

Copyright 2005, Instituto Brasileiro de Petróleo e Gás - IBP

Este Trabalho Técnico Científico foi preparado para apresentação no 3º Congresso Brasileiro de P&D em Petróleo e Gás, a ser realizado no período de 2 a 5 de outubro de 2005, em Salvador. Este Trabalho Técnico Científico foi selecionado e/ou revisado pela Comissão Científica, para apresentação no Evento. O conteúdo do Trabalho, 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, Sócios e Representantes. É de conhecimento e aprovação do(s) autor(es) que este Trabalho será publicado nos Anais do 3º Congresso Brasileiro de P&D em Petróleo e Gás.

UMA NOVA ESTRATÉGIA DE MODELAGEM PARA MONITORAMENTO DE INSTRUMENTOS E VERIFICAÇÃO DE CALIBRAÇÃO USANDO REDES NEURAIS ARTIFICIAIS

João Onofre Pereira Pinto¹, Alexandra Maria Almeida Carvalho Pinto¹, Gilberto Shimada Tatibana¹
Rogério Orlandeli Sanches¹, Benjamim Novais Carrasco², Nancy Flora³, J. Wesley Hines⁴

¹ Universidade Federal de Mato Grosso do Sul, Cidade Universitária s/n – C. P. 549,
Cidade Universitária, CEP: 79.070-900, Campo Grande – MS, jpinto@nin.ufms.br,
tatibana@nin.ufms.br, amjoiv@hotmail.com, rsanches@tbg.com.br

² PETROBRAS - Petróleo Brasileiro S.A. - Av. República do Chile, 500 / 22o
20.031-912 Rio de Janeiro - RJ, bc@petrobras.com.br

³ TBG - Transportadora de Gás Natural Bolívia-Brasil S.A. - nancy@tbg.com.br

⁴ The University of Tennessee, Maintenance and Reliability Center, 506 East Stadium Hall
Knoxville, TN 37996-0750, EUA, jhines2@utk.edu

Resumo – A verificação e validação dos sensores são essenciais para otimizar confiabilidade e operação, bem como economizar gastos dos processos monitorados. O desenvolvimento de Sistemas de Monitoramento de Instrumentos e Verificação de Calibração para processos complexos requer um modelo empírico para fornecer estimações das medições do processo. As diferenças residuais entre estimações e medições são avaliadas para determinar a operação apropriada dos sensores do processo. Este trabalho apresenta uma metodologia empírica de modelagem que combina uma técnica de modelagem bi-linear, Mínimos Quadrados Parciais, com as habilidades da função de aproximação universal de Redes Neurais Artificiais com uma única camada oculta não-linear. Esta metodologia, conhecida como Redes Neurais por Mínimos Quadrados Parciais, é comparada à conhecida Rede Neural Artificial Auto-associativa. Para validar a estratégia, resultados envolvendo dados de um sistema de geração de energia elétrica serão mostrados. Para dados relativos a 84 sinais de processo, foi obtida uma estimativa de erro média de aproximadamente 1% do valor medido, níveis de alarme de fora de calibração de aproximadamente 2,5% para o sistema da caldeira e aproximadamente 1% para sistema de turbina. Esta metodologia apresentada será futuramente aplicada a uma estação de compressão de gás natural da Transportadora Brasileira Gasoduto Bolívia-Brasil S.A., mas poderá ser estendida para qualquer outro processo.

Palavras-Chave: Rede Neural Artificial Auto-associativa (RNAA), Rede Neural por Mínimos Quadrados Parciais (RNMQP), Sensoriamento Inferencial, Calibração de Sensor

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 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 an empirical modeling approach which combines a bilinear modeling technique, Partial Least Squares, with the universal function approximation abilities of single hidden layer non-linear artificial neural networks. This approach, referred to as Neural Network Partial Least Squares, is compared to the common Autoassociative Artificial Neural Network. In order to validate the approach, results using data from a electrical power is given. Results are presented for 84 process signals with an average estimation error of ~1% of the measured value, and out-of-calibration alarm levels at ~2.5% drift for the boiler system, and ~1% for the turbine system. This approach will be applied to a compression station of the Transportadora Brasileira Gasoduto Bolívia-Brasil S.A., but its use can be extended to any other process.

Keywords: Autoassociative Artificial Neural Network (AANN), Neural Network Partial Least Squares (NNPLS), Inferential Sensing, Sensor Calibration

1. Introdução

O objetivo desta pesquisa é desenvolver e implementar um sistema que monitore sensores de processo e produza valores corretos caso os sensores reais sejam avaliados como descalibrados. O sistema desenvolvido é referido como um sistema de Vigilância de Instrumento e Verificação de Calibração (VIVC). O monitoramento de instrumentos aumenta a confiabilidade de decisões e cálculos baseados nas medições do processo através de monitoramento contínuo de saídas residuais de um sistema VIVC. As saídas residuais correspondem à diferença entre os valores medidos e os valores estimados, que são fornecidos pelo modelo empírico embutido no sistema. A Verificação de Calibração assegura a operação apropriada dos sensores do processo, e indica quando é necessária uma recalibração do sensor, através da avaliação estatística contínua das saídas residuais.

Dois sistemas VIVC para a planta completa: um modelo com Rede Neural Artificial Auto-associativa (RNAA) e o modelo com Rede Neural por Mínimos Quadrados Parciais (RNMQP) foram desenvolvidos, automatizados e testes para um sistema de geração de energia elétrica foram comparados. O algoritmo RNMQP foi escolhido por apresentar facilidade de desenvolvimento e implementação, bem como por fornecer resultados consistentes com grandes conjuntos de dados colineares. Esta metodologia apresentada será futuramente aplicada a uma estação de compressão de gás natural da Transportadora de Gás Natural Bolívia-Brasil, mas poderá ser estendida para qualquer outro processo.

2. Monitoramento de Instrumentos e Verificação de Calibração

Uma significativa quantidade de trabalhos tem sido apresentada usando Redes Neurais Artificiais (RNA) para modelar sistemas de processo. Para o propósito de VIVC, uma estrutura de RNA comumente usada é a Rede Neural Auto-associativa (RNAA) (Dong, 1994, Hines, 1998, Nabeshima, 1995, Upadhyaya, 1992). A capacidade de RNAs para modelar relações não-lineares entre dados tornou-se uma característica indispensável de modelos de processos, e tem melhorado sua precisão de predição comparado com seus modelos lineares equivalentes. Existem diversos pontos significativos considerados no desenvolvimento de modelos de processos usando RNAs, os quais incluem seleção de variável, seleção da arquitetura, sensibilidade, e os efeitos da colinearidade em predições de redes neurais (Qin, 1997).

A combinação de Mínimos Quadrados Parciais (MQP), que também se refere como Projeção de Estruturas Latentes e RNAs, conduz a um método alternativo de modelagem empírica para sistemas VIVC. A técnica MQP padrão, inicialmente desenvolvida por Wold (1966), é uma técnica onde os dados de entrada (X) e de saída (Y) são transformados para sistemas de diferentes coordenadas, baseados na covariância entre X e Y. A transformação linear do método MQP fornece uma redução supervisionada dos dados do processo do sistema, enquanto preserva a informação de maior relevância para o(s) sensor(es) específico(s) a ser(em) modelado(s). Em adição, o reduzido conjunto de dados é derivado de tal modo que as variáveis transformadas são ortogonais, eliminando assim os conhecidos problemas associados a grandes conjuntos de dados colineares em modelagem linear (Wold, 1984), bem como em RNAs (Qin, 1997). Em seguida a esta transformação, o método MQP prescreve uma regressão linear para relacionar os dados reduzidos do(s) sensor(es) a ser(em) modelado(s). Trocando a regressão linear com uma RNA com uma única camada oculta, relações não-lineares também podem ser incorporadas ao modelo.

Em anos recentes, o uso de RNAs com alimentação direta em conjunto com técnicas padrão de MQP têm adquirido importância, sendo muitas vezes referido como método dos Mínimos Quadrados Parciais Não-Lineares (MQPNL) (Holcomb, 1992, Malthouse, 1997, Qin, 1992, Rasmussen, 2000, Xu, 1997). Um método alternativo usando Redes de Função de Base Radial, ou simplesmente Redes Neurais Radiais (MQP/RBF) também foi proposto (Wilson, 1997). Para evitar confusão entre as técnicas de MQPNL incorporando quadráticas e *splines* (Baffi, 1999a, Wold, 1989, Wold 1992), o termo Rede Neural por Mínimos Quadros Parciais (RNMQP) será adotado sempre que se referir à combinação de MQP e RNAs, como têm sido feito em outros trabalhos (Baffi, 1999b, Qin, 1996).

2.1. Visão Geral da Modelagem de RNAA

Uma RNAA é uma rede neural na qual as saídas são treinadas para emular as entradas sobre um intervalo dinâmico apropriado. As relações entre as entradas e as saídas são embutidas nos pesos da RNAA, que são determinadas através de um algoritmo de aprendizagem especificado. O algoritmo de aprendizagem é utilizado em conjunto com o conjunto de dados de treinamento para obter os pesos embutidos. A arquitetura de RNAA mais comumente usada em VIVC é a arquitetura com três camadas ocultas, totalmente conectadas, alimentação direta (Dong, 1994, Hines, 1998) originalmente proposta por Kramer (1992). A arquitetura com três camadas escondidas contém quatro camadas de neurônios, sendo a quarta camada uma camada de saída linear. Todos os neurônios nas três camadas ocultas contêm funções de ativação não-lineares.

2.2 Visão Geral da Modelagem de RNMQP

O projeto do sistema VIVC baseado em RNMQP consiste de um conjunto de modelos inferenciais. Cada parâmetro a ser monitorado requer um modelo inferencial separado. Um modelo inferencial infere a predição de uma medida de um sensor específico, baseado em sensores correlacionados. Os valores dos sensores que são usados como entradas para cada modelo inferencial incluem todos os valores dos sensores, exceto os do sensor que está sendo modelado. Um esquema de um modelo inferencial RNMQP é mostrado no Figura 1.

A base teórica para MQP é explicada em detalhes na literatura (Geladi, 1986, Hoskuldsson, 1995, Martens, 1989). Os dados são escalonados para se obter uma média igual a zero, e um desvio padrão unitário, antes de sua introdução ao algoritmo MQP. O algoritmo MQP é iterativo e decompõe sequencialmente o conjunto de dados de

entrada em vetores ortogonais. O conjunto de dados de saída é também decomposto em um novo conjunto de vetores, no entanto, a ortogonalidade não é uma restrição. As transformações do conjunto de dados de entrada, e do conjunto de dados de saída, em seus respectivos vetores t e u , são derivados de tal modo que o primeiro conjunto de vetores atinge a máxima covariância entre o conjunto de entrada (X) e o conjunto de saída (Y). O algoritmo padrão MQP prescreve então uma regressão linear do vetor de entrada em um vetor de saída. A variabilidade no conjunto de dados de entrada é explicada pela primeira entrada, a qual é então subtraída do conjunto de dados de saída, resultando em uma saída residual. As entradas e saídas residuais representam a variabilidade restante, da qual a informação adicional pode ser extraída em torno da covariância entre os conjuntos de entrada e saída. O segundo conjunto de vetores é então determinado de tal modo que, a variância máxima na entrada residual relacionada à saída residual é capturada, com a restrição de ortogonalidade com o vetor de entrada prévio. Depois que o segundo conjunto de vetores é obtido, os resíduos de entrada e saída são reduzidos novamente por uma variabilidade, explicada pelo segundo conjunto de vetores. Este processo iterativo continua até que a informação deixada nas matrizes residuais seja desprezível, e possa ser atribuída a ruídos, ou variação não-relacionada com respeito à saída desejada. Baseado na precisão desejada do modelo, e no nível de ruído presente nos dados, o número de vetores de entrada a ser incluído no modelo pode ser determinado.




Figura 1. Esquema de uma unidade inferencial RNMQP.

Para estender o algoritmo MQP de modo a incorporar redes neurais, as regressões lineares entre cada par de vetores são trocadas por RNAs de Entrada Simples Saída Simples (RNA ESSS). Cada RNA ESSS foi treinada usando o algoritmo de treinamento gradiente conjugado escalonado (Moller, 1993), com uma única camada escondida com duas funções de ativação tangente hiperbólica, e um único neurônio linear de saída. O número de RNAs ESSS necessárias para um dado modelo inferencial MQPNL é igual ao número de vetores de entrada ortogonais retidos no modelo, e é menos significativo que o número de sensores da entrada. Os dados de treinamento e dados de validação foram análogos em taxas de amostragem, apesar de não existirem pontos em comum nos dois conjuntos de dados. Treinamento de validação cruzada foi usado em todos os casos para prever sobre-treinamento. O número máximo de componentes ortogonais a serem retidos como entrada para cada modelo inferencial foi de 25. O número ótimo para usar no modelo final, para cada unidade inferências, foi determinado baseado em erros de predição no conjunto de dados de validação.

2.3 Teste de Razão de Probabilidade Sequencial

Um método estatístico chamado de Teste de Razão de Probabilidade Sequencial (TRPS) (Wald, 1945) foi utilizado para checar a situação do sensor baseado nas saídas residuais. O TRPS determina se os residuais são de uma distribuição estatística normal ou anormal. Diferente de outros métodos estatísticos, que precisam de novos cálculos para média e covariância a cada nova amostra, o TRPS atualiza continuamente os valores da razão de igualdade probabilística. Esta porção indica uma situação do sensor avaliando a probabilidade de que, o resíduo atual pertença a uma distribuição normal ou anormal, baseada na informação histórica. Quando um sensor está operando corretamente, o resíduo deveria ter uma média zero, e a variância ser comparada a do sensor 1. Se o sensor está com desvio de medida, o resíduo indica alteração. Em decorrência da alteração na média do resíduo, a razão de igualdade aumenta. Se a razão de igualdade aumenta acima de uma certa fronteira pré-definida, é mais provável que os resíduos sejam de uma distribuição faltosa do que de uma distribuição não faltosa, e o sensor é classificado com fora de calibração.

2.4 Vantagens do Projeto RNMQP para VIVC

O projeto de RNAA requer o agrupamento de sensores em conjuntos correlatos de 15 a 25, e a determinação do número ótimo de neurônios nas 3 camadas escondidas. O projeto da RNMQP não requer o agrupamento de sensores, uma vez que ele é capaz de aceitar qualquer número de entradas, com limitação de implementação prática somente pelos limites de memória computacional. A disponibilidade de toda informação possível a respeito de um dado sensor do conjunto de dados completo dá uma vantagem adicional para o projeto da RNMQP porque os sensores correlacionados oferecem a necessária redundância para a redução de erros grosseiros (Qin, 1997), e também reduz a variância nas estimações na média dos sinais. Limitando-se de 15 a 25 sensores, para um dado modelo de RNAA, as estimações são mais sensíveis a ruídos e valores errôneos, do que em um modelo RNMQP equivalente.

O projeto de RNAA requer a determinação do número ótimo de neurônios ocultos em cada camada oculta. Algoritmos iterativos foram desenvolvidos para auxiliar na determinação da arquitetura ótima, no entanto, isto é uma tarefa que demanda tempo em função dos longos tempos de treinamento, necessários para RNAs relativamente grandes. A tarefa de selecionar o número ótimo de neurônios ocultos em um projeto RNAA é eliminada virtualmente com o projeto de RNMQP. É preciso determinar somente o número de neurônios ocultos nas RNAs ESSS. Experiência

prática mostrou que usando 2 neurônios ocultos, obtém-se um número adequado de parâmetros livres para representar adequadamente as relações entre os pares de vetores transformados.

A colinearidade pode criar uma situação onde soluções de peso da RNA significativamente diferentes resultam em mudanças insignificantes no erro de treinamento, assim, a estabilidade da solução torna-se uma preocupação. Uma vez que novos dados sempre incluem ruídos de medições, modelos RNA derivados de dados colineares podem exibir variâncias de predição maiores que variâncias de medições (Hines, 2000). O uso de redes neurais ESSS no projeto de RNMQP elimina os problemas associados com a colinearidade em modelos RNAs. A transformação de um dado de entrada para um novo conjunto de vetores ortogonais, ordenados para conter a covariância máxima com respeito a variável de resposta, fornece informações adicionais que a maioria da variância explanatória nos dados de entrada, e é capturada nos poucos primeiros vetores transformados. Assim, a colinearidade não é mais uma preocupação, apesar da redundância necessária dos sensores correlacionados ser mantida.

Uma desvantagem adicional do projeto de RNAA requer sobre dimensionamento externo no treinamento em decorrência de muitos mínimos locais na superfície complexa do erro, resultante do grande número de pesos. Em RNMQP, as RNAs usadas têm somente poucos pesos, o que resulta em superfícies de erro que são facilmente percorridas por algoritmos de treinamento simples e de convergência rápida.

2.5 Implementação e Resultados em um Ambiente On-line

O processo de instalar o sistema em um ambiente on-line levou à descoberta de muitas dificuldades. Os dados fornecidos pela estação de geração de energia elétrica, e que foram usados para o desenvolvimento do sistema foram amostras de um minuto cobrindo 17 dias em janeiro de 1988, 5 dias em junho de 1999, 7 dias em agosto de 1999, e 6 dias em fevereiro de 2000. Os parâmetros resultantes para o sistema VIVC foram inseridos em uma interface gráfica do Labview, com monitoramento de dados de um servidor de dados instalado na planta. Em poucos dias, muitos alarmes de fora de calibração foram produzidos pelo sistema VIVC. Uma avaliação dos dados indicou mudanças nas relações de covariância entre os dados usados para desenvolver o modelo, e os dados correntes que estavam sendo retirados do servidor. Algumas destas mudanças são atribuídas a variações de condições de operação no decorrer do ano. O sistema VIVC foi implementado on-line pela primeira vez em abril de 2000. Nenhum dado de abril do ano de 1999 foi usado para desenvolver o modelo e, assim, as inter-relações entre os sinais durante condições de tempo semelhante, não foram adequadamente representadas nos dados usados para desenvolver o modelo RNMQP. Em muitos casos, as relações entre os sinais permaneceram relativamente inalteradas e, para a maioria dos sinais, as estimações do sistema VIVC foram suficientemente precisas. No entanto, em diversos momentos em que os valores de covariância entre sinais exibiram uma mudança significativa do dado histórico para o dado atual, em abril de 2000. Neste caso extremo, a covariância entre duas variáveis foi de -0,7 quando o dado de desenvolvimento foi avaliado, e de +0,05 quando o dado atual estava sendo avaliado. Em decorrência da transformação externa da dependência do algoritmo RNMQP nas relações de covariância nos dados de treinamento para determinar os pesos da transformação, torna-se óbvio que estas mudanças terão efeitos adversos na precisão da estimacão do modelo. Outra dificuldade com os sinais da planta é que durante diferentes períodos, diferentes combinações das bombas de alimentação da caldeira (BAC) foram usadas. Por exemplo, durante janeiro de 1998 BACs A e B estavam funcionando enquanto C estava em modo de espera. Em agosto de 1999, BAC A estava em modo de espera enquanto que B e C estavam funcionando. É muito difícil monitorar estes sinais individualmente, uma vez que o desenvolvimento de dados para estes sinais contém períodos intermitentes de valores que não aparecem. Para estas três bombas, um valor geral poderia ser colocado para o sistema como a soma das três, apesar de que isto eliminaria a capacidade para isolar um sensor BAC unitário fora de calibração. Uma metodologia alternativa poderia ser implementada para determinar quais bombas estão em uso correntemente de tal modo que, estimacões não são geradas por bombas em modo de espera, o que resultaria em significativa quantidade de resíduos, produzindo alarmes fora de calibração. Esta metodologia requereria dados históricos suficientes para todas as bombas, durante condições de operação normais.

Para lidar com os problemas apresentados acima, dados foram coletados na terceira semana de abril de 2000. O conjunto original de dados de desenvolvimento foi então combinado com os novos dados, os dados das bombas BAC foram removidos e o modelo RNMQP foi treinado novamente. Os parâmetros atualizados do modelo foram colocados na interface gráfica, e o sistema VIVC foi então reposto para adquirir os dados diretamente do servidor de dados. Os resultados apresentados abaixo são baseados na performance do modelo VIVC, durante a última semana de abril de 2000. Os resultados obtidos dos dois modelos empíricos competindo, RNAA e RNMQP, foram similares tanto na precisão de estimacão quanto na detecção de desvio de calibração. Por causa dos benefícios da técnica de modelagem RNMQP, os resultados mostrados serão somente do modelo RNMQP. A Tabela 1 mostra um conjunto representativo dos resultados para 12 sinais que foram identificados como sendo de importância primária, por representarem a alimentação de um sistema de automático de detecção de perda.

Para 2 dos sinais, a estimacão de erro foi maior que 2%. Enquanto isto não é usualmente alto, avaliação futura pode indicar que dados adicionais de desenvolvimento poderiam reduzir discrepâncias em relações de covariância atual e histórica, entre estes dois sinais e os sinais restantes. Os níveis de detecção de desvio são dependentes da estimacão de erros, por causa das diferenças de resíduos adquiridas durante o desenvolvimento do modelo utilizado no ajuste da média faltosa do TRPS. A performance do sistema VIVC é limitada pela precisão dos aparelhos de medição que fornece os valores de entrada do sistema. Em muitos casos, a baixa performance do sistema VIVC pôde ser relacionada à confiabilidade e precisão do aparelho de medição.

Para demonstrar a operação do sistema VIVC na produção de alarmes fora de calibração, um desvio de 1% por dia foi induzido na unidade de geração do sinal bruto, conforme mostrado na Figura 2. Os resíduos entre as medições com desvio artificialmente induzido, e as estimações do sistema VIVC, são mostrados no gráfico do meio e os valores

Tabela 1. Sistema VIVC baseado em RNMQP para estimação de erros e detecção de níveis de desvio

Sinal	Estimação de Erro	Nível de detecção de desvio
Fluxo de Ar de Combustão A1	0.70%	4.77%
Fluxo de Ar de Combustão B1	0.96%	3.53%
Geração de Energia da Unidade	0.32%	2.20%
Carga de Serviço da Estação	0.48%	1.87%
Pressão do Primeiro Estágio - A	0.42%	1.20%
Pressão do Primeiro Estágio - B	0.45%	1.20%
Pressão do Desaerador	0.80%	2.74%
Pressão de Sucção do Ventilador – ID A	0.77%	4.00%
Pressão de Sucção do Ventilador – ID B	2.47%	5.65%
Pressão da Fornalha RH após Econ	2.25%	3.37%
Temperatura 1 da Saída de Superaquecimento	0.51%	0.93%
Temperatura 2 da Saída de Superaquecimento	0.50%	0.68%

TRPS são mostrados no gráfico de baixo. Nenhum dos outros sinais foi alterado para esta simulação. O gráfico dos resíduos mostra um aumento contínuo na magnitude, indicando que a estimação do sistema VIVC baseada nos sinais não alterados relacionados permanecem consistentes e não é afetado pelo desvio induzido. Depois de 1,7 a 1,8 dias, ou equivalentemente a um desvio de sinal de 1,7 a 1,8%, os valores TRPS começam a indicar que o sinal de geração bruta da unidade está começando a fornecer medições não características. Um alarme fora de calibração é produzido depois que o nível do desvio alcança 2,2%. Sob condições de alarme, os valores medidos dos sinais alarmados, que são as entradas do sistema VIVC, são substituídos pelas estimações correspondentes, de tal modo que as estimações dos outros sinais não são degradadas.




Figura 2. Resultados de um sistema VIVC RNMQP para uma simulação de fora de calibração pela indução artificial de um desvio de 1% por dia no sinal de geração bruta da unidade (MW).

3. Mercado e Aplicação

O objetivo deste trabalho é o desenvolvimento de um sistema de monitoramento remoto de calibração de instrumentos e validação de sensores usando inteligência artificial para estações de compressão do gasoduto Bolívia Brasil. Este sistema permitirá a mudança da filosofia de calibração/manutenção preditiva periódica para a baseada em condição. Os impactos econômicos desta filosofia têm sido relatados na literatura para diversas indústrias. Entre tais impactos destacam-se: i) custos de manutenção: redução de 50 a 80%; ii) danos nos equipamentos: redução de 50 a 60%; iii) inventário de peças sobressalentes: redução de 20 a 30%; iv) tempo de retirada de operação: redução de 50 a 80%; v) despesas de horas-extras: redução de 20 a 50%; vi) vida útil da máquina: aumento de 20 a 40%; vii) produtividade total: aumento de 20 a 30%; viii) lucro: aumento de 25 a 60%.

Embora esta proposta seja para estação de compressão, a metodologia poderá ser facilmente estendida para estações de entrega e outras instalações envolvendo gás natural, petróleo, e outros.

4. Conclusões

O algoritmo RNMQP fornece um modelo para VIVC cujos erros de predição são similares àqueles obtidos usando redes neurais auto-associativa. A porcentagem média geral da geração de erro para o modelo RNMQP é de 9,94% dos valores

medidos, e os níveis de alarme fora de calibração foram de ~2,5% de desvio para o sistema de caldeira e de ~1,0% para o sistema da turbina. O sistema da turbina teve melhor performance por causa do menor nível de ruído nos sinais monitorados, com maior correlação entre as variáveis. Durante uma demonstração o sistema VIVC detectou um sensor faltoso que é usado no cálculo da taxa de calor. A facilidade na qual os modelos RNMQP podem ser desenvolvidos é seu mais forte atributo com respeito às RNAAs. O grande número de variáveis que são monitoradas um único modelo RNMQP requereria várias RNAAs. Para cada uma destas RNAAs, subconjuntos apropriados destas variáveis deveriam ser obtidos. Deixando de lado o julgamento da engenharia, uma das técnicas primárias para seleção de subconjuntos é usar coeficientes de correlação linear. Para dados que são escalonados para ter uma média zero e um desvio padrão de um, coeficientes de correlação linear são equivalentes a valores de covariância entre preditores e resposta. Essencialmente, o método da seleção de subconjunto para RNAAs está inerente no algoritmo RNMQP, porque os valores de covariância são relacionados à transformação de pesos, a qual indica a importância das variáveis.

Os resultados mostraram que o monitoramento contínuo dos sensores do processo é possível, e a detecção imediata de sensores com defeito no processo pode dar aos operadores informações adicionais para ajudá-los a operar a planta de maneira mais apropriada e aumentar sua eficiência. Esta metodologia apresentada será futuramente aplicada a uma estação de compressão de gás natural da Transportadora de Gás Natural Bolívia-Brasil, mas poderá ainda ser estendida para qualquer outro processo.

5. Agradecimentos

Os autores gostariam de agradecer à FINEP - Financiadora de Estudos e Projetos, à RGE – Rede Gás Energia, à PETROBRAS - Petróleo Brasileiro S.A., à TBG - Transportadora de Gás Natural Bolívia-Brasil, a Companhia do Estado de Mato Grosso do Sul - MSGÁS e à UFMS – Universidade Federal de Mato Grosso do Sul pelo apoio ao projeto que originou este trabalho.

6. References

- BAFFI, G., MARTIN, E.B., MORRIS, A.J. Non-linear projection to latent structures revisited: the quadratic PLS algorithm. *Computers in Chemical Engineering* v.23, p. 395-411, 1999a
- BAFFI, G., MARTIN, E.B., MORRIS, A.J. Non-linear projection to latent structures revisited: the neural network PLS algorithm. *Computers in Chemical Engineering* v. 23, p. 1293-1307, 1999b
- DONG, D., MCAVOY, T. 1994. Sensor data analysis using autoassociative neural networks. *Proceedings of the World Congress on Neural Networks* v. 1, p. 161-166, San Diego, CA, 1994
- GELADI, P., KOWALSKI, B.R. Partial least squares regression: a tutorial. *Anal. Chim. Acta* v. 185, p. 1-17, 1986
- HINES, J.W., UHRIG, R.E. Use of autoassociative neural networks for signal validation. *Journal of Intelligent and Robotic Systems*, February, p.143-154, 1998
- HINES, J.W., GRIBOK, A.V., ATTIEH, I., UHRIG, R.E. Improved methods for on-line sensor calibration verification. *Proceedings of the 8th International Conference on Nuclear Engineering*, Baltimore, MD, 2000
- HOLCOMB, T.R., MORARI, M. PLS / Neural Networks. *Computers in Chemical Engineering* v. 16, p. 393-411, 1992
- HOSKULDSSON, A. PLS regression methods. *Journal of Chemometrics* v. 2, p. 211-228, 1988
- HOSKULDSSON, A. A combined theory for PCA and PLS. *Journal of Chemometrics* v. 9, p. 91-123, 1995
- KRAMER, M.A. Autoassociative neural networks. *Computers in Chemical Engineering* v. 16, p. 313-328, 1992
- MALTHOUSE, E.C., TAMHANE, A.C., MAH, R.S.H. Nonlinear partial least squares. *Computers in Chemical Engineering* v. 21, p. 875-890, 1997
- MARTENS, H., NÆS, T. *Multivariate Calibration*, John Wiley and Sons, Chichester, 1989
- MOLLER, F. A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks* v.6, p.525-533, 1993
- NABESHIMA, K., SUSUKI, K., TURKAN, T. Real-time nuclear power plant monitoring with hybrid artificial intelligence systems. *9th Power Plant Dynamics, Control & Testing Symposium* v. 2, p. 55.01, May 24-26, 1995
- QIN, S.J., MCAVOY, T.J. Nonlinear PLS modeling using neural networks. *Computers in Chemical Engineering* v.16, p. 1-10, 1992
- QIN, J., MCAVOY, J. Nonlinear FIR modeling via neural net PLS approach. *Computers in Chemical Eng.* - v.20, 1996
- QIN, S.J. Neural networks for intelligent sensors and control --- Practical issues and some solutions. In: OMIDVAR, O., ELLIOTT, D.L. (Ed.), *Neural Systems for Control*, Academic Press, chapter 8, 1997
- RASMUSSEN, B., HINES, J.W., UHRIG, R.E. Nonlinear partial least squares modeling for instrument surveillance and calibration verification. *Proc. of the Maintenance and Reliability Conference*, Knoxville, TN, to appear, 2000.
- UPADHYAYA, B.R., ERYUREK, E. Application of neural networks for sensor validation and plant monitoring. *Nuclear Technology* v. 97, p. 170-176, 1992
- WALD, A. Sequential tests of statistical hypothesis. *Ann. Math. Statist.* v. 16, p.117-186, 1945
- WILSON, D.J.H., IRWIN, G.W., LIGHTBODY, G. Neural networks and multivariate SPC, *Proceedings of the IEE Colloquium on Fault Diagnosis in Process Systems*, p. 5/1-5/5, London, UK, 1997
- WOLD, H. Non-linear Estimation by Iterative Least Squares Procedures. In: David, F. (Ed.), *Research Papers in Statistics*, Wiley, NY, 1966.
- WOLD, S., RUHE, A., WOLD, H., DUNN, W.J. III. The collinearity problem in linear regression: The partial least squares approach to generalized inverses. *SIAM J. Sci. Stat. Comput.* v. 5, p. 735-743, 1984
- WOLD, S., WOLD, N.K., SKAGERBERG, B. Nonlinear PLS modeling. *Chemometrics and Intelligent Laboratory Systems* v. 7, p. 53-65, 1989

WOLD, S. Nonlinear partial least squares modeling II: Spline inner relation. *Chemometrics and Intelligent Laboratory Systems* v. 14, p. 71-84, 1992