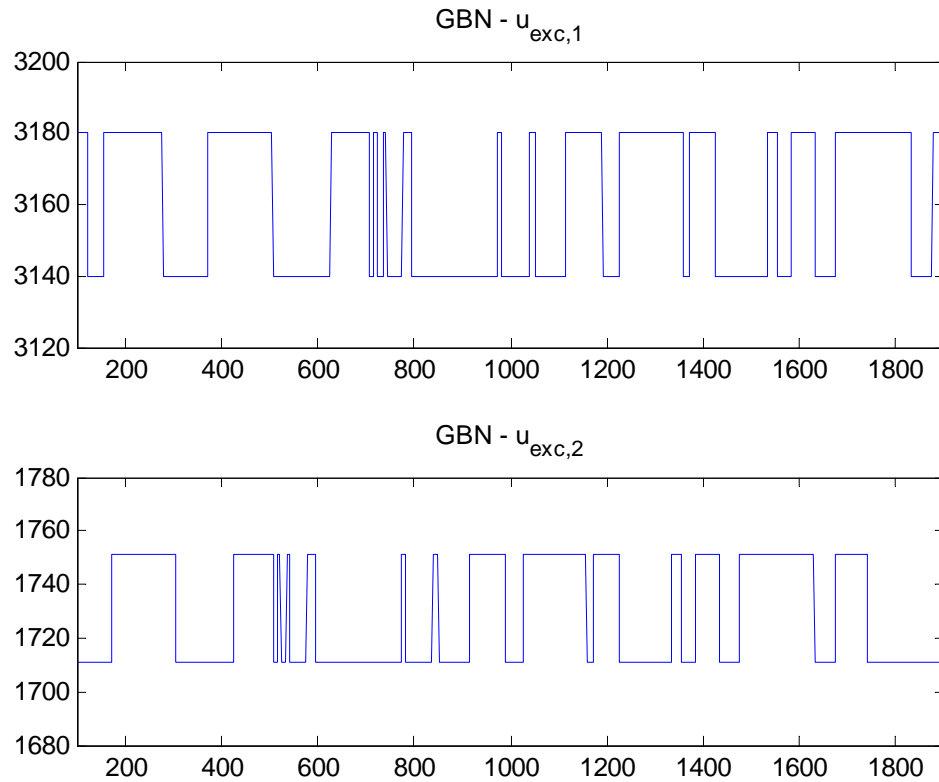


Figura 4.2.1: Sinal de excitação com $n=2$

A Figura 4.2.2 mostra as respostas da coluna com controlador MPC com camada estática resolvendo o problema definido na eq. 4.2.1 e excitado conforme a Figura 4.2.1. O controlador está usando o modelo FD e a planta real é novamente representada pelo modelo 3 da figura 3.2. Na Figura 4.2.2 os u_{target} seguem os u_{exc} com relativa precisão. Também foi notado que os u realmente implementados têm os mesmos perfis dos targets definidos pela camada estacionária. Portanto, em princípio, este método tem a vantagem de garantir com maior precisão, que as entradas do sistema serão persistentemente excitantes.

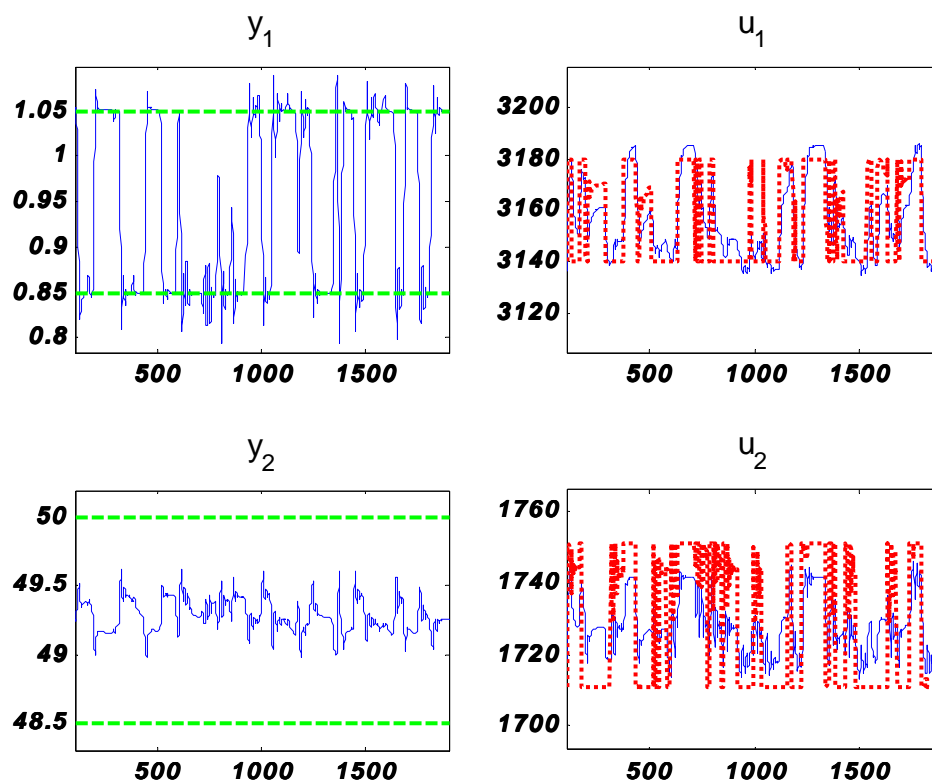


Figura 4.2.2: Comportamento do processo durante a identificação em malha fechada com excitação através dos targets: (...) targets, (—) resposta do sistema

Na Figura 4.2.3 são comparadas as respostas ao degrau do modelo identificado usando os dados representados na Figura 4.2.2, do modelo real da planta e do modelo usado no controle pelo controlador. As respostas do modelo identificado estão mais próximas das respostas do modelo da planta que as do modelo inicialmente usado no controlador. Essa tendência é também observada na validação cruzada do modelo obtido que é apresentada na Figura 4.2.4.

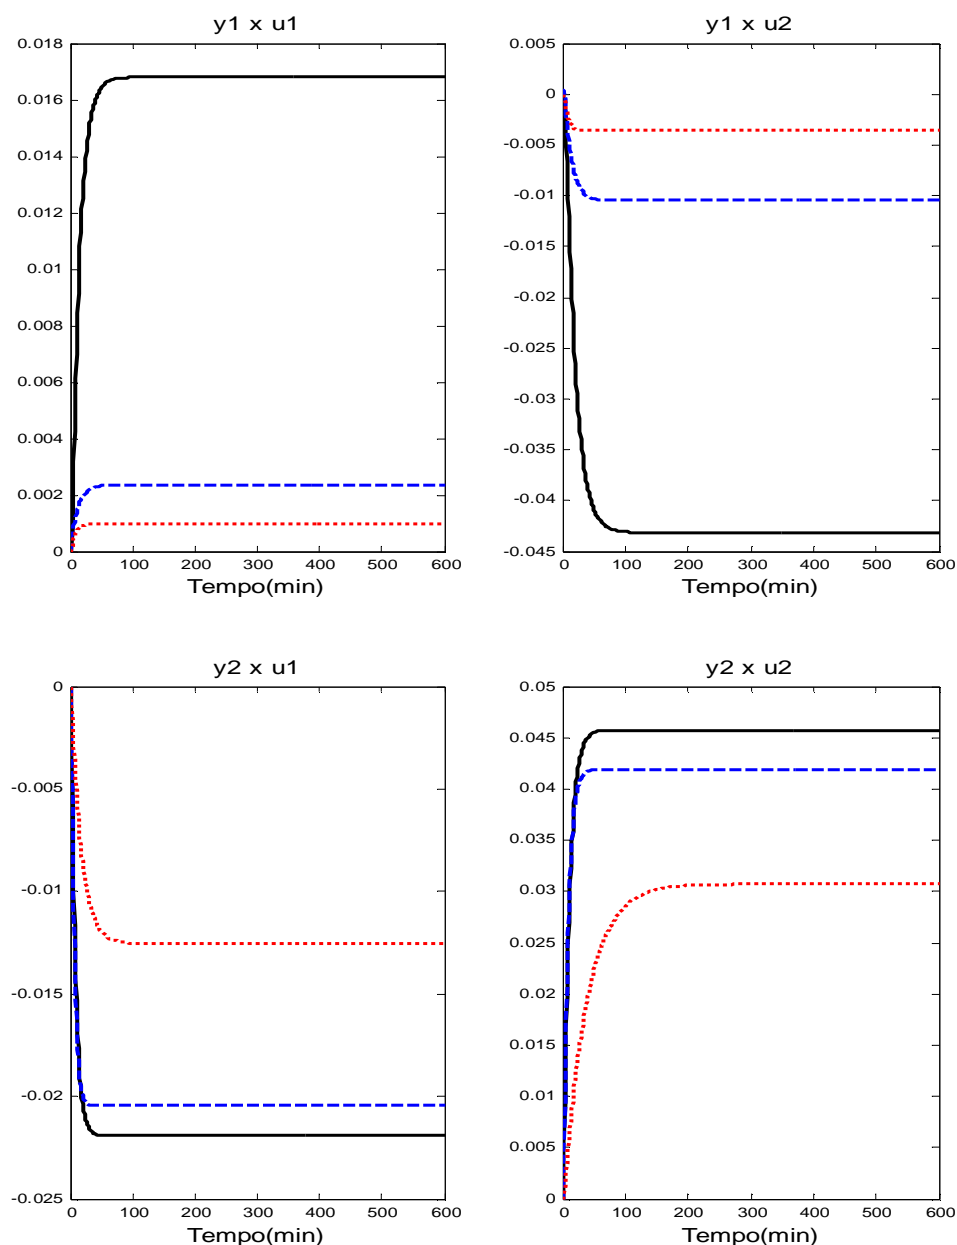


Figura 4.2.3: Resposta ao degrau dos modelos: modelo usado no controle (...), modelo identificado (---) e processo(—)

A validação cruzada do modelo obtido é representada na Figura 4.2.4 e apresenta resultados numéricos com FIT 35% e $RT_2=0.59$ na saída 1, e FIT=78% e $RT_2=0.95$ na saída 2. Observe que esses resultados são piores que os resultados correspondentes à Figura 4.1.5 e 4.1.6, seção anterior, que mostra a validação cruzada do modelo obtido na primeira iteração do método proposto na seção anterior que excita o sistema através dos coeficientes da função objetivo da camada estática.

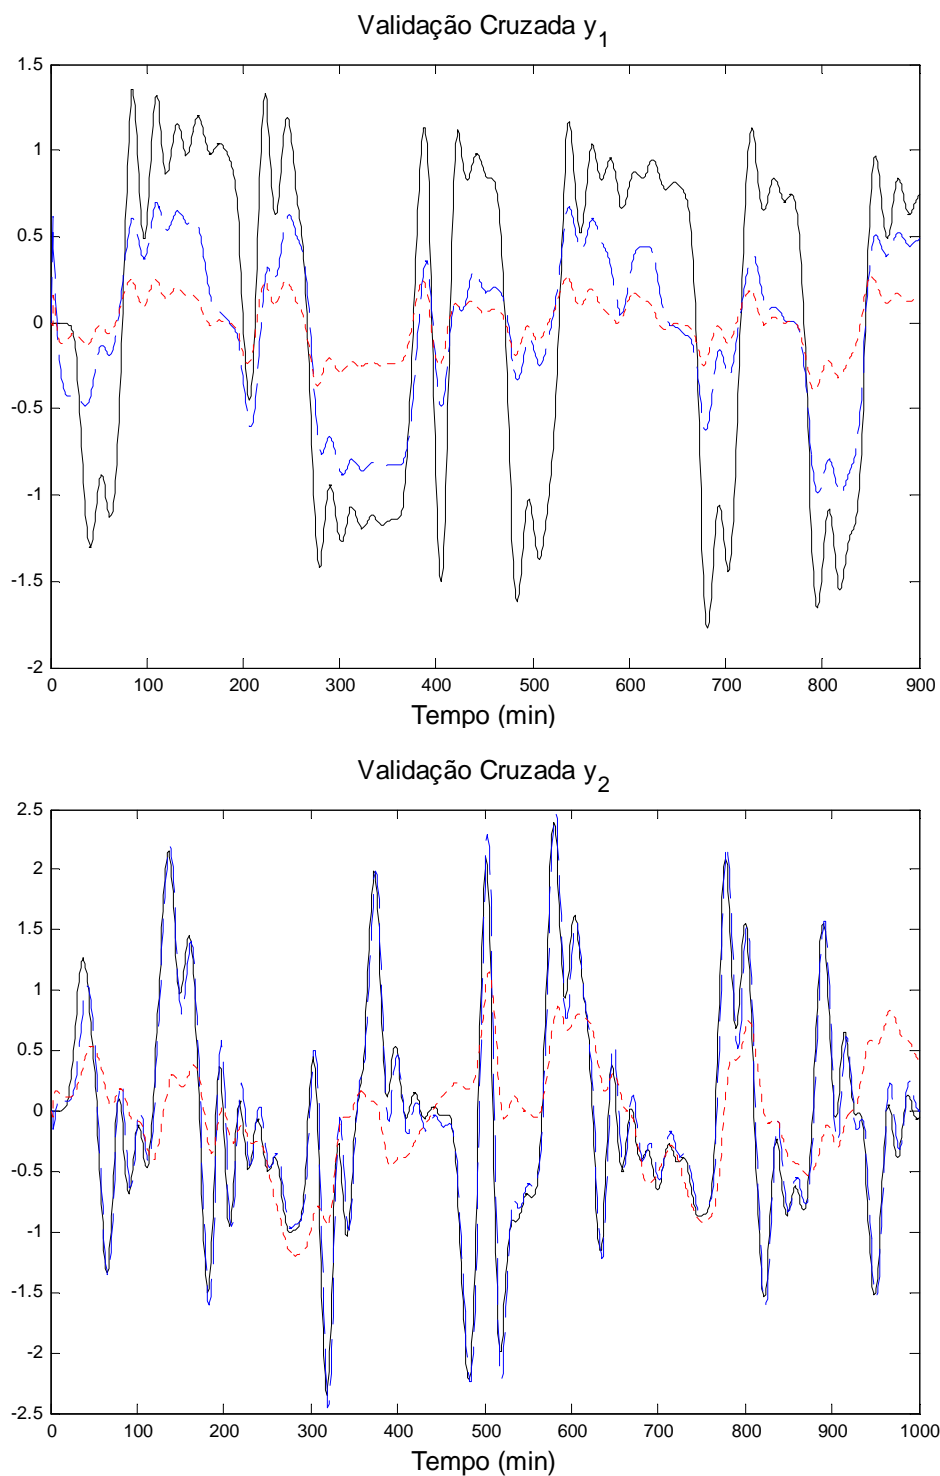


Figura 4.2.4: Validação cruzada para ambas as saídas do modelo usado no controle (...), modelo identificado (---) e processo(—)

As respostas da malha fechada, com o controlador MPC atualizado com o modelo obtido acima, são apresentadas na Figura 4.2.5. Conclui-se que a performance do controlador com o novo modelo não apresenta significativas vantagens em relação reposita

do sistema mostrada na Figura 4.1.7 que corresponde ao modelo obtido pelo método proposto na seção anterior.




Figura 4.2.5: Resposta ao degrau no setpoint das saídas do processo com MPC usando obtido via excitação dos targets

Analogamente à seção anterior, é possível melhorar o modelo obtido acima repetindo o teste de identificação, porém usando no MPC o modelo já identificado. A Figura 4.2.6 compara as respostas ao degrau em malha aberta do novo modelo com as respostas do modelo identificado inicialmente e do modelo real do processo. Pode-se observar que o resultado é bastante bom e muito semelhante ao resultado obtido na segunda iteração do método proposto na seção anterior (vide Figura 4.1.9). A Figura 4.2.7 apresenta as respostas da despropanizadora ao degrau no setpoint, operando em malha fechada com o MPC baseado neste último modelo. Pode-se notar que essas respostas são equivalentes às respostas representadas na Figura 4.1.11 que correspondem à segunda iteração do método proposto na seção anterior.

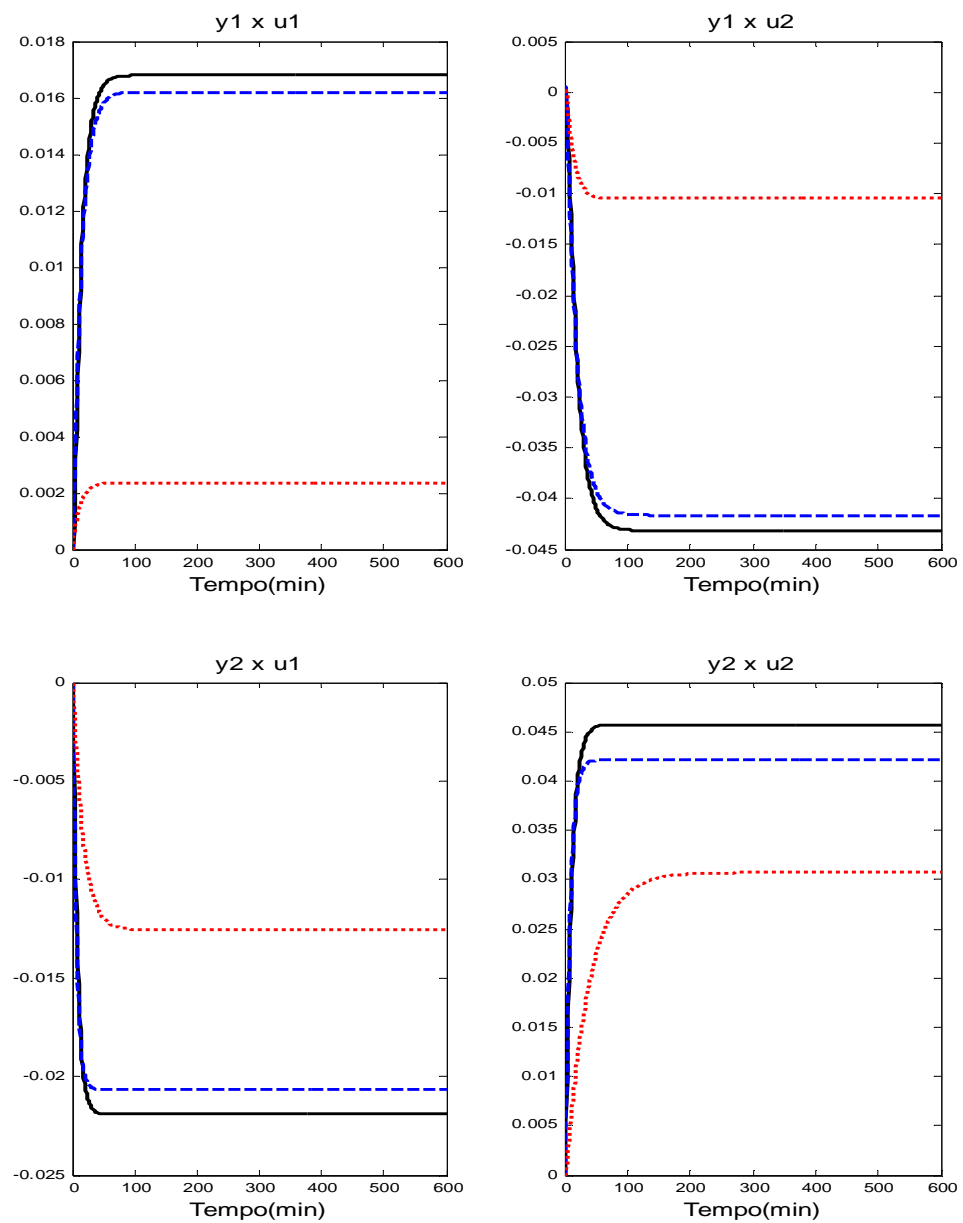


Figura 4.2.6: Resposta ao degrau dos modelos: modelo usado no controle (...), modelo identificado recursivamente (---) e processo(—)




Figura 4.2.7: Resposta ao degrau no setpoint das saídas do processo usando no controle o modelo identificado

Foram tiradas algumas conclusões sobre a aplicação dos dois métodos propostos neste trabalho para excitação do MPC em duas camadas: Embora a introdução da excitação via “targets” das manipuladas seja mais adequada no sentido de garantir que as entradas sejam persistentemente excitadas, os resultados das identificações obtidas para a coluna despropanizadora não são melhores que os resultados obtidos com o método de excitação via coeficientes da função objetivo. Acredita-se que em termos práticos os dois métodos sejam equivalentes. Entretanto, uma diferença importante entre os dois métodos é que a excitação via “targets” das manipulada exige alterações no código fonte do controlador MPC. E assim, quando o usuário não tem acesso a esse código, o método não pode ser aplicado. Por outro lado, os coeficientes da função objetivo da camada estática do controlador são parâmetros de sintonia do controlador, portanto podem ser alterados livremente pelo usuário. O uso do método de excitação via coeficientes da função objetivo é preferível, pois apresenta-se mais seguro devido às alterações menos bruscas nas variáveis manipuladas.

5 Identificação de um sistema não-linear

No exemplo considerado nas simulações do capítulo 4, o processo real era representado por um modelo linear de ordem conhecida e parâmetros desconhecidos. Seria interessante testar também o desempenho do método de identificação proposto via coeficientes da função objetivo para o caso de um sistema não-linear, onde, dependendo do ponto de operação, o modelo linear que é usado pelo controlador MPC deve ser re-identificado para representar o processo adequadamente. Para realizar esse teste é usado o modelo rigoroso de um reator CSTR de polimerização de estireno. O reator consiste de um volume bem agitado onde ocorre a reação de polimerização do estireno em solução que é iniciada por radicais livres (Maner et al., 1996). O reator é envolto por uma jaqueta de resfriamento. Hidalgo e Brosilow (1990), propuseram controlar a temperatura do reator e o peso molecular do polímero manipulando a vazão de água de resfriamento na jaqueta e a vazão de iniciador para o reator. O modelo será do tipo MIMO e será controlado próximo ao ponto de estado estacionário de baixa conversão. Uma representação esquemática do reator pode ser vista na Figura 5.1 (Sotomayor et al., 2006c).

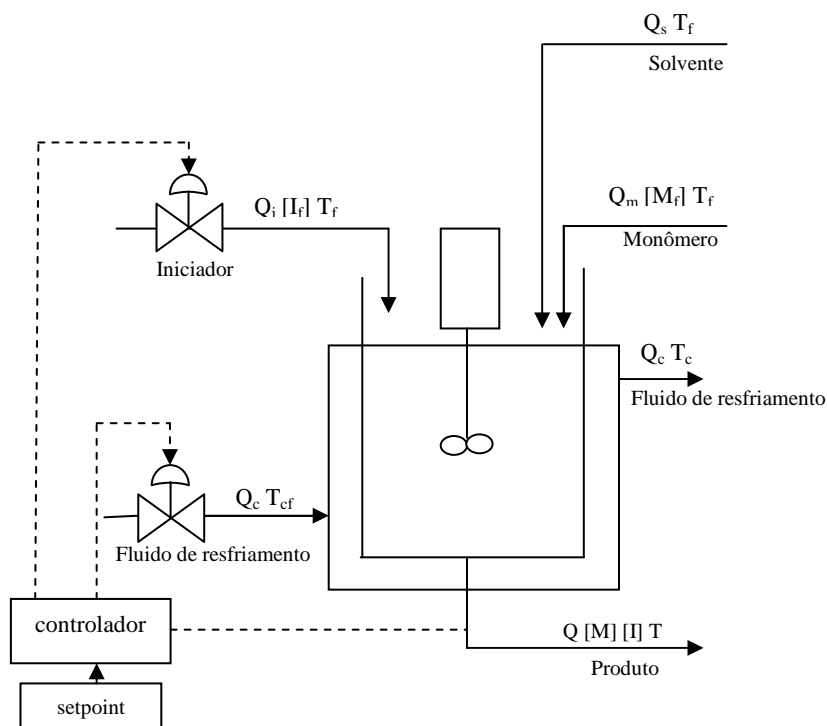


Figura 5.1: Representação esquemática do reator de polimerização de estireno

O modelo do reator é composto de quatro equações de balanços dinâmicos de massa de iniciador, massa de monômero, calor no reator e calor na camisa de refrigeração. O balanço de massa de iniciador corresponde à seguinte equação diferencial:

$$\frac{d[I]}{dt} = \frac{Q_i[I_f] - Q_t[I]}{V} - k_d[I] \quad (5.0.1)$$

onde

$[I]$ - concentração de iniciador no reator (mol/l)

$[I_f]$ - concentração de iniciador na corrente de iniciador (mol/l)

Q_i - vazão da corrente contendo o iniciador (l/s)

Q_t - vazão da mistura que deixa o reator (l/s)

V - volume do reator (l)

k_d - é a constante cinética de decomposição do iniciador (s/mol/l)

O balanço da massa de monômero no reator é descrito pela seguinte equação:

$$\frac{d[M]}{dt} = \frac{Q_m[M_f] - Q_t[M]}{V} - k_p[M][P] \quad (5.0.2)$$

onde

$[M]$ - concentração de monômero no reator (mol/l)

Q_m - vazão da corrente de entrada contendo o monômero (l/s)

$[M_f]$ - concentração de monômero na corrente de alimentação (mol/l)

k_p - constante cinética da reação de polimerização (s/mol²/l²)

$$[P] = \left[\frac{2f \cdot k_d [I]}{k_t} \right]^{0.5} \quad \text{onde } f \text{ é a fração volumétrica de solvente e } k_t \text{ é a constante}$$

cinética da reação de terminação da reação de polimerização (s/mol/l).

As constantes cinéticas de reação são calculadas por uma expressão do tipo

$$k_i = A_i \exp(-E_i/T) \quad , \quad i = d, p, t$$

onde A_i é o fator pré-exponencial, E_i a energia de ativação (K) e T a temperatura (K).

O balanço de energia no reator é descrito pela seguinte equação:

$$\frac{dT}{dt} = \frac{Q_i(T_f - T)}{V} + \frac{(-\Delta H_r)}{\rho C_p} k_p [M][P] - \frac{hA}{\rho C_p V} (T - T_c) \quad (5.0.3)$$

onde

Q_i - vazão total de fluídos introduzidos no reator (mol/s). Admitindo que o volume do reator é constante, essa vazão pode ser calculada por $Q_i = Q_s + Q_m$ onde Q_s é a vazão de solvente.

T_f - temperatura das várias alimentações (K)

ΔH_r - entalpia da reação (cal/mol)

ρC_p - capacidade calorífica da solução no reator (cal/K.l)

hA - coeficiente de transferência de calor (cal/K.s)

T_c - temperatura do fluído de refrigeração na camisa (K)

O balanço de energia na camisa de resfriamento do reator corresponde à seguinte equação:

$$\frac{dT_c}{dt} = \frac{Q_c(T_{cf} - T_c)}{V_c} + \frac{hA}{\rho_c C_{pc} V_c} (T - T_c) \quad (5.0.4)$$

onde

Q_c - vazão do fluído de refrigeração (l/s)

T_{cf} - temperatura de entrada do fluído de refrigeração (K)

V_c - volume de fluído na camisa de refrigeração (l)

$\rho_c C_{pc}$ - capacidade calorífica do fluído de refrigeração (cal/K.l)

Duas outras equações correspondentes aos balanços dos momentos de ordem 0 e 1 são incluídas no modelo do reator. Essas equações são as seguintes:

$$\frac{dD_0}{dt} = 0.5k_t[P]^2 - \frac{Q_i D_0}{V} \quad (5.0.5)$$

$$\frac{dD_1}{dt} = M_m k_t [M][P] - \frac{Q_i D_1}{V} \quad (5.0.6)$$

onde

D_0 e D_1 são os momentos de ordem 0 e 1 respectivamente e M_m é o peso molecular do monômero. Os dois momentos calculados acima podem ser usados no cálculo do peso molecular médio do polímero, que é obtido pela equação:

$$MM = \frac{D_1}{D_0}$$

Hidalgo e Brosilow (1990), assumem que a fração volumétrica de solvente é mantida constante $f = 0.6$ e a vazão de solvente é manipulada de acordo com a seguinte equação:

$$Q_s = 1.5Q_m - Q_i$$

Nas simulações realizadas nesta seção, o modelo definido pelas equações 5.0.1 a 5.0.6 é integrado pelo método de Runge-Kutta em uma rotina implementada no MATLAB. Os parâmetros cinéticos e termodinâmicos do modelo considerado nessas simulações estão listados na Tabela 5.1.

símbolo	valor	parâmetro
f	0.6	Fração de volume do solvente
A_d	$5.95 \cdot 10^{13}$ L/s	Constante cinética da reação do iniciador
E_d	14897 K	Energia de Ativação da reação do iniciador
A_t	$1.25 \cdot 10^9$ L/s	Constante cinética da reação de terminação
E_t	843 K	Energia de Ativação da reação de terminação
A_p	$1.06 \cdot 10^7$ L/s	Constante cinética da reação de adição radicalar
E_p	3557 K	Energia de Ativação da reação de adição radicalar
$-\Delta H_R$	16700 cal/mol	Entalpia da reação de adição radicalar
hA	70 cal/(K s)	Coefficiente de transferência de energia
ρC_p	360 cal/(K L)	Capacidade calorífica da solução no reator
ρC_{pc}	966.3 cal/(K L)	Capacidade calorífica da água de refrigeração

Tabela 5.1: Parâmetros cinéticos e termodinâmicos do modelo do reator

Outros parâmetros relacionados à operação do reator estão listados na Tabela 5.2 apresentada a seguir.

símbolo	valor	parâmetro
Q_s	0.175 L/s	Vazão de solvente
Q_m	0.105 L/s	Vazão de monômero
V	3000 L	Volume do reator
V_c	3312.4 L	Volume da camisa do reator
$[I_f]$	0.588 mol/L	Concentração de iniciador na entrada do reator
$[M_f]$	8.6981 mol/L	Concentração de monômero na entrada do reator
T_f	330 K	Temperatura de entrada do solvente
T_{cf}	295 K	Temperatura de entrada do fluido refrigerante na camisa
M_m	104.14 g/mol	Massa molar do monômero

Tabela 5.2: Parâmetros de operação do reator

O estado inicial que é usado como referência nas simulações aqui realizadas é definido na Tabela 5.3, apresentada abaixo.

símbolo	valor inicial	variável
$[I]$	0.066832 mol/L	Concentração de iniciador no reator
$[M]$	3.3245 mol/L	Concentração de monômero no reator
T	323.56 K	Temperatura no reator
T_c	305.17 K	Temperatura na camisa do reator
D_o	$2.7547 \cdot 10^{-4}$ mol/L	Variável auxiliar de massa molar
D_1	16.110 g/L	Variável auxiliar de massa molar
Q_i	0.03 L/s	Vazão de iniciador
Q_c	0.131 L/s	Vazão de fluido refrigerante
MM	58481 g/mol	Massa molar média do polímero no reator
T	323.56 K	Temperatura no reator

Tabela 5.3: Condições iniciais do sistema

Para o controle do reator foi adotado o controlador MPC de duas camadas descrito anteriormente. Para representar o sistema real, o sistema de equações 5.0.1 a 5.0.6 é integrado ao longo do período de amostragem que é considerado igual a 0.1h, o que corresponde aproximadamente a 1/50 da menor constante de tempo do sistema.

As variáveis controladas pelo MPC são o peso molecular médio ($y_1 = MM$) e a temperatura de reação ($y_2 = T$). As variáveis controladas pelo MPC são a vazão de iniciador ($u_1 = Q_i$) e a vazão de fluido de refrigeração ($u_2 = Q_c$).

Uma restrição operacional importante é manter a temperatura de reação bem abaixo de 423K, pois a iniciação térmica torna-se significativa quando atinge temperatura maior que 373K, e provavelmente domina a iniciação catalítica a partir de 423K. O objetivo do controle é levar o sistema para o estado desejado a fim de produzir polímeros com diferentes massas moleculares médias enquanto mantém a temperatura de reação em um setpoint bem definido. Os parâmetros de sintonia do controlador são apresentados na Tabela 5.4. É importante mencionar que nesse caso as variáveis usadas pelo controlador não são normalizadas, o que pode resultar em parâmetros de sintonia um tanto incomuns, como por exemplo, os pesos das variáveis controladas iguais a 1000 e 1. Inicialmente, o MPC foi desenvolvido com um modelo linear de segunda ordem correspondente ao estado estacionário inicial do reator. Esse modelo foi obtido a partir de testes em malha aberta (“step tests”)

variável	valor	definição
ny	2	numero de saidas
nu	2	numero de entradas
N	120	horizonte do modelo
p	20	horizonte de predição (otimização)
m	1	horizonte de controle
Ts	6	período de amostragem (min)
R	[2 1]'	peso das entradas
Q	[1000 1]'	peso das saídas
Ru	[10 10]'	peso dos targets das entradas
W2	[500 -500]'	peso econômico(GBN)
W1	[0.0002 0.0002]'	peso termo quadrático
umax	[0.0375 0.300]'	valor máximo das entradas
umin	[0.0225 0.0100]'	valor mínimo das entradas
dumax	[0.0001 0.005]'	variação máxima das entradas
ymax	[80000 373]'	valores máximos das saídas
ymin	[50000 300]'	valores mínimos das saídas

Tabela 5.4: Parâmetros de sintonia do controlador MPC

Para testar o comportamento do método de identificação proposto, imagina-se um cenário em que em um dado momento o reator sofre uma alteração devido à obsolescência.

A alteração considerada corresponde à redução do coeficiente de troca de calor de $70 \text{ cal K}^{-1}\text{s}^{-1}$ para $50 \text{ cal K}^{-1}\text{s}^{-1}$. Essa alteração é perfeitamente possível, pois ocorre quando ocorre incrustação de polímero na serpentina de resfriamento. O efeito esperado dessa ocorrência é um aumento nas constantes de tempo do modelo do processo. Simultaneamente a essa mudança simula-se a introdução de dois outros distúrbios: a redução na concentração de iniciador na alimentação de iniciador de 0.588 mol/l para 0.4888 mol/l e um aumento na concentração de monômero alimentado no reator de 8.7 mol/l para 10 mol/l . A redução na concentração do iniciador deve causar uma redução no ganho do processo em relação à vazão de iniciador que é uma variável manipulada. O efeito do aumento da concentração de monômero no modelo do processo não é muito claro. Neste cenário, após a ocorrência desses distúrbios é iniciada a excitação do sistema através dos coeficientes da função objetivo da camada estática do MPC conforme descrito no capítulo 2 desta dissertação. Acompanhando o comportamento das entradas e saídas do reator na apresentada na Figura 5.2.




Figura 5.2: Entradas e saídas do reator de polimerização durante o procedimento de excitação em malha fechada

Usando os dados apresentados na Figura 5.2, foi identificado um novo modelo linear de segunda ordem que, comparado ao modelo inicial, deve representar melhor o reator nas novas condições operacionais. A Figura 5.3 mostra as respostas ao degrau em malha aberta dos modelos antes e depois das alterações no processo. Nota-se que há significativas diferenças nas dinâmicas (o sistema ficou mais lento) e alteração em alguns ganhos do processo.

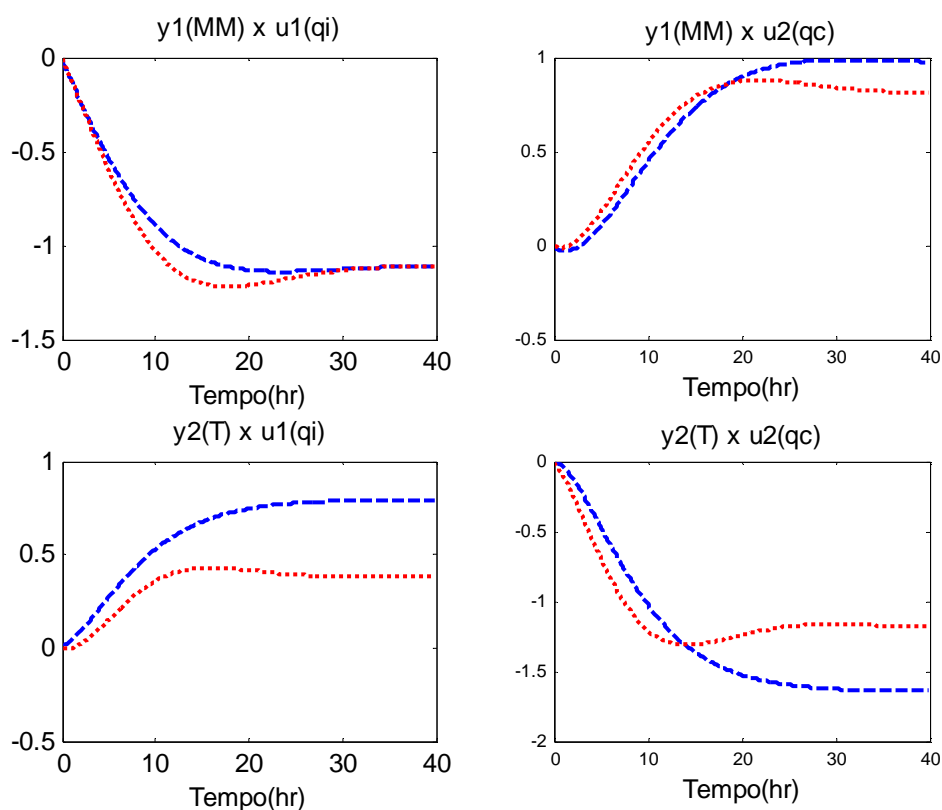


Figura 5.3: Modelo usado no controlador (...) modelo identificado (---)

Para melhor visualizar como o novo modelo se adequou ao controle do processo foi observada a validação cruzada para cada variável de saída (Figura 5.4). Na validação cruzada da saída 1 o novo modelo tem FIT de 79% em comparação a 49% do modelo usado no controle. Isso levou a uma melhoria no RT2 de 0.74 para 0.95. Na saída 2 a melhora no FIT foi de 39% para 77% após a identificação. O outro indicador RT2 subiu de 0.63 para 0.94. Conclui-se que para o reator de polimerização de estireno, o procedimento de identificação em malha fechada com controlador MPC de duas camadas é bastante eficiente no sentido de melhorar a performance do controlador através da re-identificação do modelo do processo sem causar significativos danos à operação do sistema.

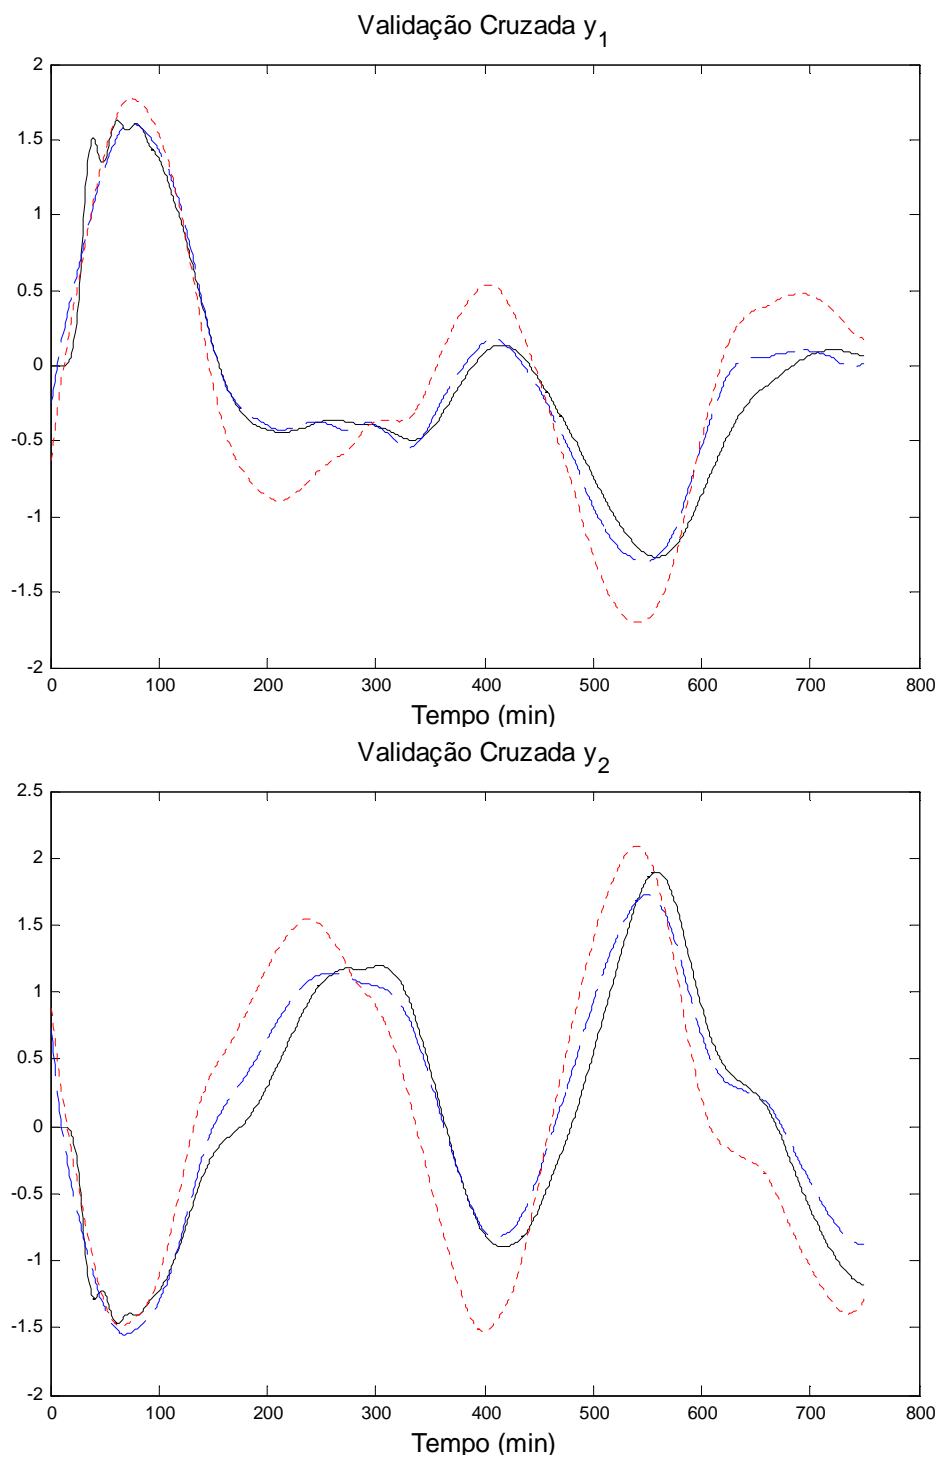


Figura 5.4: Validação cruzada: processo (—), modelo usado no controle(...), modelo identificado (---)

6 Conclusão e Recomendações

Neste trabalho é proposto um método para excitação e re-identificação em malha fechada do modelo de um processo que está sendo controlado por um MPC comercial. O método proposto enfoca o caso em que o modelo existente no controlador não é satisfatório e pode causar um desempenho deficiente ou instabilidade do sistema em malha fechada. O procedimento proposto visa à obtenção de um novo modelo mantendo o processo em operação dentro de suas restrições de especificações do produto, limites de segurança dos equipamentos, etc.

O método proposto é adequado para controladores MPC em duas camadas, onde além da camada dinâmica que minimiza os erros nas saídas controladas em relação aos valores desejados, há também a camada estacionária que define os “targets” para as entradas que são manipuladas pela camada dinâmica. Dois procedimentos são propostos neste trabalho para introdução de um sinal persistentemente excitante no processo. No primeiro método uma seqüência do tipo GBN é introduzida nos coeficientes dos termos lineares da função objetivo da camada estacionária do controlador. Em função dos novos coeficientes, os “targets” para as entradas das variáveis manipuladas são modificados e a camada dinâmica do controlador tenta implementar os novos “targets” no processo real gerando um distúrbio controlado. No segundo método, o sinal de excitação é uma seqüência (tipo GBN) de “targets” para as entradas na camada estacionária cuja função objetivo é alterada e pondera a distância entre os “targets” impostos e os “targets” que podem ser implementados de tal forma que as restrições do processo sejam atendidas. Os dois procedimentos são comparados para o caso de uma coluna despropanizadora de uma refinaria de petróleo e se mostraram equivalentes em termos de geração de excitação persistente e conseqüente identificação do modelo correto do processo. O procedimento que introduz a excitação através da função objetivo da camada estacionária do controlador parece ser o mais recomendável no caso de utilização de pacotes comerciais cujo código fonte não está disponível. O procedimento se implementado viria a ser de fácil uso por parte da equipe de operadores e engenheiros e traria benefícios à operação da unidade.

O método proposto via coeficientes da função objetivo foi também testado para um processo cujo modelo não-linear é conhecido e pode ser usado diretamente na simulação do método. O processo é o reator de polimerização de estireno onde o peso molecular deve ser

controlado em faixas adequadas. Os resultados foram bastante promissores também para esse sistema, indicando que a metodologia proposta tem um bom potencial de aplicação prática.

Uma recomendação que resulta naturalmente deste trabalho é aplicação da metodologia proposta a um sistema industrial real, que pode ser a própria coluna despropanizadora considerada no capítulo 4, pois esse é um sistema existente.

REFERÊNCIAS BIBLIOGRÁFICAS

ALING, H.; HEINTZE, J. Closed loop identification of a 600 MW Benson boiler. In: 31ST CONFERENCE ON DECISION AND CONTROL, 1992, Tucson, Arizona, **Proceedings of the CDC'92**, p.909-914.

AMJAD, S.; AL-DUWAISH, H.N. Closed loop identification with model predictive control: a case study. In: SICE ANNUAL CONFERENCE, Fukui, Japan, 2003. **Proceedings of the SICE'2003**, p.144-149.

ANDERSEN, H.W.; KÜMMEL, M. Evaluating estimation of gain directionality – Part 2: a case study of binary distillation. **Journal of Process Control**, v. 2, n. 2, p. 67-86, 1992.

ÅSTRÖM, K.J.; EYKHOFF, P. System identification – A survey. **Automatica**, v. 7, n. 2, p. 123-162, 1971.

BEZERRA, V.M.; ABU-EL-ZEET, Z.H.; ROBERTS, P.D. Integrating predictive control and economic optimization. **Computing and Control Engineering Journal**, v. 10, n. 5, p. 198-208, 1999.

CAMACHO, E.F.; BORDONS, C. Control predictivo: pasado, presente y futuro. **Revista Iberoamericana de Automática e Informática Industrial**, v. 1, n. 3, p. 5-28, 2004.

CELAYA, P.; TKATCH, B.; ZHU, Y.; PATWARDHAN, R. Closed-loop identification at the Hovensa refinery. In: NPRA DECISION SUPPORT AND AUTOMATION CONFERENCE, San Antonio, Texas, 2004.

DOMA, M.J.; TAYLOR, P.A.; VERMEER, P.J. Closed loop identification of MPC models for MIMO processes using genetic algorithms and dithering one variable at a time: application to an industrial distillation tower. **Computers and Chemical Engineering**, v. 20, p. 1035-1040, 1996. Suplemento

EATON, J.W.;RAWLINGS, J.B. Model-predictive control of chemical processes. **Chemical Engineering Science**, v. 47, n. 4, p. 705-720, 1992.

GAIKWAD, S.V.; RIVERA, D.E. Control-relevant input signal design for multivariable system identification: application to high-purity distillation. In: 13TH IFAC WORLD CONGRESS, 1996, San Francisco, California. **PROCEEDINGS OF IFAC'96**, CD-ROM.

GARCÍA, C.E; PRETT D.M.; MORARI, M. Model predictive control: theory and practice – a survey. **Automatica**, n. 25, v. 3, p. 335-348, 1989.

GARNIER, H.; MENSLER, M. The CONTSID toolbox: a Matlab toolbox for continuous-time system identification. In: 12TH IFAC SYMPOSIUM ON SYSTEM IDENTIFICATION, 2000, Santa Barbara, California. **Proceedings of the SYSID 2000**, CD-ROM

GARNIER, H.; MENSLER, M.; RICHARD, A. Continuous-time model identification from sampled data: implementation issues and performance evaluation. **International Journal of Control**, n. 76, v. 13, p. 1337-1357, 2003.

GARNIER, H.; GILSON, M.; CERVELLIN, O. Latest development for the Matlab CONTSID toolbox. In: 14TH IFAC SYMPOSIUM ON SYSTEM IDENTIFICATION, 2006, Newcastle, Australia. **Proceedings of the SYSID 2006**, CD-ROM

GOPALUNI, R.B.; PATWARDHAN, R.S.; SHAH., S.L. The nature of data pre-filters in MPC relevant identification – Open and closed-loop issues. **Automatica**, v. 39, n. 9, p.1617-1626, 2003.

HIDALGO, P M.; BROSILOW, C. B. Nonlinear model predictive control of styrene polymerization at unstable operating points. **Computers Chem. Engng**, v. 14, n. 4, p. 481-494, 1990.

JENKINS, G.M.; WATTS, D.G. **Spectral analysis and its applications**. Holden Day: San Francisco, California, 1968.

KALRA, L.; GEORGAKIS, C. The effects of operational characteristics of catalytic cracking reactors on the closed-loop performance of linear model predictive controllers. **Computers and Chemical Engineering**, v. 20, n. 4, p. 401-415, 1996.

KLINE, S.; STREET, R.; PATWARDHAN, R.S.; BAE, A. Closed loop identification for multivariable model predictive controller on a catalytic gasoline splitter. In: SEVENTH INTERNATIONAL CONFERENCE ON CHEMICAL PROCESS CONTROL. Lake Louise, Alberta, Canada, 2006. **Proceedings of the 7th CPC**.

KOUNG, C.W.; MACGREGOR, J.F. Design of identification experiments for robust control – a geometric approach for bivariate processes. **Industrial and Engineering Chemistry Research**, v. 32, n. 8, p. 1658-1666, 1993.

LANDAU I. D. Identification in closed loop: a powerful design tool (better design models, simpler controllers). **Control Engineering Practice**, v. 9, n. 1, p. 51-65, 2001.

LI, W.; LEE, J.H. Control relevant identification of ill-conditioned systems: estimation of gain directionality. **Computers and Chemical Engineering**, v. 20, n. 8, p. 1023-1042, 1996.

LJUNG L. **System Identification**, Upper Saddle River, New Jersey: Prentice Hall, 1999.

MACIEJOWSKI J. M., **Predictive Control with Constraints**, London: Prentice Hall, 2002.

MANER, B. R.; DOYLE, F. J.; OGUNNAIKE, B. A.; PEARSON, R. K. Nonlinear Model Predictive Control of a Simulated Multivariable Polymerization Reactor Using Second-order Volterra Models, **Automatica**, Vol. 32, No. 9, p. 1285-1301, 1996.

MORARI, M.; LEE, J.H. Model predictive control: past, present and future. **Computers and Chemical Engineering**, v. 23, n. 4-5, p. 667-682, 1999.

MORSHEDI, A.M.; CUTLER, C.R.; SKROVANEK, T.A. Optimal solution of dynamic matrix control with linear programming techniques (LDMC). In: AMERICAN CONTROL CONFERENCE, Boston, Massachusetts, 1985. **Proceedings of the ACC'85**, p. 199-208.

NETO, A. E. **Controle preditivo multimodelos de uma torre debutanizadora**, São Paulo, 1999

ÖSTRING, M.; GUNNARSSON, S., NORRLÖF, M. Closed-loop identification of an industrial robot containing flexibilities. **Control Engineering Practice**, v. 11, n. 3, p. 291-300, 2003.

PORFÍRIO C. R., **Implantação de um Controlador Multimodelos em uma coluna Despropanizadora Industrial**, São Paulo, 2001.

QIN, S.J.; BADGWELL, T.A. A survey of industrial model predictive control technology, **Control Engineering Practice**, v. 11, n. 7, p. 733-764, 2003.

RAO, G. P.; GARNIER, H. Identification of continuous-time systems: direct or indirect? **System science**. v. 30, n. 3, p. 25-50, 2004.

RAWLINGS, J.B. Tutorial overview of model predictive control. **IEEE Control Systems Magazine**, v. 20, n. 3, p. 38-52, 2000.

SAGIAS, D.; NIKOLAOU, M. Closed-loop identification of processes operating under model predictive control without external excitation. In: AICHE ANNUAL MEETING, Reno, Nevada, 2001.

SÖDERSTRÖM T.; STOICA, P. **Instrumental variable methods for system identification**. Berlin, Springer Verlag, 1983.

_____. **System identification**. Hemel Hempstead, UK: Prentice Hall, 1989.

SOTOMAYOR, O.A.Z.; PIRES, R.C.; ODLOAK, D. **Metodologia de avaliação de controladores preditivos instalados em unidades de refino**: Estudo do sistema de controle da unidade FCC da REVAP. São Paulo, Brasil: Departamento de Engenharia Química da Escola Politécnica da USP, 2006a. (Relatório No. 2)

SOTOMAYOR, O.A.Z., ODLOAK, D. **Identificação em Malha Fechada de Sistemas de Controle MPC em Unidades de Refino da PETROBRAS**. São Paulo, Brasil: Departamento de Engenharia Química da Escola Politécnica da USP, 2006b. (Relatório No.3)

SOTOMAYOR, O.A.Z.; ODLOAK, D.; GIUDICI, R. Diagnosis of abnormal situations in a continuous solution polymerization reactor, **Macromolecular Theory and Simulations**, v. 16, p. 247-261, 2006c.

SRINIVASAN, R.; RENGASWAMY, R. Use of inverse repeat sequence (IRS) for identification in chemical process systems. **Industrial and Engineering Chemistry Research**, v. 38, n. 9, p. 3420-3429, 1999.

TULLEKEN, H.J.A.F. Generalized binary noise test-signal concept for improved identification-experiment design. **Automatica**, v. 26, n. 1, p. 37-49, 1990.

VAN OVERSCHEE, P.; DE MOOR, B. **Subspace identification for linear systems: theory, implementation, applications**. Dordrecht: Kluwer Academic Publishers, 1996.

WALLER, J.B.; WALLER, K.V. Defining directionality: use of directionality measures with respect to scaling. **Industrial and Engineering Chemistry Research**, v. 34, n. 4, p. 1244-1252, 1995.

ZHAN, Q.; LI, T.; GEORGAKIS, C. Steady state optimal test signal design for multivariable model based control. **Industrial and Engineering Chemistry Research**, v. 45, n. 25, p. 8514-8527, 2006.

ZHU, Y., et al. (1997). Crude unit identification for MPC using ASYM method. In: AMERICAN CONTROL CONFERENCE, Albuquerque, New Mexico, 1997. **Proceedings of the ACC'97**, p.3395-3399

_____. Multivariable process identification for MPC: the asymptotic method and its applications. **Journal of Process Control**, v. 8, n. 2, p. 101-115, 1998.

_____. Tai-Ji ID: Automatic closed-loop identification package for model based process control. In: 12TH IFAC SYMPOSIUM ON SYSTEM IDENTIFICATION, Santa Barbara, California, 2000. **Proceedings of the 12TH SYSID**. CD-ROM

_____. **Multivariable system identification for process control**. Oxford, UK: Elsevier, 2001.

ZHU, Y., BUTOYI, F. Case studies on closed-loop identification for MPC. **Control Engineering Practice**, v. 10, n. 4, p. 403-417, 2002.

ZHU, Y. New development in industrial MPC identification. In: 13TH IFAC SYMPOSIUM ON SYSTEM IDENTIFICATION, Rotterdam, Holanda, 2003. **Proceedings of the SYSID**. CD-ROM