



PREDIÇÃO E DETECÇÃO DE FALTA EM SENSORES DE TEMPERATURA INSTALADOS EM CÂMARAS DE COMBUSTÃO DE TURBINAS A GÁS.

Rogério O. Sanches¹

Copyright 2006, Instituto Brasileiro de Petróleo e Gás - IBP

Este Trabalho Técnico foi preparado para apresentação na *Rio Oil & Gas Expo and Conference 2006*, realizada no período de 11 a 14 de setembro de 2006, no Rio de Janeiro. Este Trabalho Técnico foi selecionado para apresentação pelo Comitê Técnico do evento, seguindo as informações contidas na sinopse submetida pelo(s) autor(es). O conteúdo do Trabalho Técnico, como apresentado, não foi revisado pelo IBP. Os organizadores não irão traduzir ou corrigir os textos recebidos. O material conforme, apresentado, não necessariamente reflete as opiniões do Instituto Brasileiro de Petróleo e Gás, seus Associados e Representantes. É de conhecimento e aprovação do(s) autor(es) que este Trabalho Técnico seja publicado nos Anais da *Rio Oil & Gas Expo and Conference 2006*.

Resumo

A verificação e validação de sensores é essencial para otimizar a confiabilidade e operação, bem como economizar gastos com os processos monitorados. O desenvolvimento de sistemas de monitoramento de instrumentos e verificação de calibração de sensores para processos complexos requer um modelo empírico que forneça estimações das medições do processo. As diferenças residuais entre estimações e medições são avaliadas para determinar a operação apropriada dos sensores no processo.

Este trabalho apresenta duas metodologias aplicadas na modelagem de um sistema de predição. Para validar os modelos de predição, é utilizado um conjunto de dados de sensores de temperatura instalados em câmaras de combustão de turbinas a gás de uma estação de compressão de gás natural da Transportadora Brasileira Gasoduto Bolívia-Brasil S.A., mas podendo ser estendido para qualquer outro processo.

Palavras Chave: Modelagem, Predição, Detecção de Falta, Confiabilidade, Manutenção Preditiva, Desempenho do Processo, Planejamento de Manutenção, etc.

Abstract

The verification and validation of sensors is essential for optimizing the reliability, performance, and cost savings of monitored processes. The development of Instrument Surveillance and Calibration Verification of sensors systems for complex processes requires an empirical model to provide estimations of the process measurements. The residual differences between the estimations and measurements are then evaluated to determine the proper operation of the process sensors.

This work presents two modeling approach which predict modeling technique. For validate the prediction models, a group of data is used of sensor of temperature installed in combustion chambers of turbines to gas of a station of compression of natural gas of the Transportadora Brasileira Gasoduto Bolívia-Brasil S.A., but its use can be extended to any other process.

Keywords: Modelling, Prediction, Detection of Falt, Reliability, Prediction Maintenance, Acting of the Process, Planning of Maintenance, etc.

¹ Engenheiro Eletricista graduado pela Universidade Federal do Mato Grosso do Sul (UFMS), Mestrando em Engenharia Elétrica com ênfase em Sistemas de Controle pelo Departamento de Engenharia Elétrica da Universidade Federal do Mato Grosso do Sul, 02 anos de experiência profissional em engenharia de planejamento de manutenção em empresa de grande porte na área de transporte de gás natural. Atualmente Engenheiro de Planejamento de Manutenção na Gerência Regional Centro-Oeste (GRCO) da Transportadora Brasileira Gasoduto Bolívia Brasil S.A. (TBG).
rsanches@tbg.com.br.

1. Introdução

Sistemas de predição e detecção de falta são na maioria das vezes ferramentas que utilizam técnicas de modelagem auto-associativas baseadas em redundância entre sinais para validação de resultados coletados nos mais diversos processos. Há vários métodos para construção de modelos preditivos, alguns são baseados em princípios analíticos, porém sua implementação pode ser muito complexa, então normalmente utiliza-se bancos de dados como referência para modelagem de um sistema de predição. Os modelos utilizam técnicas de regressão e podem ser divididos entre modelos paramétricos e não-paramétricos. Técnicas paramétricas utilizam conjuntos de dados fixos para adquirir características paramétricas e após a modelagem do sistema de predição os dados não são mais utilizados (por exemplo, regressão linear). Com técnicas não-paramétricas deve-se manter sempre um conjunto de dados como base para a predição do sinal porque todas as estimações são feitas baseadas neste conjunto (por exemplo, regressão kernel).

A qualidade do modelo é essencial para o bom desempenho das técnicas de predição e detecção de faltas. Normalmente os processos onde se aplicam as técnicas de predição são críticos para a operação ou segurança e sua parada gera elevados custos de manutenção ou até mesmo lucro cessante.

Para este trabalho, foram construídos modelos diferentes de predição e testados em um conjunto de dados reais contendo 24 (vinte e quatro) sensores de temperatura instalados em 4 (quatro) câmaras de combustão de turbinas a gás do fabricante SOLAR TURBINES, modelo TAURUS 60, que fazem parte de um sistema de compressão de gás natural instalado na Estação de Compressão (ECOMP) de Campo Grande – MS (vide Figura 1.1), pertencente a Gerência Regional Centro Oeste da Transportadora Brasileira Gasoduto Bolívia-Brasil S.A. (TBG/GRCO).



Figura 1.1 – Vista aérea da Estação de Compressão de Campo Grande - MS.

Observa-se na Figura 1.2 os 6 sensores de temperatura instalados ao redor da câmara de combustão da turbina.



Figura 1.2 – Ilustração da distribuição dos sensores na câmara de combustão das Turbinas TAURUS 60.

2. Descrição do conjunto de dados

O conjunto de dados de sensoriamento utilizado neste trabalho foi coletado entre os dias 01/05/2005 e 31/07/2005. O período de amostragem foi definido como sendo de 1 (um) minuto, totalizando 53000 amostras. O número total de sensores de temperatura contidos no conjunto de dados é 24 (vinte e quatro), sendo que originalmente estão distribuídos em 4 (quatro) grupos contendo 6 (seis) sensores de temperatura em cada grupo.

Os sensores foram distribuídos aleatoriamente na matriz de dados, sendo que os sensores da câmara de combustão “A” são os sensores “1, 5, 9, 13, 17, 21” da matriz de dados, os sensores da câmara de combustão “B” são os sensores “2, 6, 10, 14, 18 e 22” da matriz de dados, os sensores da câmara de combustão “C” são os sensores “3, 7, 11, 15, 19 e 23” da matriz de dados e são os sensores da câmara de combustão “D” são os sensores “4, 8, 12, 16, 19 e 24” da matriz de dados. Na Figura 2.1 pode-se visualizar a dinâmica de trabalho dos sensores contidos no conjunto de dados.




Figura 2.1 - Dinâmica de trabalho dos sensores.

3. Treinamento e teste dos modelos de predição

Depois de filtrar e tratar o conjunto de dados foi gerado uma matriz de treinamento contendo as primeiras 20.000 (vinte mil) amostras e mantendo as demais 33.000 (trinta e três mil) amostras em uma matriz de dados de teste. A matriz de treinamento será utilizada para a geração dos modelos de predição e a matriz de teste será utilizada para avaliação dos modelos.

Além da matriz de dados original, foi produzida uma outra matriz de dados contendo desvios acumulativos em alguns sensores, gerando problemas de funcionalidade na resposta dos grupos de sensores, possibilitando a verificação da eficiência dos modelos predição em situações de anormalidade nos sinais.

4. Correlação e agrupamento entre sensores

Relações lineares são mais fáceis de serem identificadas do que relações não-lineares, além disso, relações lineares podem ser extrapoladas sem erros significativos. A maioria dos sensores não tem relações lineares, então é importante para assegurar uma boa modelagem de predição, que os sensores agrupados tenham um bom grau de correlação entre si. Esta aproximação evita a criação de um modelo global com uma relação muito complexa entre os sensores. Quando se utiliza sensores mais correlatos criam-se modelos mais simples para cada grupo de sensores observados.




Figura 4.3 – Grupos de sensores para grau de correlação 0,6.

No processo de agrupamento dos sensores utiliza-se a matriz de coeficientes de correlação entre os sensores, a formação dos grupos pode variar de acordo com o grau de correlação definido para o agrupamento. A variação do grau de correlação entre os sensores também afeta diretamente no número de grupos e no número de sensores contidos nestes grupos. Outro modo de se agrupar os sensores observados é analisar os diagramas físicos das instalações e o local respectivo de cada sensor no processo, para isso, deve-se conhecer bem o processo e o comportamento de cada sensor.

Na ocorrência de um baixo valor de coeficiente de correlação de um sensor entre todos os outros sensores, o sensor não fará parte de grupo algum, consequentemente o sensor não será predito e nem contribuirá com nenhum modelo de predição. Todos os sinais que permanecem constantes também são afastados, porque sinais constantes não têm informação significativa para uso em predição.

Para um agrupamento com grau de correlação fixado em 0.6, foram identificados 4 (quatro) grupos contendo 6 sensores em cada grupo respectivamente, esta formação de grupos pode ser visualizada na Figura 4.3.

Analisando os grupos gerados, obtivemos os seguintes sensores por grupo: no grupo “A” os sensores “1, 5, 9, 13, 17, 21”, no grupo “B” os sensores “2, 6, 10, 14, 18 e 22”, no grupo “C” os sensores “3, 7, 11, 15, 19 e 23” e no grupo “D” os sensores “4, 8, 12, 16, 19 e 24” como pode ser visto na Figura 4.3. Com esse resultado, pode afirmar que a técnica de agrupamento por correlação utilizada funcionou bem, gerando os grupos com os sensores esperados.

5. Modelagem

Utilizou-se neste estudo dois métodos para construção dos modelos de predição: Ridge Regression [1] (Regressão Linear) e Kernel Regression [2]. Os modelos foram testados e treinados sob as mesmas condições, fornecendo assim informações confiáveis para geração dos indicadores de desempenho aplicados neste trabalho.

5.1. Ridge Regression (Regressão Linear)

O propósito de Regressão de Ridge inicia-se na Regressão Linear que é definida como sendo a técnica de encontrar uma matriz M que multiplicada por um conjunto de sinais de entrada X , fornece um sinal de saída Y que é a resposta predita do modelo para o sistema e que pode ser mostrada pela seguinte equação:

$$Y = Mx X \quad (1)$$

Para se calcular M como uma solução normal deve-se ter Y no tempo como inversa da matriz X . Portanto, X tem normalmente mais linhas do que colunas (mais amostras que o número de sensores) e então não é possível inverter esta matriz. Desta forma, utiliza-se uma matriz pseudo-inversa para a solução do sistema.

$$M = (X^T X)^{-1} X^T Y \quad (2)$$

A matriz XTX também é chamada matriz de covariância. Esta matriz pode ser invertida, mas regularmente essa inversão é ruim, conduzindo a resultados instáveis. Para resolver este problema, os dados devem ser regularizados.

A regressão de Ridge utiliza a mesma equação (2) como solução do problema, somente acrescentando uma matriz de identidade à matriz de covariância para proporcionar sua regularização.

$$M = (X^T X + \alpha^2 . I)^{-1} X^T Y \quad (3)$$

O coeficiente α da equação (3) deve ser ajustado para minimizar o valor dos pesos da matriz M sem influenciar consideravelmente a solução.

5.2. Kernel Regression

Esta técnica é denominada não-paramétrica, sendo que todas as predições são geradas baseando-se no conjunto de dados observado. A função utilizada para a construção do modelo de predição neste caso é uma Gaussiana.

Dado o ponto da amostra a ser predito, o modelo de predição determina a distância entre este ponto e todos os outros pontos no conjunto de dados, uma função Gaussiana é aplicada em torno do ponto amostrado, desta forma, multiplica-se as distâncias dos pontos pelos valores calculados pela Gaussiana para cada ponto, obtendo-se as contribuições (pesos) de cada ponto na formação da predição do ponto analisado. Finalmente a média é terminada como descrito abaixo:

$$Y = \frac{\sum Data . W(Data, X)}{\sum W(Data, X)} \quad (4)$$

É interessante notar que até mesmo se o ponto analisado da amostra estiver deslocado do conjunto de dados, a predição sempre será um valor ao redor do conjunto de dados. Então, é importante que os dados de treinamento representem todos os pontos de operação do sistema.

6. Desempenho e comparação entre modelos

6.1. Cálculo de Desempenho

Os modelos foram testados e comparados através dos seguintes indicativos de desempenho: precisão, robustez e tempo de processamento.

Precisão é o erro quadrático médio entre o sinal predito e o sinal testado.

Robustez é a variação da predição de um sinal acumulado em relação a si mesmo. Um modelo robusto não muda a predição de um sinal mesmo que haja um erro ou desvio no sinal original.

Tempo de processamento depende do computador, mas pode ser calculada uma relação entre os tempos gastos para o processamento de cada modelo de predição.

Considerando um conjunto de dados de entrada sendo multiplicado por uma matriz de identidade (modelo de predição), torna-se um exemplo de solução trivial para um modelo auto-associativo onde a contribuição não é associativa entre os sinais. Então o cálculo de desempenho para este modelo tem um indicativo de precisão muito bom (Precisão = 0), porém, não tem uma robustez boa (Robustez = 1), porque um erro em qualquer sinal será diretamente transmitido ao sinal de predição.

Um modelo auto-associativo bom tem que combinar as contribuições de precisão com robustez. Porém, a melhoria da robustez geralmente conduz a uma perda de precisão. Uma solução para minimizar este problema e o aumento do número de sinais redundantes no conjunto de dados, neste caso estará aumentando o tempo de processamento para a geração da predição.

Os modelos de predição foram gerados e testados para todos os 4 (quatro) grupos de sensores identificados. Desta forma cada modelo de predição apresenta desempenho diferente e independente para cada grupo analisado.

6.2. Comparação entre modelos

Foram testados para cada grupo os modelos de predição do tipo Regressão Ridge e Regressão, mas foi escolhido apenas um grupo dentre os quatro grupos existentes para demonstração ilustrativa dos testes.

Considerando o grupo “A” como grupo a ser analisado, observa-se o seguinte conjunto de dados conforme Figura 6.1.




Figura 6.1 – Dados definidos como sendo os do grupo A.

Com a utilização do modelo baseado em regressão ridge, as respostas são muito precisas para sinais sem divergências (erro acumulativo), considerando o sensor 3 do grupo “A” (sensor 9 do conjunto de dados inicial) pode-se observar o comportamento do sinal do sensor (verde) e o sinal predito através do modelo de regressão ridge para o sensor (azul), como mostrado na Figura 6.2 A.




Figura 6.2 A e B– Sinal real e predito utilizando regressão ridge e kernel.

Aplicando-se para o mesmo sensor um modelo baseado em regressão kernel, as respostas foram mais robustas do que precisas, considerando um sinal sem divergências para o mesmo sensor analisado. Pode-se observar na Figura 6.2 B o sinal (verde) e o sinal predito (azul) através do modelo de regressão kernel.

Para o mesmo sensor 3 do grupo “A” foi adicionado um desvio acumulativo (azul) no sinal original (verde) para teste dos modelos de predição. Este desvio pode ser visto na Figura 6.3.




Figura 6.3 – Sinal real e sinal com desvio acumulativo.

Aplicando-se o modelo de predição baseado em regressão ridge para os dados de sinal com desvio acumulativo associado (azul) no sensor 3 do grupo “A”, o resultado foi um sinal de predição (verde) tendencioso ao erro acumulativo inserido no sinal do sensor original (vermelho), como mostra a Figura 6.4 A.




Figura 6.4 A e B – Sinal com desvio, sinal real e sinal predito (regressão ridge e kernel).

Utilizando-se o modelo de predição baseado em regressão kernel, o resultado foi um sinal de predição robusto sem qualquer vestígio de tendência ao erro acumulativo inserido no sinal do sensor original, isso pode ser observado através da Figura 6.4 B.

Observando os dados de experimento deste trabalho, verifica-se através da Figura 6.5 que o modelo de predição baseada em regressão ridge mostrou-se mais preciso e menos robusto (quanto mais próximo do zero, mais preciso é o modelo de predição), o modelo de predição baseado em regressão kernel mostrou-se mais robusto e menos preciso (quanto mais próximo do zero, mais robusto é o modelo de predição).

Ainda através da Figura 6.5 pode-se observar que o tempo de processamento exigido pelo modelo de predição baseada na técnica de regressão kernel é sensivelmente mais elevado do que os demais modelos. Isso se deve a estrutura de predição exigida pelo modelo.

A utilização da técnica de modelagem baseada na regressão ridge gera modelos mais precisos em condições normais para os sensores, a modelagem baseado em regressão kernel tem por característica maior sua robustez. A regressão kernel é computacionalmente mais pesada e pode ser um fator limitante em um sistema de monitoramento on-line com alta taxa de amostragem.

Cada técnica tem características diferentes e não é trivial a determinação da melhor técnica a ser usada para cada sistema analisado.




Figura 6.9 – Indicativos de desempenho aplicados aos modelos.

7. Detecção de Falhas

Para todos os modelos foi adotado que a diferença entre a medida do sensor com desvio acumulativo e a saída da predição equivalente ao sensor será o resíduo entre o valor estimado e o valor medido [4]. O valor de tal resíduo poderá ser usado como um indicador da necessidade de calibração ou substituição do sensor analisado. Se o valor absoluto do resíduo for maior que o limiar de detecção de falta definido, o sinal é considerado como uma falta [3][5]. No caso de detecção de faltas o sinal referente ao sensor é eliminado da entrada do processo e em seu lugar é adicionado o sinal de saída do sensor gerado pelo modelo de predição. O sinal original do sensor em falta continua sendo monitorado e somente fará parte novamente da matriz de sensoriamento quando entrar na zona de banda definida para o sistema de detecção de falta. Quando isso acontecer o sinal gerado pelo modelo de predição é substituído pelo sinal do sensor. Desta forma é possível realizar intervenções nos sensores sem que o comportamento do sistema em que o mesmo faz parte seja comprometido circunstancialmente.

Considerando ainda o grupo “A” como grupo a ser analisado e definindo um limiar de 50°C superior (verde) e -50°C inferior (azul escuro) ao sinal original (azul claro) como limiar para detecção de falta e adicionando um desvio acumulativo no sensor 3 (vermelho), tem-se os resultados mostrados pela Figura 7.1 A.

A Figura 7.1 B ilustra o momento em que o modelo de detecção de falta identifica o desvio elevado do sensor na banda superior e automaticamente retira o sinal do sensor 3 do processo, adicionando o sinal de predição do sensor 3 gerado pelo modelo de regressão kernel.

O sinal de predição será mantido pelo sistema de detecção de faltas até que se identifique que o sinal do sensor 3 retornou a faixa de medição correta (entre as bandas superior e inferior de detecção). Neste momento, o sinal de predição do sensor 3 é retirado e o sinal original do sensor 3 é adicionado novamente ao processo.

Conforme observado nas Figuras 7.1 A e B, a técnica de predição de sinais e sua aplicação junto a detecção de faltas em sensores tornam o processo mais robusto a paradas do sistema por falta de sensoriamento. Mesmo quando pensamos em ambientes onde possa ocorrer um acréscimo de ruídos a medição dos sinais.




Figura 7.1 A e B – Definição do limiar de detecção e detecção de faltas.

Esta metodologia pode ser aplicada com eficiência já que o chaveamento entre a substituição do sinal do sensor identificado como estando em falta e o seu sinal predito é feito instantaneamente, sem causar oscilações elevadas na dinâmica do processo.

8. Conclusão

O agrupamento é muito importante para a qualidade dos modelos de predição, desta forma é muito importante certificar-se de que não há sensores deslocados dentro dos grupos gerados. Uma forma de fazer esta certificação é a análise adequada dos diagramas da planta relacionados ao processo.

Um número pequeno de sensores deslocados pode aumentar o erro da solução de predição e até acarretar em dificuldades para descoberta de faltas. Um grande número de sensores em um mesmo grupo pode aumentar a discrepância da predição devido à complexidade da relação entre os sensores. Por isto não é bom trabalhar com modelos baseados em grupos grandes.

Neste trabalho, não houve sensores afastados, mas o afastamento dá-se na maioria das vezes devido aos sensores não serem correlatos entre os demais sensores do conjunto de dados. Neste caso, pode ser muito difícil ou até impossível de se fazer as predições para estes sensores em particular, caso eles sejam importantes para o processo, então uma pesquisa mais específica pode ser feita para descobrir como prever de forma confiável estes sensores.

Qualquer um dos modelos preditivos utilizados podem ser aplicados ao processo analisado, ficando a critério do projetista verificar as exigências de desempenho desejadas ao qual o modelo deverá se encaixar melhor (precisão, robustez ou tempo de processamento).

Este tipo de predição pode ser aplicado em um monitoramento on-line com um tempo de amostragem um pouco maior (por exemplo: uma amostra a cada 5 minutos). A detecção de faltas está diretamente relacionada com os limiares de banda definidos. Estes limiares devem ser especificados respeitando os limites de segurança e operação do processo.

A maioria das faltas pontuais ocorre devido a picos de alta discrepância no resíduo ocasionado por mau contato nos sensores, ruído, etc. Para minimizar este problema, pode utilizar filtros para retirada de sinais ruidosos contido no conjunto de dados coletados antes da submissão dos dados aos modelos de predição e detecção de faltas.

9. Referências

- [1] CHERKASSKY, V. AND MULIER, F., *Learning from Data*, John Wiley & Sons, 1998.
- [2] CHRISTOPHER G. ATKESON, ANDREW W. MOOREY, AND STEFAN SCHAAZ. Locally Weighted Learning. 1999.
- [3] BASSEVILLE, M. *Detecting changes in signals and systems - A survey*. Automatica, 1988.
- [4] MAHMOUD, MUFEED; JIANG, JIN; ZHANG, YOUNMIN. Active Fault Tolerant Control Systems – Stochastic Analysis and Synthesis. Springer, 2003.
- [5] MIKE LIND RANK, HENRIK NIEMANN, *Norm based threshold selection for fault detectors*, AACC 1998.