

ESTUDO COMPARATIVO DE METODOLOGIAS PARA AVALIAÇÃO DE MODELOS DE CONTROLADORES PREDITIVOS APLICADAS A UMA UNIDADE DE COQUEAMENTO RETARDADO

Viviane Botelho¹
Jorge Otávio Trierweiler¹
Marcelo Farenzena¹
Luis Gustavo Soares Longhi²
Antônio Carlos Zanin³
Herbert Teixeira⁴
Ricardo Duraiski⁵

Resumo: A baixa qualidade dos modelos é uma das causas mais frequentes da degradação de desempenho de controladores preditivos, por isso a avaliação desses em tempo real é fundamental. Este trabalho apresenta aplicação da metodologia proposta por Botelho *et al.* (2015 a e b) para avaliação de modelos de controladores preditivos na Unidade de Coqueamento Retardado da REFAP bem como a comparação com o método de Sun *et al.* (2013). Descrições das técnicas utilizadas e do processo são apresentadas. Os resultados corroboram a capacidade da metodologia em detectar adequadamente os problemas de modelagem que impactam no comportamento do processo auxiliando na identificação das suas causas.

Palavras-chave: Controle Preditivo Baseado em Modelo, Qualidade de Modelo, Discrepância entre Modelo e Planta, Unidade de Coqueamento Retardado.

Abstract: The poor model quality is one of the most frequent causes of performance deterioration of Model Predictive Controllers. Thus, model evaluation is a fundamental issue. This paper shows the application of the methodology proposed by Botelho *et al.* (2015 a and b) for assessment of the model-plant mismatch applied to a Model Predictive Controllers of the Delayed Coke Unit at REFAP and a comparison with Sun *et al.* (2013) method. Descriptions of the techniques and the process are presented. The results illustrate that the method can correctly quantify the model-plant mismatch problems and identify their sources.

Keywords: Model Predictive Control, Model Quality, Model-Plant Mismatch, Delayed Coker Unit.

¹Grupo de Intensificação, Modelagem, Simulação, Controle e Otimização de processos. Departamento de Engenharia Química. Universidade Federal do Rio Grande do Sul (UFRGS). **E-mail:** {vivirb, jorge, farenz}@enq.ufrgs.br

²PETROBRAS – UO REFAP – Refinaria Alberto Pasqualini - Gerência de Otimização. **E-mail:** longhi@petrobras.com.br

³CETAI – Centro de Excelência em Automação Industrial – Petrobras. **E-mail:** zanin@petrobras.com.br

⁴PETROBRAS – CENPES. **E-mail:** herbertteixeira@petrobras.com.br

⁵Trisolutions Soluções em Engenharia LTDA . **E-mail:** duraiski@trisolutions.com.br.

1 INTRODUÇÃO

De uma forma geral, a operação de plantas industriais envolve a utilização de estratégias capazes de controlar as variáveis de processo. As únicas estruturas disponíveis até poucas décadas eram baseadas em estratégias clássicas de controle, como PID. Contudo, os avanços tecnológicos, ao mesmo tempo em que promoveram a elevação da complexidade destes processos, permitiram que novas técnicas fossem desenvolvidas, surgindo o controle avançado de processos. Dentre as técnicas de controle avançado existentes, os controladores preditivos baseados em modelos (MPCs) são cada vez mais utilizados e aceitos em termos industriais (Holkar e Waghmare, 2010)

A avaliação e manutenção dos MPCs sob um ponto de vista técnico é fundamental para mantê-los em operação de forma adequada, conforme ilustra a Figura 1. Entretanto, esta tarefa ainda é um desafio, dada a natureza multicausal destes controladores. A grande quantidade de parâmetros de sintonia, forte dependência com o modelo do processo e a diversidade dos algoritmos de controle comerciais existentes são as principais dificuldades. Existe uma série

de trabalhos disponíveis na literatura (Huang *et al.*, 2003; Conner *et al.*, 2005; Badwe *et al.*, 2009; Jiang *et al.*, 2009; Kano *et al.*, 2010; Whang *et al.*, 2012; Ji *et al.*, 2012; Jiang *et al.*, 2012; dentre outros) propondo técnicas para monitoramento e diagnóstico, porém, a maioria delas é embasada em estruturas de controle preditivo convencionais (i. e., que possuem setpoints fixos). Em muitos casos, na indústria, é comum a inexistência de graus de liberdade suficientes para manter todas as variáveis controladas em um único valor predefinido (setpoint). Por isso o MPC é configurado por faixas e tem o objetivo de manter as variáveis controladas (CVs) dentro destes limites. Além disso, alguns controladores possuem uma camada de otimização em tempo real que estima o valor ótimo das variáveis manipuladas (*Targets*) sob o ponto de vista econômico, e estes *Targets* são variáveis da função objetivo do MPC. Dessa forma, o controlador não possui explicitamente setpoint para as variáveis controladas e, por isso, as técnicas que utilizam o setpoint acabam sendo inadequadas para o seu diagnóstico.

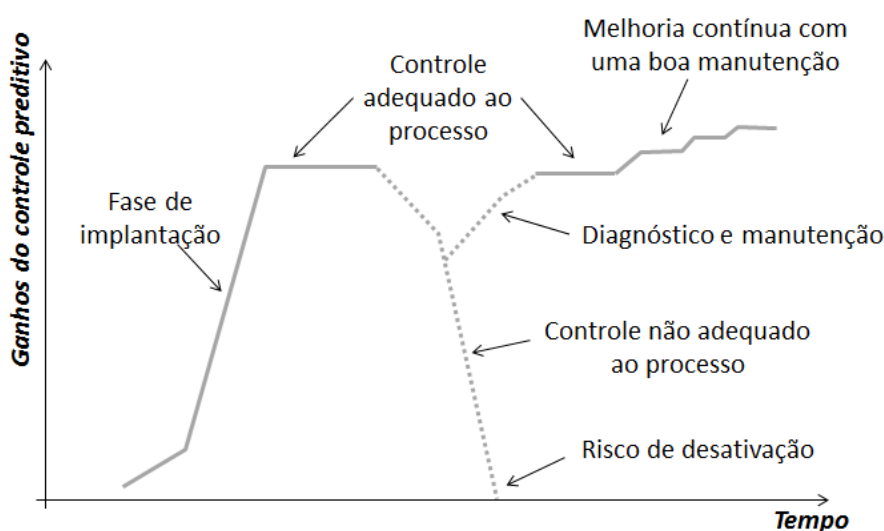


Figura 1: Ciclo de vida de um sistema de controle avançado.

Fonte: Campos *et al.*, 2013.

Dentre as fontes de degradação, a discrepância entre o modelo do controlador e a planta (*model-plant mismatch*) é a mais importante, visto que modelos ruins podem ocasionar ações de controles muito aquém daquelas que levam o processo a sua condição ótima, ou mesmo tornar o controlador instável. Sun *et al.* (2013) estima que mais de 80% do tempo de projeto de um controlador preditivo seja gasto na identificação deste modelo, dada a sua importância. Levando em conta que o modelo é obtido em uma determinada condição de operação, qualquer alteração no processo pode ser suficiente para degradar a sua representatividade. Isso deixa evidente a necessidade de seu constante monitoramento.

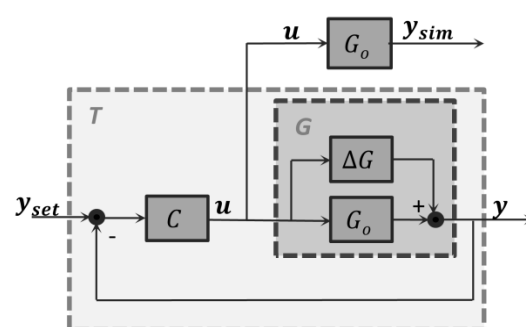
Este trabalho apresenta os resultados obtidos com a aplicação da metodologia desenvolvida por Botelho *et al.* (2015 a e b) a dados de processo provenientes do MPC da Unidade de Coqueamento Retardado da REFAP. O principal objetivo da metodologia é identificar problemas de modelagem que efetivamente impactem no desempenho do controlador e identificar se o mesmo é decorrente de uma discrepância de modelo ou de um distúrbio não medido. Os resultados são comparados com o método de Sun *et al.* (2013), a qual visa a detecção de problemas de modelagem.

2 METODOLOGIAS

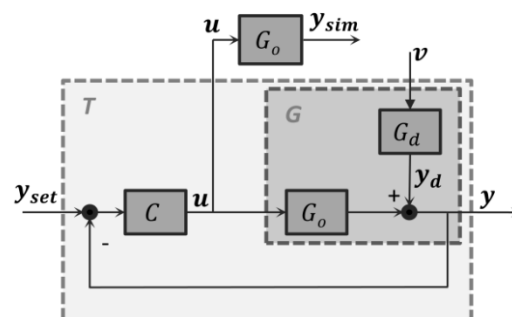
2.1 Botelho *et al.* (2015 a e b)

Os MPCs nem sempre requerem modelos de elevada acurácia, visto que a ação *feedback* é capaz de contornar parte dos erros de modelagem. Por isso a investigação dos resíduos de simulação não é um indicador adequado para avaliar modelos de controladores preditivos. Uma metodologia de monitoramento da qualidade do modelo deve ser capaz realizar tal avaliação levando em conta a faixa de frequências em que o controlador mais atua. Com base nesta premissa, Botelho *et al.* (2015 a) apresenta uma metodologia que considera a sintonia do controlador para avaliar os modelos. Tal

metodologia tem como base os sistemas em malha fechada representados pela Figura 2, onde C representa o controlador, G_0 é o modelo identificado do processo (modelo nominal), ΔG é a discrepância entre modelo identificado e planta real, G_d é o modelo de distúrbios desconhecidos, y_{set} são os setpoints, u são as variáveis manipuladas, y são as saídas medidas, y_{sim} são as saídas simuladas com o modelo nominal (G_0) para as ações de controle (u), v são sequências de variáveis aleatórias independentes e y_d são os distúrbios determinísticos desconhecidos.



(a) com discrepância de modelo



(b) com distúrbio não medido

Figura 2: Esquema representativo de um sistema em malha fechada.

A saída nominal do sistema (y_0) corresponde ao resultado que seria obtido caso não houvesse nenhum problema de modelagem. Esta grandeza pode ser estimada a partir dos dados de planta e da resposta em malha fechada do sistema (1), denominada Função de Sensibilidade Nominal (S_0), conforme (2).

$$S_0(s) = (I + G_0(s)C(s))^{-1} \quad (1)$$

$$y_0(s) = y(s) - S_0[y(s) - y_{sim}(s)] \quad (2)$$

Uma vez que y_0 é uma estimativa da saída do processo livre de problemas de modelagem, ela pode ser considerada como uma referência para o modelo do processo. Dessa forma, qualquer métrica comparativa entre $y_0(s)$ e $y(s)$ pode ser utilizada para a avaliação do modelo. Neste trabalho o diagnóstico foi realizado a partir da razão entre as variâncias de y_0 e da variável controlada medida (y) ao longo de um horizonte móvel de dimensões iguais ao horizonte de predição do controlador (p), conforme (3).

$$Rvar_i = \frac{var[y_{(i-p..i)} - \bar{y}_{(i-p..i)}]}{var[y_{0(i-p..i)} - \bar{y}_{0(i-p..i)}]} \quad (3)$$

Espera-se que y e y_0 sejam semelhantes na ausência de problemas de modelagem significativos, sendo assim $Rvar \cong 1$ deve ser obtido nesses casos.

Após a detecção das variáveis controladas com problemas de modelagem, a fonte de degradação deve ser identificada. A metodologia proposta por Botelho *et al.* (2015 b) tem o objetivo de discernir entre discrepância de modelo ou presença de distúrbios não medidos. O método é baseado na avaliação comparativa entre o erro nominal e_0 (4) e y_0 (2). Espera-se que na presença de um distúrbio não medido e_0 e y_0 não possuam nenhuma similaridade já que os distúrbios são independentes. Na presença de discrepância de modelo, e_0 e y_0 devem possuir correlação, já que ambos são dependentes das ações de controle.

$$e_0(s) = y_0(s) - y(s) \quad (4)$$

O procedimento de avaliação inicia com a determinação dos indicadores de assimetria (skn) e curtose (kts) ao longo de uma janela móvel MW de acordo com (5), (6) e (7) para e_0 e y_0 , onde Y representa o conjunto de dados avaliado

(e_0 ou y_0). Estes indicadores fornecem um panorama da distribuição estatística dos dados, conforme ilustra a Figura 3.

$$m_l = \frac{\sum_{i=1}^{MW} (Y_i - \bar{Y})^l}{MW} \quad (5)$$

$$kts = \frac{m_4}{(\sqrt{m_2})^4} \quad (6)$$

$$skn = \frac{m_3}{(\sqrt{m_3})^3} \quad (7)$$

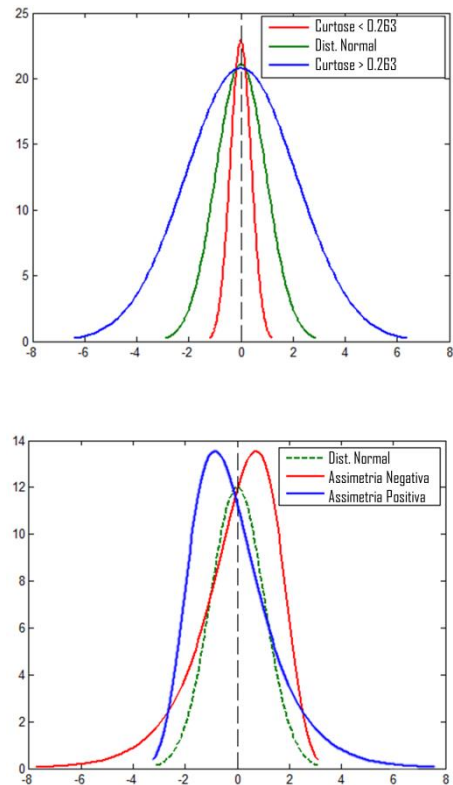


Figura 3: Comportamento Explicado pelos Indicadores de Assimetria e Curtose.

As distribuições estatísticas de e_0 e y_0 são então comparadas através da quantificação da dispersão dos coeficientes de assimetria e curtose dessas duas grandezas. A dispersão é avaliada a partir de uma regressão linear, conforme (8) e (9), onde φ representa a distribuição estatística (assimetria ou curtose), $\varphi_{y_0, i, regress}$ a estimativa do modelo de regressão correspondente e R^2 é o coeficiente de determinação. Quando $\arccos(\alpha) = 45^\circ$ e $R^2 = 1$ maior é a similaridade entre a distribuição de e_0 e

y_0 , sendo este um indicativo de discrepância de modelo.

$$\varphi_{y_0} = \alpha \varphi_{e_0} + \beta \quad (8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^{MH} (\varphi_{y_{0i}} - \varphi_{y_{0i,regress}})^2}{\sum_{i=1}^{MH} (\varphi_{y_{0i}} - \overline{\varphi_{y_0}})^2} \quad (9)$$

Outro indicador é baseado na elipse de confiança da dispersão dos dados (Figura 4). Essa elipse é construída considerando a matriz de covariância de φ_{y_0} e φ_{e_0} . O ângulo do maior autovetor corresponde à inclinação da elipse (θ). Já as dimensões da elipse (a e b) são dadas pela raiz quadrada do maior e do menor autovalor multiplicado pelo chi-quadrado crítico para o nível de confiança considerado.




Figura 4: Representação da elipse de confiança.

2.2 Sun et al. (2013)

Esta metodologia é baseada no princípio de que as inovações provenientes dos distúrbios são independentes da ação *feedback* do controlador. Sendo assim, o erro causado pelos distúrbios estocásticos (E^0) pode ser estimado e comparado ao erro de predição do modelo (E^p), de modo que a parcela remanescente é atribuída aos erros de modelagem.

A estimação de E^0 é realizada a partir de um modelo ARX de elevada ordem (elevados valores de $M1$ e $M2$) considerando os setpoints e as saídas medidas, conforme (10), onde A e B são os parâmetros do modelo ARX.

$$y(k) = \sum_{i=1}^{M1} A_i y(k-i) + \sum_{i=1}^{M2} B_i y_{set}(k-i) + E^0(k) \quad (10)$$

O erro de predição (E^p), é calculado segundo a predição um passo a frente de Ljung (1999), conforme (11) e (12), onde $\hat{y}(k)$ são as saída preditas e H é o modelo de distúrbio conhecido.

$$\hat{y}(k) = H^{-1}(q)G(q)u(k-1) + [1 - H^{-1}(q)]y(k-1) \quad (11)$$

$$E^p(k) = \hat{y}(k) - y(k) \quad (12)$$

O autor sugere o indicador de desempenho definido em (13), onde Q é o peso das variáveis de saída no MPC e ns é o número de amostras. Este indicador varia entre 0 e 1, de modo que $MQI = 1$ significa que todo o erro do sistema provém de distúrbios estocásticos e o modelo é perfeito.

$$MQI = \frac{\sum_{k=1}^{ns} E^0(k)^T Q E^0(k)}{\sum_{k=1}^{ns} E^p(k)^T Q E^p(k)} \quad (13)$$

3 DESCRIÇÃO DO PROCESSO E DO SISTEMA DE CONTROLE

A unidade de Coqueamento Retardado (UCR) em estudo tem o objetivo de converter frações de petróleo pesadas em frações leves e de maior valor, através de um mecanismo de craqueamento térmico. Simultaneamente às reações de craqueamento, ocorrem reações de coqueamento que produzem um subproduto sólido de elevado peso molecular e teor de carbono, denominado coque, o qual possui baixo valor comercial (Mattos e Longhi, 2013). A Figura 5 apresenta um esquema simplificado do processo.

A carga da unidade (V-01) é composta pela fração de petróleo mais pesada proveniente da unidade de destilação vácuo (TQ-01), além de uma corrente de reciclo. Esta é inicialmente encaminhada aos fornos de pré-aquecimento (F-01), onde a sua temperatura é elevada a cerca de 500 °C. Para evitar a formação de coque nesta

etapa, há a injeção combinada de vapor d'água, a qual viabiliza o escoamento em maior velocidade, retardando a reação de coqueamento. A fração de petróleo aquecida e a água alimentam os tambores de coque (R-01 e R-02). Uma torre fracionadora (T-01) separa os produtos do craqueamento oriundos do reator. Os reatores operam em processo de batelada com ciclos de aproximadamente 24 horas, o que é necessário para viabilizar a remoção do coque que vai se acumulando no interior dos tambores. Sendo assim, a cada ciclo, os tambores são alternados (i.e., a carga é desviada do tambor que estava em operação para o outro tambor) e é feita a operação de remoção de coque e preparação do reator (Mattos e Longhi, 2013, Longhi *et al.*, 2008).

A estrutura de controle avaliada corresponde a um MPC instalado na torre fracionadora. A principal diferença deste sistema em relação à abordagem clássica de um MPC é que conta com uma camada de otimização em tempo real simplificada, a qual visa determinar a melhor condição operacional em termos econômicos, considerando os ganhos estacionários de um modelo dinâmico linear identificado para o processo. A

Figura 6 ilustra a arquitetura simplificada deste tipo de controlador. A etapa de predição em malha aberta consiste na determinação das saídas futuras caso nenhuma ação de controle seja tomada. A camada de otimização é uma estimativa do melhor valor possível das variáveis, de acordo com critérios econômicos e restrições do processo. Por fim, a etapa de cálculo das ações de controle fornece o planejamento das ações que levam ao valor ótimo indicado pelo otimizador.

Outra característica importante desse controlador, a qual é comum em aplicações industriais, é a operação por faixas das variáveis controladas. Nesse tipo de abordagem não há penalização das variáveis controladas (na camada de otimização e controle) desde que as predições das mesmas permaneçam dentro de um limite previamente estabelecido, denominado *soft constraint*. A vantagem desta abordagem é que ela permite a flexibilização do sistema (isto é, mudança otimizada da estrutura de controle) quando não há graus de liberdade suficientes para manter todas variáveis controladas em uma referência fixa.

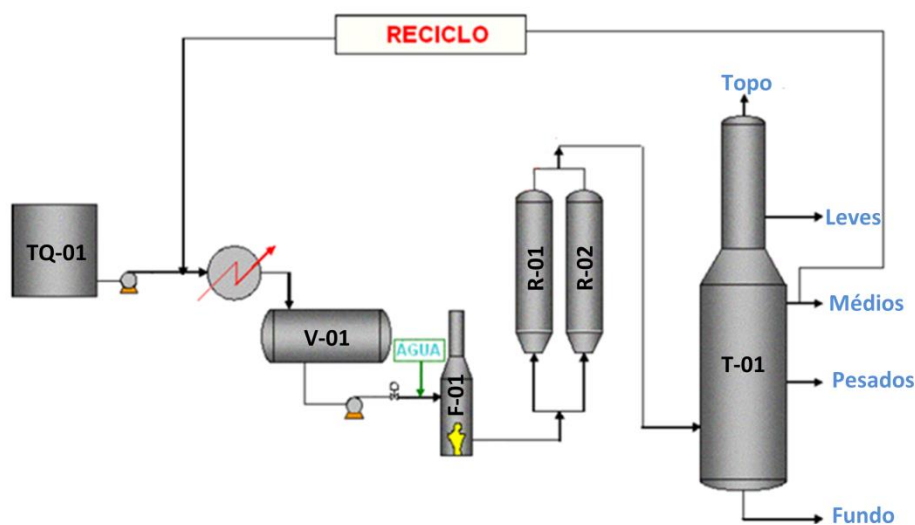


Figura 5: Representação simplificada da UCR (Adaptado de Mattos e Longhi, 2013).

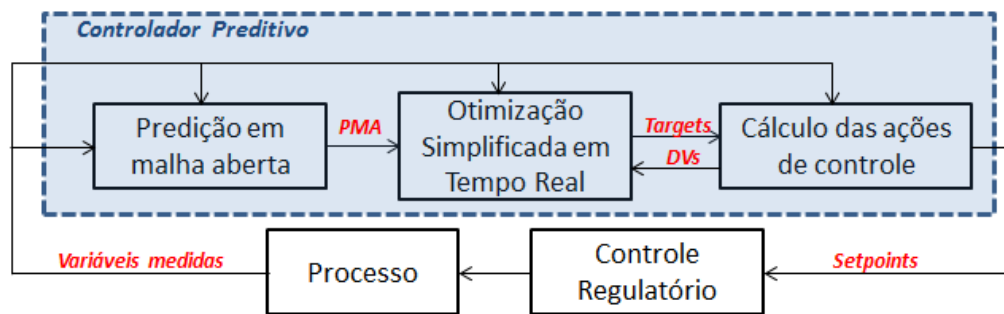


Figura 6: Arquitetura de um controlador preditivo com camada de otimização (Fonte: Campos *et al.*, 2013)

O sistema de controle da fracionadora da UCR é composto por 12 variáveis controladas por faixa (*Controlled Variables by Range – CVRs*) e 7 variáveis manipuladas (MVs). Além disso, existem duas perturbações medidas discretas (DVs), as quais são decorrentes da operação de troca e preparação dos tambores de coque a cada ciclo de execução. Salienta-se que será utilizada a terminologia CVs para representar as variáveis controladas por faixas, já que todas possuem essa característica no sistema estudado.

4 RESULTADOS E DISCUSSÃO

Foi utilizado um conjunto de dados rotineiros de processo, correspondendo a aproximadamente 3 dias de operação da planta, conforme ilustrado nas Figuras 7 e 8. Constatou-se que as variáveis controladas, em sua maioria, operam com suas restrições inativas, isto é permanecendo no interior da faixa na maior parte do tempo. Em alguns instantes há violação das restrições, as quais estão associadas à ocorrência dos distúrbios DV1 e DV2. Já na Figura 8 verifica-se que as variáveis manipuladas MV1, MV3 e MV7 permanecem saturadas, com exceção dos períodos onde ocorrem distúrbios.

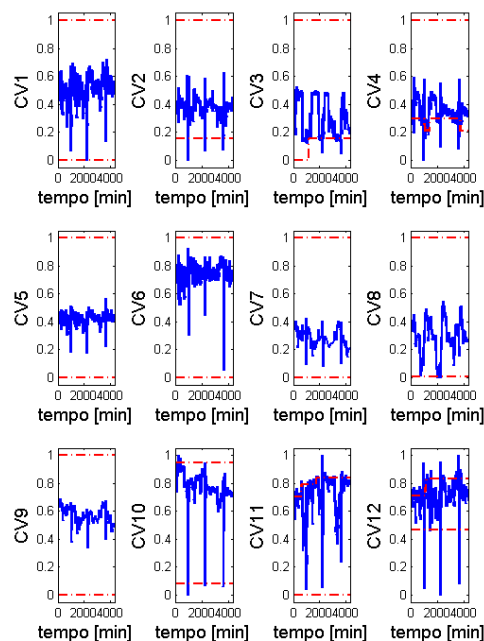


Figura 7: Variáveis controladas e respectivos limites operacionais

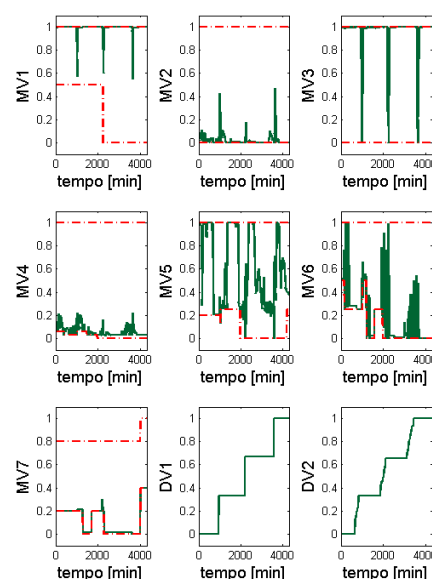


Figura 8: Variáveis manipuladas e distúrbios medidos

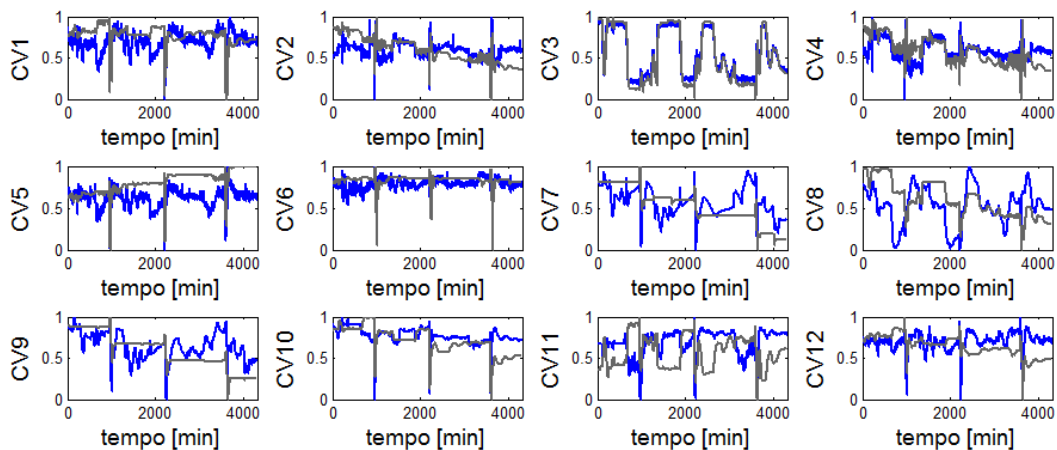


Figura 9: Simulação da UCR: Dados medidos (linha azul) versus dados simulados (linha cinza).

O modelo linear do processo foi simulado com as entradas e os resultados são apresentados na Figura 9. Constatou-se que, com exceção da CV3, todas as variáveis apresentam discrepâncias significativas na modelagem. Para a CV2, CV4, CV6 e CV10 as limitações do modelo não são tão intensas quanto as demais, nas quais os problemas de modelagem são bastante evidentes e mostram que há uma série de comportamentos que não estão sendo capturados pelos modelos (a exemplo da CV9). Entretanto, conforme já mencionado, a simulação do sistema não é um bom indicador de qualidade de modelo para sistemas em malha fechada. Dessa forma, os problemas de modelagem podem estar sendo superestimados ou amplificados devido aos distúrbios não medidos.

4.1 Método de Botelho et al. (2015 a e b)

A metodologia apresentada na Seção 2.1 foi aplicada nos dados selecionados para algumas das CVs de maior relevância para o MPC. Inicialmente, foi necessária a identificação da função complementar da sensibilidade ($T_0 = I - S_0$), a qual foi realizada a partir de uma simulação se utilizando o mesmo

controlador comercial preditivo utilizado para controlar a planta real. Como as variáveis desse conjunto de dados permanecem dentro das faixas na maior parte do tempo, o seguinte procedimento foi adotado:

- 1: Selecionar uma CV para ser avaliada e colocar as demais no modo manual.
- 2: Garantir que não haja a saturação de nenhuma MV.
- 3: Levar a CV avaliada para seu o ótimo.
- 4: Relaxar o limite ótimo (i.e, forçar a CV a atingir o novo limite).
- 5: identificar o modelo de (T_0) entre os valores da CV e limite ótimo perturbado.

Ressalta-se que a identificação dos modelos de forma individual assim como a utilização de um modelo diagonal é coerente com os dados analisados, já que corresponde ao caso onde não há violação das restrições, comportamento observado na maioria do tempo para as CVs. A partir de S_0 , foi computada a estimativa de y_0 . Os resultados são ilustrados na Figura 10. Para melhorar a visualização, a Figura 11 apresenta estes resultados para duas CVs em um período de 12 horas.






Figura 10: Comparação entre as variáveis medidas (azul) e y_0 estimado (vermelho).



(a)



(b)

Figura 11: Comparação entre as variáveis medidas (azul) e y_0 estimado (vermelho): Observação para um período de 12 horas para: (a) $CV1$ e (b) $CV11$.

Comparando as Figuras 9 e 10 é possível verificar que, quando levada em conta a sintonia do controlador, a qualidade dos modelos é superior à indicada pela simulação. Ainda assim, existem problemas de modelagem que afetam o desempenho do MPC. Este impacto pode ser visualizado na Figura 11, que ilustra um intervalo menor de tempo das $CV1$ e $CV11$. Constata-se que os erros de modelagem não possuem muita influência na $CV1$, porém na $CV11$

os mesmos se mostram significativos, já que o comportamento estimado da variável livre de discrepância de modelagem e de distúrbios, i.e., y_0 , se difere do comportamento real obtido.

A razão das variâncias R_{var} (3) para cada CV é apresentada na Figura 12. Observa-se que a $CV1$, $CV2$, $CV7$ e $CV12$ possuem modelos capazes de representar satisfatoriamente o processo na frequência de atuação do controlador, já que a variabilidade dos dados é similar ao resultado obtido na ausência de discrepância de modelo ($R_{var} \cong 1$). As $CV3$ e $CV5$ possuem razões de variabilidade relativamente elevadas, devendo ser investigadas, ainda que o modelo simulado da $CV3$ possua boa qualidade na simulação. A $CV10$ e $CV11$ são as que apresentam os problemas de modelagem mais significativos.

Após a identificação das saídas com problemas de discrepância é necessário detectar a sua fonte. Nesta etapa, se investiga se o problema é decorrente de uma discrepância de modelo ou de um distúrbio não medido conforme o procedimento apresentado na seção 2.1. Para tanto, avaliam-se as CVs que apresentaram R_{var} mais elevadas, no caso em estudo: $CV3$, $CV5$, $CV10$ e $CV11$. A aplicação da técnica considerou a distribuição dos dados ao longo de um horizonte móvel (MW) de tamanho igual ao horizonte de predição. Os resultados para os coeficientes de assimetria e curtose são apresentados nas Figuras 13 e 14, respectivamente e sumarizados na Tabela 1.




Figura 12: *Rvar* das variáveis controladas avaliadas.

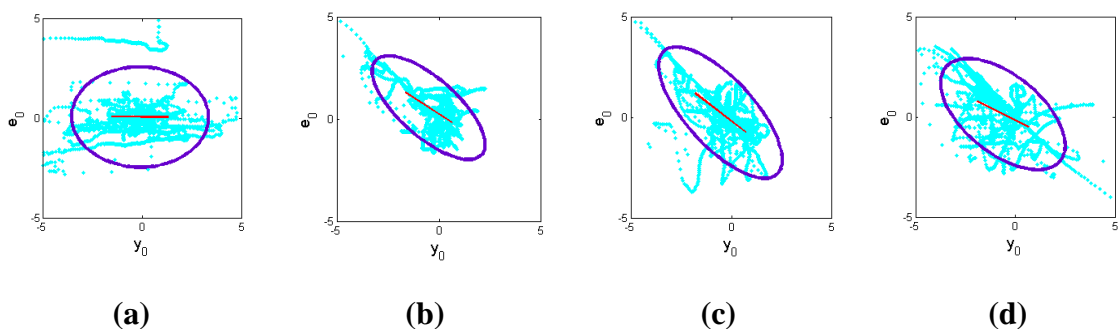


Figura 13: Assimetria de e_0 versus y_0 ao longo de um horizonte móvel (azul), ellipse de confiança (lilás) e aproximação linear (vermelho) da (a) CV3, (b) CV5, (c) CV10 e (d) CV11.

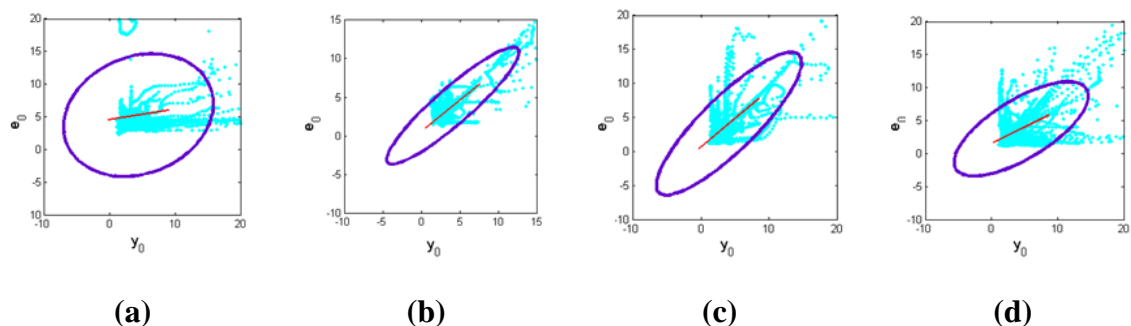


Figura 14: Curtose de e_0 versus y_0 ao longo de um horizonte móvel (azul), ellipse de confiança (lilás) e aproximação linear (vermelho) da (a) CV3, (b) CV5, (c) CV10 e (d) CV11.

Tabela 1: Parâmetros da aproximação linear e ellipse de confiança

	Inclinação da Elipse		Razão entre diâmetros da Elipse		Inclinação da Reta		Coef. de determinação da reta (%)	
	Assimetria	Curtose	Assimetria	Curtose	Assimetria	Curtose	Assimetria	Curtose
CV3	0,2741	21,60	1,37	1,32	0,3391	8,796	0,0066	3,56
CV5	48,48	41,12	2,43	4,82	32,99	39,87	50,09	83,94
CV10	42,48	44,48	2,44	3,61	37,27	40,17	51,08	73,48
CV11	50,74	31,54	1,91	2,59	26,52	26,28	31,24	48,9

As Figuras 13 e 14 e a Tabela 1 deixam evidente que a *CV3* não possui discrepância de modelo (MPM), de modo que a diferença encontrada na razão de variabilidade (Figura 12) se deve a um distúrbio não medido ou de ruídos de medição. Tal constatação é coerente com os resultados obtidos para a simulação deste sistema, que mostram que o modelo é capaz de simular com qualidade elevada os dados. A variabilidade elevada das demais *CVs* é decorrente de uma discrepância de modelo, conforme indicado pela dispersão da retas, razão entre os diâmetros das elipses e ângulos. A simulação individual de cada modelo (Figura 15), quando comparada a simulação completa (Figura 9) deixa evidente que as *CVs* indicadas possuem problemas de modelagem. Por exemplo, para a *CV11*, pode-se visualizar que o comportamento discrepante entre a simulação e os dados medidos é muito similar a contribuição da *MV5* (curva verde), logo, pode-se concluir que o modelo da *CV11* superestima o efeito da *MV5*. De forma análoga, o modelo da *CV5* subestima os efeitos da *MV1* e da *CV10* superestima o efeito da *MV5*.

Foi realizada uma nova identificação com base nos dados de planta para o modelo *MV5* versus *CV11*. O resultado indicou que o ganho do modelo deveria ser multiplicado por um fator igual a -0.5.

A partir deste novo modelo, as avaliações segundo a metodologia proposta foram refeitas. A Figura 16 ilustra a saída nominal estimada bem como seu efeito na variabilidade do sistema. Os indicadores de assimetria e curtose são ilustrados na Figura 17 e sumarizados na Tabela 2.






Figura 15: Simulação individual dos pares *CVs* versus *MVs*.




(a)




(b)

Figura 16: Resultado para a *CV11* com correção do modelo da *MV5* (a) variáveis medidas (azul) e y_0 estimado (vermelho), (b) $Rvar$.



(a)



(b)

Figura 17: (a) Assimetria e (b) Curtose de e_0 versus y_0 ao longo de um horizonte móvel (azul), ellipse de confiança (lilás) e aproximação linear (vermelho) após correção do modelo $MV5$ versus $CV11$.

Tabela 2: Comparação entre os parâmetros da aproximação linear e elipse de confiança antes e após a correção do modelo $MV5$ versus $CV11$.

		Assimetria	Curtose
Inclinação da Elipse	Antes	50,74	31,54
	Depois	24,0	22,3
Razão entre diâmetros da Elipse	Antes	1,91	2,59
	Depois	1,21	1,77
Inclinação da Reta	Antes	26,52	26,28
	Depois	9,13	14,9
Coef. de determinação da reta (%)	Antes	31,24	48,9
	Depois	3,64	15,3

A Figura 16a, quando comparada a Figura 11b assim como a Figura 16b quando comparada a Figura 12 deixam evidente que houve melhora na qualidade do modelo quando realizada a correção sugerida, uma vez que a discrepância entre y_0 estimado e os dados reais foi significativamente menor e, conseqüentemente, a razão entre as variabilidades também foi reduzida. Também é possível verificar a melhora na qualidade do modelo através da Figura 17 e da Tabela 2. Constata-se que houve redução da inclinação das aproximações lineares e elipse de confiança, bem como da razão entre os diâmetros da elipse e dispersão das curvas, denotando que o erro existente no sistema, possui menor dependência da qualidade do modelo.

4.2 Método de Sun et al. (2013)

A metodologia apresentada na seção 2.2 foi aplicada nos dados selecionados. Neste caso, como as CVs trabalham por faixa e não possuem setpoints fixos, foi utilizado o valor ótimo de cada CV fornecido pela camada de otimização em tempo real para a estimação dos modelos ARX (11). Similarmente, a determinação de MQI (13) foi realizada individualmente para cada CV, já que neste controlador elas possuem peso nulo ($Q = 0$). A Figura 18 apresenta o resultado obtido.

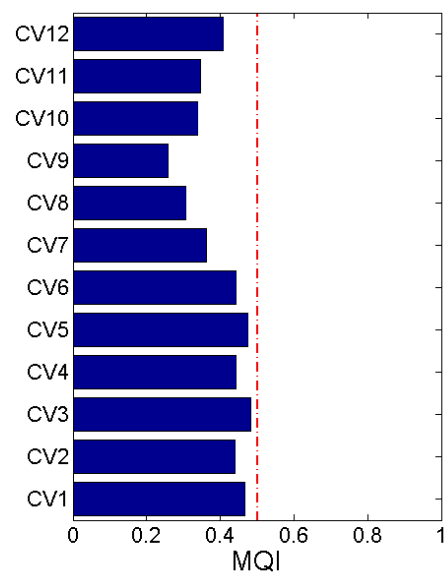


Figura 18: Resultado da Aplicação do Método de Sun et al. (2013).

De acordo com Figura 18, este método indicou que todos os modelos são de baixa qualidade e deveriam ser re-identificados, já que nenhum deles é capaz de prever o comportamento do sistema com acurácia superior a 50% ($MQI < 0,5$). Os modelos para a CV7 até CV11 tendem a ser ainda piores, já que a predição possui acurácia inferior a 35%. Aparentemente o método tende a subestimar a qualidade dos modelos quando há operação por faixas. Na Figura 19, é exemplificado o comportamento de uma variável controlada frente à saída ótima estimada pelo otimizador. Observa-se que o valor do otimizador (que neste método foi usado em lugar do setpoint), possui influência do ruído. Sendo assim, E^0 tenderá a ser estimado com um valor inferior ao real e conseqüentemente a relação entre E^0 e E^p indicará um resultado desfavorável à qualidade do modelo.




Figura 19: Comparação entre a saída do otimizador (linha verde) e valor medido (linha azul) para a CV1.

5 CONCLUSÕES

Este trabalho apresentou a aplicação da metodologia proposta por Botelho *et al.* (2015 a e b) para o monitoramento e diagnóstico dos modelos da Unidade de Coqueamento Retardado da REFAP e comparação destes resultados com o método de Sun *et al.* (2013).

Os resultados deixam evidente que o método de Sun *et al.* (2013), não apresentou um bom indicativo do modelo

quando utilizado em um controlador com *soft constraint* e camada de otimização. Este resultado é decorrente da sua dependência de ter um setpoint para as CVS, fazendo com que a técnica tenda a subestimar a qualidade dos modelos.

A metodologia de Botelho *et al.* (2015 a e b) foi capaz de indicar os modelos que efetivamente impactaram no sistema de controle, considerando a sua sintonia, utilizando apenas dados de operação rotineira e o modelo linear utilizado pelo controlador. Também foi possível diagnosticar de forma coerente a causa dos problemas de mau funcionamento, diferenciando entre a ocorrência de discrepância de modelo e distúrbios não medidos. Cabe salientar ainda que a metodologia utilizada possui a vantagem de ser capaz de trabalhar com as variáveis controladas em faixa, sendo flexível à maioria das aplicações comerciais de controladores preditivos.

Adicionalmente, após uma re-identificação, a técnica permitiu verificar os efeitos benéficos que o novo modelo traria ao processo. Essa abordagem complementar abre mais um campo de utilização da metodologia, que inclui além da auditoria e diagnóstico, a solução do problema.

6 AGRADECIMENTO

Os autores agradecem à FAPERGS e a ANP/Petrobras pelo apoio financeiro concedido para execução deste trabalho.

REFERÊNCIAS

BADWE, A., GUDI, R., PATWARHAN, R., SHAH, S., PATWARHAN, S. 2009. Detection of model-plant mismatch in MPC applications. *Journal of Process Control*, 19, 1305–1313.

BOTELHO, V., TRIERWEILER, J. O., FARENZENA, M., DURAIKI, R. 2015a. Model quality evaluation for MPC using the nominal output sensitivity

function. *Journal of Process Control*. Submetido para publicação.

BOTELHO, V., TRIERWEILER, J. O., FARENZENA, M., DURAIKI, R. 2015b. Diagnosis of bad performance in MPC: Unmeasured Disturbance versus Model-Plant-Mismatch. *Journal of Process Control*. Submetido para publicação.

CAMPOS, M., GOMES, M., PEREZ, J. 2013. *Controle Avançado e Otimização na Indústria do Petróleo*. Rio de Janeiro, Interciência.

CONNER, J., SEBORG, D. 2005. Assessing the Need for Process Re-identification. *Ind. Eng. Chem. Res.*, 44, 2767–2775.

HOLKAR, K., WAGHMARE, L. 2010. An overview of Model Predictive Control. *International Journal of Control and Automation*, 3, 47-64.

HUANG, B., MALHOTRA, A., TAMAYO, E. 2003. Model Predictive Control Relevant Identification and Validation. *Chemical Engineering Science*, 58, 2389-2401.

JI, G.; ZHANG, K.; ZHU, Y. 2012. A method of MPC model error detection. *Journal of Process Control*, 22, 635-642.

JIANG, H., HUANG, B., SHAH, S. 2009. Closed-loop model validation based on the two-model divergence method. *Journal of Process Control*, 19, 644-655.

JIANG, H., SHAH, S., HUANG, B., WILSON, B., PATWARDHAN, R., SZETO, F. 2012. Model analysis and performance analysis of two industrial MPCs. *Control Engineering Practice*. 20, 219–235.

KANO, M., SHIGI, Y., HASEBE, S., OYAMA, S. Detection of Significant Model-Plant-Mismatch from Routine Operation Data of Model Predictive Control System. 9th International Symposium on Dynamics and Control of Process Systems. 2010 Leuven, Bélgica.

LJUNG. 1999. *System Identification: Theory for the User*. Nova Jersey, Prentice Hall

MATOS, A., LONGHI, L. Comparação entre técnicas ARC e APC aplicadas a um vaso pulmão integrador de uma unidade industrial de Coqueamento retardado. VII Congresso Rio Automação. 2013 Rio de Janeiro, Brasil.

SUN, Z., QIN, J., SINGHAL, A., MEGAN, L. 2013. Performance monitoring of model-predictive controllers via model residual assessment. *Journal of Process Control*, 23, 473–482.

WHANG, H., SONG, Z., XIE, L. Parametric Mismatch Detection and Isolation in Model Predictive Control System. 8th IFAC Symposium on Advanced Control of Chemical Processes. 2012 Furama Riverfront, Singapura.