

MÉTODO DE AJUSTE DE MPC PARA SISTEMAS NÃO QUADRADOS BASEADO EM MULTICENÁRIOS

JOSÉ EDUARDO W. SANTOS, JORGE OTÁVIO TRIERWEILER, MARCELO FARENZENA

*Grupo de Intensificação, Modelagem, Simulação, Controle e Otimização de Processos, Departamento de Engenharia Química, Universidade Federal do Rio Grande do Sul
Rua Engenheiro Luiz Englert, s/n, 90040-040, Campus Central, Porto Alegre, Rio Grande do Sul, Brasil
E-mails: {jews, jorge, farenz}@enq.ufrgs.br*

Abstract— A novel strategy for predictive controller's tuning considering non-square systems for zone regions tracking is presented. This methodology consists of a determination of the best attainable performance function for the multi-scenarios, obtained from the global model, through a constrained optimization problem. Based on the attainable performance function the optimal scaling and the weights that will lead the plant to the best operational condition are determined. This constrained strategy was applied in the controller design of the Shell heavy oil fractionator problem presenting good results for soft-constraint operation.

Keywords— predictive controller, tuning, non-square systems, soft-constraints, attainable performance.

Resumo— Uma nova estratégia para ajuste de controladores preditivos considerando sistemas não quadrados operando faixas é apresentada. Essa metodologia consiste na determinação do melhor desempenho alcançável para os multi-cenários obtidos do modelo original, através de um problema de otimização com restrições. Baseado na função de desempenho alcançável o escalonamento ótimo do processo e os pesos do controlador preditivo que irão direcionar a planta para a melhor condição operacional são determinados. Essa estratégia de ajuste com restrição é aplicada no projeto de controlador para a fracionadora de óleo pesado Shell apresentando bons resultados para a operação através de *soft-constraints*.

Palavras-chave— controlador preditivo, sintonia, sistemas não quadrados, faixas de operação, desempenho alcançável.

1. Introdução

O controle preditivo baseado em modelo (MPC) é uma estratégia discreta de controle que utiliza um modelo em malha aberta do processo para descrever o comportamento da planta através de um horizonte pré-definido, chamado horizonte de predição, e baseado nesse modelo, calcula ações de controle que minimizam uma função objetivo (Camacho & Bordons, 1999). Essa estratégia possui uma ampla aplicação e sucesso na indústria de processos devido à formulação do problema de controle, ao uso explícito do modelo para prever a evolução da planta e à consideração explícita das restrições no problema de otimização (Ferramosca et al., 2009). Isso permite a consideração de plantas com comportamentos dinâmicos complexos e natureza multivariável melhor que metodologias clássicas de controle, lidando com limites físicos dos atuadores e permitindo uma operação próxima das restrições (Maciejowski, 2002).

Qin & Badgwell (2003) e Holkar & Waghmare (2010) destacam as principais diferenças entre a aplicação industrial e a consolidada teoria sobre MPCs. Os principais pontos estão relacionados à determinação de modelos do processo (lineares, não-lineares, empíricos ou fenomenológicos), à utilização de *soft-constraints* ao invés de *setpoints*, mantendo as variáveis controladas em zonas ou regiões e à consideração de sistemas não quadrados com graus de liberdade negativos, i.e., com mais variáveis controladas (CVs) do que manipuladas (MVs). Sistemas não quadrados com mais saídas do que entradas são comuns em processos químicos e podem ocorrer também em sistemas originalmente quadrados que

saturam um ou mais atuadores (Lima & Georgakis, 2006). Uma forma de manter todas as CVs dentro das especificações, para sistemas que operam dessa maneira, é através da utilização de faixas de operação (*soft-constraints*) a fim de tornar o problema de controle atingível e garantir uma maior flexibilidade para o controlador (Shead et al., 2007).

O papel do MPC é direcionar a planta para melhor condição operacional respeitando as restrições e minimizando o erro ao longo da trajetória dada por um valor de referência ou uma zona na qual as saídas podem permanecer (Qin & Badgwell, 2003). Cada parâmetro de ajuste possui uma particular importância no problema de controle sendo responsáveis em não exceder esforço computacional, oriundo de um baixo tempo de amostragem e elevados horizontes de controle e predição, priorizando as variáveis controladas e manipuladas mais importantes para o sucesso econômico da unidade (Trierweiler & Farina, 2003). A sintonia correta dos parâmetros do controlador preditivo possui grande importância na operação adequada do processo, uma vez que uma má sintonia não contribui para a redução da variabilidade das variáveis controladas além de ocasionar um aumento na oscilação dificultando a otimização da planta (Campos et al., 2013).

Garriga & Soroush (2010) classificam as metodologias para sintonia de MPCs em fórmulas baseadas em aproximações/simulações da dinâmica do processo fornecendo boas ferramentas para ajuste, mas dedicadas apenas para algoritmos particulares, sistemas quadrados, utilização de *setpoint* e modelos do processo específicos dificultando a aplicação industrial. Como forma de considerar uma grande variedade de algoritmos para MPC, uma série de

metodologias baseadas em problemas de otimização não-lineares é proposta para sistemas com e sem restrição (Nery Júnior et al., 2014) e (Gous & de Vaal, 2012). Dentre os trabalhos reportados observou-se a falta de metodologias de ajuste que contemplem a utilização de faixas de operação e sistemas não quadrados.

Baseado nisso, a metodologia de ajuste aqui introduzida permite o ajuste de MPCs não quadrados (com maior número de CVs frente às MVs). Para isso, o modelo original é dividido em cenários quadrados e o melhor desempenho robusto alcançável para cada cenário é calculado considerando métricas adequadas. Com base nessas funções, são determinadas as matrizes de escalonamento para a planta, os pesos que penalizam o excesso de movimento das variáveis manipuladas e a penalização da violação da faixa de operação.

O presente trabalho está estruturado da seguinte forma: na Seção 2 são apresentados os conceitos fundamentais necessários para o entendimento da metodologia. Na Seção 3 é descrita a metodologia de ajuste para MPCs baseado em multi-cenários. Na seção 4, a estratégia de ajuste é aplicada na fracionadora de óleo pesado Shell e, por fim, as conclusões são apresentadas.

2. Fundamentação da Metodologia

2.1 Controle Preditivo Baseado em Modelo

O MPC utiliza um modelo discreto do processo. Baseado nesse modelo, ações de controle que minimizam o erro entre as saídas e a trajetória de referência são calculadas, penalizando o excesso de movimento das variáveis manipuladas até um determinado intervalo, chamado horizonte de controle. Nas variáveis controladas é possível determinar uma folga, ou faixa (*soft-constraints*) na qual são permitidas violações temporárias até um valor inviolável (*hard-constraints*). Em alguns casos, é computado também o erro entre as variáveis manipuladas e um valor de referência, chamado *target*, que é usualmente obtido por uma camada de otimização. Os movimentos são calculados em cada instante de amostragem enviando ao processo apenas a primeira ação calculada segundo uma estratégia chamada “horizonte deslizante”. Uma forma geral de representar o problema de otimização resolvido por um MPC é:

$$\min_{u, \varepsilon_k} J = \min_{u, \varepsilon_k} \left[\sum_{j=1}^P \|\hat{y}(t+j|t) - r(t+j)\|_Q^2 + \sum_{j=1}^M \|\Delta u(t+j-1)\|_W^2 + \rho_\varepsilon \varepsilon_k \right] \quad (1a)$$

$$\begin{aligned} u_{\min} &\leq u(t) \leq u_{\max} \\ \Delta u_{\min} &\leq u(t) - u(t-1) \leq \Delta u_{\max} \\ y_{\min} - \varepsilon_k &\leq \hat{y}(t) \leq y_{\max} + \varepsilon_k \end{aligned} \quad (1b)$$

onde $\hat{y}(t+j|t)$ é a saída predita pelo modelo j instantes de amostragem no futuro, $r(t+j)$ é trajetória

de referência, $\Delta u(t) = u(t) - u(t-1)$, ε_k é o maior desvio da *soft-constraint* e $\|x\|_W^2$ é a norma-peso Euclidiana de $x \in \mathbb{R}^n$ definida como $\|x\|_W^2 = x^T W x$ com $W \in \mathbb{R}^{n \times n}$ positivo definido. Em (1b) são apresentadas as restrições do problema de otimização referentes às variáveis controladas, manipuladas e variação das ações de controle.

Os parâmetros de sintonia são: Horizonte de predição (P), Horizonte de controle (M), tempo de amostragem (t_s), matriz-peso de erro das variáveis controladas (Q), matriz-peso de supressão do movimento (W) e penalização por violação da *soft-constraint* (ρ_ε).

O horizonte de predição P marca os limites de tempo que se deseja para a saída seguir a trajetória de referência e o horizonte de controle M especifica os graus de liberdade em selecionar ações de controle (após M períodos de amostragem não há mais alteração nas variáveis manipuladas). O tempo de amostragem t_s deve ser compatível com a dinâmica da planta sendo cuidadosamente selecionado a fim de não aumentar o esforço computacional (os horizontes P e M são dependentes dessa escolha e afetarão a dimensão do problema de otimização). As matrizes-peso Q e W são diagonais onde os seus elementos são sintonizados a fim de direcionar o sistema ao valor de referência priorizando qual variável é mais importante e escalonando o sistema. A penalização por violação ρ_ε é responsável por manter as saídas em uma aceitável zona de controle.

2.2 Metodologia RPN

A função de desempenho robusto (Γ) foi desenvolvida por Trierweiler (1997) como uma medida da dificuldade para um dado sistema atingir o desempenho desejado de forma robusta, sendo desta forma uma medida da controlabilidade do processo. Essa função é definida em (2a) e o máximo valor dessa curva, definido em (2b), é denominado Número de desempenho robusto (*RPN* – “Robust Performance Number”).

$$\Gamma(G, T, \omega) \stackrel{\text{def}}{=} \sqrt{\bar{\sigma}([I - T(j\omega)]T(j\omega)) \left[\gamma^*(G(j\omega)) + \frac{1}{\gamma^*(G(j\omega))} \right]} \quad (2a)$$

$$RPN \stackrel{\text{def}}{=} \Gamma_{MAX}(G, T, \omega) = \max_{\omega \in \mathbb{R}} \{\Gamma(G, T, \omega)\} \quad (2b)$$

onde $\gamma^*(G(j\omega))$ é o condicionamento mínimo de $G(j\omega)$, $\bar{\sigma}([I - T]T)$ é o máximo valor singular da matriz de transferência $[I - T]T$ e $T(s)$ é a função de desempenho em malha fechada alcançável para o modelo $G(s)$.

A função de desempenho alcançável, $T(s)$, é calculada utilizando a Fatoração Blaschke e para o caso de zeros de transmissão no semi-plano direito (SPD) pela seguinte expressão:

$$T(s) = B_{O,z}(s) B_{O,z}^\dagger(0) T_d(s) \quad (3)$$

onde $B_{O,z}(s)$ é a fatoração Blaschke para a direção de saída do zero localizado no SPD, $B_{O,z}^\dagger(0)$ é a

pseudo-inversa de $B_{O,z}(s)$ e $T_d(s)$ é a função de desempenho desejado. Essa fatoração computa o desempenho alcançável para sistemas que possuem fatores de fase não mínima causados pela presença de zeros positivos SPD.

O número de desempenho robusto relativo ($rRPN$), desenvolvido por Trierweiler (2002), é obtido como uma medida relativa do desvio da área sob a curva da função Γ e a função Γ_{REF} .

$$rRPN \stackrel{\text{def}}{=} \frac{\int_{\omega_{MIN}}^{\omega_{MAX}} \Gamma(G, T) d\log \omega - \int_{\omega_{MIN}}^{\omega_{MAX}} \Gamma_{REF}(G, T_d) d\log \omega}{\int_{\omega_{MIN}}^{\omega_{MAX}} \Gamma_{REF}(G, T_d) d\log \omega} \quad (4)$$

A função Γ_{REF} representa o menor valor possível para função Γ para uma determinada função de desempenho desejado T_d (função não fatorada, i.e., os fatores de fase não mínimos não são considerados) e o melhor condicionamento mínimo da matriz de transferência $\gamma^*(G(j\omega)) = 1$. As funções Γ e Γ_{REF} estão ilustradas na Figura 1.




Figura 1. Funções Γ e Γ_{REF} .

3. Metodologia de Ajuste

Nessa seção, será descrita a metodologia para ajuste de controladores preditivos. A ideia principal do método consiste na decomposição do modelo original do processo em cenários, que se tratam de subcasos quadrados que compõe a matriz de transferência original. Essa decomposição é necessária pelo fato de controladores não quadrados com mais variáveis controladas do que manipuladas, trabalhando em faixas de operação, consideram um problema de controle variante no tempo, que é função das variáveis manipuladas disponíveis e as variáveis que irão violar as *soft-constraints*. Além disso, em alguns casos, um subcaso que compõe o modelo global pode trazer limitações de desempenho que não se encontram no problema inteiro. Assim, a melhor função de desempenho alcançável para cada cenário é determinada e utilizada para a determinação do escalonamento ótimo e para a sintonia dos pesos de ajuste.

O método consiste na determinação da função de desempenho alcançável em malha fechada para o modelo global, compreendendo as restrições alcançáveis presentes em cada cenário originado do modelo global.

Como observado na Eq. 3, dada uma função de desempenho desejado em malha fechada para o modelo global do processo, $T_d(s)$, sendo necessário especificar apenas os tempos de subida de cada canal i ($t_{r,i}$) e a taxa de *overshoot*, a função de desempenho alcançável é computada através da Fatoração Blaschke considerando os fatores de fase não-mínima presentes no sistema original. Assim, a determinação de $T_d(s)$, mantendo a taxa de *overshoot* fixa em 5% para cada canal, é dada por:

$$\min_{\Omega} \phi(\Omega) = \min_{\Omega} \sum_{i=1}^n (t_{r,i})^2 \quad (5a)$$

sujeito a

$$\begin{aligned} rRPN(k) &\leq 1 \\ Ms(k) &\leq 2,2 \\ Ms(k) &\geq 1,2 \\ Mk(k) &\leq 10 \end{aligned} \quad (5b)$$

onde $\Omega = [t_{r,1}, t_{r,2}, \dots, t_{r,i}]$ sendo $i = 1, \dots, n$ o número de canais da matriz de transferência original, $k = 1, \dots, nc$ é o número de cenários presentes no modelo original, $rRPN(k)$ é o Número de desempenho robusto relativo para cada cenário k , Ms é o valor da função de máxima sensibilidade para cada cenário k e $Mk(k)$ é o máximo valor da função $K(s)$ que relaciona $\Delta u = K(s)\Delta y_{set}$ para cada cenário k .

A minimização do índice $\phi(\Omega)$, apresentado na Eq. 5a, tem por objetivo obter a função de desempenho desejado com menor tempo de subida, respeitando as restrições atingíveis existentes em cada cenário.

A frequência $\omega_{MAX,k}$ em que ocorre o RPN em cada cenário possui um papel importante na determinação do escalonamento ótimo do sistema ao introduzir os fatores de robustez e desempenho automaticamente no problema de controle através das matrizes de escalonamento. Os valores para essas matrizes de escalonamento do sistema são então obtidas através do condicionamento mínimo global:

$$\gamma^{\blacksquare} \stackrel{\text{def}}{=} \min_{R_s, L_s} \|\gamma_k(L_s G(j\omega_{MAX,k}) R_s)\|_{\infty} \quad (6)$$

onde R_s e L_s são matrizes diagonais de escalonamento para as variáveis de entrada e saída, respectivamente, $G(j\omega_{MAX,k})$ é o modelo global do processo avaliado na frequência $\omega_{MAX,k}$ onde ocorre o RPN da trajetória alcançável em cada cenário k , $\gamma(M)$ é o condicionamento mínimo de M e $\|x\|_{\infty}$ é a norma infinita de x .

As matrizes R_s e L_s serão usadas para escalar o modelo da planta utilizado na simulação, e para o projeto do controlador MPC, sendo considerado o modelo $G_s = L_s G(s) R_s$. A configuração do sistema planta/controlador é ilustrada na Fig. 2.




Figura 2. Configuração do sistema de controle.

Para o caso em que todas as CVs são controladas por faixa, o passo final é a sintonia dos parâmetros W e ρ_ϵ , que irão penalizar o excesso de movimento das variáveis manipuladas e a violação das faixas de operação, respectivamente. A diagonal da matriz Q é considerada zero, uma vez que as saídas podem desviar da trajetória de referência desde que permaneçam dentro da *soft-constraint*. Aqui, a determinação da função de desempenho alcançável é importante apenas para o cálculo do escalonamento ótimo, já que as saídas podem seguir qualquer trajetória sem violar as restrições. O cálculo para os pesos do MPC é dado por:

$$\min_{\Theta} \psi(\Theta) = \min_{\Theta} \sum_{k=1}^{nc} \hat{\epsilon}_k^2 \quad (7)$$

onde $\Theta = [\rho_\epsilon W]$ e $\hat{\epsilon}_k$ é a maior violação da *soft-constraint* das variáveis controladas utilizando o sistema escalonado G_s como modelo do controlador, e as matrizes de escalonamento para a planta.

4. Estudo de Caso

Como estudo de caso foi considerado a fracionadora de óleo pesado Shell proposta por Prett & Morari (1987) apresentada na Fig. 3. Esse sistema consiste numa coluna de destilação que compreende relevantes problemas de controle através da interação entre as entradas e saídas e grandes valores de tempo morto.




Figura 3. Representação da fracionadora de óleo pesado Shell (Fonte: Maciejowski, 2002).

O sistema original é composto por 7 variáveis monitoradas e 5 entradas, nas quais 3 são variáveis manipuladas e 2 são distúrbios. O objetivo é controlar a composição de saída de topo (y_1), composição de saída lateral (y_2), temperatura de topo (y_3), temperatura do refluxo superior (y_4), temperatura de retirada lateral (y_5), temperatura do refluxo intermediário (y_6) e temperatura do refluxo de fundo (y_7) através da manipulação da retirada de topo (u_1), retirada lateral (u_2) e taxa de refluxo de fundo (u_3) rejeitando os distúrbios dados pela taxa de refluxo intermediário (d_1) e taxa de refluxo superior (d_2).

Cada canal do modelo é composto por uma função de primeira ordem com tempo morto, dada por:

$$G_0 = \begin{bmatrix} \frac{4,05 + 2,11\epsilon_1}{50s + 1} e^{-27s} & \frac{1,77 + 0,39\epsilon_2}{60s + 1} e^{-28s} & \frac{5,88 + 0,59\epsilon_3}{50s + 1} e^{-27s} \\ \frac{5,39 + 3,29\epsilon_1}{50s + 1} e^{-18s} & \frac{5,72 + 0,57\epsilon_2}{60s + 1} e^{-14s} & \frac{6,90 + 0,89\epsilon_3}{40s + 1} e^{-15s} \\ \frac{3,66 + 2,29\epsilon_1}{9s + 1} e^{-2s} & \frac{1,65 + 0,35\epsilon_2}{30s + 1} e^{-20s} & \frac{5,53 + 0,67\epsilon_3}{40s + 1} e^{-2s} \\ \frac{5,92 + 2,34\epsilon_1}{12s + 1} e^{-11s} & \frac{2,54 + 0,24\epsilon_2}{27s + 1} e^{-12s} & \frac{8,10 + 0,32\epsilon_3}{20s + 1} e^{-2s} \\ \frac{4,13 + 1,71\epsilon_1}{8s + 1} e^{-5s} & \frac{2,38 + 0,93\epsilon_2}{19s + 1} e^{-7s} & \frac{6,23 + 0,30\epsilon_3}{10s + 1} e^{-2s} \\ \frac{4,06 + 2,39\epsilon_1}{13s + 1} e^{-8s} & \frac{4,18 + 0,35\epsilon_2}{33s + 1} e^{-4s} & \frac{6,53 + 0,72\epsilon_3}{9s + 1} e^{-1s} \\ \frac{4,38 + 3,11\epsilon_1}{33s + 1} e^{-20s} & \frac{4,42 + 0,73\epsilon_2}{44s + 1} e^{-22s} & \frac{7,20 + 1,33\epsilon_3}{19s + 1} \end{bmatrix} \quad (8)$$

onde ϵ_i são as incertezas no ganho do modelo, e as constantes de tempo são dadas em minutos.

As saídas y_1 e y_2 devem permanecer na especificação $\pm 0,005$, e y_3, y_4, y_5, y_6 e y_7 devem permanecer em $\pm 0,5$ no estado estacionário. Todas as variáveis manipuladas possuem uma restrição rígida (inviolável) $\pm 0,5$. A maior amplitude de movimento para as variáveis manipuladas é $\pm 0,20$ por amostragem, considerando $t_s = 4 \text{ min}$.

A matriz de transferência que representa os distúrbios é dada por:

$$D_0 = \begin{bmatrix} \frac{1,20 + 0,12\epsilon_4}{45s + 1} e^{-27s} & \frac{1,44 + 0,16\epsilon_5}{40s + 1} e^{-27s} \\ \frac{1,52 + 0,13\epsilon_4}{25s + 1} e^{-15s} & \frac{1,83 + 0,13\epsilon_5}{20s + 1} e^{-15s} \\ \frac{1,16 + 0,08\epsilon_4}{11s + 1} & \frac{1,27 + 0,08\epsilon_5}{6s + 1} \\ \frac{1,73 + 0,02\epsilon_4}{5s + 1} & \frac{1,79 + 0,04\epsilon_5}{19s + 1} \\ \frac{1,31 + 0,03\epsilon_4}{2s + 1} & \frac{1,26 + 0,02\epsilon_5}{22s + 1} \\ \frac{1,19 + 0,08\epsilon_4}{19s + 1} & \frac{1,17 + 0,01\epsilon_5}{24s + 1} \\ \frac{1,14 + 0,18\epsilon_4}{24s + 1} & \frac{1,26 + 0,18\epsilon_5}{32s + 1} \end{bmatrix} \quad (9)$$

4.1 Caso 1

Nessa simulação foi considerado que o modelo do controlador e a planta não possuem incerteza nos ganhos, i.e., $\epsilon_1 = \epsilon_2 = \epsilon_3 = \epsilon_4 = \epsilon_5 = 0$, e foram enviados degraus aos distúrbios, no tempo $t = 100 \text{ min}$, de valores $d_1 = d_2 = 0,5$. Foram assumidas que todas as entradas e saídas iniciais do modelo do controlador e da planta são iguais à zero. A resposta em malha aberta das saídas em relação aos distúrbios é ilustrada pela Fig. 4.




Figura 4. Resposta em malha aberta das saídas frente aos distúrbios enviados ao processo no Caso 1.





Figura 5. Variáveis (a) controladas e (b) manipuladas para ajuste baseado em multi-cenários no Caso 1.

Os horizontes de predição (P) e controle (M) foram sintonizados conforme proposto por Trierweiler & Farina (2003), sendo P baseado no tempo de assentamento do modelo do processo em malha aberta e $M = P/4$. Para o ajuste do MPC não quadrado, em faixas de operação foram considerados 98 cenários decompostos do modelo original (63 cenários 2×2 e 35 cenários 3×3). As frequências com que ocorre o RPN em cada cenário foram utilizadas para o cálculo das matrizes de escalonamento através do condicionamento mínimo global. Os valores para as matrizes, obtidas através do algoritmo Nelder-Mead são $R_s = \text{diag}[1,5151; 0,7575; 1,0]$ e $L_s = \text{diag}[0,0012; 2,0854; 0,0013; 1,3287; 5,51 \times 10^{-6}; 0,0002; 2,6241]$. Essas matrizes serão responsáveis pela normalização entre as entradas e saídas, considerando as grandezas em um mesmo tamanho. O sistema foi configurado conforme a Fig. 2, e os pesos do controlador preditivo calculado através do algoritmo Nelder-Mead. A simulação encontra-se na Fig. 5.

4.2 Caso 2

Nessa simulação, foi considerado como incertezas do modelo os valores $\epsilon_1 = -1$, $\epsilon_2 = 1$ e $\epsilon_3 = \epsilon_4 = \epsilon_5 = 0$. Foram enviados degraus aos distúrbios no tempo $t = 100 \text{ min}$ iguais a $d_1 = d_2 = -0,5$, e os valores iniciais para as entradas e saídas do controlador e planta foram considerados zero. A resposta em malha aberta das saídas em relação aos distúrbios é dada pela Fig. 6




Figura 6. Resposta em malha aberta das saídas frente aos distúrbios enviados ao processo no Caso 2.

Os horizontes P e M , o número de cenários, as matrizes de escalonamento e os valores das matrizes-peso foram mantidos iguais às sintonizadas no Caso 1. A simulação encontra-se na Fig. 7.





Figura 7. Variáveis (a) controladas e (b) manipuladas para ajuste baseado em multi-cenários no Caso 2.

4.3. Sintonia Direta

Como forma de comparar a estratégia de ajuste proposta nesse trabalho, foi considerada uma sintonia direta para a determinação dos pesos do MPC. Essa sintonia trata-se da minimização direta da Eq. 7, ou seja, é minimizada a violação da *soft-constraint* sem considerar o escalonamento do sistema. Os valores das matrizes de peso foram obtidos através do algoritmo Nelder-Mead (função *fminsearch* do Matlab®

R2012b). As simulações para os casos 1 e 2 encontram-se nas Figuras 8 e 9.




Figura 8. Variáveis (a) controladas e (b) manipuladas para ajuste através da sintonia direta para o Caso 1.

Observa-se que o ajuste proposto se mostrou fundamental para a operação estável do processo garantindo que as CVs permanecessem nas faixas especificadas e não excedendo movimento nas ações de controle. O ajuste obtido através da sintonia direta além de não garantir a estabilidade do processo apresentou excesso de movimento para as MVs.

5. Conclusão

Este trabalho propõe uma estratégia de ajuste para MPC baseado em multi-cenários, focando nos sistemas não quadrados, com mais CVs do que MVs, e utilização de faixas de operação. A sintonia é obtida através da determinação do desempenho alcançável para o modelo global, com restrições de desempenho obtidas para cada subcaso quadrado, do escalonamento do sistema e da determinação dos pesos que levam a planta para a melhor condição operacional. É feita a abordagem em cenários a fim de incluir na sintonia do sistema global, fatores limitantes de desempenho presentes em cenários quadrados que por vezes não estão presentes no sistema global, e surgem ao saturar uma ou mais variáveis.

A metodologia foi empregada na fracionadora de óleo pesado Shell, apresentando bons resultados para rejeição de distúrbios. O escalonamento se mostrou fundamental para a boa operação do sistema, uma vez que é responsável pela paridade entre as variáveis de entrada e saída e agrega fatores de robustez e desempenho garantidos pelo Número de Desempenho robusto. Os pesos do controlador foram obtidos a fim de priorizar as variáveis de entrada e saída e

garantir que o sistema opere dentro das restrições desejadas sem instabilizar.

Cabe salientar que a fracionadora Shell é um problema padrão proposto por Prett & Morari (1987) onde normalmente é considerado em seu subcaso (3×3) dada a sua dificuldade. Não foi encontrado na literatura nenhum artigo envolvendo MPC capaz de resolver o sistema proposto originalmente na versão analisada neste trabalho.




Figura 9. Variáveis (a) controladas e (b) manipuladas para ajuste através da sintonia direta para o Caso 2.

Referências Bibliográficas

- Camacho, E. F. & Bordons, C. (1999). *Model Predictive Control*.
- Campos, M. C. M. d., Gomes, M. V. d. C. & Perez, J. M. G. T. (2013) *Controle Avançado e Otimização na Indústria do Petróleo*, 1ª Edição. Rio de Janeiro.
- Ferramosca, A., Limon, D., González, A. H., Odloak, D. & Camacho, E. F. (2009) MPC for tracking target sets, *Proceedings of the IEEE Conference on Decision and Control*.
- Garriga, J. L. & Soroush, M. (2010) Model predictive control tuning methods: A review. *Industrial and Engineering Chemistry Research*, 49(8), 3505-3515.
- Gous, G. Z. & de Vaal, P. L. (2012) Using MV overshoot as a tuning metric in choosing DMC move suppression values. *ISA transactions*, 51(5), 657-664.
- Holkar, K. S. & Waghmare, L. M. (2010) An overview of model predictive control. *International Journal of Control and Automation*, 3(4), 7.
- Lima, F. & Georgakis, C. (2006) Operability of multivariable non-square systems. *Proc. IFAC Symp. ADCHEM*.
- Maciejowski, J. M. (2002). *Predictive Control with Constraints*.
- Nery Júnior, G. A., Martins, M. A. F. & Kalid, R. (2014) A PSO-based optimal tuning strategy for constrained multivariable predictive controllers with model uncertainty. *ISA Transactions*, 53(2), 560-567.
- Prett, D. M. & Morari, M. (1987). *Shell Process Control Workshop*, 369.
- Qin, S. J. & Badgwell, T. A. (2003) A survey of industrial model predictive control technology. *Control Engineering Practice*, 11(7), 733-764.
- Shead, L. R. E., Anastassakis, C. G. & Rossiter, J. A. (2007) Steady-state operability of multi-variable non-square systems: Application to Model Predictive Control (MPC) of the Shell Heavy Oil Fractionator (SHOF). *2007 Mediterranean Conference on Control and Automation, MED*.
- Trierweiler, J. O. (1997). *A Systematic Approach to Control Structure Design*.
- Trierweiler, J. O. (2002) Application of the RPN methodology for quantification of the operability of the quadruple-tank process. *Brazilian Journal of Chemical Engineering*, 19, 195-206.
- Trierweiler, J. O. & Farina, L. A. (2003) RPN tuning strategy for model predictive control. *Journal of Process Control*, 13(7), 591-598.