Javier Eduardo Reyes Sánchez

**Sistema de Monitoramento de Múltiplos Sensores por
Redes Neurais Auto-Associativas e Lógica Fuzzy**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para
obtenção do título de Mestre pelo Programa de Pós-
Graduação em Engenharia Elétrica da PUC-Rio.

Orientadora: Prof. Marley Maria Bernardes Rebuzzi Vellasco
Co-orientador: Prof. Ricardo Tanscheit

Rio de Janeiro
Março de 2011

Javier Eduardo Reyes Sánchez

Sistema de Monitoramento de Múltiplos Sensores por Redes Neurais Auto-Associativas e Lógica Fuzzy

Dissertação apresentada como requisito parcial para obtenção do título de Mestre pelo Programa de Pós-Graduação em Engenharia Elétrica da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Marley Maria Bernardes Rebuzzi Vellasco

Orientadora

Departamento de Engenharia Elétrica / PUC-Rio

Ricardo Tanscheit

Co-orientador

Departamento de Engenharia Elétrica / PUC-Rio

Jorge Luís Machado do Amaral

Departamento de Engenharia Elétrica / UERJ

Sebastian Yuri Cavalcanti Catunda

Departamento de Engenharia Elétrica / UFMA

Carlos Roberto Hall Barbosa

Programa de Pós-Graduação em Metrologia / PUC-Rio

Prof. José Eugênio Leal

Coordenador Setorial do Centro Técnico Científico / PUC-Rio

Rio de Janeiro, 01 de março de 2011

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, da autora e do orientador.

Javier Eduardo Reyes Sánchez

Graduou-se em Engenharia Eletrônica pela Pontifícia Universidad Católica del Peru /PUCP em 2006. Trabalhou na área industrial, especializado em Instrumentação, Automação e Controle de Processos de Manufatura. A sua linha de pesquisa está relacionada a aplicações de inteligência computacional na área de Instrumentação e Automação, mais especificamente, no problema de auto-correção e auto-validação de medições em sensores industriais.

Ficha Catalográfica

Reyes Sánchez, Javier Eduardo

Sistema de monitoramento de múltiplos sensores por redes neurais auto-associativas e lógica fuzzy / Javier Eduardo Reyes Sánchez ; orientadora: Marley Maria Bernardes Rebuzzi Vellasco ; co-orientador: Ricardo Tanscheit. – 2011.

131 f. : il. (color.) ; 30 cm

Dissertação (mestrado)—Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2011.

Inclui bibliografia

1. Engenharia elétrica, – Teses. 2. Redes neurais auto-associativas. 3. Lógica fuzzy. 4. Sensores. 5. Automação. 6. Sistemas de monitoramento. 7. Confiabilidade. 8. Classificação. 9. Detecção de falha. I. Vellasco, Marley Maria Bernardes Rebuzzi. II. Tanscheit, Ricardo. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. IV. Título.

CDD: 621.3

À Gloria Maria

Agradecimentos

Ao Prof. Marcos Azevedo da Silveira (in memoriam), pela ajuda e oportunidade de ingresso nesta universidade.

Agradeço a minha orientadora Profa. Dra. Marley Vellasco pelos conhecimentos e sugestões fornecidos durante o desenvolvimento da pesquisa, sem os quais nada seria possível.

Agradeço muito a meu co-orientador Prof. Dr. Ricardo Tanscheit pela amizade, paciência e ajuda no desenvolvimento deste trabalho e dos artigos publicados.

A meus pais e irmãos pelo apoio durante a realização deste mestrado apesar da distância.

A minha companheira, Gloria Maria que se juntara a mim nesta nova etapa.

A meus amigos e colegas da PUC-Rio e do ICA, pelo companheirismo e sugestões fornecidas nestes anos de estudo, em especial ao Gustavo, Ronald, Leonardo e Alvaro.

A CAPES, à PUC-Rio e ao laboratório ICA sou grato pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

.

Resumo

Reyes S., Javier Eduardo; Vellasco, Marley M.B.Rebuzzi. **Sistema de Monitoramento de Múltiplos Sensores por Redes Neurais Auto-Associativas e Lógica Fuzzy**. Rio de Janeiro, 2011. 131 p. Dissertação de Mestrado – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Calibrações manuais periódicas asseguram o funcionamento correto de um instrumento durante certo período de tempo, mas não garantem que sensores defeituosos permaneçam calibrados por outros períodos, além de eventualmente serem desnecessárias. Em plantas industriais, a análise dos sinais fornecidos pelos sensores que monitoram os processos de produção é uma tarefa difícil em virtude da grande dimensão dos dados. Portanto, uma estratégia de monitoramento e correção *on-line* para múltiplos sensores se faz necessária.

Este trabalho propõe a utilização de dois modelos: um que emprega Redes Neurais Auto-Associativas com Treinamento Robusto Modificado (RNAAM), e outro que emprega o Teste Seqüencial da Razão de Probabilidade (SPRT) e Lógica Fuzzy. Esses modelos são aplicados em um sistema de monitoramento para auto-correção *on-line* e auto-validação das medições realizadas por um grande número de sensores. Diferentemente dos modelos existentes, o sistema proposto faz uso de apenas uma RNAAM para reconstruir os sinais dos sensores com falha. Além disso, os estados do sensor e do modelo de auto-correção são validados por meio dos módulos de confiabilidade e de classificação, respectivamente.

Para avaliação do modelo, faz-se uso de uma base de dados com medidas de sensores industriais que controlam e realizam o monitoramento de um motor de combustão interna, instalado em um caminhão de mineração. Os resultados obtidos mostram a capacidade do modelo proposto de mapear e corrigir, com um baixo nível de erro, os sinais dos sensores que apresentam falhas, além de fornecer ao especialista uma ferramenta para a realização de cronogramas de revisão de sensores.

Palavras-chave

Redes Neurais Auto-Associativas; Lógica Fuzzy; Sensores; Automação, Sistemas de Monitoramento; Confiabilidade; Classificação; Detecção de falha.

Abstract

Reyes S., Javier Eduardo; Vellasco, Marley M.B.Rebuzzi (Advisor). **Sistema de Monitoramento de Múltiplos Sensores por Redes Neurais Auto-Associativas e Lógica Fuzzy**. Rio de Janeiro, 2011. 131p. MSc. Dissertation – Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro.

Periodical manual calibrations assure the correct operation of an instrument for a certain period of time, but do not guarantee that faulty sensors remain calibrated for other periods, besides being occasionally unnecessary. In industrial plants the analysis of signals from sensors that monitor a plant is a difficult task due to the high-dimensionality of data. Therefore an on-line strategy for monitoring and correcting multiple sensors is required.

This work proposes the use of two models: one that employs Auto-Associative Neural Networks with a Modified Robust Training, and another that employs the Sequential Probability Ratio Test (SPRT) and Fuzzy Logic. These models are applied to an on-line monitoring system for self-correction and self-validation of measurements generated by a large number of sensors. Unlike existing models, the proposed system makes use of only one AANN to reconstruct signals from faulty sensors. Moreover, the states of the sensor and of the self-correction model are validated through the reliability and classification modules, respectively.

The model is evaluated with a database containing measurements of industrial sensors that control and carry out the monitoring of an internal combustion engine installed in a mining truck. Experimental results show the ability of the proposed model to map and correct signals from faulty sensors with a low error, and to provide a tool for sensor review scheduling.

Keywords

Auto-Associative Neural Networks; Fuzzy Logic; Sensors; Automation, Monitoring Systems; Reliability; Classification; Failure Detection.

Sumário

1	Introdução	15
1.1.	Motivação	15
1.2.	Objetivo	18
1.3.	Descrição do Trabalho	19
1.4.	Organização da Dissertação	21
2	Monitoramento de Sensores	23
2.1.	Sistemas de medição digital	23
2.2.	Monitoramento clássico de sensores na Indústria	27
2.2.1.	Agendamento de Revisões	27
2.2.2.	Revisão do Instrumento <i>In-Situ</i>	28
2.2.3.	Ajuste do Instrumento <i>In-Situ</i>	28
2.2.4.	Retirada do Instrumento	28
2.2.5.	Revisão e Ajuste do Instrumento no Laboratório	28
2.2.6.	Substituição Momentânea ou Parcial do Instrumento	29
2.2.7.	Agendamento de uma nova Calibração	29
2.3.	Inteligência Computacional Aplicada em Instrumentação	29
2.3.1.	Sensores Inteligentes	30
2.3.2.	Instrumentação Inteligente na Indústria	32
2.4.	Tipos de Falha em Sensores	35
2.5.	Monitoramento redundante de sensores	38
2.6.	Monitoramento não redundante de sensores	40
2.6.1.	Modelos Inferenciais, Hetero-Associativos e Auto-Associativos	41
2.6.2.	Modelagem Empírica em Sistemas de Monitoramento para calibrações	42
3	Redes Neurais Auto-Associativas	44
3.1.	Neurônio Artificial	44
3.2.	Arquitetura de Redes Neurais	45
3.2.1.	Treinamento de Redes Neurais	47
3.3.	Arquitetura de Redes Neurais Auto-Associativas	48
3.3.1.	Análise de Componentes Principais (PCA)	49
3.3.2.	Análise de Componentes Principais Não Lineais	51

3.3.3. Técnicas de Regularização	56
3.3.3.1 Número de Neurônios	56
3.3.3.2 Treinamento Robusto	57
3.3.4. Filtragem de Ruído	58
3.3.5. Erro súbito	59
3.3.6. Trabalhos Relacionados	60
 4 Sistema para Auto-Correção e Auto-Validação em Sensores Inteligentes	 63
4.1. Modelo de Auto-Correção	64
4.1.1. Cálculo de Correlação de Sensores	65
4.1.2. Pré-processamento de dados	66
4.1.3. Determinação do Número de Neurônios	67
4.1.4. Treinamento Modificado em RNAA – RNAAM	68
4.2. Modelo de Auto-Validação	70
4.2.1. Detecção de Falha (Teste da Razão de Probabilidade Seqüencial – SPTR)	71
4.2.2. Módulo de Confiabilidade	73
4.2.3. Módulo de Classificação de estado do sensor	76
 5 Sensores do Motor de Combustão Interna – Estudo de Caso	 79
5.1. Princípio de Funcionamento do Motor de Combustão Interna	79
5.2. Desenvolvimento do Projeto	81
5.2.1. Definição de Grupos	83
5.2.2. Sistema de Monitoramento para Auto-Correção e Auto-Validação de Múltiplos Sensores	84
5.3. Resultados do Modelo de Auto-Correção	86
5.3.1. Resultados do Primeiro Grupo	86
5.3.2. Resultados do Segundo Grupo	94
5.3.3. Resultados do Terceiro Grupo	98
5.4. Resultados do Modelo de Auto-Validação	105
5.4.1. Resultados do Módulo de Detecção de Falha	105
5.4.2. Resultados do modelo de Confiabilidade e Classificação	107
 6 Conclusões e Trabalhos Futuros	 114
6.1. Conclusões	114
6.2. Trabalhos Futuros	116

7 Referências	117
Anexos	124

Lista de figuras

Figura 1. Diagrama representativo de um sistema de medição analógico e digital.Fonte: Oliveira e Cavalcanti (2007)	244
Figura 2. Concentração de CO ₂ no solo em três diferentes profundidades na Reserva James. O sensor de 16 cm apresenta problemas de calibração.	38
Figura 3. Monitoramento Redundante – Técnica tradicional	399
Figura 4. Monitoramento não redundante – Metodologia atual	41
Figura 5. Diagrama esquemático dos modelos (a) Inferencial (b) Hetero-Associativo e (c) Modelo Auto-Associativo	411
Figura 6. Sistema de Monitoramento de Calibração Genérico	43
Figura 7. (a) Neurônio Biológico (b) Modelo Neurônio artificial	444
Figura 8. Redes Feed Forward de Camada Única	455
Figura 9. Rede Multilayer Perceptron	466
Figura 10. Rede Recorrente ou Realimentada	477
Figura 11. Fluxograma para o Treinamento Geral das Redes Neurais	488
Figura 12. Notação de interligação dos neurônios de uma rede MLP	522
Figura 13. Redes Neurais que implementam as funções de mapeamento G (a) e desmapeamento H (b)	533
Figura 14. Implementação da rede neural auto-associativa	533
Figura 15. Modelo de Monitoramento on-line	644
Figura 16. Modelo de Auto-Correção utilizando RNAA	66
Figura 17. Respostas da RNAA frente à falha na entrada X_1	69
Figura 18. Ruído aleatório nas entradas X_2 e X_m	69
Figura 19. Especificação do Modelo de Auto-Validação	71
Figura 20. Comportamento do resíduo frente ao SPRT	73
Figura 21. Sistema de Inferência Fuzzy do Módulo de Confiabilidade	74
Figura 22. Funções de Pertinência da Confiabilidade	755
Figura 23. Sistema de Inferência Fuzzy do Módulo de Classificação	77
Figura 24. Funções de Pertinência do Módulo de Classificação	77
Figura 25. Funcionamento do Motor de Combustão Interna	80
Figura 26. Projeção Horizontal do Caminhão Komatsu 730E	83
Figura 27. Sistema de Monitoramento para Auto-Correção e	

Auto-Validação de Múltiplos Sensores	85
Figura 28. Erro MAPE em função do número de neurônios na camada de estrangulamento	87
Figura 29. Resposta da RNAAM ₁ frente ao desvio no sensor 1	89
Figura 30. Resposta dos sensores 1 e 2 frente ao desvio total de 100 °F no sensor 1	90
Figura 31. Resposta dos sensores frente ao desvio lento de 0,2 °F por minuto nos sensores 1,5 e 11	92
Figura 32. Resposta da RNAA ₁ frente ao ruído no sensor 1	93
Figura 33. Resposta dos sensores 3 e 4 da RNAA ₂	95
Figura 34. Respostas dos sensores 1 e 2 da RNAAM ₂ com falha no Sensor 2 (Offset=4 psi)	96
Figura 35. Resposta da RNAAM ₂ para falhas nos sensores 2,4,5,6 e 7 (<i>offset</i> =4 unidades)	97
Figura 36. Resposta da RNAAM ₂ frente ao ruído no sensor 1	98
Figura 37. Respostas da RNAA ₃ frente a uma falha no sensor 1 (Offset=4 psi)	100
Figura 38. Respostas da RNAAM ₃ frente a uma falha de desvio no sensor 9 (Desvio Final=10 °F)	101
Figura 39. Respostas da RNAAM ₃ frente a uma falha nos sensores 1 e 3 (Offset=4 unidades)	102
Figura 40. Resposta da RNAAM ₃ a falha nos sensores 1,3 e 7 (<i>offset</i> =5 unidades)	103
Figura 41. Resposta da RNAAM ₃ a falhas nos sensores 1, 3, 7 e 9 (<i>offset</i> =5 unidades)	104
Figura 42. Resposta do MDF frente ao erro no sensor9/Grupo 3 (<i>offset</i> =2º F)	106
Figura 43. Resposta do MDF frente ao desvio no sensor 1/Grupo1 (5ºF por minuto)	106
Figura 44. Respostas do MDF frente as falhas simultâneas nos sensores do Grupo 3	107
Figura 45. Respostas do modelo de Auto-Validação a falhas nos sensores 1, 3, 7 e 9 (<i>offset</i> =5 unidades)	108
Figura 46. Respostas do modelo de auto-correção às falhas nos sensores 1 e 4	109
Figura 47. Respostas do modelo de auto-validação às falhas nos sensores 1 e 4.	110

Figura 48. Resposta da RNAAM ₃ à falha no Sensor 9 - Grupo 3	110
Figura 49. Resposta do modelo de Auto-Validação ao desvio no Sensor 9-Grupo 3	111
Figura 50. Resposta da RNAAM2 à falha no sensor 1-Grupo 2	112
Figura 51. Resposta do modelo de auto-validação	112
Figura 52. Detalhamento da resposta da RNAAM ₂ à falha do sensor 1	113

Lista de tabelas

Tabela 1. Taxonomia de Falhas: Definições, Possíveis Causas e Impacto (Ni <i>et al.</i> , 2009)	36
Tabela 2. Regras do Módulo de Confiabilidade	76
Tabela 3. Regras do Módulo de Classificação	78
Tabela 4. Especificações do Caminhão e do Motor de Combustão Interna (Cummins, 2004)	81
Tabela 5. Sensores do Motor de Combustão Interna	82
Tabela 6. Sensores de Temperatura nos Cilindros - Grupo 1	86
Tabela 7. Resultados do Grupo 1	88
Tabela 8. Desvio lento de 0,2 °F por minuto no sensor 1	89
Tabela 9. Desvio máximo em 100 unidades dos sensores 1, 5 e 11	91
Tabela 10. Ruído de 20% da faixa de medição no sensor 1	93
Tabela 11. Sensores de Temperatura e Pressão - Grupo 2	94
Tabela 12. Resposta da RNAA do Grupo 2	95
Tabela 13. Resposta da RNAAM ₂ a Falha do Sensor 2 (Offset=4 psi)	96
Tabela 14. Resposta da RNAAM ₂ para falhas nos sensores 2,4,5,6 e 7 (<i>offset</i> =4 unidades)	97
Tabela 15. Sensores de Temperatura e Pressão- Grupo 3	98
Tabela 16. Resultados da RNAAM ₃ -Matriz de Identidade	99
Tabela 17. Sensores de Temperatura e Pressão - Grupo 3	99
Tabela 18. Resposta da RNAA ₃ para o desvio no sensor 9	100
Tabela 19. Resposta da RNAAM ₃ para uma falha nos sensores 1 e 3	102
Tabela 20. Resposta da RNAAM ₃ à falha do sensor 1, 3, e 7	104
Tabela 21. Resposta da RNAAM ₃ a Falha do Sensor 1, 3, 7 e 9 (<i>offset</i> =5 unidades)	104
Tabela 22. Valores máximos para a normalização dos resíduos	108
Tabela 23. Parâmetros escolhidos às falhas nos sensores 1 e 4	109