

8º CONGRESSO BRASILEIRO DE PESQUISA E DESENVOLVIMENTO EM PETRÓLEO E GÁS



TÍTULO DO TRABALHO:

Técnicas de Correlação para Detecção de Erro Planta-Modelo em Aplicações MPC

AUTORES:

Diego D. G. B. Cruz, Oscar A. Z. Sotomayor, Danilo D. Tannus

INSTITUIÇÃO:

Universidade Federal de Sergipe

Este Trabalho foi preparado para apresentação no 8º Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás - 8º PDPETRO, realizado pela Associação Brasileira de P&D em Petróleo e Gás - ABPG, no período de 20 a 22 de outubro de 2015, em Curitiba/PR. Esse Trabalho foi selecionado pelo Comitê Científico do evento para apresentação, seguindo as informações contidas no documento submetido pelo(s) autor(es). O conteúdo do Trabalho, como apresentado, não foi revisado pela ABPG. Os organizadores não irão traduzir ou corrigir os textos recebidos. O material conforme, apresentado, não necessariamente reflete as opiniões da Associação Brasileira de P&D em Petróleo e Gás. O(s) autor(es) tem conhecimento e aprovação de que este Trabalho seja publicado nos Anais do 8º PDPETRO.

TÉCNICAS DE CORRELAÇÃO PARA DETECÇÃO DE ERROS PLANTA-MODELO EM APLICAÇÕES MPC

Abstract

Predictive control strategies (MPC) have become the standard for advanced control applications in the process industry, especially oil and petrochemicals. In these controllers a large percentage of degradation of the performance are associated with deterioration of the model that the controller uses to make the prediction of process outputs and calculate the entries. The aim of this work is the implementation of mathematical methods that can be used to detect plant-model mismatch by providing indicative for a possible re-identification of the process model. First, it conducted a study of the effects of divergence between plant and model the performance of the MPC system, aiming to know the cases of higher incidence in the deterioration of control. From this analysis, plant-model mismatch detection techniques based on cross-correlation and partial correlation are implemented and tested by numerical simulation in a typical case study of the petrochemical industry operating under MPC control. The application of these methods indicates the location of the input-output channel affected by the mismatch presence in the model whose information provides a significant reduction in the time required for a re-identification procedure model.

Keywords: Predictive control, plant-model mismatch detection, correlation and model.

Introdução

Controladores preditivos (MPC) pertencem a uma classe de controladores avançados que utilizam modelo do processo como um dos princípios de funcionamento. O erro entre planta e modelo é a diferença entre as saídas do processo atual e a do modelo que está sendo utilizado para prever o seu comportamento. Com o tempo os processos vão sofrendo modificações e, conseqüentemente, os modelos precisam acompanhá-las para manter o desempenho adequado no controle. Para que isso ocorra, muitas vezes há a necessidade de atualização e reajuste do modelo, de preferência com o controle em pleno funcionamento. Quando um canal de um controlador MPC multivariável (MIMO) tem uma modelagem errada, várias saídas são afetadas. A detecção do erro entre a planta e o modelo torna-se então um fator importante tanto no auxílio na reidentificação do processo e resintonia do controlador, quanto no monitoramento contínuo do desempenho, com finalidade de obter o máximo ganho de produtividade do sistema MPC. Em processos com grande número de entradas e saídas a reidentificação do modelo pode necessitar de métodos que comprometem a produção, como o de manter um grande número de entradas em um estado perturbado por um longo período de tempo, o que pode causar elevados prejuízos à produção. Portanto, é desejável a detecção e localização exata do erro no modelo, para que seja possível perturbar um número menor de entradas e assim atualizar apenas a parte degradada no modelo (Badwe et al., 2009). Neste trabalho é demonstrado como a ocorrência de alterações no modelo afeta o desempenho do controlador MPC e são aplicados métodos matemáticos baseados em correlação que possibilitam a detecção de erros planta-modelo.

No tema de detecção de erros planta-modelo é possível encontrar diversas pesquisas que utilizam variados métodos. Webber e Gupta (2008) utilizaram correlações cruzadas para a detecção de erros planta-modelo. Em Badwe et al. (2009) é utilizada a correlação parcial e em Carlsson (2009) o método é estendido para sistemas não lineares. Mais recentemente, em Cruz (2014) o desempenho das correlações cruzada e parcial, entre o sinal de controle e erro de predição, são comparados quando aplicados em um estudo de caso característico da indústria petroquímica operando sob controle MPC.

Metodologia

O controle por modelo interno (IMC) tem como principal objetivo a obtenção do melhor controlador a partir do modelo do processo e de uma especificação de desempenho. A necessidade do modelo do processo faz com que o controlador MPC seja similar à estrutura de um IMC (Nafsun e Yusoff, 2011). A representação em diagrama de blocos de um sistema em malha fechada de uma estrutura IMC pode ser ilustrada na Figura 1. De acordo com Carlsson (2010) a utilização do IMC faz-se necessário para os casos em que não há um modelo explícito, em um sistema linear e invariante no tempo, capaz de descrever um controlador MPC, com a vantagem de permitir incertezas no modelo e ter o equilíbrio entre robustez e desempenho de maneira sistemática.




Figura 1. Sistema de controle em malha fechada de uma estrutura IMC (Badwe et al., 2009)

Em que G : processo.

$\hat{G}$: modelo.

Q : controlador.

$r(k)$: set-point.

$u(k)$: saída do controlador.

$v(k)$: perturbações não medidas do processo.

$y(k)$: saída do processo.

$\hat{y}(k)$: saída do modelo.

$e(k)$: erro de predição

Considerando o modelo de um processo com múltiplas entradas e saídas as modificações serão aplicadas nas funções de transferência de G , o erro produzido entre a planta e o modelo é encontrado através da Equação (1) e o erro de predição a partir da Equação (2), de acordo com a estrutura IMC da Figura 1.

$$\Delta = G - \hat{G} \quad (1)$$

$$e(k) = y(k) - \hat{y}(k) \quad (2)$$

Devido à natureza do processo ser MIMO, a abordagem utiliza múltiplas variáveis para as expressões dos erros de predição (e) e sinais de controle (u). Novamente é considerada a Equação (2) com base na estrutura IMC em malha fechada para desenvolver a expressão dos erros de predição:

$$\bar{e}(k)I = \Delta \bar{u}(k) + \bar{v}(k) \quad (3)$$

$$\bar{u}(k) = [\bar{r}(k) - \bar{e}(k)]\bar{Q} \quad (4)$$

Substituindo a Equação (4) na Equação (3):

$$\bar{e}(k)I = [\bar{r}(k) - \bar{e}(k)]\Delta\bar{Q} + \bar{v}(k) \quad (5)$$

$$\bar{e}(k) = [I + \Delta\bar{Q}]^{-1} \Delta\bar{Q}\bar{r}(k) + [I + \Delta\bar{Q}]^{-1} \bar{v}(k) \quad (6)$$

Para o caso dos sinais de controle, o desenvolvimento da expressão tem início através da Equação (4):

$$\bar{u}(k) = \bar{Q}[I + \Delta\bar{Q}]^{-1} \bar{r}(k) - \bar{Q}[I + \Delta\bar{Q}]^{-1} \bar{v}(k) \quad (7)$$

A necessidade da excitação no set-point para a detecção de erro pode ser deduzida por meio das Equações (6) e (7). Como prova faz-se com que o set-point seja igual a zero ($\bar{r} = 0$), a partir disso é possível observar que as expressões para os erros de predição e sinais de controle ficam dependentes apenas das perturbações do processo, i.e. Equações (8) e (9).

$$\bar{e}(k) = [I + \Delta \bar{Q}]^{-1} \bar{v}(k) \quad (8)$$

$$\bar{u}(k) = -\bar{Q}[I + \Delta \bar{Q}]^{-1} \bar{v}(k) \quad (9)$$

Fazendo uma substituição de termos da Equação (9) na (8) é possível constatar com base na Equação (10) que os efeitos provenientes do erro entre o modelo e planta são anulados. Faz-se necessário então a aplicação da variação de *set-point* por um determinado período de tempo para que ocorra a detecção de erro planta-modelo de maneira adequada.

$$\bar{e}(k) = -\bar{Q}^{-1} u(k) \quad (10)$$

Correlação Cruzada

Através do conceito dado a correlação, é possível utilizar uma medida de similaridade aplicando um atraso em um dos pares de sinais, tal medida é conhecida como correlação cruzada. Para definição, considere dois sinais aleatórios discretos X e Y . Inicialmente encontra-se a covariância cruzada normalizada aplicando diferentes atrasos, caracterizados por k , em um dos sinais como visto na Equação (11).

$$xcov_{x,y}(k) = \frac{1}{N} \sum_{t=1-k}^{N-k} (x(t+k) - \bar{x})(y(t) - \bar{y}), \text{ para } k = 0, 1, \dots, N-1 \quad (11)$$

Utilizando a Equação (11) é possível obter o coeficiente de correlação cruzada entre dois sinais aleatórios discretos:

$$r_{x,y} = \frac{xcov_{x,y}(k)}{\sqrt{var(X)var(Y)}} \quad (12)$$

Correlação Parcial

A aplicação da correlação cruzada já demonstra relações lineares entre duas ou mais variáveis. O problema de utilizar tal abordagem é quando as variáveis independentes apresentam correlações entre si, criando resultados falsos para a existência ou não de relações. Sendo assim, é necessária a remoção da dependência das correlações em análise.

A abordagem através de correlação parcial é utilizada para encontrar correlações entre duas variáveis após a remoção dos efeitos de outra variável. Supondo então que $X_1, X_2, \dots, X_n$ são variáveis afetadas pela variável Z e que também todas as variáveis $\vec{X}$ são correlacionadas entre si, de acordo com Badwe et al. (2009).

$$Z = \vec{X}\theta_z + E_z \quad (13)$$

$$X_1 = \vec{X}\theta_{x_1} + E_{x_1} \quad (14)$$

Admitindo que nas Equações 13 e 14 $\vec{X}$ é uma matriz de regressores composta por $[X_2, X_3, \dots, X_n]$ e que θ_z e θ_{x_1} são os vetores de coeficientes de regressão. Utilizando a pseudo-inversa de $\vec{X}$, desenvolve-se as expressões para extrair a influência das demais variáveis sobre X_1 .

$$e_z = Z - X(\vec{X}\vec{X}^T)^{-1} \vec{X}^T Z \quad (15)$$

$$e_{x_1} = X_1 - \vec{X}(\vec{X}\vec{X}^T)^{-1} \vec{X}^T X_1 \quad (16)$$

Após a efetuação das operações nas Equações (15) e (16), e_z e e_{x_i} apresentarão resultados livres dos efeitos das outras variáveis que compõe $\vec{X}$. O resultado final da correlação parcial se dará através da aplicação de e_z e e_{x_i} na correlação convencional, com a equação da correlação semelhante à Equação (17).

$$r_{e_z, e_{x_i}} = \frac{xcov_{e_z, e_{x_i}}(k)}{\sqrt{var(e_z)var(e_{x_i})}} \quad (17)$$

Para descorrelacionar a saída do controlador (u) dos erros de predição (e), primeiramente é encontrada a componente de $\bar{u}_i$ que é descorrelacionada com as outras variáveis manipuladas. Para isso denota-se $\tilde{u}$ como o vetor contendo todas as variáveis manipuladas menos $\bar{u}_i$ e $\bar{\varepsilon}_{u_i}$ (a componente de $\bar{u}_i$ que é descorrelacionada com as variáveis presentes em $\tilde{u}$). A Equação (18) demonstra matematicamente a relação entre estas variáveis, e a Equação (19) isola a componente de interesse, que é a variável manipulada livre dos efeitos de $\tilde{u}$.

$$\bar{u}_i(k) = G_{u_i} \tilde{u}(k) + \bar{\varepsilon}_{u_i}(k) \quad (18)$$

$$\bar{\varepsilon}_{u_i}(k) = \bar{u}_i(k) - G_{u_i} \tilde{u}(k) \quad (19)$$

Em seguida, e de forma semelhante, os erros de predição $\bar{e}_j$ são descorrelacionados de todas as outras variáveis manipuladas menos $\bar{u}_i$, para encontrar a variável independente $\bar{\varepsilon}_{e_j}$. Após descorrelacionar as variáveis $\bar{\varepsilon}_{u_i}$ e $\bar{\varepsilon}_{e_j}$ é realizada correlação convencional.

$$\bar{e}_j(k) = G_{e_j} \tilde{u}(k) + \bar{\varepsilon}_{e_j}(k) \quad (20)$$

$$\bar{\varepsilon}_{e_j}(k) = \bar{e}_j(k) - G_{e_j} \tilde{u}(k) \quad (21)$$

Resultados e Discussões

Para demonstrar os efeitos da presença de erros entre o processo e o modelo no desempenho do controle, usa-se a coluna de destilação Wood-Berry como um estudo de caso, vista em Nafsun e Yousoff (2011). Tal escolha foi devido à possibilidade de visualização mais clara dos efeitos. Nas aplicações da correlação cruzada e parcial é utilizado o processo da Coluna Fracionadora de Óleo da Shell de Prett e Morari (1987), com o propósito de evidenciar a eficiência da detecção de erro dos métodos, por ser um processo de maior complexidade que a coluna de destilação Wood-Berry. Para maiores detalhes dos processos e seus respectivos sistemas de controle MPC consultar Cruz (2014).

Análises dos Efeitos de Erros Planta-Modelo

Serão analisados quatro tipos de erros presentes na função de transferência G_{11} , que representa a relação entre a saída da Composição do Destilado e a entrada Vazão do Refluxo do processo: erro na magnitude do ganho do sistema, reversão na magnitude do ganho, erro na constante de tempo e no tempo de atraso. No processo é aplicada uma mudança de *set-point* apenas na variável manipulada da Vazão do Refluxo.

a) Variação de Magnitude no Ganho de G_{11}

No gráfico da Figura 2 é possível visualizar o decaimento do desempenho do controlador a medida que a porcentagem de erro aumenta. Em menos de 10% do ganho é visível que o desempenho do controlador já não é mais desejável, pois o mesmo não atinge o set-point estabelecido. Abaixo de 50% já não há possibilidade de manter a composição do destilado e em 70% ocorre redução próximo de 0,4 mol %.




Figura 2. Resposta da composição do destilado com a variação do ganho em G_{11}




Figura 3. Resposta da composição do destilado com a variação de ganho reverso em G_{11}

b) Variação Reversa de Magnitude no Ganho de G_{11}

Ao contrário do gráfico da subseção anterior, o desempenho melhora com o aumento da porcentagem de erro no ganho com relação à composição do destilado. É visto na Figura 3 que esse efeito se deve a aproximação do erro ao ganho ideal do sistema.

c) Variação da Constante de tempo de G_{11}

Através da Figura 4 vê-se claramente que a reposta se torna mais rápida com o aumento inicial do erro, nos casos de 10% e 30%. Após ser aplicado erro sobre a constante de tempo, de valores de 50% e 70%, a reposta do processo torna-se mais lenta. Apesar da ocorrência destes eventos o desempenho do controlador não é afetado de maneira drástica, pois a variável controlada consegue atingir o set-point estimado.

d) Variação do Tempo Morto de G_{11}

Através da Figura 5 é possível observar que quanto menor for o tempo morto mais rápido é a resposta do sistema, que é exatamente o resultado esperado.




Figura 4. Resposta da composição do destilado com a variação da constante de tempo em G_{11}




Figura 5. Resposta da composição do destilado com a variação do tempo morto em G_{11}

Aplicação da Correlação Cruzada

Na aplicação deste método foi realizada a simulação do processo da Coluna Fracionadora de Óleo da Shell para um período igual a 3000 min e um tempo de amostragem de coleta de dados igual a 2min. Ao todo foram coletadas 1500 amostras referentes aos sinais de controle e os erros de predição. A partir das Equações (11) e (12) é possível encontrar a covariância cruzada e os coeficientes de correlação cruzada, respectivamente, entre e e u .

Neste cenário foi realizado a aplicação proposital de erros entre a planta e o modelo. No processo a magnitude da função de transferência G_{11} , que representa a relação entre a saída da ponto de saída do topo e a entrada tração da válvula de saída de topo do processo, foi modificada em 52% do seu valor ideal no intuito de simular as modificações que podem ocorrer naturalmente no processo. A partir da Figura 6 é visto que a detecção de erro é possível, porém o erro em G_{11} se propaga para os canais de entrada e saída $y_1 - u_{1-3}$ e $y_{1-3} - u_1$.




Figura 6. Detecção de erro através correlação cruzada (com erro em G_{11})

Aplicação da Correlação Parcial

Os princípios do emprego da correlação parcial são semelhantes aos da cruzada, mas diferem quanto ao tratamento dos dados. O mesmo cenário da aplicação da correlação cruzada é utilizado e inicialmente são coletados os dados referentes a variáveis manipuladas e os erros de predição por um período suficiente em que ocorra excitação nos *set-points*. Inicialmente é realizado o procedimento de decorrelação das variáveis e e u , utilizando as Equações (19) e (21), em seguida é aplicada a correlação de maneira convencional com a obtenção do resultado mostrado na Figura 7.

Com base na Figura 7 é possível visualizar que as falsas detecções de erro nos canais de entrada e saída $y_1 - u_{1-3}$ diminuíram de forma considerável. Em Cruz (2014) e Cruz e Sotomayor (2015) é possível encontrar outros resultados e discussões das aplicações.




Figura 7. Detecção de erro através correlação parcial (com erro em G_{11})

Conclusões

Os estudos da influência dos tipos de erro planta-modelo no desempenho dos controladores MPC possibilitaram um direcionamento para o desenvolvimento dos métodos de detecção considerando o pior caso, i.e. variações do ganho da função de transferência. A utilização dos métodos de detecção de erro planta-modelo em sistemas de controle MPC proporciona indicadores do desempenho ruim do controlador, localizando os canais de entradas e saídas afetadas pela presença de erro no modelo. Com essas informações é possível diminuir de maneira significativa o tempo necessário para um procedimento de reidentificação do modelo.

Os resultados obtidos com a aplicação das metodologias apresentadas mostram que a correlação parcial é mais eficiente do que a correlação cruzada na detecção de erros planta-modelo. Devido à independência gerada pela aplicação da correlação parcial, os resultados referentes aos erros de predição dos canais apresentaram-se de forma independente. No entanto, os canais referentes às variáveis manipuladas continuaram apresentando dependência na correlação. Portanto a detecção informa em que canal de saída o erro de modelagem está acontecendo.

Trabalhos futuros poderão ser focalizados na melhoria dos resultados, no intuito de obter a localização exata do erro nos canais de entrada e saída.

Agradecimentos

Os autores agradecem o auxílio financeiro do programa de recursos humanos PRH/ANP-45.

Referências Bibliográficas

BADWE, A.S; GUDI, R.D; PATWARDHAN, R.S; SHAH, S.L. AND PATWARDHAN, S.C. Detection of model-plant mismatch in MPC applications, **Journal of Process Control**, v. 19, n. 8, pp. 1305-1313, 2009.

CARLSSON, R. **A practical approach to detection of plant model mismatch for MPC**. MSc thesis, Department of Electrical Engineering, Linköpings Universitet, Linköping – Sweden, 2010.

CRUZ, D. D.G.B. **Detecção de erros em planta-modelo em sistemas de controle MPC**. Trabalho de Conclusão de Curso em Engenharia Elétrica, Universidade Federal de Sergipe, 2014.

CRUZ, D.D.G.B.; SOTOMAYOR, O.A.Z. Detecção de erros em planta-modelo em sistemas de controle preditivo. **Anais do Congresso Rio Automação 2015**, 2015.

NAFSUN, A. I; YOUSOFF, N. Effect of Model-plant Mismatch on MPC Controller Performance, **Journal of Applied Sciences**, v. 11, n. 21, pp. 3579-3585, 2011.

PRETT, D. M; MORARI, M. The Shell Process Control Workshop. **Process Control Research: Industrial and Academic Perspectives**. Butterworths, Boston, 1987.

STANFELJ, N; MARLIN, THOMAS E; MACGREGOR, J. F. Monitoring and diagnosing process control performance: the single-loop case. **Industrial & Engineering Chemistry Research**, v. 32, n. 2, pp. 301-314, 1993.

WEBBER, J. R; GUPTA, Y. P. A closed-loop cross-correlation method for detecting model mismatch in MIMO model-based controllers. **ISA transactions**, v. 47, n. 4, pp. 395-400, 2008.