



DINCON 2017

CONFERÊNCIA BRASILEIRA DE DINÂMICA, CONTROLE E APLICAÇÕES
30 de outubro a 01 de novembro de 2017 – São José do Rio Preto/SP

Monitoramento de processos industriais em diferentes regiões de operação utilizando análise externa não linear

Arthur Assis¹

Departamento de Engenharia Elétrica, Centro Tecnológico, Universidade Federal do Espírito Santo

Celso José Munaro²

Departamento de Engenharia Elétrica, Centro Tecnológico, Universidade Federal do Espírito Santo

Patrick Marques Ciarelli³

Departamento de Engenharia Elétrica, Centro Tecnológico, Universidade Federal do Espírito Santo

Júlio César Oliveira Faria⁴

Vale S.A.

Resumo. A utilização de métodos multivariados de controle de processos é amplamente difundida para detecção de falhas. Como processos industriais geralmente trabalham em múltiplas regiões de operação, estas mudanças devem ser consideradas nestes métodos para evitar falsas indicações de falhas. Um método que trata naturalmente este problema é o da análise externa, que relaciona as variáveis responsáveis pelas condições de operação com o conjunto de variáveis monitoradas, gerando um resíduo utilizado para o monitoramento. Entretanto, a presença de não linearidades requer um tratamento adequado para que os resíduos não sejam afetados por elas. Neste trabalho, diferentes funções não lineares são comparadas para a análise externa, bem como a utilização de métricas e métodos para seleção de seus parâmetros. A metodologia é avaliada através de sua aplicação a um exemplo simulado e a dados de um ventilador de processo industrial.

Palavras-chave. análise externa, detecção de falhas, modelos não lineares.

¹ arthur.a.assis@gmail.com

² munaro@ele.ufes.br

³ patrick.ciarelli@ufes.br

⁴ julio.oliveira.faria@vale.com

1 Introdução

Técnicas de controle estatístico multivariado de processos (MSPC – *Multivariate Statistic Process Control*) vêm sendo largamente utilizadas para monitoramento de processos industriais, visando obter informações relevantes da crescente geração de dados dos sistemas de controle industriais. Muitas técnicas para a detecção e o diagnóstico de falhas estão disponíveis quando o processo opera em um único estado estacionário [2]. Entretanto, o monitoramento de processos em múltiplos pontos de operação não pode ser realizado por estas técnicas, uma vez que os sinais analisados não têm uma única distribuição gaussiana.

Técnicas alternativas têm sido desenvolvidas nas últimas duas décadas. Em [9] é proposta uma metodologia baseada em múltiplos modelos usando Análise de Componentes Principais (*Principal Component Analysis* - PCA). O método requer o treinamento de muitos modelos para manter a estrutura de monitoramento de processos sensível às falhas.

Em [4] foi proposto um método promissor baseado em análise externa. As variáveis do processo são divididas em dois grupos, e assume-se que as variáveis principais podem ser explicadas pelas variáveis externas através de um modelo de regressão. Os resíduos resultantes da diferença entre as variáveis principais medidas e estimadas são utilizados para os diagnósticos. Desta forma, as variáveis monitoradas passam a ser independentes de variações da região de operação, podendo ser analisadas pelas técnicas tradicionais de monitoramento estatístico multivariado. Esta metodologia não é adequada quando as relações entre as variáveis externas e as principais não são lineares, o que é comum em processos industriais reais, que geralmente apresentam não linearidades. Alternativas para monitoramento de processos com múltiplos pontos de operação têm sido propostas [3, 6, 7], muitas delas considerando o processo modelado por múltiplas distribuições gaussianas (*gaussian mixture models*).

Neste artigo será proposta uma metodologia para detectar falhas em processos com múltiplos pontos de operação que apresentam não linearidades significativas, comparando diferentes modelos não lineares dinâmicos e estáticos em substituição a regressão linear para realizar a análise externa [4]. Desde que os resíduos dos modelos de análise externa sejam independentes dos pontos de operação do processo, eles podem ser usados para detectar falhas usando um único modelo PCA. Além de diferentes modelos de regressão, serão também empregadas diferentes métricas para escolha dos parâmetros destes modelos.

O artigo é dividido da seguinte forma: a seção 2 apresenta a revisão teórica e a metodologia proposta de detecção de falhas via análise externa não linear. A seção 3 apresenta dois estudos de caso, onde a metodologia proposta será aplicada a um sistema simulado de válvulas de controle e em uma aplicação real de monitoramento de vibrações de um ventilador de processo de uma Usina de Pelotização de minério de ferro. Por fim, a seção 4 apresenta as conclusões, onde serão discutidos os resultados.

2 Detecção de falhas via análise externa não linear

Considere uma matriz de dados de treinamento $Z \in R^{n,m}$ de um determinado processo com m variáveis e n amostras. As variáveis de Z podem ser divididas em dois grupos: as q variáveis externas $U \in R^{n,q}$, que determinam os pontos de operação do processo e as p variáveis principais $Y \in R^{n,p}$, que serão as variáveis a serem monitoradas. Portanto, Z pode ser escrita como

$$Z = [Y \ U] \quad (1)$$

A matriz Y será decomposta em duas partes,

$$Y = f(U) + e \quad (2)$$

onde $\hat{Y} = f(U)$ é uma estimativa de Y , e e são os resíduos do modelo. Neste artigo serão comparados os seguintes modelos lineares e não lineares: modelos de regressão polinomial de diferentes ordens estático e dinâmico e GRNN (*General Regression Neural Network*) [5] estático e dinâmico. Nos modelos dinâmicos são considerados também os atrasos das variáveis de entrada como entrada para modelar a dinâmica do processo, enquanto que nos modelos estáticos são utilizadas somente as variáveis de entrada originais.

A função $f(U)$ para modelos de regressão polinomial é dada por:

$$f(U) = U\theta \quad (3)$$

$$\theta = (U_p^T U_p)^{-1} U_p^T Y \quad (4)$$

onde θ é o vetor de coeficientes e U_p é a matriz de variáveis externas de treinamento modificada. A primeira coluna desta matriz é um vetor unitário para estimar o *bias*, que é o parâmetro independente do modelo. Novas colunas são adicionadas com potências das variáveis correspondentes a ordem do polinômio escolhido. A ordem do modelo de regressão polinomial deverá ser aumentada até que os indicadores que serão calculados para avaliar a qualidade dos modelos parem de melhorar. A função $\hat{Y} = f(U)$ para GRNN pode ser encontrada em [5].

O número de atrasos dos modelos dinâmicos será definido como a quantidade de amostras presentes na transição entre duas regiões de operação, como em [4]. A utilização de sinais de entrada dos modelos com variações suaves, como senoidal ou rampa, não permite que os efeitos da dinâmica do processo sejam identificados pelos modelos. Assim, um sinal de entrada com variações em degrau é o mais indicado para treinamento de tal modelo. Quando as mudanças nas variáveis externas não ocorrem na forma de degraus, os dados de treinamento podem ser divididos em subconjuntos, utilizando a validação cruzada k -fold para identificar o melhor modelo, que obtém o menor resíduo.

Espera-se que os resíduos e dos modelos de análise externa sejam independentes dos pontos de operação do processo. Isto permite que sejam monitorados utilizando modelos PCA e a estatística T^2 de *Hotelling* [2], sendo que o limiar estatístico será calculado utilizando distribuição F , com sensibilidade de 1%.

Serão calculados índices para medir a qualidade dos modelos. Eles medirão fatores que indiquem a capacidade de um modelo representar as relações entre as variáveis externas e principais e o desempenho para detecção de falhas. Os três índices selecionados são:

- Norma dos resíduos – Norma-2 da matriz e da equação 2, que representa a medição do erro de predição do modelo de análise externa. Quanto melhor um modelo consegue explicar os dados, menor o erro de predição e sua norma, permitindo reduzir seu intervalo de confiança;
- Falsos positivos (*FP*) – Quantidade de falsos alarmes para o processo em condição normal. Um resíduo maior mascara a quantidade de falsos positivos, tolerando variações maiores em condições normais;
- Tempo de detecção da falha (*TF*) – Tempo entre o início e a detecção de uma falha. O uso de uma falha com intensidade crescente torna o uso deste índice mais intuitivo do que a utilização de falsos negativos.

Os falsos positivos são medidos em porcentagem, tempo de detecção em número de amostras entre a falha e a detecção multiplicado pelo tempo de amostragem em segundos, e a norma dos resíduos em valores absolutos. Os indicadores são calculados utilizando dados diferentes dos

utilizados na etapa de treinamento dos modelos. Os modelos que apresentarem os menores valores dos índices deverão ser escolhidos para realizar o monitoramento de falhas.

3 Estudos de caso

Para teste da metodologia proposta, dois estudos de casos serão apresentados. O primeiro consiste em uma simulação de uma válvula de controle e o segundo consiste em uma aplicação real de monitoramento de vibrações de um ventilador de um processo de pelotização de minério de ferro.

3.1 Monitoramento de válvula de controle

A metodologia proposta na seção anterior será aplicada em uma simulação de uma malha fechada de controle de vazão, utilizando um controlador PID e uma válvula de controle com o mesmo modelo proposto em [1]:

$$x(k) = \frac{0,0616q^{-1} + 0,0543q^{-2}}{1 - 1,5714q^{-1} + 0,687q^{-2}} v(k) \quad (5)$$

$$y(k) = \frac{x(k)}{\sqrt{0,10 + 0,9x(k)^2}} \quad (6)$$

onde $x(k)$ é a posição da válvula, $v(k)$ é a pressão de controle e $y(k)$ o fluxo através da válvula no instante k .

A variável externa será o *setpoint* de vazão, e as variáveis principais serão o sinal de controle e a vazão de saída. Para gerar os dados de treinamento dos modelos, cinquenta degraus distintos do *setpoint* foram aplicados, sendo obtidas 200 amostras para cada degrau, todos em condição de normalidade. Com conjuntos de dados em pontos de operação distintos foram gerados para validação, com uma falha no formato de rampa somada ao sinal de vazão de saída presente em todas as simulações. Utilizando os dados de validação nos modelos de análise externa e PCA treinados, é possível calcular os índices definidos na metodologia. As médias dos indicadores para todos os conjuntos de dados são apresentadas na Figura 1 para todos os modelos avaliados.




Figura 1 – Métricas para modelos de monitoramento de válvula de controle

Observa-se na Figura 1 que o aumento da ordem dos modelos de regressão polinomial melhorou os índices até a quinta ordem. Fica evidente a melhoria nos índices dos modelos de regressão polinomial, conforme a ordem vai aumentando, quando comparado com o desempenho do modelo linear. O modelo GRNN estático obteve um desempenho melhor que o linear na métrica de tempo de detecção da falha, mas para os outros indicadores os resultados são semelhantes.

Foram adicionados 40 atrasos no modelo GRNN e no modelo polinomial de quinta ordem para modelar a dinâmica do processo. O desempenho dos modelos dinâmicos foi superior aos estáticos, com uma única exceção, que foi o tempo de detecção do modelo GRNN dinâmico, estando um pouco acima do modelo GRNN estático, sendo o modelo polinomial de quinta ordem dinâmico o que apresentou melhor desempenho nesta métrica.

3.2 Monitoramento de vibração de um ventilador de processo

O processo de pelletização de minério de ferro é um processo de aglomeração de finos de minério para geração de pelotas e exige um tratamento térmico, visando o aumento da resistência mecânica do produto para atender o processo posterior de geração de aço em siderúrgicas. O forno de pelletização possui vários queimadores de combustíveis e a queima das pelotas é realizada através de fluxos de gases quentes que passam entre as pelotas. Estes fluxos de gases são gerados por grandes ventiladores de processo, que também são utilizados para obter um reaproveitamento de gases quentes dentro do forno, de forma a diminuir o custo energético, assim como fornecer o oxigênio necessário para a queima do combustível.

Estes ventiladores de grande porte possuem acionamento por motores e são sustentados por mancais normalmente lubrificados a óleo. Devido à criticidade destes equipamentos, eles possuem vários instrumentos de proteção, sendo os medidores de vibração dos mancais uns dos mais importantes, visto que as falhas mais críticas afetam estas variáveis. Neste estudo de caso é aplicada a metodologia proposta ao monitoramento de vibração de mancais de um ventilador de processo de uma usina de pelletização da mineradora Vale S. A.. A vibração do mancal acoplado ao motor e a vibração do mancal não acoplado ao motor serão as variáveis principais. A rotação do ventilador será a variável externa, visto que ela determina os pontos de operação dos sinais de proteção deste equipamento. A relação entre a rotação e as vibrações de mancais tem características não lineares.

O objetivo do monitoramento é detectar falhas, através da análise do comportamento dos sinais de vibração, de forma a identificar anomalias em componentes mecânicos antes que a falha se agrave. Na Figura 2 são mostradas as medidas de rotação e vibração do ventilador utilizado na aplicação. Fica claro que o uso de limiares univariados fixos para as medidas de vibração




Figura 2 – Sinais utilizados na aplicação: Rotação do Ventilador e as vibrações

produziriam muitos alarmes falsos. Por se tratarem de dados de processos reais e a escassez de dados, os métodos de treinamento e validação dos modelos tiveram de ser modificados. Foram separados cinco conjuntos de dados para realizar o treinamento dos modelos, e o treinamento foi feito em um processo semelhante a validação cruzada pelo método *k-fold* com $k=5$, onde um conjunto é separado para validação e os outros para treinamento, todos sem a presença de falhas, alternando tais conjuntos. Os modelos com menor resíduos foram escolhidos. Os falsos positivos foram medidos com base no conjunto que foi utilizado para validação do modelo definido na validação cruzada. O tempo de detecção de falha foi calculado em dois momentos, visto que há duas falhas no conjunto dados. A falha 1 se inicia em 40 e termina em 60 horas e a falha 2, que é a mais crítica, se inicia em 120 horas e vai até o final do conjunto de dados. As variações da rotação do motor do ventilador são feitas através de um inversor de frequência que possui aceleração máxima limitada, gerando variações lentas, não sendo necessário a geração de modelos dinâmicos.

Os índices calculados são apresentados na Figura 3, onde observa-se que o aumento da ordem do modelo polinomial e uma rede GRNN fez com que o tempo de detecção da falha fosse reduzido em ambos os casos, cerca de 30 minutos para falha crítica e de 4 horas para falha com evolução mais suave. A taxa de falsos positivos permaneceu acima do limiar estabelecido pelo modelo PCA, de 1%, mas próxima dele. Tanto o polinomial de terceira ordem quanto o GRNN obtiveram resultados semelhantes, com melhor desempenho que o modelo de regressão linear.




Figura 3 – Métricas medidas relativas a aplicação ao ventilador

4 Conclusão

Uma metodologia para detecção de falhas em processos não lineares com múltiplos pontos de operação baseada em análise externa não linear foi proposta e apresentou desempenho superior quando comparado ao método proposto em [4], na qual são utilização de modelos lineares para análise externa. A melhora no desempenho é mostrada através da aplicação da metodologia em uma simulação de uma malha de controle de vazão e de uma aplicação real de monitoramento de vibrações de mancais de um ventilador de processo, calculando as métricas falsos positivos, tempo de detecção de falhas e norma dos resíduos para comparação dos diferentes modelos. O

uso de modelos não lineares de análise externa contribuiu para que as variáveis principais sejam melhores explicadas pelas variáveis externas, gerando resíduos com comportamento sem grandes variações, uniforme, contribuindo para o melhor desempenho da estrutura de monitoramento de processos.

Agradecimentos

Este trabalho recebeu apoio da Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (FAPES) e da Vale S.A., sob o termo de cooperação 29501.412.19434.19122015.

Referências

- [1] Al-Duwaish, H. and Naeem, W., Nonlinear model predictive control of hammerstein and wiener models using genetic algorithms. In Control Applications, 2001.(CCA'01). Proceedings of the 2001 IEEE International Conference On, 465-469, (2001).
- [2] Chiang, L.H., Russell, E.L. and Braatz, R.D., Fault detection and diagnosis in industrial systems. Springer Science & Business Media, (2000).
- [3] Ge, Z., Yang, C., Song, Z. and Wang, H., Robust online monitoring for multimode processes based on nonlinear external analysis. Industrial & Engineering Chemistry Research, vol. 47, 4775-4783, (2008).
- [4] Kano, M., Hasebe, S., Hashimoto, I. and Ohno, H., Evolution of multivariate statistical process control: application of independent component analysis and external analysis. Computers & chemical engineering, vol. 28, 1157-1166, (2004).
- [5] Specht, D.F., A general regression neural network. IEEE transactions on neural networks, vol. 2, 568-576, (1991)
- [6] Tan, S., Wang, F., Peng, J., Chang, Y. and Wang, S., Multimode process monitoring based on mode identification. Industrial & Engineering Chemistry Research, vol. 51, 374-388, (2011).
- [7] Tong, C., Palazoglu, A. and Yan, X., An adaptive multimode process monitoring strategy based on mode clustering and mode unfolding. Journal of Process Control, vol. 23, 1497-1507, (2013).
- [8] Yu, J. and Qin, S.J., Multimode process monitoring with Bayesian inference-based finite Gaussian mixture models. AIChE Journal, vol. 54, 1811-1829, (2008).
- [9] Zhao, S.J., Zhang, J. and Xu, Y.M., Monitoring of processes with multiple operating modes through multiple principle component analysis models. Industrial & engineering chemistry research, vol. 43, 7025-7035, (2004).