



Eleazar Cristian Mejia Sanchez

**Controle por Aprendizado Acelerado e Neuro-Fuzzy
de Sistemas Servo - Hidráulicos de Alta Frequência**

Dissertação de Mestrado

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

Orientador: Prof. Marco Antonio Meggiolaro

Rio de Janeiro, Setembro de 2009

Eleazar Cristian Mejia Sanchez

Controle por Aprendizado Acelerado e Neuro-Fuzzy de Sistemas Servo - Hidráulicos de Alta Frequência

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

Prof. Marco Antonio Meggiolaro

Orientador

Departamento de Engenharia Mecânica PUC - Rio

Prof. Jaime Tupiassu Pinho de Castro

Departamento de Engenharia Mecânica PUC - Rio

Prof.^a Karla Tereza Figueiredo Leite

Departamento de Engenharia Elétrica - PUC - Rio

Prof. José Eugenio Leal

Coordenador Setorial do Centro Técnico Científico - PUC - Rio

Rio de Janeiro, Setembro 2009.

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

Eleazar Cristian Mejia Sanchez

Graduou-se em Engenharia Mecatrônica Universidad Nacional de Ingenieria Lima - Peru em 2005.

Ficha Catalográfica

Mejia Sanchez, Eleazar Cristian.

Controle por aprendizado acelerado e neuro-fuzzy de sistemas servo-hidráulicos de alta frequência / Eleazar Cristian Mejia Sanchez ; orientador: Marco Antonio Meggiolaro. – 2009.

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

Dissertação (Mestrado em Engenharia Mecânica)– Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2009.

Inclui bibliografia.

1. Engenharia mecânica – Teses. 2. Lógica fuzzy. 3. Sistemas de neuro-fuzzy. 4. Redes neurais. 5. Controle por aprendizado neuro-fuzzy. I. Meggiolaro, Marco Antonio. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Mecânica. III. Título.

CDD: 621

Ao Senhor Jesus Cristo, meu pai Jesus Israel, minha mãe Agripina, meu irmão
Ronald, e minha irmã Liliana, meus avós Marcos e Juana, e meus queridos
amigos.

Agradecimentos

Ao Professor Marco Antonio Meggiolaro pela paciência e orientação durante o desenvolvimento do curso de mestrado.

Agradecemos à Professora Karla Tereza Figueiredo Leite por toda a valiosa contribuição na concepção do controle proposto.

Ao Professor Jaime Tupiassú Pinho de Castro pelas sábias sugestões.

Ao meu grande amigo Juan Gerardo Castillo Alva, pela ajuda na parte experimental em todo momento.

A Marco Perez, Jesus Leal, Jorge Hinostroza e Gilmar amigos e colegas de laboratório.

Aos meus amigos Hernan zambrano, David Achancaray, Nilton Anchayhua, Edwin Campos, Cesar Mamani, Josue e Carlos.

Aos professores da PUC - Rio pelo ensino.

Ao Departamento de Engenharia Mecânica da PUC - Rio e seus funcionários, pela colaboração comigo.

A CNPq Conselho Nacional de Desenvolvimento Científico e Tecnológico pela ajuda financeira.

A todas aquelas pessoas que de alguma outra forma participaram no desenvolvimento da dissertação.

Resumo

Mejía Sánchez, Eleazar Cristian; Meggiolaro, Marco Antonio. **Controle por Aprendizado Acelerado e Neuro-Fuzzy de Sistemas Servo-Hidráulicos de Alta Frequência**. Rio de Janeiro, 2009. 130p. Dissertação de Mestrado - Departamento de Engenharia Mecânica, Pontifícia Universidade Católica do Rio de Janeiro.

Nesta dissertação foram desenvolvidas técnicas de controle por aprendizado acelerado e Neuro-Fuzzy, aplicadas em um sistema servo-hidráulico para ensaio de fadiga. Este sistema tem o propósito de fazer ensaios em materiais para prever a resistência à fadiga dos materiais. O trabalho envolveu quatro etapas principais: levantamento bibliográfico, desenvolvimento de um controle por aprendizado acelerado, desenvolvimento de um controle por aprendizado Neuro-Fuzzy, e implementação experimental dos modelos de controle por aprendizado proposto em uma máquina de ensaios de materiais. A implementação do controle por aprendizado acelerado foi feita a partir do modelo de controle desenvolvido por Alva[5], com o objetivo de acelerar o processo de aprendizagem. Esta metodologia consiste em fazer um controle do tipo *bang-bang*, restringindo a servo-válvula a trabalhar sempre em seus limites extremos de operação, i.e., procurando mantê-la sempre completamente aberta em uma ou outra direção. Para manter a servo-válvula trabalhando em seus limites de seu funcionamento, os instantes ótimos para as reversões são obtidos pelo algoritmo de aprendizado, e armazenados em tabelas específicas para cada tipo de carregamento. Estes pontos de reversão dependem de diversos fatores, como a amplitude e carga média da solicitação, e são influenciados pela dinâmica do sistema. Na metodologia proposta, a lei de aprendizado inclui um termo de momentum que permite acelerar a aprendizagem dos valores das tabelas constantemente durante a execução dos testes, melhorando a resposta a cada evento. O desenvolvimento de um controle por aprendizado Neuro-Fuzzy foi motivado pela necessidade de ter um agente com a capacidade de aprendizado e armazenamento dos pontos ótimos de reversão. Este modelo de controle também consiste na implementação de um controle do tipo *bang-bang*, trabalhando com a servo-válvula sempre nos seus limites extremos de operação. O instante de reversão é determinado pelo sistema Neuro-Fuzzy, o qual tem como entradas a gama (dobro da amplitude) e o valor mínimo do carregamento solicitado. O processo de aprendizado é feito pelas

atualizações dos pesos do sistema Neuro-Fuzzy, baseado nos erros obtidos durante a execução dos testes, melhorando a resposta do sistema a cada evento. A validação experimental dos modelos propostos é feita em uma máquina servo-hidráulica de ensaios de fadiga. Para este fim, o algoritmo de controle proposto foi implementado em tempo real em um módulo de controle *CompactRIO* da *National Instruments*. Os testes efetuados demonstraram a eficiência da metodologia proposta.

Palavras-chave

Sistemas Servo-hidráulicos; Controle de Alta Frequência; Controle por Aprendizado Acelerado; Controle Neuro-Fuzzy; Máquina de Testes de Fadiga.

Abstract

Mejía Sánchez, Eleazar Cristian; Meggiolaro, Marco Antonio (Advisor). **Accelerated Learning and Neuro-Fuzzy Control of High Frequency Servo-Hydraulic Systems**. Rio de Janeiro, 2009. 130p. M.Sc. Dissertation – Departamento de Engenharia Mecânica, Pontifícia Universidade Católica de Rio de Janeiro.

In this thesis, accelerated learning and Neuro-Fuzzy control techniques were developed and applied to a servo-hydraulic system used in fatigue tests. This work involved four main stages: literature review, development of an accelerated learning control, development of a Neuro-Fuzzy control, and implementation of the learning control models into a fatigue testing machine. The accelerated learning control was implemented based on a learning control developed in previous works, introducing a faster learning law. Both learning control methodologies consist on implementing a bang-bang control, forcing the servo-valve to always work in its operational limits. As the servo-valve works in its operational limits, the reversion points to achieve every peak or valley in the desired history are obtained by the learning algorithm, and stored in a specific table for each combination of minimum and mean load. The servo-valve reversion points depend on a few factors, such as alternate and mean loading components, while they are as well influenced by the system dynamics. In the proposed accelerated methodology, the learning law includes one momentum term that allows to speed up the learning process of the table cell values during the execution of the tests. The developed Neuro-Fuzzy control also consists on a bang-bang control, making the servo-valve work in its operational limits. However, here the instant of each reversion is determined by the Neuro-Fuzzy system, which has the load range and minimum load required as inputs. The learning process is made by the update of the Neuro-Fuzzy system weights, based on the errors obtained during the execution of the test. The experimental validation of the proposed models was made using a servo-hydraulic testing machine. The control algorithm was implemented in real time in a C-RIO computational system. The tests demonstrated the efficiency of the proposed methodology.

Keywords

Servo-Hydraulic Systems; High Frequency Control; Accelerated Learning Control; Neuro-Fuzzy Control; Fatigue Testing Machine.

Sumário

1 . Introdução	17
1.1. Objetivo	17
1.2. Considerações Iniciais	17
1.3. Motivação	18
1.4. Revisão Bibliográfica	20
1.5. Roteiro da Dissertação	22
2 Lógica Fuzzy	23
2.1. Introdução	23
2.2. Conjuntos Fuzzy	24
2.2.1. Variáveis lingüísticas	26
2.2.2. Função de Pertinência.	27
2.2.3. Operações entre Conjuntos Fuzzy	28
2.3. Sistema de Inferência Fuzzy	30
2.3.1. Fuzzificação	30
2.3.2. Regras e Inferência Fuzzy	31
2.3.3. Defuzzificação.	32
2.4. Tipos de Sistema Fuzzy	32
2.4.1. Modelo de Mandani	33
2.4.2. Modelo de Takagi-Sugeno	33
2.5. Vantagens e Desvantagens dos Sistemas Fuzzy	34
2.5.1. Vantagens dos Sistemas Fuzzy	34
2.5.2. Desvantagens dos Sistemas Fuzzy	35
3 Redes Neurais	36
3.1. Introdução	36
3.2. Estrutura do neurônio	37
3.2.1. Peso de conexão	38
3.2.2. Função Somatório (Net)	38
3.2.3. Função de Ativação	39

3.3. Arquitetura das Redes Neurais	41
3.3.1. Rede <i>Perceptron</i>	41
3.3.2. Rede Multilayer Perceptron	43
3.4. Algoritmo <i>Backpropagation</i>	48
3.4.1. Fases do Algoritmo <i>Backpropagation</i>	48
3.4.2. Algoritmo de Aprendizado	50
3.4.3. Parâmetros de Aprendizado	54
3.5. Modelagem da <i>ANN</i>	57
3.6. Vantagens e Desvantagens das <i>ANN</i>	58
3.6.1. Vantagens das <i>ANN</i>	58
3.6.2. Desvantagens das <i>ANN</i>	58
4 . Sistemas Neuro-Fuzzy	59
4.1. Introdução	59
4.2. Sistemas Híbridos	60
4.2.1. Sistema Híbrido Seqüencial	60
4.2.2. Sistema Híbrido Auxiliar	60
4.2.3. Sistema Híbrido Incorporado	61
4.3. Sistemas Neuro-Fuzzy	62
4.3.1. Características de Sistemas Neuro-Fuzzy	63
4.3.2. Modelos de Sistemas Neuro-Fuzzy	66
4.4. Vantagens e Desvantagens dos <i>SNF</i>	72
4.4.1. Vantagens das <i>SNF</i>	72
4.4.2. Desvantagens dos <i>SNF</i>	72
5 . Controle por Aprendizado Acelerado e Simulação	73
5.1. Introdução	73
5.2. Modelagem do Sistema Servo-Hidráulico	73
5.2.1. Modelagem da Servo-válvula	74
5.2.2. Modelagem do Pistão Hidráulico	76
5.2.3. Modelos lineares	77
5.3. Controle por Aprendizado Acelerado	79
5.3.1. Metodologia de controle	80
5.3.2. Tabelas de Aprendizado	81

5.3.3. Determinação do Valor de U_{IJ}	83
5.3.4. Processo de Aprendizado	85
5.3.5. Algoritmo de Aprendizado	90
5.3.6. Resultado das simulações do Algoritmo de Controle por Aprendizado Acelerado	92
 6 . Controle por Aprendizado Neuro-Fuzzy	 97
6.1. Introdução	97
6.2. Esquema do controle por aprendizado NF	97
6.3. Modelagem do Controle por Aprendizado Neuro-Fuzzy	99
6.3.1. Modelagem Fuzzy do <i>SNF</i>	99
6.3.2. Modelagem da parte neural	101
6.4. Controle por Aprendizado Neuro-Fuzzy	102
6.4.1. Cálculo do valor de U_{IJ}	102
6.4.2. Lei de aprendizado do <i>SNF</i>	104
6.4.3. Algoritmo de controle por aprendizado Neuro-Fuzzy	105
6.4.4. Resultado das simulações do controle por aprendizado <i>SNF</i>	107
 7 . Resultados Experimentais	 119
7.1. Sistema Experimental	119
7.2. Módulo de Controle <i>CompactRIO</i>	121
7.3. Software desenvolvido em LabVIEW	123
7.4. Resultados Experimentais	124
 8 . Conclusões	 128
 Bibliografia	 129

Lista de figuras

Figura 1.1. Ensaio de Fadiga.	19
Figura 2.1. (a) lógica booleana (b) lógica fuzzy.	25
Figura 2.2. Variável lingüística	26
Figura 2.3. Funções de pertinência.	27
Figura 2.4. Funções de pertinência: (a) Triangular (b) Trapezoidal (c) Sigmoidal (d) Função de Bell.	28
Figura 2.4. Operações entre conjuntos fuzzy: (a) Conjuntos A e B, (b) União, (c) Interseção e (d) Complemento. [2].	29
Figura 2.5. Sistema de Inferência Fuzzy.	30
Figura 2.6. Regra e inferência fuzzy [8].	31
Figura 2.7. Processo de Defuzzificação.	32
Figura 3.1. Esquema básico do neurônio biológico.	37
Figura 3.2. Modelo básico de um neurônio Artificial "Perceptron".	38
Figura 3.3. Funções de Ativação: (a) Função de Grau. (b) Função linear. (c) Função Logsig. (d) Função Tansig.	40
Figura 3.4. Rede perceptron com k Neurônios de saída.	41
Figura 3.6. Configuração da rede MLP.	45
Figura 3.7. Treinamento Supervisionado.	48
Figura 3.9. (a) Fase de propagação (b) Sinais Funcionais.	49
Figura 3.10. (a) Fase de Retro-propagação (b) Sinais de erro.	50
Figura 3.11. Cálculo de erro e_j na camada de saída.	53
Figura 3.13. Taxa de aprendizado pequeno, com problema do mínimo local.	55
Figura 3.14. Taxa de aprendizado grande, com problema de oscilações.	55
Figura 3.15. Aprendizado com Termo de Momentum.	56
Figura 4.1. Sistema Híbrido Seqüencial.	60
Figura 4.2. Sistema Híbrido Auxiliar.	61
Figura 4.3. Sistema Híbrido Incorporado.	61
Figura 4.4. Arquitetura básica de um Sistema Neuro-Fuzzy.	62
Figura 4.5. Características do Sistema Neuro-Fuzzy.	63
Figura 4.6. Características fuzzy do Sistema Neuro-Fuzzy.	64

Figura 4.7. Características RNA do Sistema Neuro-Fuzzy.	65
Figura 4.8. Arquitetura ANFIS.	66
Figura 4.9. Arquitetura NEFCLASS.	69
Figura 4.10. Arquitetura FSOM.	70
Figura 5.1. Sistema Servo-Hidráulico	73
Figura 5.2. Representação esquemática da servo-válvula.	74
Figura 5.3. Diagrama de blocos do controle por aprendizado.	80
Figura 5.4. Pontos de reversão da servo-válvula.	81
Figura 5.5. Termo de momentum em função do erro para $a=10$ e $b=0,5$.	87
Figura 5.6. Esquema do grau de influência do erro.	88
Figura 5.7. Algoritmo de controle por aprendizado acelerado.	91
Figura 5.8. Resposta do controle por aprendizado acelerado para um carregamento de amplitude constante de ± 10 kN.	92
Figura 5.9. Resposta do controle por aprendizado acelerado para um carregamento de amplitude constante de ± 75 kN.	92
Figura 5.10. Resposta do controle por aprendizado acelerado para diferentes amplitudes de carregamento.	93
Figura 5.11. Resposta do controle por aprendizado acelerado para carregamento já apresentados.	94
Figura 5.12. Resposta para um carregamento constante de ± 25 kN: (a) Controle por aprendizado de Alva e (b) Controle por aprendizado acelerado.	95
Figura 5.13. Erro do controle por aprendizado de Alva e aprendizado acelerado.	96
Figura 6.1. Diagrama de blocos do controle por aprendizado Neuro-Fuzzy.	98
Figura 6.2. Estrutura do Sistema Neuro-Fuzzy.	98
Figura 6.3. Função de pertinência triangular do SNF.	100
Figura 6.4. Particionamento Fuzzy Grid, onde ρ_1, γ_1, μ_1 e ρ_2, γ_2, μ_2 , são os graus de pertinência dos conjuntos Fuzzy das variáveis “ <i>minimo</i> ” e “ <i>gama</i> ” respectivamente.	100
Figura 6.5. Cálculo de U_{II} e descrição das camadas do SNF.	103
Figura 6.6. Algoritmo de controle por aprendizado Neuro-Fuzzy.	106
Figura 6.7. Resposta do controle por aprendizado Neuro-Fuzzy	

para um carregamento de amplitude constante de ± 10 kN .	107
Figura 6.8. Resposta do controle por aprendizado Neuro-Fuzzy para um carregamento de amplitude constante de ± 75 kN.	107
Figura 6.9. Resposta do controle por aprendizado Neuro-Fuzzy para diferentes amplitudes de carregamento.	108
Figura 6.10. Resposta do controle por aprendizado Neuro-Fuzzy para carregamentos já apresentados anteriormente.	109
Figura 6.11. Desempenho dos Modelos de controle por aprendizado para carregamento constante ± 20 kN.	110
Figura 6.12. Desempenho do controle por aprendizado para $\eta = 0.1$ e carregamento de amplitude constante de ± 25 kN.	110
Figura 6.13. Desempenho do controle por aprendizado para $\eta = 0.95$ e carregamento de amplitude constante de ± 25 kN.	111
Figura 6.14. Desempenho do controle por aprendizado para $\eta = 1.5$ e carregamento constante de ± 25 kN.	112
Figura 6.15. Número de ciclos de convergência em função da taxa de aprendizado, carregamento de ± 25 kN.	113
Figura 6.16. Desempenho do controle por aprendizado para $\eta = 0.1$ e carregamento de amplitude constante de ± 80 kN.	113
Figura 6.17. Desempenho do controle por aprendizado para $\eta = 0.85$ e carregamento de amplitude constante de ± 80 kN.	114
Figura 6.18. Desempenho do controle por aprendizado para $\eta = 0.95$ e carregamento de amplitude constante de ± 80 kN.	115
Figura 6.19. Número de ciclos de convergência em função da taxa de aprendizado, carregamento de ± 80 kN.	115
Figura 6.20. Número de ciclos de convergência em função da taxa de aprendizado, para diferentes carregamentos.	116
Figura 7.1. Máquina de Ensaios INSTRON 8501.	119
Figura 7.2. Conexões para o sistema de controle por aprendizado.	120
Figura 7.3. Controlador <i>cRIO</i> -9004.	121
Figura 7.4. Componentes do Chip FPGA.	122
Figura 7.5. (a) NI cRIO 9263 e (b) NI cRIO 9237.	123

Figura 7.6. Tela de controle por aprendizado Neuro-Fuzzy.	123
Figura 7.7. Resposta da máquina servo-hidráulica a um ensaio de fadiga sob amplitude constante com controle por aprendizado Neuro-Fuzzy.	124
Figura 7.8 Convergência do erro em função do numero de ciclos.	125
Figura 7.9. Antecipação dos pontos de reversão à medida que a frequência é aumentada.	126

Lista de tabelas

Tabela 1. Tabela de aprendizado.	82
Tabela 2. Tabelas de aprendizado e de momentum.	83
Tabela 3. Método de interpolação quando os valores de gama e mínimo estão entre duas células.	84