

ABORDAGEM DE CONTROLADOR MPC+OTIMIZADOR EM UMA CAMADA

JOSÉ EDUARDO W. SANTOS, ANDRESSA APIO, JORGE OTÁVIO TRIERWEILER E MARCELO FAREZENA

*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, aapio, jorge, farenz}@enq.ufrgs.br*

Abstract— The search for optimization of processes, aiming a greater economic return and lower consumption of raw materials and energy is still a challenge to be overcome in industry. Most papers published in the literature that involve real-time optimization use steady-state data, nonlinear algorithms, and layered hierarchical structures. In the absence of a real-time optimization (RTO) layer, a static optimization layer is often proposed which calculates optimal values for the targets in the dynamic layer (MPC) through linear/quadratic program problems. However, the influence of disturbances and the discrepancy of sampling times between these layers do not guarantee that the system will operate at the optimum point in a stable way. In this study, a two-layer structure is proposed that differs from the structures already stated by controlling the optimal value of the cost calculated in the upper layer, rather than the value of the targets. This approach is done through a single cost function for the MPC, capable of covering the use of predictive control (regulatory layer) and economic optimization. An industrial example has been described in order to corroborate the efficiency of the proposed approach in comparison with the classic two-layer strategy.

Keywords— Economic optimization, real time optimization, predictive control, layers.

Resumo— A busca pela otimização de processos, visando o maior retorno econômico e o menor consumo de matéria-prima e energia ainda é um desafio a ser superado na indústria. A maior parte dos trabalhos publicados na literatura que envolve otimização em tempo real, utilizam dados em estado estacionário, algoritmos não lineares e estruturas hierarquizadas em camadas. Na falta de uma camada de otimização em tempo real (RTO), frequentemente é proposta uma camada de otimização estática que calcula, através de problemas de programação quadrática/linear, valores ótimos para os *targets* da camada dinâmica (MPC). Entretanto, a influência de distúrbios e a discrepância dos tempos de amostragem entre essas camadas não garante que o sistema irá operar no ponto ótimo de forma estável. Nesse estudo, é proposta uma estrutura em duas camadas que difere das estruturas já abordadas ao controlar o valor do custo ótimo da camada superior, ao invés do valor dos *targets*. Essa abordagem é feita através de uma única função custo para o MPC, capaz de abranger o uso do controle preditivo (camada regulatória) e otimização econômica. Um exemplo industrial foi descrito a fim de corroborar a eficiência da abordagem proposta comparando com a estratégia clássica em duas camadas.

Palavras-chave— Otimização econômica, otimização em tempo real, controle preditivo, camadas.

1. Introdução

Algumas mudanças nos objetivos de produção ou compensação de distúrbios, a fim de alcançar a operação ótima do processo, ainda são estabelecidas através de heurísticas ou experiência dos engenheiros de processos (de Gouvêa & Odloak, 1998). Além disso, é frequentemente utilizada na indústria a estrutura hierarquizada de controle (Qin & Badgwell, 2003) que relaciona controle preditivo e otimização em tempo real. Ambas as técnicas de otimização são empregadas a fim de obter um melhor retorno econômico da unidade (seja através da maximização do lucro ou minimização do custo de operação).

O otimizador em tempo real (RTO) é baseado em um modelo do processo, complexo e geralmente não linear, e implementa a decisão ótima (como valores de referência *targets* e *setpoints*) em uma escala de tempo menor que o tempo de amostragem da planta (Hinojosa, Ferramosca, González, & Odloak, 2017). O MPC por sua vez, calcula ações de controle que tendem a levar a planta o mais próximo possível dos valores calculados pela camada superior, considerando o modelo dinâmico do processo, além de restrições físicas e critérios de estabilidade (Nikandrov & Swartz, 2009). A diferença entre essas duas camadas, ao considerar diferentes funções cus-

to, e a forma de comunicação entre elas pode causar problemas no desempenho econômico e valores inalcançáveis como referência, uma vez que os novos valores de *setpoint/target* são normalmente calculados quando a planta está estabilizada.

Outra maneira frequentemente abordada é através da utilização de problemas de otimização simplificados na camada imediatamente superior ao MPC, onde geralmente é abordado um problema de programação quadrática (QP) ou programação linear (LP) (Ying & Joseph, 1999). Esse problema de otimização, utiliza modelos estáticos consistentes com o modelo dinâmico do controlador MPC e fornece *targets* atingíveis para a camada dinâmica de forma sequencial e com o mesmo tempo de amostragem (Alvarez & Odloak, 2014). Essa característica permite a compensação de distúrbios não medidos e, uma vez que esse problema de otimização possui as mesmas restrições do controlador, o cálculo de valores de referência alcançáveis.

Como forma de superar o conflito de comunicação entre as camadas, os diferentes tempos de amostragem e a compensação de distúrbios não medidos, foram propostas abordagens em uma camada única (Adetola & Guay, 2010; De Souza, Odloak, & Zanin, 2010; Zanin, Tvrtzka de Gouveia, & Odloak, 2002). Aqui o esquema de controle e otimização são resol-

vidos juntos com vantagens em relação à compensação de distúrbios e ainda a possibilidade de utilização de técnicas conhecidas de ajuste para o controlador estendido. Esses estudos relacionam a função custo complexa do RTO ou ainda o gradiente dessa função como uma parcela no problema de otimização do controlador MPC, com a principal desvantagem relacionada ao tempo computacional necessário para resolver os problemas de otimização não lineares, e a não garantia de obtenção de ótimos globais.

Nesse trabalho será abordada uma metodologia capaz de integrar a camada de otimização estática e simplificada na camada dinâmica (MPC). A inclusão da camada otimização na camada regulatória irá ocorrer através da ponderação da função custo do problema LP na função custo do controlador MPC, obtendo assim um controlador com otimizador. A camada superior continuará existindo a fim de gerar os valores de referência para o custo ótimo do problema LP. Essa abordagem considera o controlador preditivo operando através de faixas, nas variáveis controladas, sendo enviados valores de *setpoint* apenas para o custo ótimo de operação do processo.

O trabalho está organizado da seguinte maneira: a seção 2 apresenta e discute a estrutura clássica de LP-MPC em cascata. Na seção 3 é apresentada a proposta que inclui na função custo do MPC a otimização estática e a forma de comunicação com a camada imediatamente superior. Na seção 4 é apresentado um estudo de caso para ilustrar a metodologia em comparação com a metodologia clássica e, na seção 5, as conclusões são descritas.

2. Estrutura Clássica LP-MPC Cascata

Em um controlador preditivo, as variáveis controladas (CVS) e manipuladas (MVS) possuem valores definidos de *setpoint* e *target*, respectivamente. Esses valores são calculados através de problemas de otimização que utilizam uma função objetivo econômica, i.e., com objetivo de gerar um menor gasto de matéria-prima, energia, ou ainda um maior retorno financeiro da unidade. Além disso, são incluídas restrições de máximo e mínimo nas CVS e MVS e de variação de movimento nas MVS. A função que representa o problema a ser resolvido pelo MPC é:

$$\min_u J = \min_u \left[\sum_{j=0}^P \|\hat{y}(t+j|t) - y_{set}(t+j)\|_{Q_y}^2 + \sum_{j=0}^M \|u(t+j|t) - u_{tgt}(t+j)\|_{Q_u}^2 + \sum_{j=0}^M \|\Delta u(t+j-1)\|_W^2 + \|\hat{\varepsilon}\|_{\rho_\varepsilon}^2 \right] \quad (1)$$

s.a

$$u_{min} \leq u(t+j|t) \leq u_{max}$$

$$\Delta u_{min} \leq u(t+j|t) - u(t-1) \leq \Delta u_{max} \quad (2)$$

$$\underbrace{y_{min}^{soft} - \varepsilon_k}_{y_{min}^{hard}} \leq \hat{y}(t+j|t) \leq \underbrace{y_{max}^{soft} + \varepsilon_k}_{y_{max}^{hard}}$$

onde $\hat{y}(t+j|t)$ é a saída predita pelo modelo j instantes de amostragem no futuro, $y_{set}(t+j)$ é a trajetória de referência para as variáveis controladas, $u(t+j|t)$ são as ações de controle calculadas pelo controlador, $u_{tgt}(t+j)$ é a trajetória de referência para as ações de controle, $\Delta u(t) = u(t+j|t) - u(t-1)$ é o incremento nas ações de controle, $\hat{\varepsilon}$ é a máxima folga utilizada para as variáveis controladas. Os parâmetros de ajuste do controlador são o horizonte de predição (P), horizonte de controle (M), matriz-peso do erro de desvio do *setpoint* (Q_y), matriz-peso do erro de desvio do *target* (Q_u), e penalização da violação da *soft-constraint* (ρ_ε). $\|x\|_W^2 = x^T W x$ é a norma-peso Euclidiana de $x \in \mathbb{R}^n$, com $W \in \mathbb{R}^{n \times n}$.

Ao definir o valor da matriz-peso do erro das variáveis controladas (Q_y) nulo, as saídas correspondentes não irão seguir a sua trajetória de referência (*setpoint*) e irão permanecer nas faixas especificadas (com penalização ao serem violadas). As faixas brandas, chamadas de *soft-constraints* permitem violações enquanto as faixas rígidas, *hard-constraints* não.

Na camada imediatamente superior ao MPC, é resolvido o problema de programação linear que determina os valores de *target* para as variáveis manipuladas do controlador MPC. O problema de otimização é descrito por:

$$\min_{\Delta u_{tgt}} J_{LP} = \min_{\Delta u_{tgt}} \sum_{i=1}^n \beta_i \Delta u_{tgt,i} \quad (3)$$

s.a.

$$\Delta u_{tgt,i,min} \leq \Delta u_{tgt} \leq \Delta u_{tgt,i,max} \quad (4)$$

$$K \cdot \Delta u_{tgt} \leq b$$

onde β_i é o custo da variável manipulada i e n o número total de variáveis manipuladas. Esse problema de otimização possui restrições de máximo e mínimo para os valores de *target* calculados, e restrições de desigualdade. Aqui foram consideradas as variáveis através de desvio em relação ao valor anterior, uma vez que o modelo linear do processo é dado através de uma variação de saída frente a uma variação de entrada.

As restrições de desigualdade são atualizadas em cada instante de amostragem a fim de compensar o distúrbio não medido (Φ), através do modelo estático do processo. Considerando que as variáveis controladas do processo estão definidas em faixas de opera-

ção, a definição do ganho do processo, na restrição de desigualdade fica:

$$K = \frac{\Delta y(t \rightarrow \infty)}{\Delta u(t \rightarrow \infty)} = \frac{\Delta y^{soft}}{\Delta u_{tgt}} \Rightarrow K \cdot \Delta u_{tgt}$$

$$K \cdot \Delta u_{tgt} \leq \underbrace{\Delta y_{max}^{soft} - \Phi}_b \quad (5)$$

$$K \cdot \Delta u_{tgt} \geq \underbrace{\Delta y_{min}^{soft} - \Phi}_b$$

onde K é o ganho estático do processo, Δu_{tgt} é a variação do *target*, Δy_{min}^{soft} e Δy_{max}^{soft} é o valor da faixa inferior e superior, respectivamente, das variáveis controladas corrigidas em variáveis desvio e Φ é o distúrbio não medido. O valor de Φ é determinado através do esquema proposto na Fig.1 e descrito na Eq. 6.




Figura 1. Malha de retroalimentação.

$$\Delta \bar{y} = \Phi + \Delta y_s$$

$$\Phi = \Delta y_s - \Delta \bar{y} \quad (6)$$

onde Φ é o distúrbio não medido, Δy_s é o valor simulado do modelo da planta utilizada no controlador MPC ($G(s)$) com a entrada Δu oriunda do próprio controlador e $\Delta \bar{y}$ é a leitura de saída atual. Neste trabalho não foi considerada a variação do custo de cada variável manipulada, mantendo o mesmo constante. O valor ótimo do *target* é enviado como valor de referência para o controlador MPC.

O esquema em duas camadas está resumido na Fig. 2.




Figura 2. Estrutura LP-MPC em cascata.

Outros exemplos de estruturas LP-MPC em cascata utilizados na indústria são abordados em

Nagrath, Prasad, & Bequette, 2000; Nikandrov & Swartz, 2009; Ying & Joseph, 1999.

3. Estrutura de Controlador MPC+Otimizador

Nessa abordagem é proposta uma nova função custo para o controlador MPC. Ao considerar que as saídas do sistema estão sendo controladas através de *soft-constraints*, a parcela da função custo do MPC (Eq. 1) que relaciona o desvio das saídas do valor de *setpoint* é desprezada juntamente com a parcela que relaciona os valores das entradas com os *targets* oriundos da camada de otimização LP. Em contrapartida uma nova parcela que minimiza o valor do custo ótimo de um valor de referência para o problema de programação linear (calculada na camada superior) é incorporada na função a ser resolvida pelo MPC. A função custo proposta encontra-se na Eq. 7.

$$\min_u J_1 = \min_u \left[\sum_{j=0}^P \|J_{LP}(t+j|t) - J_{LP,set}(t+j)\|_{Q_j}^2 + \sum_{j=0}^M \|\Delta u(t+j-1)\|_{W_j}^2 + \|\hat{\epsilon}\|_{\rho_\epsilon}^2 \right]$$

$$u_{min} \leq u(t+j|t) \leq u_{max} \quad (7)$$

$$\Delta u_{min} \leq u(t+j|t) - u(t-1) \leq \Delta u_{max} \quad (8)$$

$$\underbrace{y_{min}^{soft} - \epsilon_k}_{y_{min}^{hard}} \leq \hat{y}(t+j|t) \leq \underbrace{y_{max}^{soft} + \epsilon_k}_{y_{max}^{hard}}$$

onde $J_{LP} = \sum_{i=1}^n \beta_i \Delta u_{tgt,i}$ representa o problema LP na função custo do MPC e $J_{LP,set}$ é o valor ótimo da função objetivo resolvida na camada superior. As demais variáveis e parâmetros da função custo do MPC permanecem as mesmas da estrutura clássica.

O esquema proposto está resumido na Fig.3.




Figura 3. Estrutura de MPC+Otimizador.


A principal diferença entre as duas abordagens está relacionada à comunicação entre as duas camadas. Na estrutura clássica LP-MPC em cascata, a camada de otimização envia ao controlador MPC valores ótimos de *targets* para as MVS. Já na estrutura proposta, a camada de otimização serve para calcular o valor ótimo da função objetivo e enviá-lo como valor de referência (*setpoint*) já que o custo é considerado uma variável controlada. O valor de $J_{LP,set}$ é calculado com base num problema estático em cada instante de amostragem e enviado ao controlador MPC, que calcula de forma dinâmica as ações de controle que irão levar a planta para a melhor condição operacional.

Em modelos com várias entradas, essa abordagem permite uma maior flexibilidade ao controlador já que ao invés de calcular ações de controle que possuam o menor desvio possível dos valores de referência para as entradas (*targets*), o controlador irá calcular ações de controle que possuam o menor desvio possível de uma única CV, o valor ótimo do custo ($J_{LP,set}$). Além disso, não há alteração no tempo computacional necessário para resolver o problema de otimização e o controlador MPC, já que se trata de uma função linear.

4. Estudo de Caso - CSTR com coluna de separação e reciclo

Como estudo de caso, considerou-se um sistema composto por um reator CSTR, e uma coluna de separação e reciclo (Schultz, Trierweiler, & Farenzena, 2016), conforme mostrado na Fig. 4.

O processo possui quatro componentes (A, B, C e D). Apenas o componente A é alimentado no reator, onde ocorre uma reação que segue a cinética de Van de Vusse:



No processo, considera-se o controle perfeito de temperatura (T) e volume de reação (V_R), o qual é modelado por (9).

$$\begin{aligned} V_R \frac{dC_A}{dt} &= F_{in}C_{A,in} + F_{RO}C_{A,RO} - FC_A \\ &\quad - V_R(k_1C_A + 2k_3C_A^2) \\ V_R \frac{dC_B}{dt} &= F_{RO}C_{B,RO} - FC_B \\ &\quad - V_R(k_2C_B - k_1C_A) \\ V_R \frac{dC_C}{dt} &= -FC_C + V_R k_2C_B \\ V_R \frac{dC_D}{dt} &= -FC_D + V_R k_3C_A^2 \\ \left(\frac{0.1}{(1-ya)^{0.7}}\right) \frac{dC_{A,RO}}{dt} &= C_{A,R} - C_{A,RO} \\ \left(\frac{0.1}{(1-ya)^{0.7}}\right) \frac{dC_{B,RO}}{dt} &= C_{B,R} - C_{B,RO} \\ (0.1) \frac{dF_{RO}}{dt} &= F_R - F_{RO} \end{aligned} \quad (9)$$

onde C_A, C_B, C_C e C_D são as concentrações dos componentes A, B, C e D , respectivamente, $C_{A,RO}$ e $C_{B,RO}$ são as concentrações de A e B na corrente de reciclo e $C_{A,in}$ é a concentração de A na alimentação. F_{in}, F e F_{RO} são as vazões na alimentação, na saída do reator e na saída do refluxo, respectivamente. y_A é a fração molar de A na corrente de refluxo e $k_1, k_2, k_3, C_{A,R}, C_{B,R}$ e F_R são definidos por (10).

$$\begin{aligned} k_1 &= 1.2870 \times 10^{12} \exp\left(-\frac{9758.3}{T[^\circ C] + 273.15}\right) \\ k_2 &= 1.2870 \times 10^{12} \exp\left(-\frac{9758.3}{T[^\circ C] + 273.15}\right) \\ k_3 &= 4.5215 \times 10^9 \exp\left(-\frac{8560}{T[^\circ C] + 273.15}\right) \\ C_{A,R} &= \sqrt{y_A(C_A + C_B + C_C + C_D)C_A} \\ C_{B,R} &= -\frac{\sqrt{y_A(C_A + C_B + C_C + C_D)C_A}(y_A - 1)}{y_A} \\ F_R &= \frac{\sqrt{y_A(C_A + C_B + C_C + C_D)C_A}F}{y_A(C_A + C_B + C_C + C_D)} \end{aligned} \quad (10)$$

Esse modelo foi linearizado, a fim de ser utilizado no controlador MPC. O Ponto de Operação, as *soft* e *hard-constraints* definidos para o modelo estão na Tabela 1.

Como variáveis controladas em faixas foram consideradas as concentrações dos componentes A, B, C e D . Como variáveis manipuladas foram consideradas a fração molar de A na corrente de reciclo (y_A) e a temperatura de reação (T). Além disso, considerou-se que o volume de reação (V_R) encontra-se perfeitamente controlado através da manipulação da vazão de entrada (F_{in}), e o valor da vazão de saída do reator (F) é mantido constante. O sistema foi submetido a distúrbios na concentração de alimentação do reator ($C_{A,in}$) a fim de observar o comportamento do custo de operação do processo.

O custo definido para a Fração Molar de A na corrente de reciclo é $\beta_{y_A} = 2,047$, e para a Temperatura da reação é $\beta_T = 0,0074$. O valor do custo de y_A foi normalizado e definido maior que o da temperatura ao considerar que a energia gasta para separar A na coluna de destilação é mais “cara” que a energia gasta para aquecer a mistura reacional no reator CSTR fazendo com que a camada LP atue como uma camada de otimização simplificada.

O modelo não linear do processo foi feito em OMEdit – OpenModelica Connection Editor v1.9.6. Esse programa trata-se de um *software* livre que proporciona uma interface gráfica de fácil implementação e simulação, onde os modelos podem ser descritos através de comando de linha ou blocos. A simulação do modelo não linear e do controlador MPC foi feita no *software* livre Spyder 3.0 (do inglês *Scientific PYthon Development EnviRonment*) que se trata de um ambiente avançado de criação e edição para a linguagem Python.

Considerando que o objetivo desse trabalho não é avaliar o ajuste do controlador, e sim a comparação entre as estratégias de otimização, manteve-se o

controlador com os mesmos parâmetros, conforme Tabela 2.




Figura 4. CSTR com coluna de separação e reciclo.

Tabela 1: Ponto de Operação, *Soft-* e *Hard-constraints*.

Parâmetros	Ponto de Operação	<i>Soft-Constraint</i>	<i>Hard-Constraint</i>	Δu_{max}
V_R [m ³]	0,611	-	-	-
F [kmol/h]	30	-	-	-
T [°C]	135	-	$95 \leq T \leq 135$	$0 \leq \Delta T \leq 8$
y_A	0,977	-	$0 \leq y_A \leq 1,0$	$0 \leq \Delta y_A \leq 0,2$
$C_{A,in}$ [kmol/m ³]	5,1	-	-	-
C_A [kmol/m ³]	1,2786	$1,0 \leq C_A \leq 2,0$	$0 \leq C_A \leq 3,0$	-
C_B [kmol/m ³]	0,6796	$0,5 \leq C_B \leq 1,0$	$0 \leq C_B \leq 3,0$	-
C_C [kmol/m ³]	0,7369	$0,5 \leq C_C \leq 1,0$	$0 \leq C_C \leq 3,0$	-
C_D [kmol/m ³]	0,1173	$0,08 \leq C_D \leq 1,0$	$0 \leq C_D \leq 3,0$	-
$C_{A,RO}$ [kmol/m ³]	1,8742	-	-	-
$C_{B,RO}$ [kmol/m ³]	0,0443	-	-	-
F_{RO} [kmol/h]	20,4655	-	-	-

Observa-se que as variáveis de saída estão controladas através de faixas ($Q_y = 0$) e que o peso dos *targets* (estrutura clássica) e peso da ponderação da função custo (estrutura proposta) são iguais.

Foram feitos distúrbios na forma de degraus na concentração na corrente de alimentação, nos tempos $t = 150$ s e $t = 300$ s. O tempo de amostragem foi de $T_s = 1$ s e o tempo final de simulação foi $t_f = 500$ s. Os resultados encontram-se nas Figuras 5, 6 e 7.

Tabela 2: Parâmetros dos controladores MPC.

Parâmetros	Estrutura Clássica	Estrutura Proposta
T_s	1	
P	20	
M	5	
Q_u	$diag[0,05; 0,05]$	-
Q_j	-	$[0,05]$
W	$diag[0,75; 0,75]$	
ρ_ϵ	$diag[5,5,5,5]$	




Figura 5. Variáveis controladas (a) e manipuladas (b) para estrutura clássica

É possível observar através das figuras, que o modelo proposto apresenta uma menor variação nas ações de controle a fim de obter um resultado semelhante para as saídas. Isso era esperado, já que esse modelo proposto possui apenas 1 variável controlada através de *setpoint*, ou seja, o sistema possui uma maior liberdade nas ações de controle a fim de obter o resultado ótimo de custo de operação. Pode-se observar no problema clássico, que as variáveis manipuladas tendem a seguir valores bruscos de variação do *target*, o que é indesejável para uma operação robusta. Há uma diferença nos valores estacionários para as saídas e entradas devido ao fato de que na estrutura proposta o controlador tem como referência apenas o custo ótimo $J_{LP, set}$. A integral do erro quadrático (*ISE*) da violação da *soft-constraint* para as variáveis controladas na estrutura proposta foi $ISE_1 = 0,0165$ enquanto para estrutura clássica foi $ISE = 0,0405$.




Figura 6. Variáveis controladas (a) e manipuladas (b) para estrutura proposta.

Os custos de operação das duas estratégias, que correspondem aos valores da função objetivo do problema LP, encontram-se na Fig. 7.

É possível observar graficamente que o custo de operação ótimo é similar para a estratégia proposta em relação ao da estratégia clássica. Além disso, calculou-se a variância das variáveis manipuladas a fim de observar o quanto agressivas foram as ações de controle para manter as variáveis controladas nas faixas especificadas. Para a metodologia proposta foi encontrado o valor $VAR_1 = 7,65$ e para a metodologia clássica o valor $VAR = 8,90$.




Figura 7. Comparação entre o custo de operação para a estrutura clássica e proposta.

5. Conclusão

Esse trabalho aborda uma estrutura unificada de controle e otimização de forma a superar as dificuldades (compensação de distúrbios, discrepância de modelo, diferenças de tempo de amostragem e etc.) presentes na estrutura clássica. A estrutura proposta de controlador+otimizador deu-se através da modificação da função custo do MPC, que ao invés de colocar valores de referência para as variáveis manipuladas (*targets*) e controladas (*setpoints*), estabeleceu valores de referência para o custo ótimo do processo. Essa abordagem permite uma maior flexibilidade ao permitir que cada entrada contribua de forma diferente da estrutura clássica, no objetivo econômico.

Como forma de exemplificar a proposta de controle e otimização em uma única camada, foi utilizado o modelo não-linear de um reator com uma coluna de destilação e reciclo. Esse exemplo foi capaz de corroborar a estrutura proposta, mostrando um custo de operação similar, uma menor variação nas ações de controle necessárias para manter as variáveis controladas nas faixas especificadas e uma menor violação das *soft-constraints* durante a operação.

Agradecimentos

A CAPES, PETROBRAS e ANP por suporte financeiro à pesquisa.

Referências Bibliográficas

- Adetola, V., & Guay, M. (2010). Integration of real-time optimization and model predictive control. *Journal of Process Control*, 20(2), 125–133. <https://doi.org/10.1016/j.jprocont.2009.09.001>
- Alvarez, L. A., & Odloak, D. (2014). Reduction of the QP-MPC cascade structure to a single layer MPC. *Journal of Process Control*, 24(10), 1627–1638. <https://doi.org/10.1016/j.jprocont.2014.08.008>
- de Gouvêa, M. T., & Odloak, D. (1998). One-layer

real time optimization of LPG production in the FCC unit: procedure, advantages and disadvantages. *Computers & Chemical Engineering*, 22(1997), S191–S198. [https://doi.org/10.1016/S0098-1354\(98\)00054-4](https://doi.org/10.1016/S0098-1354(98)00054-4)

- De Souza, G., Odloak, D., & Zanin, A. C. (2010). Real time optimization (RTO) with model predictive control (MPC). *Computers and Chemical Engineering*, 34(12), 1999–2006. <https://doi.org/10.1016/j.compchemeng.2010.07.001>
- Hinojosa, A. I., Ferramosca, A., González, A. H., & Odloak, D. (2017). One-layer gradient-based MPC + RTO of a propylene/propane splitter. *Computers and Chemical Engineering*, 106, 160–170. <https://doi.org/10.1016/j.compchemeng.2017.06.006>
- Nagrath, D., Prasad, V., & Bequette, W. B. (2000). Model predictive control of open-loop unstable cascade systems. In *Proceedings of the American Control Conference* (Vol. 6, pp. 3747–3752).
- Nikandrov, A., & Swartz, C. L. E. (2009). Sensitivity analysis of LP-MPC cascade control systems. *Journal of Process Control*, 19(1), 16–24. <https://doi.org/10.1016/j.jprocont.2008.02.005>
- Qin, S. J., & Badgwell, T. A. (2003). A survey of industrial model predictive control technology. *Control Engineering Practice*, 11(7), 733–764. [https://doi.org/10.1016/S0967-0661\(02\)00186-7](https://doi.org/10.1016/S0967-0661(02)00186-7)
- Schultz, E. S., Trierweiler, J. O., & Farenzena, M. (2016). The Importance of Nominal Operating Point Selection in Self-Optimizing Control. *Industrial & Engineering Chemistry Research*. <https://doi.org/10.1021/acs.iecr.5b02044>
- Ying, C., & Joseph, B. (1999). Performance and Stability Analysis of LP-MPC and QP-MPC Cascade Control Systems. *AIChE Journal*, 45(7).
- Zanin, a. C., Tvrzka de Gouvea, M., & Odloak, D. (2002). Integrating real-time optimization into the model predictive controller of the FCC system. *Control Engineering Practice*, 10, 819–831. [https://doi.org/10.1016/S0967-0661\(02\)00033-3](https://doi.org/10.1016/S0967-0661(02)00033-3)