



APLICAÇÃO DE FILTRO DE PARTÍCULAS PARA ESTIMAÇÃO DO COMPORTAMENTO DE VÁLVULAS EM CONDIÇÃO DE FALHA

L. R. DEMUNER¹, F. D. RANGEL¹, J. C. S. DUTRA² e W. B. DA SILVA²

¹ LAMCES – Pesquisa em Métodos Computacionais, Controle e Estimação

^{1,2} Programa de Pós-graduação em Engenharia Química (PPEQ)

Universidade Federal do Espírito Santo – campus de Alegre, ES/Brasil.

E-mail: juliosdutra@yahoo.com.br; wellingtonuff@yahoo.com.br

RESUMO: O monitoramento e o controle de processos químicos realizados de modo satisfatório são primordiais para o atendimento dos objetivos operacionais. Estes processos são dinâmicos e apresentam elementos não gaussianos e não lineares, que tornam necessárias ferramentas computacionais para auxiliar em uma análise mais precisa. Na Engenharia Química, é comum o uso de tanques para armazenar misturas e produtos e reduzir perturbações. A esses tanques, estão associadas válvulas que regulam o nível do material acumulado para manter a quantidade desejada e garantir a segurança na planta. Diante da dificuldade em detectar falhas nessas válvulas, a estimação de parâmetros utilizando filtros de partículas é uma solução viável para este problema. Neste trabalho, estimou-se o coeficiente de uma válvula e recuperaram-se as medidas de nível, utilizando-se o Filtro SIR. Foram obtidos resultados satisfatórios ao se variar o número de partículas, o nível de incerteza do modelo e o tipo de informação *a priori*.

PALAVRAS-CHAVE: Filtros de Partículas; Estimação de Parâmetros; Válvulas.

1. INTRODUÇÃO

Diante de um mercado altamente competitivo, os processos industriais são frequentemente forçados a operar em condições desafiadoras para atender aos requerimentos de taxa de produção e qualidade de produto (Dutra *et al.*, 2014). Como apresentam uma complexidade de equipamentos, instrumentos e malhas de controle, o desempenho de controle do processo pode ser severamente prejudicado se houver o funcionamento defeituoso de uma dessas partes (Wang *et al.*, 2008). Por exemplo, pode haver a perda funcional de alguns instrumentos, como atuadores

e sensores, ou então modificações intrínsecas que afetam as propriedades internas do processo, como desativação catalítica e aumento de incrustação em trocadores de calor. Desse modo, há espaço interessante para o desenvolvimento e aplicação de métodos de supervisão e monitoramento contínuo da condição do processo para garantia da operabilidade em toda sua vida útil (Boussaid *et al.*, 2011).

Um dos processos mais comuns na Engenharia Química compreende o escoamento em tanques para armazenar misturas e produtos ou mesmo para atenuar perturbações. Estes tanques possuem válvulas que são empregadas para controle do nível do material por meio da manipulação da vazão de saída (Figura 1). Nestes processos, as válvulas têm papel fundamental no controle automático, manipulando o fluxo de matéria e/ou energia. Elas atuam de modo a corrigir o valor da variável controlada sempre que houver um desvio em relação ao valor desejado. Reagindo às perturbações da vazão de alimentação F_o , o controlador do nível h ajusta a abertura da válvula, cujo efeito é a alteração do seu coeficiente de vazão indicado por c_v (Seborg *et al.*, 2011). Desse modo, é preciso que as válvulas estejam sempre em boas condições, o que acontece apenas quando há monitoramento efetivo e manutenção preventiva (Bega, 2011).




Figura 1: Esquema representativo de um tanque de armazenamento.

Normalmente, a simulação do escoamento em um tanque de armazenamento é feita com o modelo matemático dado pela Equação 1.

$$A \frac{dh}{dt} = F_o - c_v \sqrt{h} \quad (1)$$

onde A é a área transversal (m^2); F_o , a corrente de alimentação (m^3/min); c_v , o coeficiente da válvula ($m^{2,5}/min$); h , o nível no tanque (m); e t , o tempo (min).

A detecção de falhas, enquanto o processo opera em uma região controlável, pode evitar um comportamento indesejado do sistema e impedir, por exemplo, sua parada, que implica diretamente em perdas econômicas. Neste sentido, diversas

pesquisas têm sido motivadas pela busca por alternativas de controle tolerante a falhas, cujo objetivo principal é a manutenção da estabilidade do processo mediante acomodação automática das falhas (Zhang e Jiang, 2008). Podem ser encontrados muitos métodos na literatura (Venkatasubramanian *et al.*, 2003 a, b, c), que envolvem, por exemplo, (a) modelos quantitativos: modelagem empírica por meio de redes neurais (Lennox *et al.*, 2001) ou modelos fenomenológicos para predição de variáveis e parâmetros, análise de componentes principais (Misra *et al.*, 2002) e de *clusters* com modelos de mistura para processos multimodais (Feital *et al.*, 2013), e sensoriamento virtual que emprega as medidas do processo (Zhang e Jiang, 2008); (b) modelos qualitativos: modelos causais e hierarquias de abstração que permitem o entendimento do processo; e (c) modelos baseados em dados históricos: cartas univariadas (Shewhart, CUSUM, etc.) de controle de qualidade (Montgomery, 2001).

Esses métodos são responsáveis pelo gerenciamento de todo o processo, indicando o início, a localização e a gravidade das falhas que ocorrem, informando a condição atual para uma camada de supervisão de todo o sistema. Grande parte destas técnicas tem forte respaldo estatístico e fornecem um aumento significativo na qualidade das informações disponíveis do processo (Feital, 2011).

Em alguns casos, mesmo conhecendo o fenômeno no qual se fundamenta o processo, pouco se sabe sobre os parâmetros que nele estão contidos. Neste caso, o sensoriamento virtual permite o emprego de técnicas de estimação de estados e parâmetros baseadas, por exemplo, na reconciliação de dados (Prata *et al.*, 2010) ou em técnicas estatísticas com filtros de Kalman ou filtros Bayesianos (Kaipio e Somersalo, 2004). Estes são empregados, na maioria das vezes, para resolver problemas inversos não lineares e não gaussianos (Da Silva, 2012), e são baseado no método sequencial de Monte Carlo. Eles têm como objetivo o cálculo recursivo das distribuições de probabilidades relevantes utilizando o conceito de amostragem por importância e a aproximação das funções de distribuição de probabilidades por medidas aleatórias discretas (Djuric *et al.*, 2003).

Neste contexto, este artigo propõe a aplicação dos métodos sequenciais Monte Carlo, também conhecidos como filtros de partículas, como um meio não intrusivo para a identificação de parâmetros de processos, no intuito de verificar as causas de eventos anormais (isto é, detecção de falhas). Dessa forma, o monitoramento da condição do processo visa estimar propriedades envolvidas no evento da falha a partir da observação das medidas do processo. Simultaneamente, os parâmetros estimados permitem obter os valores recuperados das variáveis medidas por meio da redução da variância (Da Silva, 2012). Para tanto, é

considerado o caso de ocorrência de falhas em elemento final de controle, representado por uma válvula de abertura definida por um atuador linear em um tanque de armazenamento. Especificamente, consideram-se variações no coeficiente de capacidade da válvula.

Segundo Garcia (2008), cerca de 30% das malhas de controle encontradas na indústria oscilam ou apresentam erros estacionários devido a problemas relacionados às válvulas de controle. Na maioria dos casos, a válvula é submetida a condições severas de pressão, temperatura, corrosão e erosão; mas, ainda assim, deve operar de modo satisfatório. Além da perda funcional deste instrumento, estas condições podem causar problemas operacionais, como agarramento (ou atrito estático), banda morta e histerese, que afetam a qualidade do controle. Dentre os vários tipos de não linearidade presentes em válvulas com atuador linear, o agarramento é o tipo mais comum (Bega, 2011). Assim, o monitoramento da condição da válvula contribui para a redução das paradas da produção, de investimentos com comissionamento de malhas e reajustes de controladores.

2. MATERIAIS E MÉTODOS

2.1. O Problema de Estimação

Uns dos principais problemas na estimação de estados são os modelos utilizados para representar os dados obtidos pela observação e representação da evolução dos estados. Esta modelagem é representada em espaço de estados de sistemas dinâmicos, onde o modelo de observação das medidas completa a descrição matemática do problema. Neste contexto, os modelos dinâmicos podem ser formulados com base fenomenológica com o intuito de permitir a evolução das variáveis de estado que são estimadas. Assim, os problemas de estimação são formulados tanto para predição de parâmetros quanto para uma melhor representação das observações, envolvendo simultaneamente a recuperação (ou correção) das evoluções das variáveis de estado não medidas. Este problema de estimação pode ser tratado como uma versão especial do caso mais geral do problema de minimização do erro médio quadrático, onde a distribuição *a priori* para a variável de estado desconhecida no tempo é dada por um modelo de evolução temporal (Kaipio e Somersalo, 2004; Da Silva, 2012).

Com a intuito de resolver o problema de estimação, pode-se considerar o modelo de evolução dado pela Equação 2.

$$x_k = f_{k-1}(x_{k-1}, u_{k-1}, v_{k-1}) \quad (2)$$

onde o subscrito $k = 1, 2, 3, \dots$, representa o instante de tempo t_k , que varia de um tempo inicial até um tempo final. O vetor de estados que contém todas as variáveis a ser estimadas é o vetor $x \in R^{n_x}$. Este vetor avança no tempo de acordo com o modelo de evolução de estado dado pela Equação 2, na qual f é geralmente considerada uma função não linear das variáveis de estado, das variáveis de entrada, $u \in R^{n_u}$, e do vetor de incertezas, $v \in R^{n_x}$, que representa o vetor de ruído do estado (Kaipio e Somersalo, 2004).

O modelo de observação ou de medidas é dado pela Equação 3, onde $z \in R^{n_z}$ é o vetor de medidas e $n \in R^{n_z}$ representa o ruído das medidas.

$$z_k = h_k(x_k, n_k) \quad (3)$$

A estimação de estado tem como objetivo a obtenção de informações sobre o vetor x_k baseado nos modelos de evolução e de observação dados pelas Equações 2 e 3, e nas seguintes suposições (Da Silva, 2012):

1. A sequência x_k para $k = 1, 2, 3, \dots$, é um processo Markoviano de primeira ordem, que significa que, a probabilidade de um estado depende apenas do estado imediatamente precedente, como mostra a Equação 4.

$$\pi(x_k | x_0, x_1, \dots, x_{k-1}) = \pi(x_k | x_{k-1}) \quad (4)$$

2. A sequência z_k^{obs} para $k = 1, 2, 3, \dots$, é um processo Markoviano com respeito à história de x_k , como se pode observar na Equação 5.

$$\pi(z_k^{obs} | x_0, x_1, \dots, x_{k-1}) = \pi(z_k^{obs} | x_k) \quad (5)$$

3. A sequência x_k depende das observações anteriores através de sua própria história, e pode ser representada pela Equação 6.

$$\pi(x_k | x_{k-1}, z_{1:k-1}^{obs}) = \pi(x_k | x_{k-1}) \quad (6)$$

Neste contexto, o Teorema de Bayes é dado pela Equação 7.

$$\pi_{posteriori}(x_k) = \frac{\pi(x_k)\pi(z_k^{obs} | x_k)}{\pi(z_k^{obs})} \quad (7)$$

onde $\pi(x_k)$ corresponde à densidade *a priori* da variável de estado; $\pi(z_k^{obs})$, à densidade de probabilidade marginal das medidas; e $\pi(z_k^{obs} | x_k)$, ao risco, ou seja, à probabilidade condicional das medições z_k^{obs} dadas as variáveis de estado x_k .

Filtro SIS (Sequential Importance Sampling): Os filtros de partículas são baseados no método de Amostragem por Importância Sequencial (Da Silva, 2012). Esta técnica tem como objetivo principal gerar amostras independentes e identicamente distribuídas da distribuição *a posteriori* desejada (Fu e Jia, 2010). Isso pode ser feito, primeiramente, amostrando aleatoriamente um número de N partículas de uma distribuição inicial $\pi(x_0)$, que são amostras da distribuição no instante de tempo $t = 0$. Para avançar as partículas do tempo t_{k-1} para o tempo t_k , $k = 1, 2, 3, \dots$, um valor observado z_{t_k} é usado no instante de tempo t . Verifica-se então a proximidade destes valores e calcula-se a sua probabilidade $\pi(z_k | x_k)$ obtendo-se assim a importância de cada partícula, através da normalização dos pesos, \hat{w}_k^i . As partículas de maior peso representam as regiões de maior importância da distribuição. O grande problema desse filtro é a degeneração das partículas, ou seja, um aumento gradual da variância dos pesos, que significa que após algumas iterações apenas uma partícula tem um peso não desprezível.

Filtro SIR (Sequential Importance Resampling): O conceito fundamental na teoria do filtro SIR, baseado na Amostragem por Importância e Reamostragem Sequencial, é preservar as partículas com grandes pesos (i.e., grandes probabilidades), e descartar aquelas com pesos pequenos. A implementação do filtro SIR segue os mesmos passos do filtro SIS, para a etapa de amostragem por importância. Feito essa amostragem, após a normalização dos pesos, é feito o processo de seleção, onde é realizada a reamostragem da distribuição anterior $\pi(x_k | x_{k-1})$ das N partículas, usando os pesos \hat{w}_k^i . As novas partículas no instante de tempo t , que representam a distribuição *a posteriori*, são então obtidas, e chamadas x_k^i . No fim, há o passo de evolução em que, a partir da equação de transição $\pi(x_k | x_{k-1})$, novas partículas são geradas de modo a representar a distribuição *a posteriori* no tempo t .

2.2. Metodologia

As rotinas computacionais do problema de estimação descrito acima foram implementadas na ferramenta computacional Scilab em um computador com processador Intel® Core™ i7. Foram obtidos dados de nível do tanque com o

modelo da Equação 1, com a condição inicial $h_0 = 1\text{ m}$, $A = 1\text{ m}^2$ e $F_0 = 5\text{ m}^3/\text{min}$, para 30 min de operação. A esses dados simulados foram acrescentados ruídos gaussianos, aditivos, com média zero e desvio padrão de 5% da altura inicial h_0 (isto é, $\sigma_h = 0,05h_0$), a fim de evitar o crime inverso (Colaço *et al.*, 2006), gerando assim as medidas simuladas (z_k^{obs}) para o problema de estimação.

Foram feitas simulações considerando dois exemplos aplicativos. No primeiro, simulou-se a situação em que o coeficiente c_v da válvula varia de modo senoidal. Já no segundo, implementou-se o caso de agarramento estático quando da entrada de uma ação de controle. Em ambos os casos, objetivou-se avaliar se os filtros fornecem resultados satisfatórios para a estimação do coeficiente da válvula por meio do algoritmo SIR, cujo esquema computacional é fornecido na Figura 2.

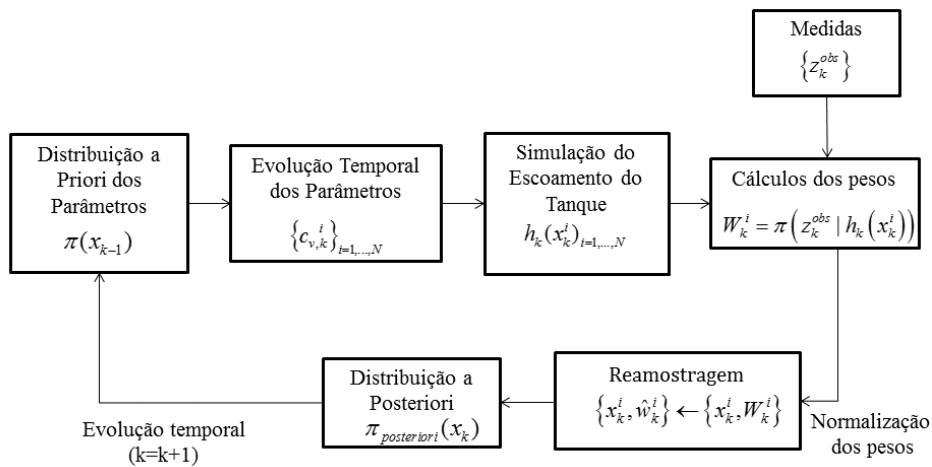


Figura 2: Fluxograma do esquema do Filtro SIR para o problema de estimação.

Vale destacar que as informações do processo estão contidas no vetor $x_k = [h_k \ c_{v,k}]^T$ e que a evolução temporal da variável de estado (nível do tanque) foi feita pelo método Runge-Kutta por meio da função *ode*, cuja estrutura da solução é dada pela Equação 8. Nesta representação, b_i e k_i são constantes próprias do esquema numérico, Δt é o intervalo de integração, s é um escalar que depende da ordem do método e $v_{h,k} \sim N(0, \sigma_h^2)$ é a incerteza do modelo de evolução. Como pode ser visto, o efeito estocástico é dado explicitamente pela expressão de $v_{h,k}$, que segue uma distribuição normal com média nula e variância σ_h^2 .

$$h_k = h_{k-1} + \Delta t \sum_{j=1}^s b_j k_j + v_{h,k} \tag{8}$$

No caso do parâmetro c_v , a evolução temporal foi baseada no passeio aleatório (Equação 9). Contudo, para testar a contribuição de uma melhor informação *a priori*, supôs-se conhecido o comportamento de c_v apenas para o exemplo aplicativo 1 com um modelo informativo do tipo senoidal (Equação 10). Nestas equações, $\nu_{c_v} \sim U(-\sigma_{c_v}, +\sigma_{c_v})$ é a incerteza do modelo de evolução, seguindo uma distribuição uniforme com desvio-padrão σ_{c_v} .

$$c_{v,k} = c_{v,k-1} + \nu_{c_v,k} \quad (9)$$

$$c_{v,k} = c_{v,k-1} + 0.1[\sin(t_k) - \sin(t_{k-1})] + \nu_{c_v,k} \quad (10)$$

Durante os testes, foram considerados diferentes números de partículas e dois níveis de desvio-padrão para a evolução do parâmetro, de acordo com a expressão $\sigma_{c_v,k} = p \cdot c_{v,k-1}$, onde o valor p é o nível de incerteza assumido como 1% ou 30%.

3. RESULTADO E DISCUSSÃO

3.1. Exemplo aplicativo 1

A Figura 3 apresenta os resultados obtidos do coeficiente da válvula com passeio aleatório e 300 partículas. Enquanto na Figura 3A, empregou-se o nível de incerteza de 1% e, na Figura 3B, o nível de 30%. Do mesmo modo, foi feito para a Figura 4, considerando o emprego do modelo informativo com 50 partículas.

Analisando-se a Figura 3, percebe-se que, quando se emprega o passeio aleatório, é necessário aumentar a incerteza do modelo de evolução do parâmetro. Isso faz com que o campo de busca do modelo seja maior e suficiente e, assim, capaz de descrever bem o comportamento do parâmetro c_v . Na Figura 3A, devido ao baixo valor de desvio-padrão, o valor estimado do parâmetro não alcança o valor verdadeiro (indicado como exato), pois a incerteza considerada não foi suficiente para explicar a dinâmica do processo.

O valor de incerteza do modelo de evolução pode ser baseado na incerteza do conjunto de medidas de nível. Neste caso, assumindo a mesma ordem de grandeza de desvio-padrão do nível, encontra-se o valor de incerteza a ser usado pelo filtro no modelo de evolução de c_v . O nível de incerteza σ_h das medidas é de 0,6362 m , que leva a uma incerteza equivalente de 25% do valor nominal do coeficiente da válvula. Este fato corrobora os resultados da Figura 3B, onde a incerteza é de 30%.

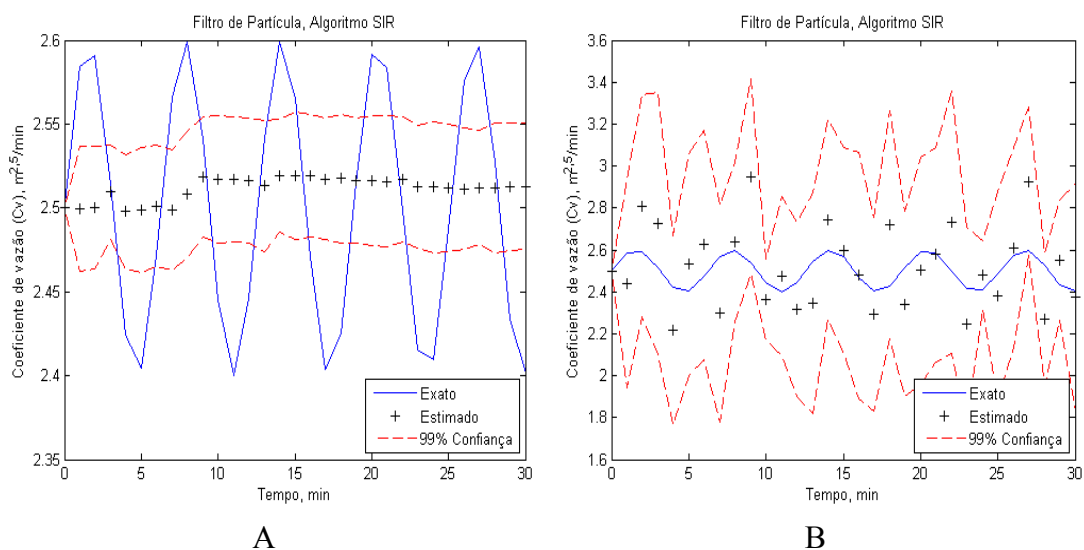


Figura 3 - Estimação do coeficiente da válvula com 300 partículas, passeio aleatório e com os níveis de incerteza de 1% (A) e de 30% (B).

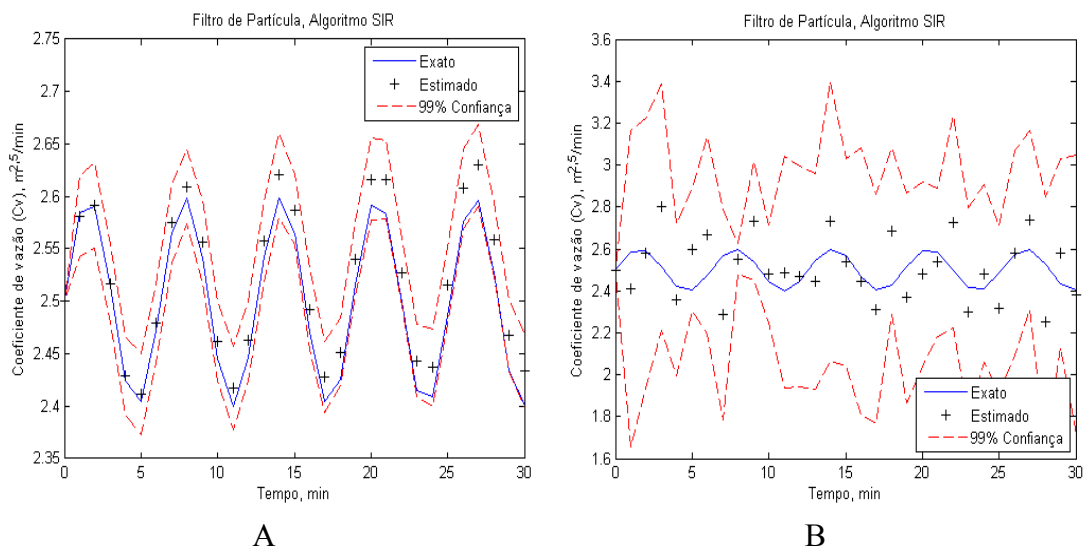


Figura 4 - Estimação do coeficiente da válvula com 300 partículas, modelo informativo e com os níveis de incerteza de 1% (A) e de 30% (B).

A Figura 4 permite notar que, quando foi utilizado um modelo informativo com 50 partículas e baixo valor de desvio-padrão, a estratégia descreveu melhor o comportamento da válvula de controle na condição de oscilação senoidal. Para um nível de 30% de incerteza, a média do tempo computacional gasto para o caso com

50 partículas e modelo informativo foi de 5 s; por outro lado, com 300 partículas e passeio aleatório, esse tempo aumenta para 40 s. Pode-se ver que o modelo informativo agrega uma grande vantagem na utilização do filtro de partículas, já que o custo computacional foi expressivamente menor.

O nível do tanque ao longo do tempo foi recuperado para o caso onde se utilizou modelo informativo e desvio-padrão de 1% com 50 partículas (Figura 5). O uso do modelo informativo permitiu a obtenção da melhor estimativa de nível dentre as realizadas, mesmo com um baixo número de partículas e de incerteza, uma vez que não houve necessidade de aumentar do campo de busca. Os valores mais exatos de nível podem ser usados então para monitoramento e controle.

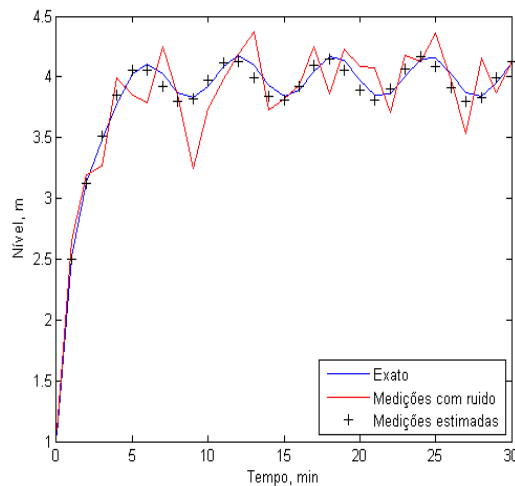


Figura 5 – Valores de nível recuperados para o caso com modelo informativo.

3.2. Exemplo aplicativo 2

Neste exemplo, simulou-se o caso em que a válvula que apresenta o problema de agarramento quando da entrada de ação de controle, modificando-se c_v de $2,5 \text{ m}^{2,5}/\text{min}$ para um valor médio de $3,0 \text{ m}^{2,5}/\text{min}$. Para tanto, considerou-se o comportamento descrito pela Equação 11 para geração dos dados medidos, onde $\nu_k \sim U(-0,05; 0,05)$ é a incerteza em torno do valor final, seguindo distribuição uniforme com desvio-padrão de 0,05 a partir de $k^* = 10 \text{ min}$. No algoritmo do filtro SIR, foi considerado o passeio aleatório para a evolução temporal, já que este é o caso de sistemas reais onde não se conhece a trajetória de c_v a priori.

$$c_{v,k} = \begin{cases} 2,5 & k < k^* \\ 3,0 + \nu_k & k \geq k^* \end{cases} \quad (11)$$

A Figura 6 apresenta os resultados com os níveis de incerteza de 1% e 30%, aplicados no passeio aleatório, e com 50 e 300 partículas.

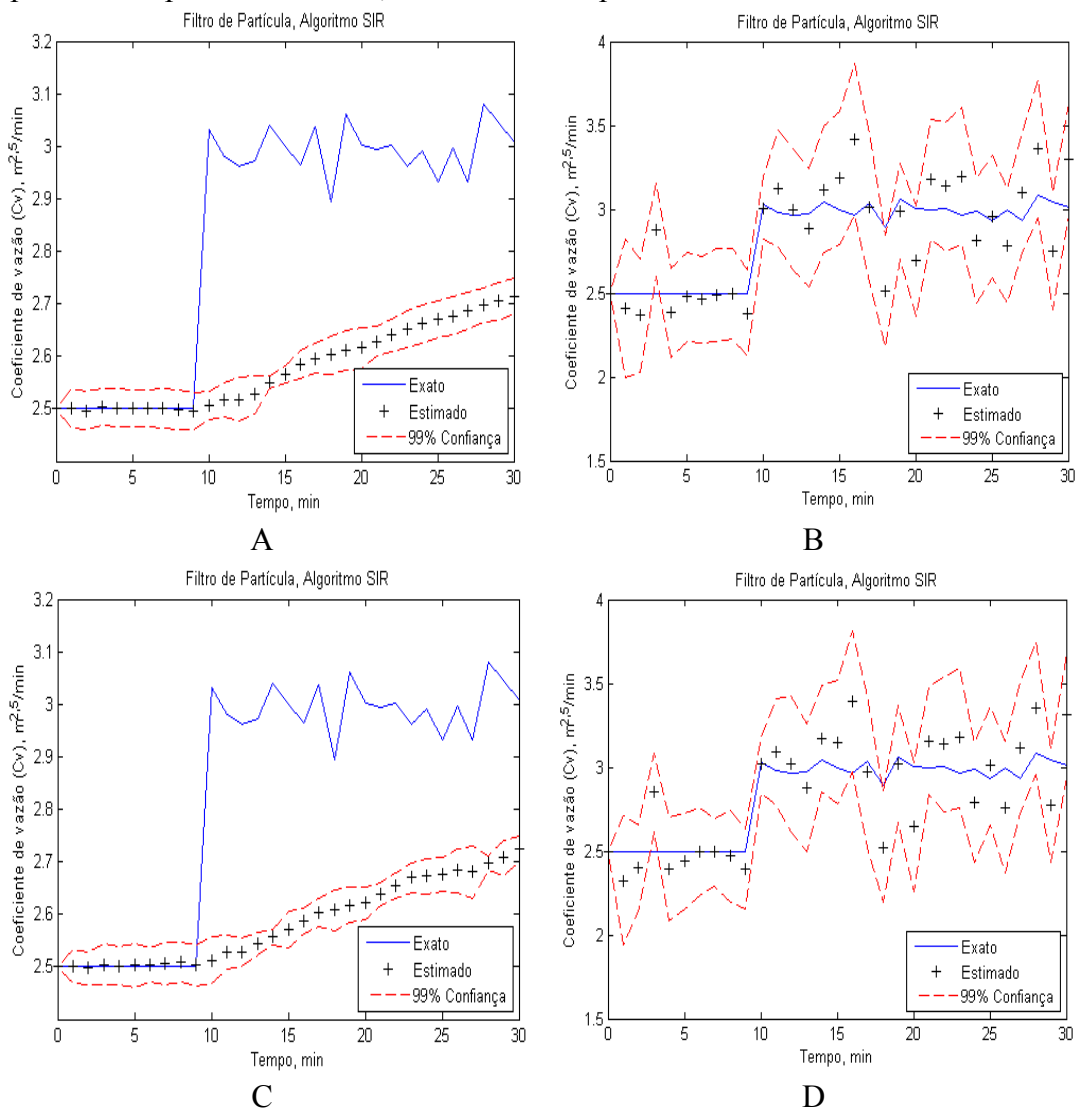


Figura 6 - Estimação do coeficiente da válvula com agarramento estático, com 300 partículas: (A) e (B) com 1% e 30% de incerteza, respectivamente; e com 50 partículas: (C) e (D) com 1% e 30% de incerteza, respectivamente.

Analisando as Figuras 6A e 6C, percebe-se que o filtro para ambos os casos teve o mesmo desempenho e que, devido ao baixo nível de incerteza, o valor do parâmetro estimado está muito distante do valor exato. Além disso, as Figuras 6B e 6D mostram que uma melhor aproximação do parâmetro pode ser obtida com o uso

de um maior desvio-padrão dentro do passeio aleatório, pois novamente o campo de busca deste modelo torna-se maior capturando o comportamento do parâmetro.

O nível de incerteza de 30% fornece um amplo intervalo de confiança, independente do número de partículas. Poder-se-ia calcular o nível de incerteza mínima como feito no exemplo aplicativo 1. Contudo, a consideração de todo o conjunto de medidas superestimaria o nível de incerteza necessário para o parâmetro. Dessa forma, o ideal é limitar às medidas após o instante da ação de controle, já que é a região que se refere ao agarramento. Essas medidas levam a um nível de incerteza equivalente cerca de 10% para o parâmetro c_v . Para trabalhos futuros, espera-se implementar um controle na incerteza do filtro, para que assim seja possível minimizar o intervalo de confiança para uma solução mais precisa.

Os resultados para recuperação de nível são apresentados na Figura 7, onde foram empregadas 300 partículas, variando-se o nível de incerteza. Mantendo-se a incerteza de 30%, nota-se que as estimações, durante o agarramento, não alcançam os valores exatos. Isto pode ser associado ao alto nível de incerteza considerado, já que, com 10% de incerteza, há mais valores estimados próximos ao exato. Deste modo, destaca-se a importância da determinação adequada do nível de incerteza.




Figura 7 - Valores da variável nível recuperados para o caso de agarramento: (A) 10% de incerteza; (B) 30% de incerteza.

3.3. Utilização dos parâmetros estimados

O método proposto neste trabalho pode ser utilizado como uma ferramenta de sensoriamento virtual do coeficiente de válvulas, visando sua utilização para determinar se as anormalidades nas medidas de nível são causadas por falhas no atuador da válvula. Por exemplo, pode permitir a adaptação dos parâmetros de um sistema de controle com objetivo de tolerância a falhas. Neste caso, o controle por modelo interno (IMC) utiliza os parâmetros estimados do processo para inferir os parâmetros do controlador. Dessa forma, toda vez que houver mudanças no valor de c_v , pode ser feita uma nova sintonia do controlador para garantir uma estrutura de controle sempre atualizada e adequada às condições operacionais.

4. CONCLUSÃO

No presente trabalho, foi implementado o filtro SIR com diferentes números de partículas e níveis de incerteza do modelo de evolução do parâmetro. Também foi avaliado o efeito do emprego de modelo informativo como informação *a priori*.

De acordo com a literatura, muitos métodos têm dificuldade em estimar parâmetros, já que normalmente eles têm caráter probabilístico e dinâmico. Isto ficou evidente no exemplo aplicativo 1, pois, quando foi utilizado passeio aleatório, mesmo com elevado número de partículas, o método apresentou dificuldade em estimar o parâmetro. No entanto, quando existe um modelo informativo a respeito do comportamento do parâmetro, tem-se um melhor resultado, com um tempo computacional menor, utilizando baixo número de partículas e nível de incerteza.

Vale ressaltar que, para se estimar a quantidade de partículas necessárias para descrever o problema, devem ser feitas tentativas até que a estimação possa convergir ou se obter valores satisfatórios. Isso apenas ocorre quando os resultados se encontram dentro dos limites do intervalo de confiança ou se esse intervalo diminui. Além disso, pode-se usar a incerteza das medidas para inferir sobre o nível de incerteza a ser usado nos modelos de evolução dos parâmetros.

A contribuição deste trabalho dá-se pela utilização de filtros de partículas, empregando modelo não linear, ruídos não gaussianos nas medidas e o efeito de modelo informativo sobre o desempenho do filtro. Além disso, foi considerado o fato de que as distribuições uniformes foram propostas para representar situações em que as informações iniciais são limitadas ou não são disponíveis.

Para trabalhos futuros, vislumbra-se a alteração do algoritmo SIR no sentido de regular o nível de incerteza requerido em função dos erros de estimação

observados. Isso pode evitar a busca exaustiva pelo nível de incerteza adequado durante a etapa de projeto do filtro.

5. REFERÊNCIAS

- Bega, E. A. *Instrumentação Industrial*. Rio de Janeiro: Interciência, 2011.
- Boussaid, B.; Ubrun, C.; Abdelkrim N.; Ben Gayed, M. Performance evaluation based fault tolerant control with actuator saturation avoidance. *Journal of Applied Mathematics and Computer Science*, v. 21, n. 3, p. 457-466, 2011.
- Colaço, M. J.; Orlande H. R. B.; Roberty N. C.; Alves C. J. S.. On the use of MFS in linear inverse diffusion problems. In: *Congress of Thermal Sciences and Engineering - ENCIT*, Curitiba, Brazil, p. 14–21, 2006.
- Da Silva, W. B. *Aplicação de Filtros de Partículas para a Assimilação de Dados em Problemas de Fronteira Móvel*. Tese de Doutorado, PEM/COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2012.
- Djuric, P.; Kotecha, J.; Zhang, J.; Huang, Y.; Ghirmai, T.; Bugallo, M.; Miguez, J. Particle filter. *IEEE Signal Processing Magazine*, p. 19–38, 2003.
- Dutra, J. C. S.; Feital, T. S.; Skogestad, S.; Lima, E. L.; Pinto, J. C. Control of bulk propylene polymerizations operated with multiple catalysts through controller reconfiguration. *Macromolecular Reaction Engineering*, v. 8, p. 201-216, 2014.
- Feital, T. S., *Monitoramento da Condição de Processos Químicos Industriais*. Tese de Doutorado, PEQ/COPPE/UFRJ, Rio de Janeiro, RJ, Brasil, 2011.
- Feital, T.; Kruger, U.; Dutra, J.; Pinto, J. C.; Lima, E. L. Modeling and performance monitoring of multivariate multimodal processes, *AIChE Journal*. 5.ed., v. 59, p. 1557-1569, 2013.
- Fu, X.; Jia, Y. An improvement on resampling algorithm of particle filters. *IEEE Transaction on Signal Processing*, v. 58, p. 5414–5420, 2010.
- Garcia, C. Comparison of friction models applied to a control valve. *Control Engineering Practice* 10 ed., v. 16, p.1231 – 1243, 2008.
- Kaipio, J.; Somersalo, E. *Statistical and computational inverse problems*. New York: Springer, 2004.
- Lennox, B.; Montague, G. A.; Frith, A. M.; Gent, C.; Bevan, V. Industrial Application of Neural Networks – An Investigation. *Journal of Process*. v. 11, p. 497- 507. 2001.

- Misra, M.; Yue, H. H.; Qin, S. J. E.; Ling, C. Multivariate process monitoring and fault diagnosis by multi-scale PCA. *Computers and Chemical Engineering*, v. 26, p. 1281–1293, 2002.
- Montgomery, D.C. *Introdução ao Controle Estatístico da Qualidade*, 4.ed. Rio de Janeiro: LTC, 2001.
- Prata, D. M.; Schwaab, M.; Lima, E. L.; Pinto, J. C. Nonlinear dynamic data reconciliation and parameter estimation through particle swarm optimization: Application for an industrial polypropylene reactor”. *Chemical Engineering Science*, v. 64, p. 3953-3967, 2009
- Seborg, D. E.; Edgar, T. F.; Mellichamp, D. A. *Process Dynamics and Control*. 3 ed. New York: John Wiley and Sons, 2011.
- Venkatasubramanian, V.; Rengaswamy, R.; Yin, K.; Kavuri, S. N. A review of process fault detection and diagnosis. Part I. Quantitative model-based methods. *Computers and Chemical Engineering*, v. 27, n. 3, p. 293–311, 2003a.
- Venkatasubramanian, V.; Rengaswamy, R.; Kavuri, S. N. A review of process fault detection and diagnosis. Part II. Qualitative models and search strategies. *Computers and Chemical Engineering*, v. 27, n. 3, p. 313– 326, 2003b.
- Venkatasubramanian, V.; Rengaswamy, R.; Kavuri, S. N.; Yin, K. A review of process fault detection and diagnosis. Part III. Process history based methods. *Computers and Chemical Engineering*, v. 27, n. 3, p. 327–346, 2003c.
- Wang, Y.; Zhou, D.; Qin, S. J.; Wang, H. “Active Fault-Tolerant Control for a Class of Nonlinear Systems with Sensor Faults”. *International Journal of Control, Automation, and Systems*, v. 6, n. 3, p. 339-350, 2008.
- Zhang, Y.; Jiang J. Bibliographical review on reconfigurable fault-tolerant control systems. *Annual Reviews in Control*, v. 32, p. 229–252, 2008.