



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
DE COMPUTAÇÃO



Identificação Fuzzy-Multimodelos para Sistemas Não Lineares

Marconi Câmara Rodrigues

Orientador: Prof. Dr. Fábio Meneghetti Ugulino de Araújo

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação da UFRN (área de concentração: Automação e Sistemas) como parte dos requisitos para obtenção do título de Doutor em Ciências.

Natal, RN, março de 2010



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
DE COMPUTAÇÃO



Identificação Fuzzy-Multimodelos para Sistemas Não Lineares

Marconi Câmara Rodrigues¹

Orientador: Prof. Dr. Fábio Meneghetti Ugulino de Araújo

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação da UFRN (área de concentração: Automação e Sistemas) como parte dos requisitos para obtenção do título de Doutor em Ciências.

Número de ordem PPgEEC: D57
Natal, RN, março de 2010

¹Beneficiário de auxílio financeiro da CAPES-Brasil.

Divisão de Serviços Técnicos

Catálogo da publicação na fonte. UFRN / Biblioteca Central Zila Mamede

Rodrigues, Marconi Câmara.

Identificação fuzzy-multimodelos para sistemas não lineares / Marconi Câmara Rodrigues. - Natal, RN, 2010

85 f.

Orientador: Fábio Meneghetti Ugulino de Araújo

Tese (doutorado) - Universidade Federal do Rio Grande do Norte. Centro de Tecnologia. Programa de Pós-Graduação em Engenharia Elétrica e de Computação.

1. Identificação - Tese. 2. Múltiplos modelos - Tese. 3. Sistemas *fuzzy* T-S – Tese. 4. *Neuro-Fuzzy* – Tese. 5. ANFIS – Tese. 6. Sistema não linear – Tese. I. Araújo, Fábio Meneghetti Ugulino de. II. Universidade Federal do Rio Grande do Norte. III. Título.

RN/UF/BCZM

CDU 681.5.015(043.3)

Identificação Fuzzy-Multimodelos para Sistemas Não Lineares

Marconi Câmara Rodrigues

Tese de Doutorado aprovada em 16 de março de 2010 pela banca examinadora composta pelos seguintes membros:

Prof. Dr. Fábio Meneghetti Ugulino de Araújo (Orientador) UFRN

Prof. Dr. Cairo Lúcio Nascimento Júnior (Examinador Externo) ITA

Prof. Dr. Oscar Gabriel Filho (Examinador Externo) UNP

Prof. Dr. Gilbert Azevedo da Silva (Examinador Externo) IFRN

Prof. Dr. André Laurindo Maitelli (Examinador Interno) UFRN

Agradecimentos

Ao meu orientador Fábio Meneghetti Ugolino de Araújo, pelas idéias e ensinamentos que propiciaram soluções e correções para adversidades ao longo do trabalho.

À minha família pelo apoio e consideração que, refletidas em ações, demonstravam, às vezes apenas com um simples olhar, a felicidade compartilhada ao longo das conquistas.

À minha prima Francielly Câmara Lopes, pelos seus conhecimentos em gramática que conferiram aumento da qualidade do texto apresentado.

Aos amigos da sala 16 do DCA, responsáveis por momentos de descontração e, principalmente, fonte de conhecimento e discussão acerca dos mais variados assuntos.

Aos professores e demais colegas de pós-graduação, pelas sugestões e conhecimentos disponibilizados.

Aos funcionários Henrique e Paulo Ívens das secretarias, que facilitavam os serviços burocráticos existentes nos processos.

À CAPES, pelo apoio financeiro.

À todos que contribuíram com meu desenvolvimento e que viveram juntos alegrias e tristezas,

Obrigado.

Resumo

Este trabalho apresenta uma nova técnica de identificação multimodelos baseada em ANFIS para sistemas não lineares. Nesta técnica, a estrutura utilizada é do tipo *fuzzy* Takagi-Sugeno cujos consequentes são modelos lineares locais que representam o sistema em diferentes pontos de operação e os antecedentes são funções de pertinência cujos ajustes são realizados pela fase de aprendizagem da técnica *neuro-fuzzy* ANFIS.

Modelos que representem o sistema em diferentes pontos de operação podem ser encontrados com técnicas de linearização como, por exemplo, o método dos Mínimos Quadrados que é robusto a ruídos e de simples aplicação. Cabe à fase de implicação do sistema *fuzzy* informar a proporção de cada modelo que deve ser empregada, utilizando, para isto, as funções de pertinência. As funções de pertinência podem ser ajustadas pelo ANFIS com o uso de algoritmos de redes neurais, como o de retropropagação do erro, de modo que os modelos encontrados para cada região sejam devidamente interpolados e, assim, definam-se a atuação de cada modelo para as possíveis entradas do sistema. Em multimodelos a definição de atuação de modelos é conhecida por métrica e, como neste trabalho é realizada pelo ANFIS, será denominada de métrica ANFIS. Desta forma, uma métrica ANFIS é utilizada para interpolar vários modelos, compondo o sistema a ser identificado. Diferentemente do ANFIS tradicional, a técnica desenvolvida necessariamente representa o sistema em várias regiões bem definidas por modelos inalteráveis que, por sua vez, terão sua ativação ponderada a partir das funções de pertinência.

A seleção de regiões para a aplicação do método dos Mínimos Quadrados é realizada manualmente a partir da análise gráfica do comportamento do sistema ou a partir do conhecimento de características físicas da planta. Esta seleção serve como base para iniciar a técnica definindo modelos lineares e gerando a configuração inicial das funções de pertinência.

Experimentos são realizados em um tanque didático, com múltiplas seções, projetado e desenvolvido com a finalidade de mostrar características da técnica. Os resultados neste tanque ilustram o bom desempenho alcançado pela técnica na tarefa de identificação, utilizando, para isto, várias configurações do ANFIS, comparando a técnica desenvolvida com múltiplos modelos de métrica simples e comparando com a técnica NNARX, também adaptada para identificação.

Palavras-chave: Identificação, Múltiplos modelos, Sistemas *fuzzy* T-S, *Neuro-fuzzy*, ANFIS, Não linear.

Abstract

This paper presents a new multi-model technique of identification in ANFIS for non-linear systems. In this technique, the structure used is of the fuzzy Takagi-Sugeno of which the consequences are local linear models that represent the system of different points of operation and the precursors are membership functions whose adjustments are realized by the learning phase of the neuro-fuzzy ANFIS technique.

The models that represent the system at different points of the operation can be found with linearization techniques like, for example, the Least Squares method that is robust against sounds and of simple application. The fuzzy system is responsible for informing the proportion of each model that should be utilized, using the membership functions. The membership functions can be adjusted by ANFIS with the use of neural network algorithms, like the back propagation error type, in such a way that the models found for each area are correctly interpolated and define an action of each model for possible entries into the system. In multi-models, the definition of action of models is known as metrics and, since this paper is based on ANFIS, it shall be denominated in ANFIS metrics. This way, ANFIS metrics is utilized to interpolate various models, composing a system to be identified. Differing from the traditional ANFIS, the created technique necessarily represents the system in various well defined regions by unaltered models whose pondered activation as per the membership functions.

The selection of regions for the application of the Least Squares method is realized manually from the graphic analysis of the system behavior or from the physical characteristics of the plant. This selection serves as a base to initiate the linear model defining technique and generating the initial configuration of the membership functions.

The experiments are conducted in a teaching tank, with multiple sections, designed and created to show the characteristics of the technique. The results from this tank illustrate the performance reached by the technique in task of identifying, utilizing configurations of ANFIS, comparing the developed technique with various models of simple metrics and comparing with the NNARX technique, also adapted to identification.

Keywords: Identification, Multiple models, T-S Fuzzy systems, Neuro-fuzzy, ANFIS, Nonlinear.

Sumário

Sumário	i
Lista de Figuras	iii
Lista de Tabelas	v
Lista de Símbolos	vii
Lista de Abreviaturas	ix
1 Introdução	1
2 Técnicas Utilizadas	7
2.1 Múltiplos Modelos	7
2.2 ANFIS	8
3 Múltiplos modelos utilizando ANFIS	11
3.1 Estrutura SISO – <i>Single Input Single Output</i>	11
3.2 Estrutura MISO – <i>Multi Input Single Output</i>	13
3.3 Estrutura MIMO – <i>Multi Input Multi Output</i>	16
4 Procedimento do Método	19
4.1 Modelos Lineares para as Regras – Método LSE	19
4.2 Funções de Pertinência	25
4.3 Algoritmo de aprendizagem	27
5 Estudo de Caso	29
5.1 O Sistema de Tanque com Múltiplas Seções	29
5.1.1 Sensor de Pressão	30
5.1.2 Bomba de água	30
5.1.3 Placa de Aquisição de Dados (PAD)	32
5.1.4 Outros componentes	33
5.2 Implementação da Técnica	34
5.2.1 Primeiro Programa – Comunicação com a Planta	34
5.2.2 Segundo Programa – Identificação	35
5.2.3 Terceiro Programa - Validação	35
5.3 Resultado da Identificação Tipo Caixa Preta	36

5.3.1	Identificador caixa preta com 3 regras (CP3R)	39
5.3.2	Identificador caixa preta com 9 regras (CP9R)	47
5.4	Resultado da Identificação Tipo Caixa Cinza	53
5.4.1	Identificação caixa cinza com 3 regras (CC3R)	55
5.4.2	Identificador caixa cinza com 5 regras (CC5R)	60
5.4.3	Identificador caixa cinza com 2 regras (CC2R)	64
5.5	Resultado da Identificação Tipo Caixa Branca	70
5.5.1	Identificador caixa branca com 3 regras (CB3R)	71
5.6	Resultado da Identificação NNARX	74
6	Conclusões	77
	Referências bibliográficas	79
A	Custo do Sistema de Nível	85

Lista de Figuras

2.1	Estratégia clássica de identificação com múltiplos modelos.	9
2.2	Estratégia inteligente de identificação com múltiplos modelos.	10
2.3	Esquema da estrutura híbrida ANFIS dividida em camadas.	10
3.1	Representação da técnica em estrutura SISO.	12
3.2	Estrutura SISO do modelo <i>neuro-fuzzy</i> ANFIS proposto por Jang.	13
3.3	Estrutura SISO simplificada.	14
3.4	Representação da técnica em estrutura MISO.	14
3.5	Estrutura MISO com apenas uma entrada dividida em regiões.	15
3.6	Estrutura MISO simplificada e com apenas uma entrada dividida em regiões.	16
3.7	Representação da técnica em estrutura MIMO para duas saídas.	17
4.1	Intervalo de excursão do sistema dividido em 3 partições.	20
4.2	Intervalo de excursão da segunda entrada dividido em partições.	21
5.1	Tanque 53x30x10 cm idealizado, em que 1 é o orifício para o sensor de pressão e 2 é o orifício de vazão (Esquerda). Foto real do tanque (Direita).	30
5.2	Sensor de pressão da Motorola TM	31
5.3	Bomba submersa com vazão máxima de 6,5 litros por minuto.	31
5.4	Vazão da bomba submersa em relação à tensão aplicada.	32
5.5	Kit NI PCI-6024E/CB-68LP da <i>National Instruments</i> [®]	33
5.6	Regulador de tensão modelo SD7805.	33
5.7	Nível obtido (acima), com destaque para amostra 2011, e tensão aplicada na bomba (abaixo) pertencente ao conjunto utilizado no treinamento.	37
5.8	Comportamento do sistema quando $Y_k = 8$ volts (contínuo), modelos lineares aproximados com particionamento manual de X (tracejado). L1, L2 e L3 são as partições de X	38
5.9	Comportamento da variação do nível (X_k) para cada partição em função dos valores de tensão Y_k	39
5.10	Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) com R1. Abaixo, a tensão Y_k utilizada em cada amostra.	40
5.11	Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) com R2. Abaixo, a tensão Y_k utilizada em cada amostra.	41
5.12	Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) com R3. Abaixo, a tensão Y_k utilizada em cada amostra.	42
5.13	Forma inicial das funções de pertinência do CP3R.	44
5.14	Forma otimizada das funções de pertinência do CP3R.	45

5.15	Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CP3R.	46
5.16	Divisão da segunda entrada em três regiões utilizando informações gráficas.	48
5.17	Divisão da segunda entrada em três regiões simétricas.	49
5.18	Forma otimizada das funções de pertinência do CP9RS.	53
5.19	Forma otimizada das funções de pertinência do CP9RG.	54
5.20	Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CP9RS.	55
5.21	Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CP9RG.	56
5.22	Comparação do CP9RG com o CP3R.	57
5.23	Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) para $L1$. Abaixo, a tensão Y_k utilizada em cada amostra.	58
5.24	Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) para $L3$. Abaixo, a tensão Y_k utilizada em cada amostra.	59
5.25	Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) para $L5$. Abaixo, a tensão Y_k utilizada em cada amostra.	60
5.26	Forma otimizada das funções de pertinência do CC3R.	61
5.27	Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CC3R.	62
5.28	Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) para $L2$. Abaixo, a tensão Y_k utilizada em cada amostra.	63
5.29	Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) para $L4$. Abaixo, a tensão Y_k utilizada em cada amostra.	64
5.30	Forma otimizada das funções de pertinência após a aprendizagem do CC5R.	65
5.31	Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CC5R.	66
5.32	Forma inicial das funções de pertinência do CC2R.	67
5.33	Forma otimizada das funções de pertinência após a aprendizagem do CC2R.	68
5.34	Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CC2R.	69
5.35	Forma otimizada das funções de pertinência do CB3R.	72
5.36	Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CB3R.	73
5.37	Acima, nível de X_{k+1} desejado (contínuo) e NNARX (tracejado). Abaixo, tensão Y_k utilizada para a validação de NNARX.	75

Lista de Tabelas

4.1	Exemplo de base de regras com modelos lineares.	23
5.1	Modelos lineares das funções Sugeno encontrados pelo LSE para CP3R. . .	42
5.2	Parâmetros iniciais das funções de pertinência de entrada em formato de sino para CP3R.	43
5.3	Parâmetros ótimos das funções de pertinência de entrada em CP3R. . . .	44
5.4	Modelos lineares encontrados para os identificadores CP9RS e CP9RG. . .	50
5.5	Estado inicial das funções de pertinência para CP9RS e para CP9RG. . .	51
5.6	Estado ótimo das funções de pertinência para os identificadores CP9RS e CP9RG.	52
5.7	Comparação numérica entre os identificadores caixa preta.	58
5.8	Modelos lineares para CC3R.	61
5.9	Valores iniciais para as funções de pertinência do CC3R.	61
5.10	Valores ótimos para o CC3R.	62
5.11	Modelos lineares do CC5R.	65
5.12	Valores iniciais para as funções de pertinência do CC5R.	65
5.13	Valores ótimos para as funções de pertinência do CC5R.	66
5.14	Modelos lineares das funções Sugeno encontrados pelo LSE para o CC2R. .	67
5.15	Valores iniciais para as funções de pertinência do CC2R.	67
5.16	Valores ótimos para as funções de pertinência do CC2R.	68
5.17	Comparação numérica entre os identificadores caixa cinza produzidos. . .	70
5.18	Valores iniciais para as funções de pertinência do CB3R.	72
5.19	Valores ótimos para as funções de pertinência do CB3R.	73
5.20	Comparação numérica entre os identificadores produzidos.	74
5.21	Comparação numérica entre NNARX.	75
A.1	Custo dos componentes que compõem o sistema de tanque.	85

Lista de Símbolos

p, q, r Coeficientes ajustáveis dos polinômios Sugeno como modelos lineares.

X_k Estado do sistema no instante k .

Y_k Estado das entradas do sistema no instante k .

N Número de regras.

f_1, f_2, \dots, f_N Funções de modelos lineares para N regras.

$bell(\cdot)$ Função de pertinência em formato de sino.

\bar{w}_i Normalização da variável w_i .

$\mu_{x,B}$ Função que indica a pertinência de x no conjunto *fuzzy* B .

L_1, L_2, L_3, L_4 e L_5 Partições do espaço de estados de X_k .

M_1, M_2, M_3, M_4 e M_5 Partições do espaço de estados de Y_k .

R_1, R_2, \dots, R_N Modelos lineares.

T Período de amostragem.

η Coeficiente de aprendizagem.

\dot{V} Variação volumétrica.

F_{in} Vazão de entrada.

F_{out} Vazão de saída.

V_p Tensão aplicada à bomba.

a Área do orifício de saída.

g Aceleração da gravidade.

L Nível do tanque.

\dot{L} Taxa de variação do nível do tanque.

A Área da base do retângulo.

T Período de discretização.

L_{po} Ponto de operação do nível do tanque.

Lista de Abreviaturas

ANFIS *Adaptive-Network-Based Fuzzy Inference System*.

RNA Redes Neurais Artificiais.

LSE *Least Square Error*.

SISO *Single-Input and Single-Output*.

MISO *Multiple-Input and Single-Output*.

MIMO *Multiple-Input and Multiple-Output*.

PAD Placa de aquisição de dados.

CP3R Caixa preta com 3 regras.

CP9RS Caixa preta com 9 regras simetricamente divididas.

CP9RG Caixa preta com 9 regras e análise gráfica.

CC3R, CC5R, CC2R Caixa cinza com 3, 5 e 2 regras, respectivamente.

IAE *Integral of the Absolute magnitude of the Error*.

ISE *Integral of the Square of the Error*.

CB3R Caixa branca com 3 regras.

NNARX *Neural Network Auto-regressive Model with Exogenous Inputs*.

Capítulo 1

Introdução

Um modelo matemático pode ser definido como uma representação ou interpretação simplificada da realidade, ou uma interpretação de um fragmento de um sistema, segundo uma estrutura de conceitos mentais ou experimentais. A identificação de sistemas aborda a construção de modelos com base em dados experimentais. Assim, na construção de um modelo com base na Teoria da Identificação de Sistemas, os parâmetros do identificador são adaptados segundo determinado critério, com o intuito de se obter uma representação final susceptível a reproduzir com sucesso os dados empíricos utilizados [Paiva 1999]. Em outra definição, a identificação de sistemas se propõe a obter um modelo matemático que explique, pelo menos em parte e de forma aproximada, a relação de causa e efeito presente nos dados [Aguirre 2007].

Uma técnica para identificar sistemas não lineares que tem uma proposta interessante é a identificação com multimodelos [Foss et al. 1995], também conhecida como múltiplos modelos. Esta forma de identificação sugere dividir sistemas complexos e de grande porte em pequenos sistemas que, combinados por uma métrica, resultam no sistema maior. Dividir um problema mais complexo em problemas mais simples em que a combinação das soluções mais simples gera a solução do problema complexo, não é uma idéia nova. K. Konstantinov [Konstantinov & Yoshida 1989], e mais recentemente Zhang [Zhang et al. 1994] produziram trabalhos para resolver o problema de controle do processo de fermentação utilizando uma técnica similar a esta. Eles utilizaram o fato de que diferentes fenômenos dominam o sistema em diferentes partes do ciclo, e construíram um conjunto de modelos locais que são válidos para cada uma destas diferentes partes. Eles também especificaram um método para selecionar o modelo local mais apropriado para cada situação. Atualmente, seus trabalhos inspiram outros trabalhos tanto na área de identificação de sistemas quanto na área de controle, sendo o método de seleção dos modelos locais conhecido como métrica.

O trabalho de Foss [Foss et al. 1995] afirma que modelos locais, aos quais chamou de modelos baseados nos regimes de operações, podem ser usados como medidas para o processo de modelagem em torno da região abrangida pelas condições de operação dos modelos locais. Esta técnica de modelagem foi utilizada como uma das etapas do controle preditivo de um processo de fermentação. Smith-Murray e Johansen [Smith-Murray & Johansen 1997] generalizaram a idéia de Foss [Foss et al. 1995] com o conceito básico de representar um sistema não linear como a combinação de sistemas lineares em que

técnicas clássicas de controle podiam ser aplicadas. Neste momento, o conceito de multimodelos e de métrica já estão sendo utilizados para caracterizar a técnica. Multimodelos seria, então, a idéia de combinar vários modelos simples de forma que sua combinação forme um modelo mais complexo. Métrica seria a forma em que essa combinação de modelos simples é realizada.

Várias outras métricas se desenvolveram a partir dos conceitos de Foss e Smith-Murray e dentre estas se destacou a chamada métrica de medida da lacuna (*Gap Metric*) proposta por Galán [Galán et al. 2000]. Neste trabalho, uma lacuna é calculada para cada duas funções lineares e, utilizando seu valor, descarta-se ou não uma função linear. O trabalho não especificava o valor exato da lacuna para poder descartar uma função linear, porém sabe-se que quando a lacuna era próxima de “zero”, as duas funções eram bem parecidas e uma delas poderia ser descartada. Quando era próximo de “um”, as funções eram distintas e necessitavam continuar. A técnica operava de forma off-line para saber quantas e quais as funções lineares são necessárias para controlar o sistema não linear. A métrica de medida da lacuna passa a ser utilizada em malha fechada e de forma on-line no trabalho de Arslan [Arslan et al. 2004].

Mais recentemente, a estratégia de multimodelos vem sendo utilizada como uma das etapas do controle preditivo [Fontes et al. 2007]. Neste tipo de controlador, vários modelos locais são criados e a predição de qual será o estado do sistema em um instante subsequente torna possível a escolha de uma ação ótima para o controlador [Camacho & C.Bordons 2004, Maciejowski 2002]. Assim, quanto mais exata a predição do comportamento real, melhor poderá ser a escolha do controlador utilizado. A predição, contudo, pode ser realizada por um modelo simulado do sistema real e que é identificado a partir deste.

A identificação ou modelagem de um problema pode ser realizada de diversas formas. Segundo Aguirre [Aguirre 2007] a identificação de sistemas pode ocorrer de forma determinística onde nenhum tratamento de ruídos é realizado, ou seja, só apresentam bons resultados quando a relação sinal/ruído é suficientemente alta ou através de outros métodos, como o estocástico LSE que constrói modelos lineares fazendo um tratamento dos sinais com ruídos, porém não é um método aconselhável para identificar sistemas não lineares.

Para sistemas não lineares alguns métodos são consistentes na literatura. Dentre estes métodos estão as redes neurais artificiais, as funções de base radial, RBF's, sistemas *fuzzy*, sistemas *neuro-fuzzy* e outros. Na rede neural, um problema pertinente é a configuração de sua estrutura. Descobrir qual a função de ativação dos neurônios, quantas camadas e quantos neurônios em cada camada deve ter a rede neural para que esta apresente os melhores resultados pode se tornar um trabalho árduo e cansativo. Nos sistemas *fuzzy* e *neuro-fuzzy* do tipo Sugeno, por exemplo, deve-se descobrir qual o grau do polinômio Sugeno, quantas e qual o formato das funções de pertinência que devem ser utilizadas. Nas RBF's, o número de funções de base radial, a escolha dos centros das funções e suas aberturas, também interferem substancialmente na etapa de projeto do método.

No âmbito da busca constante por técnicas com características que atendam cada vez mais as crescentes necessidades da indústria, a mistura de técnicas vem sendo utilizada como artifício para novas descobertas. Uma técnica híbrida, nova, que se firma diante

da sociedade acadêmica, abre espaço para novas combinações envolvendo os princípios recém desenvolvidos. A forma como esta combinação é realizada também influencia no diferencial para o surgimento de uma nova técnica. Como exemplo, considere a técnica *neuro-fuzzy* de modelo ANFIS. Nesta técnica, um sistema *fuzzy* de modelo Takagi-Sugeno tem o seu desenvolvimento descrito em camadas, assim como em uma rede neural de seis camadas com pesos unitários interligando os neurônios e funções de ativação distintas para as camadas. A identificação com este tipo de técnica ocorre, geralmente, com a obtenção de um conjunto de treinamento, formado por pares de entrada-saída, assim como nas redes neurais de múltiplas camadas. Uma das principais características que diferenciam o ANFIS das redes neurais artificiais é a forma de codificação do conhecimento. Enquanto nas RNAs o conhecimento é codificado em pesos cujas ações são de difícil interpretação, no ANFIS o conhecimento é codificado em uma estrutura do tipo *fuzzy* que possui uma certa aproximação da lógica utilizada por humanos.

No trabalho de Yang [Yang et al. 2003], a mistura de técnicas ocorre de forma distinta da apresentada pelo ANFIS. Neste trabalho, duas estruturas colaboram para a formação da única técnica, diferentemente do que ocorre no ANFIS em que duas técnicas colaboram em uma mesma estrutura. Mais especificamente, o que acontece é a criação de duas estruturas distintas, a primeira baseada na análise de mecanismos e identificação e a segunda é uma rede neural do tipo RBF. A primeira estrutura é utilizada para aprender conceitos gerais e fórmulas matemáticas que representem, aproximadamente, o sistema a ser identificado. Estas informações são codificadas diretamente através de fórmulas matemáticas pelo projetista. Em seguida, uma subtração entre as saídas desejadas e a obtida pela primeira estrutura é realizada e uma RBF é utilizada para aprender esta diferença. Assim, a RBF realiza um tipo de ajuste fino e a saída total da técnica é dada pela soma da primeira com a segunda estrutura.

Como proposta deste trabalho, em uma única estrutura ocorre a combinação de duas principais técnicas, multimodelos e ANFIS. Enquanto a técnica de multimodelos acrescenta à estrutura uma forma prática de encontrar os parâmetros da estrutura ANFIS, o ANFIS incorpora ao multimodelos a possibilidade de otimização da interpolação dos modelos (métrica) com o aprendizado.

O primeiro passo para a implementação da técnica proposta é identificar as entradas que interferem na dinâmica do sistema. Em seguida, verifica-se como essas entradas se relacionam para, assim, definir as funções de pertinência e, conseqüentemente, o número de modelos lineares para representar o sistema por completo.

Para verificar o relacionamento entre as entradas, considere o exemplo de um sistema dinâmico. Neste tipo de sistema, um novo estado é verificado através do conhecimento do estado atual e das variáveis que influenciam o sistema. Desta forma, tem-se como entrada de um possível identificador as variáveis que influenciam o sistema e uma variável para representar o estado atual do sistema. Para encontrar o número de funções de pertinência desta última entrada, o procedimento desenvolvido foi a observação da não linearidade de seu comportamento quando submetido a variações nas variáveis que influenciam o sistema e a divisão de seu intervalo de excursão em sub-regiões de forma que cada sub-região possa ser aproximada por uma função linear. Para as outras entradas, o procedimento é equivalente, ou seja, observar a não linearidade de sua influência

no sistema quando submetido a variações em seu próprio valor ou nas outras variáveis que influenciam o sistema, dividindo esta influência, caso seja não linear, em sub-regiões (também chamadas de partições) que possam ser aproximadas por equações lineares.

Cada uma das sub-regiões encontradas corresponderá a uma função de pertinência e seus cruzamentos corresponderão às regras do tipo *fuzzy*. Estas regras concluirão funções do tipo Sugeno que podem ser modelos lineares encontrados com a aplicação do método dos mínimos quadrados (LSE). Para a aplicação do algoritmo de mínimos quadrados é necessário obter um conjunto de dados que informem o comportamento do sistema para cada modelo linear que se deseja obter, ou seja, para cada regra *fuzzy*. Desta forma, as entradas do sistema serão excitadas em cada sub-região separadamente de forma a encontrar um conjunto de dados para cada regra, possibilitando a aplicação do algoritmo dos mínimos quadrados. Observe que com a aplicação do LSE não linearidades provenientes de ruídos dos sensores de leitura, dinâmica de atuadores, atraso de transporte do sistema, dentre outros, são desprezados. Aplicações on-line podem utilizar o algoritmo dos mínimos quadrados recursivo, porém esta não será abordada neste trabalho.

O próximo passo da técnica desenvolvida é a atribuição de valores iniciais para os parâmetros das funções de pertinência que estão dispostas de forma a representar as sub-regiões das variáveis de entrada. Para este passo, uma forma prática baseada nos dados utilizados para a criação dos modelos lineares foi empregada. Finalmente, um novo conjunto de dados será utilizado como conjunto de aprendizagem para otimizar as funções de pertinência do identificador. Esta otimização incorpora ao identificador algumas das não linearidades desprezadas pela aplicação do algoritmo LSE e é inerente à técnica *neuro-fuzzy* ANFIS.

Das técnicas já consolidadas, as Funções de Base Radial se assemelham bastante com a idéia empregada. Analisando o fluxo de dados em uma RBF e fazendo um paralelo com os sistemas *fuzzy*, tem-se que as funções de base radial são equivalentes às funções de pertinência, guardando suas diferenças em relação às dimensionalidades das equações, e os pesos são equivalentes a *sigletons* nas funções de pertinência de saída de um sistema *fuzzy*. A estrutura de identificação multimodelos proposta substitui os pesos da RBF por modelos lineares de cada região, aplica normalização nos dados provenientes das regras, antes de multiplicar pelos modelos lineares, e visualiza funções de pertinência independentes para cada entrada. Esta última característica possibilita a relação direta entre a entrada, o resultado produzido e o desenvolvimento de funções de pertinência de base não radial, como, por exemplo, o formato trapezoidal.

A diferença para o ANFIS proposto por Jang em seu livro [Jang et al. 1997] está no fato de na nova técnica as funções Sugeno assumirem o papel de modelos lineares que aproximam regiões bem definidas, formadas pelo cruzamento das sub-regiões de entrada, cujo objetivo da aprendizagem é interpolar devidamente as regiões de forma a obter um comportamento desejado e com alguma não linearidade.

Outra técnica que possui semelhanças à apresentada neste trabalho é a identificação de modelos *fuzzy* baseadas em estimação de blocos (*Cluster Estimation*), cuja idéia principal é iniciar automaticamente os parâmetros do *fuzzy* através dos dados de aprendizagem. A base dos identificadores que utilizam estimação de blocos pode ser encontrada no algoritmo chamado de *Mountain Method* [Yager & Filev 1992, Yager & Filev 1993]. De forma

simplificada, neste algoritmo é definido o número de blocos (*clusters*) para cada uma das entradas de modo que seus cruzamentos formem uma tabela e, utilizando o conjunto de treinamento, verifica-se quantos pontos do conjunto de treinamento caem em cada posição desta tabela. A posição da tabela com maior número de pontos será considerada como um centro de bloco. Após encontrar um centro, as posições da tabela próximas a este centro são decrescidas por um fator de forma a diminuir a potencialidade das posições próximas dos centros a se tornarem novos centros. O algoritmo segue encontrando centros até que determinado critério relacionado à potencialidade das posições da tabela seja satisfeito. De posse dos centros é possível extrair os dados necessários para gerar tanto as funções de pertinência de entrada quanto os *singletons* para as funções de pertinência de saída. Então, o algoritmo de retropropagação do erro pode ser aplicado para otimizar a estrutura.

O trabalho de Chiu [Chiu 1994] faz algumas alterações na proposta do *Mountain Method*. Ao considerar cada ponto de treinamento como um possível centro de um bloco fez com que a tabela de *clusters* tivesse exatamente o número de pares de treinamento como possíveis centros e a influência do centro recém criado na sua vizinhança poderia cair exponencialmente em relação à distância. Outra contribuição de Chui ocorre em relação ao critério de parada que verifica uma margem e não apenas um ponto de corte, que poderia ser muito difícil de encontrar. O trabalho também sugere a aplicação do algoritmo LSE para adaptação dos consequentes das funções de pertinência que deixariam de ser *singletons* e passariam a ser funções Sugeno de primeira ordem.

Observando o desenvolvimento das técnicas baseadas em *Cluster Estimation* verifica-se que uma das grandes dificuldades está no fato de definir constantes para o limite do ponto de corte ou da região de corte para determinar o número de centros de blocos. A identificação com multimodelos resolve este problema dividindo o comportamento das entradas em sub-regiões que, se comparadas às técnicas baseadas em *Cluster Estimation*, são equivalentes aos centros. Observe que a criação dos centros não está relacionada com a quantidade de pontos para cada região, mas com o comportamento do sistema e das variáveis que o alteram. Desta forma, os algoritmos baseados em *Cluster Estimation* podem deixar de criar centros em regiões cujo comportamento é bastante não linear por apresentarem poucos pontos, fazendo com que a dinâmica do sistema seja precária nessas regiões. A possibilidade de funções de pertinência em formato de base não radial também é uma característica que possibilita o aumento da generalização do identificador sem a necessidade de mais centros de blocos.

Uma outra contribuição desta técnica abrange a área de identificação com multi-objetivos, pois o treinamento do sistema com multimodelos não altera as funções lineares encontradas para cada região. Desta forma, o modelo identificado cumpre tanto o objetivo de descrição do sistema quanto o de interpretação dos modelos locais [Johansen & Babuška 2003].

A técnica apresentada foi testada num tanque de água real medindo 53 cm de altura e com capacidade para aproximadamente 10 litros. Este tanque possui 5 seções distintas e bem definidas, um orifício de saída e um sensor de pressão, ambos no fundo, e uma bomba de alimentação com capacidade para bombear, aproximadamente, 6,5 litros por minuto em condições ideais. O uso de tal sistema é justificado pelos diversos modelos que podem

ser obtidos em regiões bem estabelecidas e que possibilitam a análise da técnica com distintas configurações. As não linearidades pertinentes de um sistema real testam tanto a robustez quanto a aplicabilidade da técnica em problemas relacionados à sua prática.

Este trabalho foi dividido da seguinte maneira: o capítulo 2 é uma revisão a respeito das duas principais técnicas utilizadas neste trabalho, múltiplos modelos e ANFIS. O capítulo 3 apresenta as diferentes estruturas do algoritmo do ponto de vista do ANFIS. O capítulo 4 trata da técnica desenvolvida mostrando como utilizar e iniciar as estruturas para representar o identificador de sistemas. No capítulo 5 é discutido um estudo de caso em que um tanque multisseções junto com todos os seus principais componentes são apresentados. Ainda no capítulo 5 são apresentados os programas desenvolvidos e como os programas atuavam para aplicar a técnica sobre o tanque em questão. Os resultados do estudo de caso são divididos em três partes, identificação caixa preta, identificação caixa cinza e identificação caixa branca. Na identificação caixa preta, tem-se o conhecimento apenas das entradas e saídas do sistema a ser identificado e, a partir destes dados, monta-se a estrutura e aplica-se a técnica. Já na identificação caixa cinza modelos são incorporados ao identificador com base na estrutura do sistema. Na identificação caixa branca os modelos são obtidos a partir das relações fenomenológicas do sistema. Para finalizar os resultados, a identificação utilizando a técnica NNARX é implementada e seus resultados são comparados com os obtidos pela técnica proposta. O capítulo 6 conclui o trabalho apresentando comentários sobre o que foi desenvolvido e apresenta possibilidades para trabalhos futuros.

Capítulo 2

Técnicas Utilizadas

Neste capítulo são apresentadas as duas principais técnicas utilizadas neste trabalho: Múltiplos modelos e ANFIS. Um breve comentário sobre suas características e estruturas é realizado, assim como a classificação e a nomenclatura correntemente utilizada nas áreas.

2.1 Múltiplos Modelos

Os Múltiplos modelos têm sido usados largamente na engenharia com aplicações em modelagem [Liu & Djurdjanovic 2008, Vinsonneau et al. 2005, Venkat et al. 2003], estimação de estados [Orjuela et al. 2008a, Orjuela et al. 2008b, Uppal et al. 2003] e controle de sistemas não lineares [Cavalcanti et al. 2008, Mazinan & Sadati 2008, Wengang et al. 2008, Giovanini et al. 2005, Cavalcanti 2008]. A ideia principal de Múltiplos modelos é empregar a estratégia de “dividir para conquistar” em que um sistema não linear tem seu intervalo de excursão dividido em regiões menores e que possam ser aproximadas por modelos mais simples, como os lineares. Desta forma, vários modelos são desenvolvidos e, de acordo com o estado do sistema, um ou vários destes modelos são utilizados para compor o sistema original em cada instante. Observe que a precisão da estimação dos modelos a serem utilizados está ligada à precisão do modelo matemático utilizado e a qualidade das medições empregadas. Porém, o modelo matemático é uma representação abstrata do mundo real que apenas aproxima o comportamento dinâmico do sistema em questão. Consequentemente, erros de modelagem entre o sistema e o modelo são inevitáveis.

A estratégia de identificação com múltiplos modelos pode ser descrita resumidamente como,

- Definir alguns modelos correspondendo a pontos de operação distintos do sistema complexo.
- Identificar e aplicar o modelo que melhor representa o sistema em cada instante.

A classificação dos identificadores com múltiplos modelos pode corresponder à mesma aplicada aos controladores que utilizam a mesma técnica [Mazinan & Sadati 2008]: identificador clássico ou identificador inteligente. No identificador do tipo clássico, os modelos são selecionados através de um chaveamento. Então, de acordo com este critério,

o modelo com menor erro em relação ao processo é escolhido, ou seja, o chaveamento é usado para identificar o modelo mais próximo ao processo naquele instante. Matematicamente, tem-se que a escolha dos modelos é dada pela equação [Habibi et al. 2006],

$$X_{k+1} = \begin{cases} p_1 X_k + q_1 Y_k, & \text{se } X_k \in L_1 \\ \dots & \\ p_N X_k + q_N Y_k, & \text{se } X_k \in L_N \end{cases} \quad (2.1)$$

em que X é o estado do sistema, Y é a entrada, p e q são constantes, $\{L_i\}_{i=1}^N$ são as partições do intervalo de excursão. Ou pela representação equivalente [Liu & Djurdjanovic 2008],

$$X_{k+1} = \sum_{i=1}^N g_i(X_k) \cdot Ri(X_k, Y_k); \quad (2.2)$$

em que $Ri(X_k, Y_k)$ é o modelo local em função das entradas e $g_i(\cdot)$ é o ganho que é dado pela função delta de Kronecker,

$$g_i(X_k) = \begin{cases} 1, & \text{se } X_k \in L_i \\ \dots & \\ 0, & \text{caso contrário} \end{cases} \quad (2.3)$$

A figura 2.1 apresenta a metodologia da identificação com múltiplos modelos do tipo clássico. Os blocos R1, R2 e RN representam os modelos encontrados para as N regiões em que o intervalo de excursão das variáveis de entrada foi dividido. Note que o intervalo de excursão de uma variável de entrada é definido, neste trabalho, como o conjunto formado pelos valores que esta variável pode assumir.

Para os identificadores do tipo inteligente, a metodologia da identificação é ilustrada na figura 2.2, cujo mecanismo de definição é baseado em lógica *fuzzy*. Outros métodos como RBF ou algoritmos genéticos podem ser classificados como inteligentes, já que a grande distinção entre os tipos clássicos e inteligentes está no fato do primeiro chavear em busca do modelo mais apropriado, enquanto que os inteligentes realizam a interpolação de modelos e encontram uma combinação ótima que pode ser, inclusive, a escolha de um único modelo.

2.2 ANFIS

O ANFIS, *Adaptive Neuro-Fuzzy Inference Systems*, é uma técnica inteligente híbrida, mais especificamente uma técnica *neuro-fuzzy*, que infere conhecimentos utilizando uma estrutura com lógica *fuzzy*, fácil de tratar, e acrescenta à esta estrutura a possibilidade de aprendizagem inerente às redes neurais artificiais. O ANFIS também pode ser visto como uma rede neural artificial de seis camadas (figura 2.3), em que cada camada é responsável por uma operação que resultará em uma saída equivalente à encontrada por um sistema *fuzzy* do tipo Takagi-Sugeno [Jang et al. 1997, Jang & Sun 1995].

O fluxo de dados no ANFIS pode ser descrito em camadas. Na camada de número zero estão dispostas as entradas do sistema. Na camada um, os valores das entradas

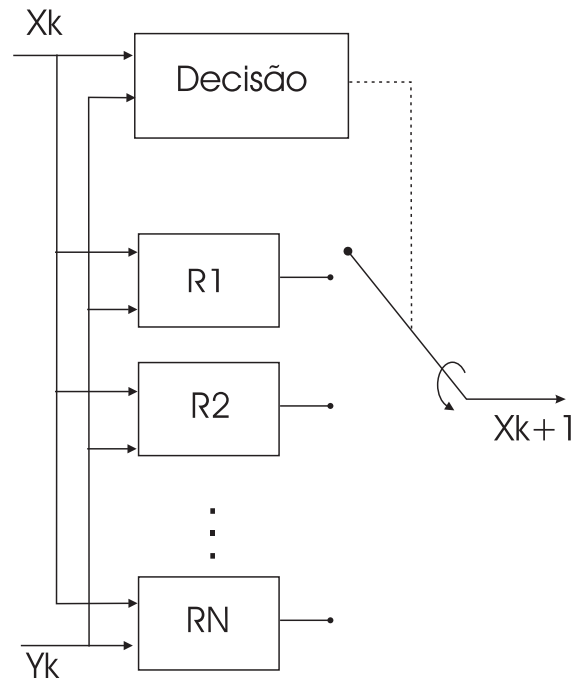


Figura 2.1: Estratégia clássica de identificação com múltiplos modelos.

são operados por funções de pertinência que indicam o grau de compatibilidade de cada entrada nos conjuntos *fuzzy* de entrada. Na camada dois, as regras *fuzzy* são implementadas. Na camada três ocorre a normalização das saídas dos neurônios da camada anterior, $\bar{w}_i = \frac{w_i}{\sum_{j=1}^N w_j}$, em que N é o número de neurônios da camada anterior. Já na camada quatro, os valores normalizados são multiplicados por funções do tipo Sugeno em função das entradas para serem somados na camada cinco.

No ANFIS, o ajuste dos parâmetros ocorre, principalmente, em duas camadas: na camada número dois e na camada número quatro. Os neurônios destas camadas são representados graficamente por quadrados e possuem funções com parâmetros variáveis que podem ser ajustados para otimizar um critério da mesma forma que as redes neurais artificiais com aplicação de métodos de aprendizagem baseados no gradiente, como a retropropagação do erro (*back propagation*).

Por seu caráter híbrido unir características de duas técnicas inteligentes, o ANFIS vem sendo aplicado em muitos trabalhos nas áreas de modelagem [Zhai et al. 2009, Ding & Liang 2008], previsão [Xie et al. 2009, Bao-ping & Zeng-qiang 2009, Khadangi et al. 2009], tratamento de sinais [WenNa et al. 2009], associação de dados [Tafti & Sadati 2009], controle [Rodrigues et al. 2009], dentre outras.

Observando a estratégia inteligente de identificação com múltiplos modelos, tem-se que a escolha dos modelos lineares é realizada pela estrutura *fuzzy*. Então, ao utilizar os modelos lineares como consequentes na estrutura ANFIS, pode-se realizar a seleção dos modelos com a inferência *fuzzy* e ainda otimizar os parâmetros com a característica neural pertinente ao ANFIS. Esta idéia de unir *neuro-fuzzy* e multimodelos pode ser encontrada ainda no trabalho [Uppal et al. 2006], como observador de estados. Porém, a forma de ini-

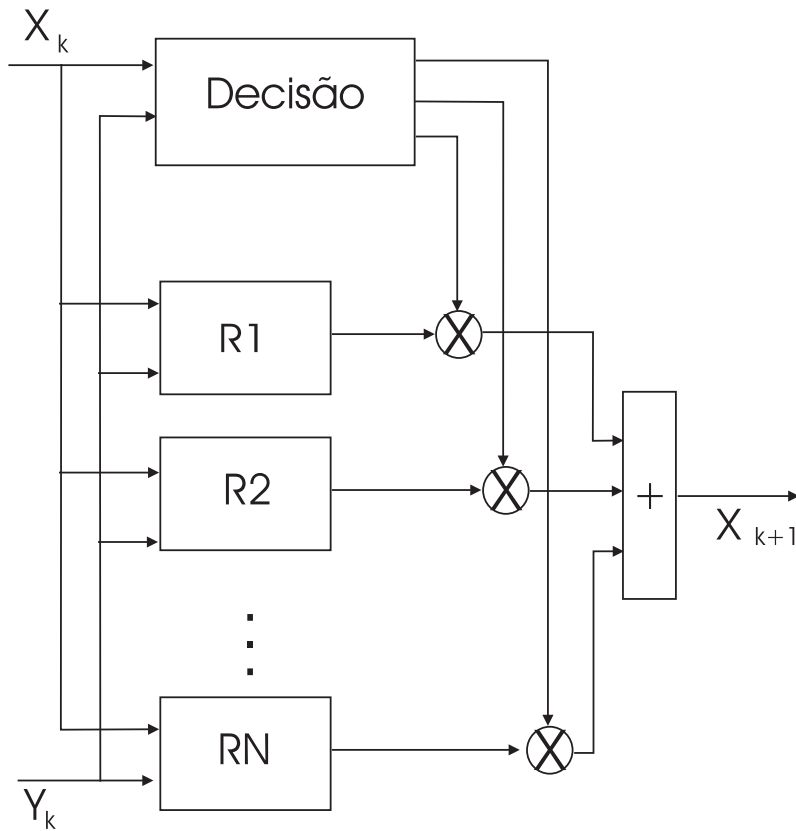


Figura 2.2: Estratégia inteligente de identificação com múltiplos modelos.

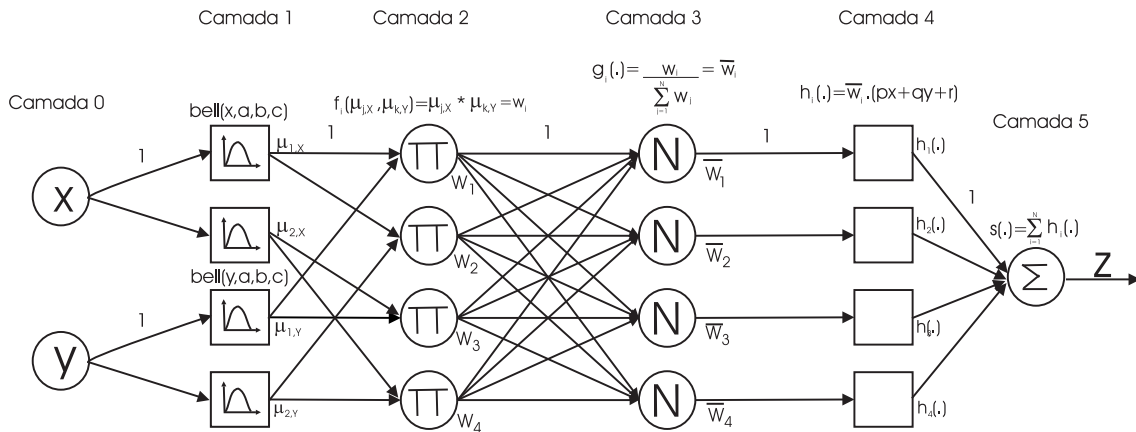


Figura 2.3: Esquema da estrutura híbrida ANFIS dividida em camadas.

cialização dos modelos, otimização de variáveis e ainda a aplicabilidade do desenvolvido neste trabalho, diverge em relação ao já produzido.

Capítulo 3

Múltiplos modelos utilizando ANFIS

Neste capítulo é apresentada a estrutura para a representação da nova técnica de identificação com múltiplos modelos. De forma simplificada, a técnica visa partir de um sistema complexo e dividi-lo em setores, que serão equivalentes às regras *fuzzy*. Estes setores possuem não linearidades mais suaves e podem ser aproximados pelos modelos lineares gerados a partir do algoritmo dos mínimos quadrados (LSE) com mais exatidão do que um único modelo para todo o sistema. Desta forma, os modelos lineares encontrados para cada setor serão ativados utilizando regras que são formadas pelo cruzamento das funções de pertinências das entradas. Assim, pode-se concluir que, para a aplicação e para a escolha da estrutura da técnica, é necessário definir o número de entradas e o número de funções de pertinência das entradas. Inicialmente é apresentada a estrutura do identificador com uma entrada e uma saída (SISO) e são comentadas as operações realizadas durante o fluxo de dados na estrutura. Em seguida, é apresentada a estrutura para múltiplas entradas e uma saída (MISO) e, finalmente, para múltiplas entradas e múltiplas saídas (MIMO).

3.1 Estrutura SISO – *Single Input Single Output*

A representação de um sistema dinâmico SISO (*Single Input Single Output*) com estrutura em conformidade com o modelo *neuro-fuzzy* ANFIS, para três funções de pertinência, pode ser observada na figura 3.1. Seguindo a notação proposta por Jang [Jang et al. 1997] e ilustrado na figura 2.3, observa-se que todos os pesos que interligam neurônios são iguais a 1 e não são ajustáveis. Os neurônios representados por quadrados possuem parâmetros ajustáveis, já os neurônios representados por circunferências não necessitam de adaptação, ou por realizarem apenas operações matemáticas, não contendo parâmetros ajustáveis, ou por estes parâmetros já serem considerados ótimos na estrutura.

Analisando o fluxo de dados da figura, temos que:

- Na camada 0 estão dispostas as entradas do sistema. Por se tratar de um SISO, esta camada possui um único elemento e este corresponderá ao estado atual do sistema dinâmico. Configurações com mais entradas serão estudadas posteriormente.
- Na camada 1 ocorre a chamada *fuzzyficação*, em que os valores das entradas são convertidos em pertinências *fuzzy* (μ), ou seja, ocorre a verificação de quão compatível é a entrada com relação às funções de pertinência. As funções de pertinência




Figura 3.1: Representação da técnica em estrutura SIS0.

podem ser de vários formatos, dentre os mais comuns temos: formato de sino, gaussiana, triangular, trapezoidal e *Left – Right MF*.

- Na camada 2 nenhuma operação é efetuada. Esta camada corresponde às regras *fuzzy* e só realiza operações quando são consideradas mais de uma entrada.
- Na camada 3 ocorre a etapa de normalização das pertinências *fuzzy*. Na saída desta camada, a soma dos valores dos μ 's da *fuzzyficação* passará a ser igual a 1.

$$\bar{\mu}_i = \frac{\mu_i}{\sum_{j=1}^N \mu_j}; \quad (3.1)$$

em que i é a pertinência em questão e N é o número total de pertinências.

Note que é necessária a ativação de pelo menos uma função de pertinência para que a normalização não resulte em uma divisão por zero.

- Na camada 4 os μ 's normalizados da camada anterior ($\bar{\mu}_i$) são multiplicados pelas funções Sugeno. Estas funções Sugeno serão modelos lineares do tipo [Takagi & Sugeno 1985, Sugeno & Kang 1988]:

$$f_i(X_k) = p_i X_k; \quad (3.2)$$

em que i é o neurônio em questão, k é o índice da entrada e a constante p pode ser encontrada através da aplicação de um método de modelagem linear como o estocástico LSE que será visto no capítulo 4.

- Na camada 5 as funções lineares devidamente ponderadas da camada anterior serão somadas gerando, assim, a saída da rede.

$$X_{k+1} = \sum_{i=1}^N \bar{\mu}_i \cdot f_i(X_k); \quad (3.3)$$

Nesta rede neural, pode-se aplicar o algoritmo de aprendizagem como, por exemplo, o de retropropagação do erro (*Back-propagation*) [Haykin 2001] para ajustar as funções de pertinência e, assim, obter uma combinação otimizada de modelos lineares. No capítulo 4 o algoritmo *Back-propagation* será apresentado.

Observe que diferente da estrutura ANFIS proposta por Jang [Jang et al. 1997] e esquematizada na figura 3.2, a aprendizagem da técnica proposta, figura 3.1, está restrita à camada 1, não se estendendo a outras camadas. Esta opção justifica-se pela obtenção dos modelos lineares que representam cada região individualmente e que sejam satisfatórios para sua região específica. Assim, a função do ANFIS será a de encontrar a melhor combinação destes modelos ajustando apenas as funções de pertinência. Qualquer adaptação dos modelos lineares deve ocorrer logo antes da linearização, ajustando os dados que serão linearizados, aumentando o número de regiões para representar o sistema ou modificando o formato das funções de pertinência que serão usadas.




Figura 3.2: Estrutura SISO do modelo *neuro-fuzzy* ANFIS proposto por Jang.

A realização da aprendizagem apenas na camada 1 da rede, além de possibilitar uma convergência mais rápida do algoritmo de aprendizagem, pois possui um número menor de variáveis ajustáveis, satisfaz os requisitos de identificação com múltiplos objetivos, garantindo a descrição do sistema identificado e a interpretação dos modelos locais, já que estes não serão alterados.

Observe que a camada 2 da figura 3.1 pode deixar de existir e formar uma representação mais simplificada para a representação SISO (figura 3.3). Esta camada é responsável pela formação das regras *fuzzy*, mas a estrutura possui apenas uma entrada dividida em funções de pertinência. Sendo assim, a saída da regra é a própria pertinência da função de pertinência e esta camada pode ser omitida sem qualquer implicação ao resultado final.

3.2 Estrutura MISO – *Multi Input Single Output*

A figura 3.4 ilustra a estrutura do identificador quando duas entradas e duas funções de pertinência para cada entrada são consideradas.

Note que no esquema desta configuração a técnica também irá ajustar apenas as funções de pertinência, pois os modelos lineares encontrados pelo LSE serão considerados ótimos.

A técnica visa encontrar modelos lineares que aproximem o comportamento do sistema em setores distintos e os interpolar de forma que o resultado da interpolação seja

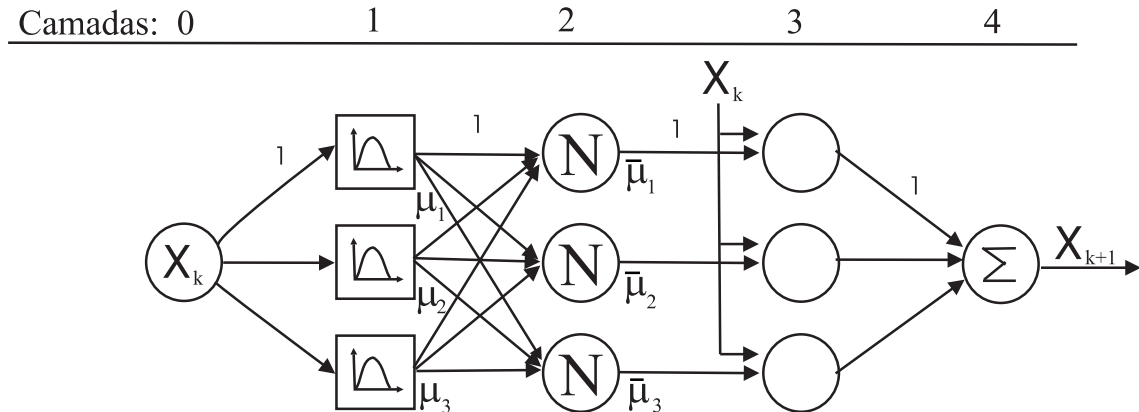


Figura 3.3: Estrutura SISO simplificada.

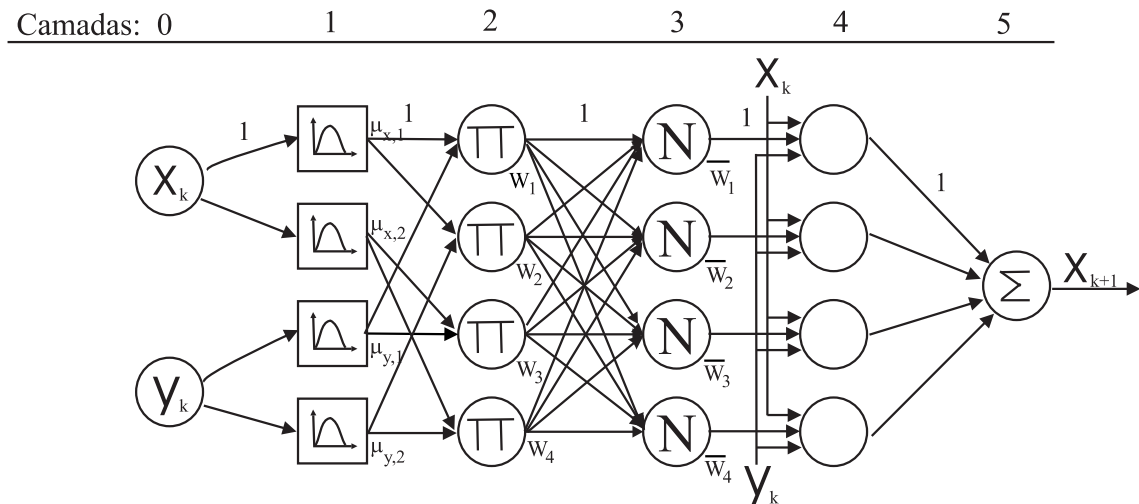


Figura 3.4: Representação da técnica em estrutura MISO.

o próprio comportamento do sistema. Em um sistema dinâmico, uma entrada deve representar o estado atual do sistema, enquanto as outras alteram a dinâmica deste sistema. A entrada que corresponde ao estado atual deve ter seu intervalo de excursão dividido em partições, ou sub-regiões, de forma que modelos lineares possam ser utilizados para aproximá-las devidamente. No caso das outras entradas, verifica-se em quantas sub-regiões, ou partições, podem ser divididas o seu intervalo de excursão para que suas influências no sistema se aproximem de funções do tipo linear. Essa divisão pode ser realizada através da análise das variações em seu próprio valor ou em outras entradas, caso existam. A forma de divisão do intervalo de excursão das variáveis é comentada no capítulo 4 e um exemplo prático de aplicação é apresentado no capítulo 5. Observe que na figura 3.4 o intervalo de excursão da entrada que representa o estado atual, entrada X_k , e de uma variável que altera o estado do sistema, entrada Y_k , foram divididas em duas partições. Estas partições irão constituir funções de pertinência e o cruzamento destas funções de pertinência irá gerar as regras *fuzzy* da técnica desenvolvida.

Analisando o fluxo de dados na estrutura, pode-se observar que a função de pertinência

informará o grau de compatibilidade de cada entrada com uma partição e cada regra irá informar qual a intensidade de ativação de cada modelo linear. As funções de pertinência estão relacionadas com as regras através da inferência *fuzzy* que pode ser vista como o cruzamento da compatibilidade das partições.

Note que a camada 2 desta configuração representa as regras *fuzzy* e a normalização da camada 3 ocorre em relação aos valores resultantes destas regras. Só depois de normalizados é que estes valores irão ativar os modelos lineares, tornando a soma dos pesos que ativam os modelos lineares igual a 1.

Para a estrutura da figura 3.4 as funções Sugeno da camada 4 (equação 3.2) passarão a ser modelos lineares do tipo:

$$f_i(X_k, Y_k) = p_i X_k + q_i Y_k; \quad (3.4)$$

em que i é o neurônio em questão, k é o índice da entrada e as constantes p e q podem ser encontradas através da aplicação de um método de modelagem linear como o LSE que será visto no capítulo 4.

Em uma nova configuração, apenas uma das entradas é dividida em partições. Nela, considera-se que uma entrada influencia no resultado através de diferentes funções lineares, enquanto as outras entradas influenciam o sistema através de uma única função linear, ou seja, seu comportamento pode ser aproximado por uma única reta. A figura 3.5 apresenta esta nova configuração, que pode ser aproximada por uma configuração próxima à SISO simplificada, como mostra a figura 3.6.

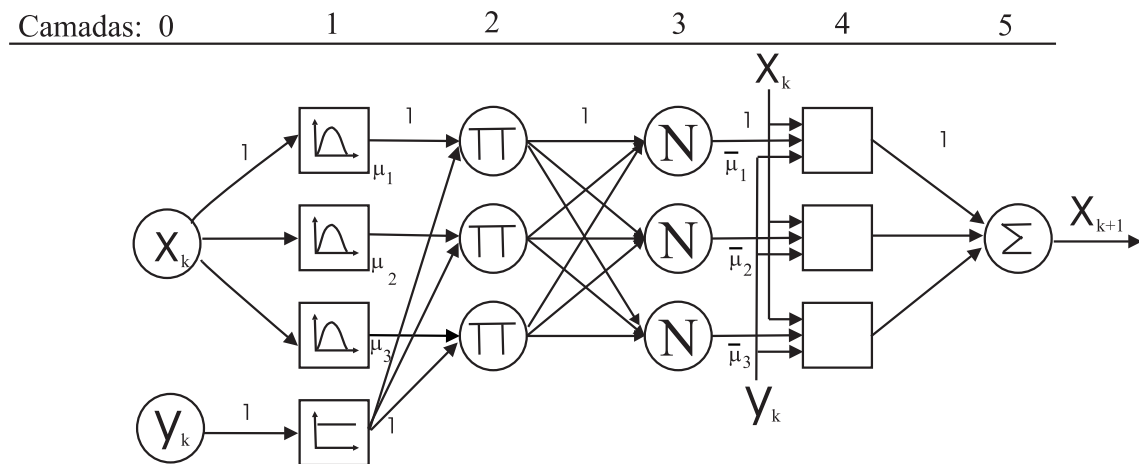


Figura 3.5: Estrutura MISO com apenas uma entrada dividida em regiões.

Observe que a omissão da camada 2 da estrutura inicial só é possível quando apenas uma entrada é dividida em regiões, que torna dispensável o cálculo da regra. A segunda entrada, por sua vez, atuará diretamente nos modelos lineares.

Assim como a segunda entrada foi adicionada, acredita-se que outras entradas possam ser acrescentadas à estrutura com pequenas alterações. Observe que quanto maior o número de entradas, maior poderá ser o relacionamento entre estas e, conseqüentemente, maior o número de regras e o número das regiões para as quais modelos lineares deverão ser encontrados.

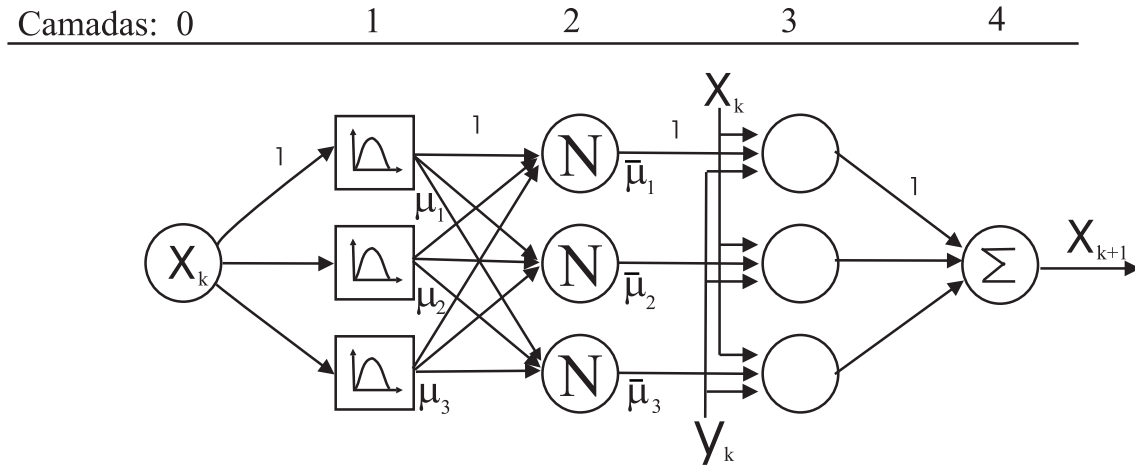


Figura 3.6: Estrutura MISO simplificada e com apenas uma entrada dividida em regiões.

Modelos lineares de ordem superior também podem ser considerados para os conseqüentes da camada 4. Porém esta estratégia aumenta o número de entradas do sistema, o que pode levar a um aumento considerável do número de regras, tornando o emprego da técnica laborioso.

3.3 Estrutura MIMO – *Multi Input Multi Output*

Um sistema linear de primeira ordem, discreto, invariante no tempo, com múltiplas entradas e múltiplas saídas (MIMO) pode ser representado pelas equações,

$$\begin{cases} X1_{k+1} = p_{11}X1_k + p_{12}X2_k + q_{11}Y1_k + q_{12}Y2_k \\ X2_{k+1} = p_{21}X1_k + p_{22}X2_k + q_{21}Y1_k + q_{22}Y2_k \end{cases} \quad (3.5)$$

em que k é o índice da entrada e as constantes p_{11} , p_{12} , q_{11} , q_{12} , p_{21} , p_{22} , q_{21} e q_{22} podem ser encontradas através da aplicação de um método de modelagem linear, como o estocástico LSE, para cada um dos sistemas separadamente.

Observe que o número de entradas é maior para um sistema MIMO. Conseqüentemente, o número de regras e o número de regiões poderão ser maiores e tornar a aplicação da técnica laboriosa, pois muitas regiões teriam que ser consideradas e a legibilidade das ações da técnica ficaria comprometida.

A figura 3.7 ilustra o caso em que a estrutura MIMO é apresentada como a combinação de duas estruturas MISO. Desta forma, múltiplas saídas podem ser representadas pela técnica que utilizará o número de estruturas MISO igual ao número de saídas do sistema [Akhlaghi et al. 2008, Ding & Liang 2008].

Quando uma variável de saída independe das variações da outra variável de saída, ou seja, o sistema é desacoplado, a estrutura para identificar se torna mais simples.

A definição da estrutura a ser usada pelo identificador vai depender da característica do sistema que se deseja identificar. Quando se trata de sistemas dinâmicos, uma entrada é obrigatória ao desenvolvimento da técnica e esta entrada é a própria variável a

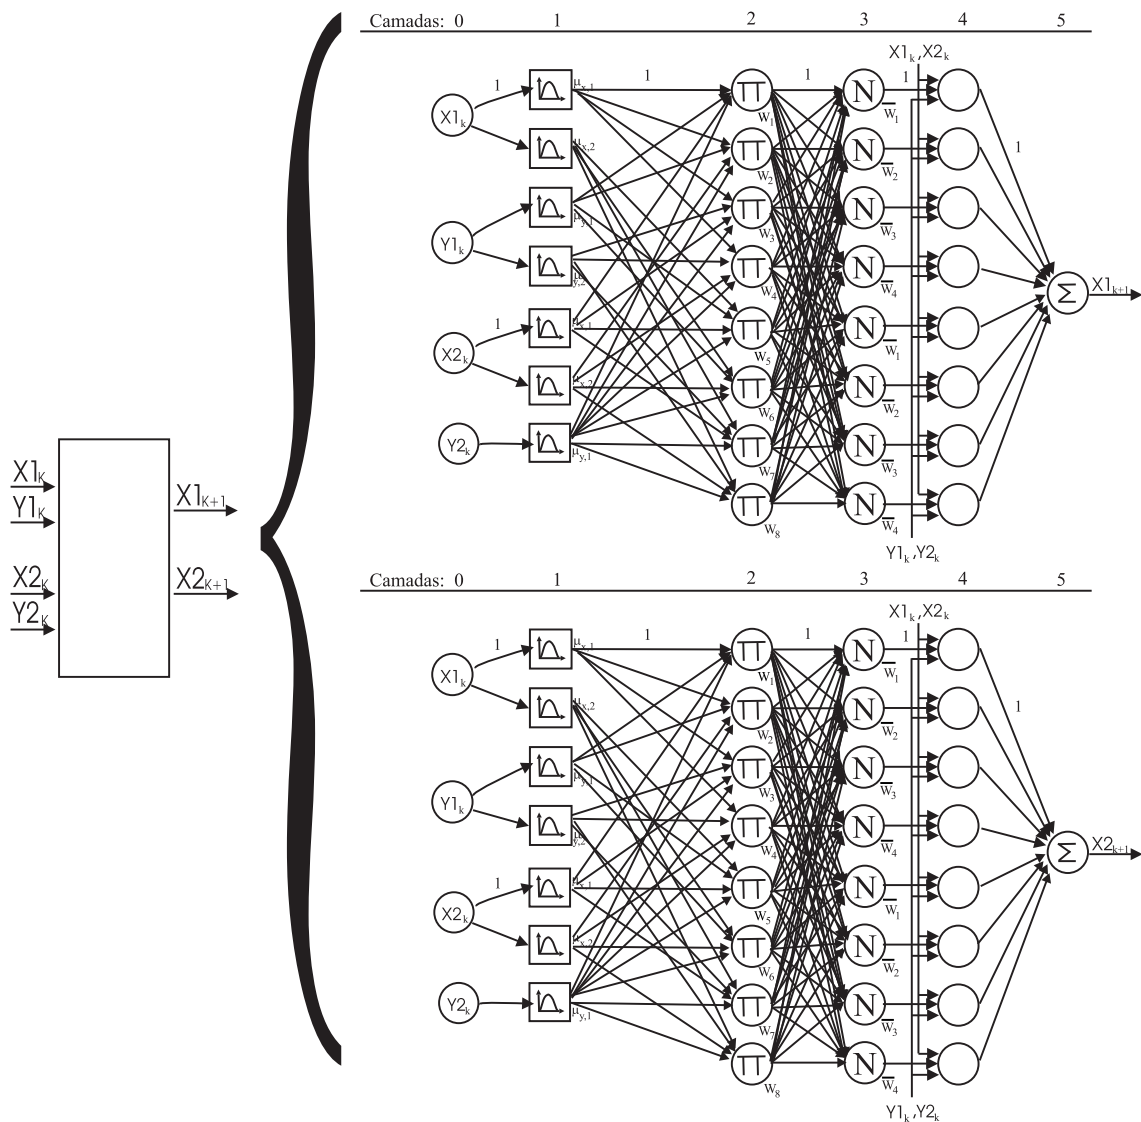


Figura 3.7: Representação da técnica em estrutura MIMO para duas saídas.

ser identificada. Se o sistema não possuir nenhuma perturbação além da própria variável a identificar, então a estrutura SISO poderá ser usada. Se além da própria variável a ser identificada, outras variáveis também interferirem na dinâmica do sistema, a estrutura MISO poderá ser utilizada. Se a identificação ocorre em 2 variáveis, então utilizar duas estruturas MISO, como mostrado na estrutura MIMO. O número de funções de pertinência utilizado vai depender não apenas da não linearidade das variáveis de entrada do

sistema, mas também da precisão da identificação desejada.

Observe que se espera uma continuidade dentro da área de atuação das variáveis de entrada. Uma descontinuidade não seria representada pelo sistema através da interpolação dos modelos e pode criar lacunas indesejáveis entre as funções de pertinência durante a aplicação do algoritmo de aprendizagem.

De posse da estrutura, pode-se passar a discutir como realizar a aplicação do método com a obtenção dos modelos lineares para as regiões, a obtenção dos valores iniciais e a otimização das funções de pertinência.

Capítulo 4

Procedimento do Método

Para a aplicação do método proposto, além da seleção da estrutura mais adequada para realizar a identificação, é necessário verificar o relacionamento entre as entradas, de modo que ocorra a divisão dos seus intervalos de excursões em partições, cujos cruzamentos formem regras que possam ser aproximados por modelos lineares. Os modelos lineares serão implicações das regras e farão parte da configuração inicial da técnica, assim como os valores iniciais das funções de pertinência. Após a obtenção da configuração inicial, o algoritmo de retropropagação do erro realiza a otimização da interpolação dos modelos lineares para que o identificador se aproxime ao máximo do sistema original.

Este capítulo apresenta uma forma prática para dividir as entradas em partições do intervalo de excursão e, a partir delas, encontrar informações que levem à formação dos modelos lineares para as regras do sistema *fuzzy*. Em seguida, discute os formatos das funções de pertinência e mostra como iniciá-las satisfazendo aos pré-requisitos da técnica desenvolvida. Por fim, mostra como encontrar valores ótimos para as funções de pertinência com a aplicação do algoritmo de retropropagação do erro.

4.1 Modelos Lineares para as Regras – Método LSE

As funções Sugeno da estrutura do ANFIS podem ser encontradas através da utilização do método dos mínimos quadrados (*Least Squares Error* – LSE) sobre um conjunto de dados de treinamento obtidos para cada regra *fuzzy* separadamente. Mas as regras *fuzzy* são formadas durante a inferência e podem ser vistas como os cruzamentos das funções de pertinência das entradas, por isso o primeiro passo para encontrar os modelos lineares que farão parte do sistema é descobrir o número de funções de pertinência de cada entrada. Como cada função de pertinência será responsável por informar a compatibilidade da entrada com cada partição, faz-se necessário descobrir em quantas partições devem ser divididos os intervalos de excursões de cada uma das entradas para que uma função linear possa substituir o comportamento de cada regra de maneira satisfatória e sua interpolação seja suficientemente próxima do sistema original [Foss et al. 1995, Smith-Murray & Johansen 1997, Fontes et al. 2007]. Os procedimentos para a aplicação da técnica desenvolvida fazem uso da análise gráfica do comportamento do sistema e serão apresentados para uma estrutura MISO. Acredita-se que procedimento semelhante possa ser aplicado a outras estruturas.

Em um sistema dinâmico MISO, uma das variáveis consideradas como entrada é o estado atual do sistema e esta variável será a primeira a ter seu intervalo de excursão dividido em partições. Quando o sistema é submetido a valores constantes das outras entradas, o comportamento do estado atual do sistema forma um gráfico do estado em função do tempo. O procedimento desenvolvido para a divisão em partições do intervalo de excursão da variável utiliza o fato de aproximar o gráfico desta variável por um conjunto de retas. Cada reta representa a aproximação do sistema feita por uma função linear e, desta forma, a área de atuação de cada reta representa uma partição em que o intervalo de excursão da entrada será dividido. Note que, para a escolha dos valores constantes das outras entradas, é interessante que estes permitam que o sistema passe pelo maior número de estados possíveis da variável cujo intervalo de excursão será dividido em partições. A figura 4.1 ilustra um exemplo onde um sistema tem o seu intervalo de excursão dividido em 3 partições denominadas de $L1$, $L2$ e $L3$.




Figura 4.1: Intervalo de excursão do sistema dividido em 3 partições.

Diferentemente do procedimento para a divisão do intervalo de excursão da primeira entrada, para a segunda entrada serão traçados gráficos da variação produzida no estado do sistema em função das variações da segunda entrada para cada uma das partições da primeira entrada. Assim, se o intervalo de excursão da primeira entrada for dividido em três partições: $L1$, $L2$ e $L3$, então para a segunda entrada serão traçados três gráficos: um para a partição $L1$, em que o valor da primeira entrada pertence à partição $L1$, outro para a partição $L2$, em que o valor da primeira entrada pertence à $L2$ e um terceiro $L3$, em que o valor da primeira entrada pertence à $L3$. Considere valores constantes para as outras entradas, inclusive para a primeira (estado atual do sistema) que assumirá valores para cada partição em cada gráfico. Cada um dos gráficos traçados poderá ser aproximado por retas e as áreas de atuação de cada reta serão equivalentes às partições da segunda entrada.

A figura 4.2 ilustra o procedimento de divisão do intervalo de excursão da segunda entrada (Y1) em partições, onde a divisão da primeira entrada foi obtida pela ilustração da figura 4.1. Observe que um gráfico de variação do sistema é traçado para cada partição da primeira entrada e a necessidade de modelos lineares distintos para cada um dos gráficos resulta no número total de partições em que a entrada será dividida. Analisando o gráfico de L1, três retas foram consideradas para aproximá-lo: início do intervalo de excursão de Y1 à D1, D1 à D2 e D2 ao fim do intervalo de excursão de Y1. Para o gráfico de L2, também foram utilizadas três retas: início de Y1 à D3, D3 à D4 e D4 ao fim de Y1. Já para o terceiro gráfico, apenas uma reta do início ao fim do intervalo de excursão de Y1 foi considerada.

Para este exemplo, a análise gráfica mostra que L1 pode ser dividido em 3 partições: [M1], [M2,M3 e M4] e [M5]. Para L2, outras 3 partições seriam necessárias: [M1 e M2], [M3] e [M4 e M5]. Já para L3, apenas uma partição é considerada: [M1, M2, M3, M4 e M5], pois um único modelo pode representar bem seu comportamento. Realizando a correspondência de todas as partições com o intervalo de excursão de Y1, nota-se que cinco partições são necessárias para a representação do comportamento do sistema em funções dos modelos lineares.

Como opção para a redução do número de partições, o projetista pode escolher uma delas para eliminar. Eliminando a menor delas, por exemplo, a M4, e expandindo as adjacentes M3 e M5, pode-se reduzir o número de partições e ainda assim realizar a identificação do sistema. Esta opção é interessante quando a identificação é realizada em sistemas com o número de modelos limitado, ou pela memória de trabalho, ou pelos requisitos predefinidos no projeto.




Figura 4.2: Intervalo de excursão da segunda entrada dividido em partições.

Para a terceira entrada, o procedimento é equivalente ao apresentado para a segunda

entrada. Porém, o número de gráficos desenhados será igual ao produto das partições da primeira pelas partições da segunda entrada. Fixando um valor constante em cada partição da primeira e da segunda entrada é possível traçar um gráfico da variação da terceira entrada em função da variação produzida no estado do sistema. A necessidade de modelos lineares para cada um dos gráficos informará em quantas partições deve ser dividido o intervalo de excursão da terceira entrada. Para as outras entradas o procedimento se repete.

Utilizando a estratégia proposta é possível notar que quanto mais entradas e quanto mais regiões, mais gráficos terão de ser analisados para a divisão das entradas em regiões. Quando os intervalos de excursões das duas primeiras entradas estão divididos em 3 regiões, é necessário traçar 9 gráficos para a análise da terceira entrada e, caso dividida em apenas 2 regiões e exista uma quarta entrada, será necessário traçar 18 gráficos para uma análise completa do seu comportamento.

Uma abordagem automática com algoritmos baseados em *cluster estimation* pode ser utilizada para estimação do número de funções de pertinência baseando-se no conjunto de dados do treinamento. Porém, existem variáveis nestes algoritmos para estabelecer o número de funções de pertinência, e essas variáveis podem ser difíceis de encontrar. Além disso, estes algoritmos não possuem a opção de inserção preliminar de modelos lineares que podem facilitar a legibilidade e restringir a busca da interface ótima.

Na técnica proposta, supõe-se que um modelo linear pode reproduzir o comportamento do sistema em cada setor, que equivale às regras *fuzzy*. Porém, a aproximação gerada por este modelo no setor pode ser tão imprecisa que dois pontos distintos no mesmo setor podem produzir comportamentos distintos para as mesmas perturbações. A solução seria criar novas partições e, com isso, gerar mais funções de pertinência de modo que os setores se aproximem cada vez mais de modelos lineares.

Em alguns sistemas é possível extrair características do comportamento sem a necessidade de traçar gráficos ou fazer simulações, apenas observando a planta. Para estes sistemas a divisão dos intervalos de excursões em partições é realizada através das características próprias do sistema que podem informar, aproximadamente, regiões de linearidade para a divisão do intervalo de excursão das entradas.

As regras *fuzzy* são geradas pela inferência e podem ser vistas como o cruzamento das partições de cada entrada, informando a intensidade dos modelos lineares na saída do sistema. Desta forma, para cada regra um modelo linear deve ser encontrado e a combinação deles corresponderá a uma aproximação do sistema complexo a ser identificado. Observe que o número de regras vai depender tanto da combinação das partições em que as entradas foram divididas, quanto da aproximação desejada pelo identificador. Pode-se notar que quanto maior o número de partições, maior será o número de regras. Porém, os tempos para a convergência do algoritmo e a precisão final do modelo ótimo podem não ser proporcionais.

Para cada espaço delimitado por uma regra *fuzzy*, ou seja, o espaço formado pelo cruzamento das partições de entrada, um sinal pseudo-randômico (PRS) é aplicado. As entradas do sistema devem oscilar dentro dos limites estabelecidos pelas partições encontradas e que compõem as regras *fuzzy*. Desta forma, um conjunto de pares de entradas e saídas é coletado. Estes pares coletados serão avaliados pelo algoritmo LSE que, por

sua vez, retornará um modelo linear com o melhor ajuste para o conjunto de pares coletado [Coelho & dos Santos Coelho 2004, Aguirre 2007]. Observe que o procedimento descrito equivale a dizer que um modelo linear será encontrado para cada regra.

O número de pares de dados coletados para cada regra *fuzzy* também varia com a aplicação. Duas formas de distribuição de dados tornam-se interessantes para a aplicação do algoritmo LSE: a uniforme e a normal (esta última também é conhecida como Gaussiana). Na distribuição uniforme, a relevância de todo o intervalo de excursão de uma variável é apresentado como uniforme e, desta forma, o número de pontos para todas as regras é igual. Já na distribuição normal uma relevância maior é considerada em alguma parte do intervalo de excursão de uma variável e isto faz com que o algoritmo LSE gere um modelo linear com menor erro onde um número maior de pontos foi coletado.

Deve-se ter um cuidado especial quando a escolha da distribuição dos dados for do tipo normal. A escolha desta distribuição é aconselhável quando, a priori, tem-se conhecimento das regiões com maior incidência dentro do intervalo de excursão de uma variável de entrada, ou quando da utilização normal do sistema, esta distribuição de dados foi obtida. A escolha da distribuição também afeta na forma inicial das funções de pertinência, pois seus valores são encontrados com base nos dados pertencentes a cada partição.

É importante salientar que para a proposta da técnica não existem ajustes automáticos, através de outros algoritmos, para os modelos lineares encontrados. Desta forma, os ajustes necessários aos modelos lineares devem ser realizados com a análise dos dados coletados para que os mesmos representem o sistema de forma devida em cada região.

Para ilustrar o que foi apresentado até o presente instante, considere um sistema complexo S com duas entradas e uma saída (MISO). Considere ainda que a primeira das entradas do sistema complexo corresponde ao estado atual do sistema que, quando submetido a valores constantes das outras entradas, resulta em um gráfico que pode ser aproximado por 2 retas, ou seja, 2 partições, L1 e L2. Os gráficos para a segunda entrada, por sua vez, mostram que a influência da segunda entrada no sistema pode ser dividida em duas partições, M1 e M2. Observe que este exemplo corresponde à estrutura MISO ilustrada na figura 3.4 e a base de regras formada corresponde aos cruzamentos da tabela 4.1.

Tabela 4.1: Exemplo de base de regras com modelos lineares.

	L1	L2
M1	$p_{L1 \times M1} X_k + q_{L1 \times M1} Y_k$	$p_{L2 \times M1} X_k + q_{L2 \times M1} Y_k$
M2	$p_{L1 \times M2} X_k + q_{L1 \times M2} Y_k$	$p_{L2 \times M2} X_k + q_{L2 \times M2} Y_k$

Os modelos lineares devem ser da forma mostrada na equação 3.4. Assim, para o intervalo de excursão delimitado pelas partições L1xM1, coletou-se K pares de entrada e saída ($[X_k, Y_k]$ e X_{k+1}) seguindo uma distribuição uniforme de dados. Os dados são,

$$\begin{aligned}
f_1(X_1, Y_1) &= p_1 X_1 + q_1 Y_1; \\
f_1(X_2, Y_2) &= p_1 X_2 + q_1 Y_2; \\
f_1(X_3, Y_3) &= p_1 X_3 + q_1 Y_3; \\
&\vdots \\
f_1(X_K, Y_K) &= p_1 X_K + q_1 Y_K;
\end{aligned} \tag{4.1}$$

em que $f_1(X_k, Y_k) = X_{k+1}$, p_1 e q_1 são encontrados por LSE.

Representando os dados em forma de matriz, tem-se que:

$$B = A \cdot \theta; \tag{4.2}$$

em que $B = \begin{pmatrix} f_1(X_1, Y_1) \\ f_1(X_2, Y_2) \\ f_1(X_3, Y_3) \\ \vdots \\ f_1(X_K, Y_K) \end{pmatrix}$, $A = \begin{pmatrix} X_1 & Y_1 \\ X_2 & Y_2 \\ X_3 & Y_3 \\ \vdots & \vdots \\ X_K & Y_K \end{pmatrix}$ e $\theta = \begin{pmatrix} p_1 \\ q_1 \end{pmatrix}$;

O vetor de solução θ pode ser encontrado usando a pseudoinversa da matriz A , como mostra a equação abaixo:

$$\theta = [A^T A]^{-1} A^T B; \tag{4.3}$$

Como o vetor θ é composto pelos coeficientes dos modelos lineares (equação 3.4), as fórmulas que representam estes modelos são facilmente encontradas.

Quanto maior o número de entradas, maior será o número de colunas da matriz A e, conseqüentemente, maior o número de elementos do vetor θ . Como pode ser observado, o número de elementos do vetor θ será igual ao número de entradas, ou seja, para cada entrada do identificador, uma variável deve ser encontrada. Seguindo este procedimento, um modelo linear pode ser encontrado para cada uma das regras do identificador.

De acordo com [Chen 1999], um modelo é considerado linear quando obedece aos princípios da homogeneidade e da aditividade (ou superposição). Facilmente, verifica-se que a equação 3.4 satisfaz estes princípios. Desta forma, os modelos de primeira ordem encontrados pelo algoritmo LSE para cada região são lineares.

O LSE possui como uma de suas propriedades uma boa robustez ao ruído [Aguirre 2007], o que dispensa o uso de filtros que podem elevar o custo computacional e o tempo de processamento.

O algoritmo LSE também pode ser aplicado de forma a encontrar equações polinômiais de segunda ordem ou de ordens superiores. O livro de [Barroso et al. 1987] mostra o método para aplicar este algoritmo e encontrar tais equações. O polinômio de segunda ordem para representar o sistema pode assumir a forma,

$$F(X1_k, X2_k) = p_2 X1_k^2 + q_2 X2_k^2 + p_1 X1_k + q_1 X2_k; \tag{4.4}$$

Observe que a equação 4.4 não obedece nem ao princípio da homogeneidade nem ao princípio da superposição. Logo, não se trata de um modelo linear. O uso de ordens mais

elevadas para o polinômio e, conseqüentemente, para as funções Sugeno, pode aumentar a precisão dos modelos, porém é substancialmente interessante encontrar uma combinação ótima de modelos lineares, que são simples e muito utilizados na indústria [Campos & Teixeira 2007].

Uma estratégia para manter os modelos lineares e aumentar a precisão da técnica seria considerar retardos nas entradas do sistema, aumentando o número de entradas como mostra a equação 4.5. Esta estratégia pode contribuir para o aumento da precisão do algoritmo, porém aumentaria o número de entradas consideradas, o que corresponde ao aumento da complexidade de iniciação das variáveis.

$$F(X1_{k-1}, X2_{k-1}, X1_k, X2_k) = p_2 X1_{k-1} + q_2 X2_{k-1} + p_1 X1_k + q_1 X2_k; \quad (4.5)$$

4.2 Funções de Pertinência

As funções de pertinência são utilizadas na fase de *fuzzyficação* e se relacionam com a fase de inferência *fuzzy* para indicar a intensidade de cada modelo linear na saída do identificador. Desta forma, o formato das funções de pertinência deve ser considerado tanto para produzir uma combinação apropriada dos modelos quanto para possibilitar o uso eficiente do algoritmo de aprendizagem.

Este trabalho não objetiva fazer um estudo aprofundado sobre os tipos das funções de pertinência. Porém, algumas características influenciaram na escolha do formato de sino (do inglês *Bell shaped*) para a aplicação.

As funções de pertinência em forma de sino são deriváveis em todo seu intervalo de excursão, o que facilita o uso do algoritmo de retropropagação do erro, e ainda possuem 3 parâmetros ajustáveis nas funções de pertinência, que facilita a generalização para outros tipos, como o Gaussiano com 2 e o *Left-Right MF* com 5 parâmetros ajustáveis. Note que quanto mais parâmetros para ajustar, mais tempo o algoritmo de aprendizagem pode levar para a convergência, correndo um risco maior de entrar em mínimos locais. Assim, deve-se escolher o formato da função de pertinência de forma a evitar um número excessivo de funções de pertinência para o sistema ou de variáveis desnecessárias em cada função. De qualquer forma, uma função de pertinência com forma de sino possui um valor intermediário de parâmetros e será utilizada a fim de generalizar a técnica para os outros formatos.

A função em forma de sino é dada pela fórmula,

$$f(X_i) = \frac{1}{1 + \left| \frac{X_i - c}{a} \right|^{2b}}; \quad (4.6)$$

em que c é o centro da função de pertinência, a e b estão relacionados com a abertura da função de pertinência.

Na aplicação da técnica desenvolvida, o centro da função de pertinência e a sua abertura podem ser iniciados seguindo o procedimento discutido a seguir.

Para cada partição em que o intervalo de excursão das entradas foi dividido, uma função de pertinência será definida. Com a finalidade de encontrar um modelo linear para

cada regra, um conjunto de dados foi formado pelo cruzamento de cada partição de uma entrada com as partições das outras entradas. Utilizando os conjuntos de dados referentes a cada partição, pode-se calcular o centro de cada função de pertinência como sendo a esperança estatística da variável, ou seja, a média dos pontos de cada variável em cada uma das partições separadamente.

$$c_1 = \frac{\sum_{k=1}^K X_k}{K} \quad \forall X_k \in L1; \quad (4.7)$$

Vale lembrar que se uma distribuição de dados for uniforme ou normal com o centro no meio da partição, o centro da função de pertinência tenderá a ficar no meio da partição. Caso a distribuição seja normal com o centro da distribuição deslocado do meio da partição, o centro da função de pertinência também será deslocado. Com isso, verifica-se que além de aumentar a precisão do modelo linear, o aumento do número de pontos em determinada região da partição aumenta também a intensidade da função de pertinência naquela área específica, ou seja, a pertinência inicial do modelo linear para a região com mais pontos é maior na configuração inicial das funções de pertinência.

Para encontrar o centro das outras funções de pertinência, da primeira e das outras entradas, o procedimento é equivalente ao utilizado para a partição L1.

Os parâmetros que definem a abertura das funções de pertinência podem ser encontrados fazendo uma relação entre a distância dos seus centros. Para definir a abertura serão consideradas as funções de pertinência em formato de sino (*Bell Shaped*). Acredita-se que um procedimento similar possa ser utilizado para outros formatos de funções de pertinência bastando pequenas adaptações.

Considere que os centros das funções de pertinência já foram definidos pelo procedimento anterior. Para garantir que pelo menos uma função de pertinência esteja ativa em toda região de atuação da planta, utilizou-se a estratégia em que: o valor da pertinência de duas funções de pertinência, na metade da distância entre estas, deve ser igual a 0,5 para ambas. Para facilitar os cálculos, o valor de b foi iniciado com 0,5 para todas as funções de pertinência. Assim, matematicamente, teremos:

$$f(X_k) = \frac{1}{1 + \left| \frac{X_k - c}{a} \right|^{2b}} \Rightarrow 0,5 = \frac{1}{1 + \left| \frac{\frac{c_{s+1} - c}{2} + c - c}{a} \right|^{2 \cdot 0,5}}; \quad (4.8)$$

em que c_{s+1} é o centro da função de pertinência seguinte.

Que, por sua vez, reduz-se à:

$$a = \left| \frac{c_{s+1} - c}{2} \right|; \quad (4.9)$$

Observe que o cálculo dos valores iniciais que definem as funções de pertinência utiliza os mesmos conjuntos de dados empregados para encontrar os modelos lineares referente às regras. Para estes valores, os conjuntos de dados precisam ser agrupados e aplicados sequencialmente por partições. Considerando o exemplo com 2 entradas divididas em 3 funções de pertinência cada, encontra-se primeiro o centro de L1 utilizando todos os pontos desta partição. Em seguida, calcula-se o centro de L2 e a abertura de L1.

Finalmente, calcula-se o centro de L3 a abertura de L2 e de L3. Para a segunda entrada, repete-se o procedimento em relação as suas respectivas partições.

Diferentemente dos modelos lineares, as funções de pertinência encontradas possuem valores iniciais e podem ser alteradas por um algoritmo de aprendizagem como o de retropropagação do erro.

4.3 Algoritmo de aprendizagem

Após definir as entradas, dividir estas entradas em partições, calcular modelos lineares para representar cada regra e calcular os valores iniciais para as funções de pertinência que representarão as partições, pode-se, finalmente, aplicar o algoritmo de aprendizagem de redes neurais para ajustar os parâmetros das funções de pertinência. O algoritmo empregado será o de retropropagação do erro com o acréscimo da técnica *eta*-adaptativo. Técnica semelhante foi utilizada para aprendizagem das ações de um controlador em um sistema trave-bola [Apkarian 1995] pela estrutura ANFIS onde resultou em bons resultados [Rodrigues 2006].

Inicialmente, coleta-se um conjunto de treinamento significativo para todo o sistema. Em seguida, aplica-se o algoritmo de retropropagação do erro para ajustar os parâmetros das funções de pertinência. Observe que, diferentemente do procedimento para obtenção dos modelos lineares, o conjunto de treinamento é obtido a partir de todas as variações no intervalo de excursão de todas as variáveis e não de regiões específicas. O uso de um novo conjunto de dados de todo o sistema é justificado principalmente em casos cujas regiões não abrangem todo o intervalo de excursão de uma variável. Esta condição assegura que, mesmo as regiões não contempladas para produzir modelos lineares, sejam aproximadas por interpolação de modelos de regiões adjacentes, evitando lacunas.

Para a aplicação do algoritmo de retropropagação do erro, necessita-se das derivadas parciais das funções de pertinência em formato de sino em relação aos seus parâmetros. Jang, em seu livro [Jang et al. 1997], mostra estas derivadas.

$$\frac{\partial f(X)}{\partial a} = \frac{2b}{a} \cdot f(X) \cdot (1 - f(X)); \quad (4.10)$$

$$\frac{\partial f(X)}{\partial b} = -2 \cdot \ln \left| \frac{X - c}{a} \right| \cdot f(X) \cdot (1 - f(X)); \quad (4.11)$$

$$\frac{\partial f(X)}{\partial c} = \frac{2b}{X - c} \cdot f(X) \cdot (1 - f(X)); \quad (4.12)$$

Nestas equações a , b e c são os parâmetros da função de pertinência e caso $X = c$ então 4.11 e 4.12 serão consideradas como sendo zero.

A variação dos parâmetros ocorre em lote (ou batelada). Desta forma, os parâmetros a , b e c são ajustados apenas após a passagem por todos os pares de aprendizagem, que também é chamada de época do algoritmo. Os pontos de aprendizagem são misturados ao fim de cada época com o intuito de tornar a busca no espaço de pesos estocástica sobre os ciclos de aprendizagem, evitando assim a possibilidade de ciclos limitados durante a

aprendizagem [Haykin 2001].

Optou-se por utilizar uma técnica para aumentar a velocidade de convergência das redes neurais chamada de *eta*-adaptativo (ou η -adaptativo) pelo fato desta técnica ter sido utilizada com sucesso em alguns trabalhos com implementações práticas [Gabriel 2004]. Esta técnica consiste em variar a constante de aprendizado η (*eta*) durante a etapa de treinamento da rede, buscando otimizar o processo de adaptação dos parâmetros, como também evitar a parada em um mínimo local.

A rotina do algoritmo 1 mostra como essa técnica funciona.

Algorithm 1 η -adaptive algorithm

```

1: procedure  $\eta$ -ADAPTIVE( $e_{aux}, e$ )    ▷  $e_{aux}$  = previous quadratic erro and  $e$  = actual
   quadratic error
2:   if  $e > 1.04 * e_{aux}$  then
3:      $\eta = 0.7 * \eta$ ;
4:   else if  $e \leq e_{aux}$  then
5:      $\eta = 1.05 * \eta$ ;
6:   end if
7:   if  $\eta > 0.1$  then
8:      $\eta = 0.1$ ;                                ▷  $\eta$  saturation
9:   end if
10:   $e_{aux} = e$ ;
11:  return  $\eta$ 
12: end procedure

```

Os fatores 1,04, 1,05 e 0,7 usados no algoritmo do η -adaptativo são sugeridos por [Rezende & Maitelli 1999a, Rezende & Maitelli 1999b, Gabriel 2004].

Uma saturação do valor do η também foi adicionada para que seu valor não exceda um limite estimado de 0.1. Sem esta saturação, o algoritmo correria o risco de eliminar uma função de pertinência em um único ajuste de parâmetro, condição que o próprio algoritmo não teria como desfazer.

Outros algoritmos de aprendizagem, assim como outras funções de pertinência, podem ser utilizados para a aplicação da técnica. A escolha do formato das funções de pertinência e do número delas, a quantidade de parâmetros dos modelos lineares e o algoritmo de aprendizagem, dependerão tanto da aproximação que deseja obter do sistema a ser identificado quanto da complexidade requerida.

Após a aprendizagem, o identificador deverá ser validado com um novo conjunto de dados e então uma análise do resultado produzido pode ser realizada. Um estudo de caso com um sistema de nível foi desenvolvido. Tal sistema foi projetado e construído a fim de aplicar todos os conceitos e mostrar características da técnica proposta.

Capítulo 5

Estudo de Caso

Este capítulo apresenta o sistema de tanques desenvolvido e utilizado para aplicar a técnica proposta. O objetivo da técnica neste estudo de caso será identificar o comportamento do tanque quando submetido a distintas tensões na alimentação de uma bomba que responde aumentando ou diminuindo a vazão de entrada de água no tanque. Os principais componentes do sistema são comentados, a interação e as características destes componentes são discutidas. O capítulo mostra ainda como se procedeu a implementação do método, quantos programas foram utilizados para operar com a técnica sobre o sistema e quais as funções de cada um destes programas desenvolvidos. Por fim, resultados deste estudo de caso são apresentados para diferentes configurações em que informações a cerca do sistema podem ser incorporadas ao desenvolvimento do identificador.

5.1 O Sistema de Tanque com Múltiplas Seções

O sistema é composto, basicamente, de um tanque 53x30x10cm feito em acrílico e construído artesanalmente. Um sensor de pressão, uma bomba d'água e uma placa de aquisição de dados complementam o sistema. A figura 5.1 ilustra o sistema idealizado e apresenta uma foto do tanque real.

Nesta figura esquemática, a distância entre dois pontos sempre mede 10cm, existem 2 orifícios na base: um para saída de água (orifício 2) e outro para o sensor de pressão (orifício 1), que será responsável por informar o nível da água no tanque. Por ter sido construída artesanalmente, esta planta apresentou algumas imperfeições em relação ao modelo teórico idealizado. Por exemplo, todas as seções deveriam apresentar 10 cm de altura, porém uma apresentou 13 cm, já outra apresentou 8 cm de altura. Algumas arestas que deveriam ser verticais apresentaram uma inclinação de alguns graus visivelmente identificáveis. Estas imperfeições em relação ao idealizado adicionaram incertezas ao modelo.

Além do tanque de acrílico, outros componentes que formaram o sistema, como o sensor de pressão, a bomba de água e a placa de aquisição de dados, merecem destaque. O custo referente ao sistema desenvolvido está no apêndice A.

1- Sensor de Pressão
 2- Orifício de vazão
 PAD - Placa de Aquisição de Dados




Figura 5.1: Tanque 53x30x10 cm idealizado, em que 1 é o orifício para o sensor de pressão e 2 é o orifício de vazão (Esquerda). Foto real do tanque (Direita).

5.1.1 Sensor de Pressão

Instalado em um orifício na base do tanque, o sensor de pressão MPX5010DP da MotorolaTM (figura 5.2) é utilizado para informar o nível de água presente no tanque. Este sensor pode medir uma coluna de água de até um metro de altura respondendo linearmente com uma voltagem típica de 0,2 a 4,7 volts. Uma tensão de 5 volts necessita ser aplicada ao sensor para que o mesmo entre em funcionamento [Motorola 1997].

De acordo com o fabricante, o sensor possui precisão de mais ou menos 0,225 volts e tempo de resposta de 1 milissegundo.

5.1.2 Bomba de água

A bomba submersa (figura 5.3) usada para alimentar o tanque, bombeando água de um reservatório externo para dentro do tanque, possui uma vazão de, aproximadamente, 6,5 litros por minuto, quando aplicada uma tensão de 12 volts DC com 2 amperes de corrente, e um refluxo de 0,9 litros por minuto, quando a tensão aplicada era de 0 volts.

A metodologia empregada para analisar o comportamento da bomba em relação às tensões aplicadas consistiu em obstruir o orifício de saída do tanque e verificar a altura da coluna d'água correspondente a dois litros (resultou em 15 centímetros). Após esta verificação, o tanque era esvaziado e, ainda com o orifício obstruído, tensões de três a doze




Figura 5.2: Sensor de pressão da MotorolaTM.



Figura 5.3: Bomba submersa com vazão máxima de 6,5 litros por minuto.

volts foram aplicadas à bomba e o tempo necessário para que a marca de 15 centímetros fosse alcançada foi armazenado em uma tabela. Para as tensões de zero até aproximadamente dois volts, condições de refluxo da bomba, o tanque era, inicialmente, nivelado em 15 cm e o tempo para que esvaziasse era medido. O procedimento acima foi realizado três vezes para cada tensão e o valor médio da vazão para cada uma das tensões está ilustrado na figura 5.4.




Figura 5.4: Vazão da bomba submersa em relação à tensão aplicada.

5.1.3 Placa de Aquisição de Dados (PAD)

Para estabelecer uma comunicação entre o computador e a planta, a placa de aquisição de dados NI 6024E da *National Instruments*[®] foi utilizada. Esta placa necessitou dos acessórios CB-68LP e TB-2705 que constituem o kit NI PCI-6024E/CB-68LP da *National Instruments*[®] (figura 5.5). O acessório CB-68LP é uma placa contendo orifícios para conexões tanto dos fios de leitura do sensor quanto os de acionamento da bomba d'água. Já o cabo TB-2705 é utilizado para conectar o acessório CB-68LP à placa NI 6024E instalada no computador.

A placa NI 6024E possui 16 entradas analógicas com resolução de 12 bits operando a uma taxa máxima de amostragem de 200ks/s para valores de entrada de ± 0.05 até $\pm 10\text{V}$, 2 saídas analógicas com resolução de 12 bits operando a uma taxa típica de 10ks/s e valores de $\pm 10\text{V}$, 8 *I/O* digitais, 2 contadores de 24 bits e gatilhos do tipo digital [Instruments 2006]. Especificações e mais características da placa podem ser encontradas eletronicamente em [Instruments 2005].




Figura 5.5: Kit NI PCI-6024E/CB-68LP da *National Instruments*[®].

5.1.4 Outros componentes

O sinal de acionamento do motor da bomba proveniente da placa de aquisição de dados possui uma corrente muito pequena, cerca de 20 miliamperes, e necessitou passar por um amplificador. O módulo de potência modelo UPM2405-240 da *Quanser Consulting* [Quanser 2010] foi utilizado para amplificar a corrente e, puramente pela característica do amplificador, a tensão foi multiplicada por 5. Como a bomba submersa usada funciona com até 12 volts, a tensão aplicada pela placa de aquisição de dados será de até 2,4 volts, que, multiplicado pelo ganho de 5, gera a tensão máxima suportada pela bomba.

O módulo de potência também foi utilizado para alimentar o sensor de pressão com 5 volts. Uma saída constante de 12 volts passa por um regulador de voltagem de modelo SD7805 (figura 5.6) que regula a tensão para os 5 volts necessários ao acionamento do sensor.




Figura 5.6: Regulador de tensão modelo SD7805.

Outros acessórios também fazem parte do sistema: um reservatório de água de 12 litros, peças com orifícios de diferentes calibres que alteram a vazão do tanque, fios para conexões elétricas e uma mangueira para alimentar o tanque com múltiplas seções a partir da bomba d'água submersa no reservatório.

O tanque com múltiplas seções desenvolvido apresenta algumas não linearidades que podem ser observadas de imediato. As várias seções distintas do sistema fazem com que, mesmo para entradas constantes, o comportamento do nível não seja linear. A pressão no orifício de saída da mangueira, que se encontra no fundo do tanque, faz com que a vazão da bomba varie em função do nível do tanque. A vazão da bomba também não é linear quando a tensão se aproxima de valores de saturação em 12 e em 0 volts (figura 5.4). Há não linearidade também no orifício localizado na base do tanque cuja vazão varia em função da raiz quadrada do nível. Além destes, existe o ruído de leitura, o atraso e a imprecisão do sensor. Desta forma, para que o identificador obtenha sucesso é necessário que sejam consideradas não linearidades.

5.2 Implementação da Técnica

Todos os programas desenvolvidos para implementar a técnica foram escritos na linguagem C++ utilizando o compilador Builder C++, versão 5.0 instalados em um computador com sistema operacional Windows XP[®] de 32 bits. Os *drivers* da placa de aquisição da *National Instruments*[®] foram instalados no computador para estabelecer a comunicação entre o computador e a placa de aquisição.

O objetivo da aplicação da técnica no sistema de tanques com múltiplas seções será o de identificar o comportamento do nível do tanque quando a bomba submersa é submetida a várias tensões distintas. Para cumprir o objetivo, duas entradas foram utilizadas na estrutura do identificador, o nível atual do tanque (estado atual) e o valor da tensão aplicada à bomba.

De forma geral, para a aplicação da técnica foram criados três programas com características distintas. O primeiro programa é responsável pela comunicação com o sistema e coleta tanto dados para o procedimento de validação do sistema quanto dados de treinamento. Estes últimos dados servem para encontrar os modelos lineares das regras e para a utilização da retropropagação do erro com o sistema completo. No segundo programa os modelos lineares são encontrados, funções de pertinência são iniciadas e otimizadas. Já o terceiro programa utiliza os dados otimizados e realiza a validação do sistema com um novo conjunto de dados também obtido pelo primeiro programa. Estes programas serão descritos mais detalhadamente a seguir.

5.2.1 Primeiro Programa – Comunicação com a Planta

O primeiro programa é responsável por coletar dados do tanque de forma *off-line*. Este programa escreve em arquivo os pares entrada-saída de cada região, que servirão para gerar os modelos lineares e as funções de pertinência, de acordo com o explicado nos capítulos 3 e 4. Dados para o treinamento e para a validação do identificador, assim como dados sobre o comportamento do sistema para a divisão do intervalo de excursão das entradas em partições, também são obtidos executando este programa.

O período de amostragem [Ogata 2003, Aguirre 2007] utilizado tem valor igual a $T = 0,5$ segundos e foi obtido com base em experiências práticas com a planta.

Este programa ainda realiza algumas conversões de dados para facilitar a interpretação do usuário. Na primeira delas, os dados lidos do sensor de pressão, em volts, são convertidos para centímetros através da equação 5.1, cujos fatores de conversão foram obtidos através da observação da tensão do sensor e do nível real da planta.

$$X_{k+1}(cm) = (X_{k+1}(V) - 0,275) * 22,9; \quad (5.1)$$

Na segunda conversão, o valor aplicado pelo usuário para acionar a bomba é dividido por 5 para que seu valor de entrada no amplificador varie de 0 à 2,4. Observe que este procedimento torna transparente ao usuário a amplificação dos dados proveniente do módulo de potência, pois este deverá digitar no intervalo de 0 a 12. A divisão por cinco e a amplificação por cinco se anularão e o valor digitado corresponderá ao real enviado para a bomba.

5.2.2 Segundo Programa – Identificação

O segundo programa é responsável por iniciar e otimizar a estrutura utilizada para a identificação. Para tanto, este programa recebe o número de entradas e o número de funções de pertinência, ou partições, de cada entrada. A partir destes valores, o programa monta a base de regras e solicita a entrada dos conjuntos de dados de cada regra para calcular o modelo linear correspondente utilizando o método LSE (ver capítulo 4). Em seguida o programa inicia as funções de pertinência e solicita a entrada de um arquivo contendo o conjunto de treinamento para todo o sistema. Utilizando este arquivo, o programa realiza a retropropagação do erro para otimização das funções de pertinência.

Durante toda a execução da aprendizagem, a melhor configuração para as funções de pertinência, diante dos dados de treinamento, vai sendo armazenada em arquivo, assim como o modelo linear de cada regra. Na tela, o programador tem acesso aos formatos das funções de pertinência, a um gráfico contendo o desenvolvimento do erro médio quadrático da aprendizagem e ao valor de η que é variável.

Foi implementada uma alternativa para a iniciação dos parâmetros, possibilitando a leitura destes a partir de arquivo. Esta opção é útil quando o treinamento é lento ou quando outra técnica for utilizada para iniciar os parâmetros, pois permite a leitura direta tanto do formato das funções de pertinência quanto dos modelos lineares obtidos com auxílio de outros métodos.

5.2.3 Terceiro Programa - Validação

O terceiro programa é responsável pela validação do modelo identificado no programa anterior. Este programa exhibe na tela o comportamento desejado da planta, o comportamento obtido pelo identificador do segundo programa e o comportamento obtido com modelos lineares de cada regra separadamente. Também exhibe o comportamento de um identificador com os mesmos modelos lineares chaveados por uma métrica simples onde se utiliza 100% do modelo linear da regra cuja distância euclidiana dos centros das funções de pertinência é mais próxima das entradas atuais do sistema. Note que este último identificador irá utilizar os mesmos modelos lineares que o identificador gerado a partir do

segundo programa, gerando uma comparação mais justa, porém não realiza a interpolação dos modelos, o que enfatiza esta operação.

Todos os dados apresentados na tela são salvos pelo terceiro programa em arquivo para análise detalhada de comportamento e possíveis comparações futuras.

Observe que o tanque com múltiplas seções desenvolvido possui um formato que possibilita extrair informações de sua não linearidade a partir de sua forma física, criando possibilidade de novos ensaios onde é desnecessária a construção de muitos dos gráficos da análise de comportamento discutidos no capítulo 4. Nestes ensaios, considera-se um modelo linear para algumas das seções do tanque e então várias combinações de modelos podem ser utilizadas.

Modelos lineares baseados puramente no comportamento do sistema e outros modelos gerados a partir de uma análise das informações físicas serão denominados de: identificação caixa preta e identificação caixa cinza, respectivamente.

5.3 Resultado da Identificação Tipo Caixa Preta

Os resultados apresentados neste trabalho foram observados no sistema dinâmico de tanque desenvolvido e apresentado anteriormente com aplicação do método de múltiplos modelos discutido nos capítulos 3 e 4. Para o tanque com múltiplas seções, duas entradas são utilizadas na estrutura do algoritmo. A primeira é o estado atual do sistema que é o nível da coluna de água presente no tanque e é medido em centímetros. A segunda entrada é a tensão aplicada na bomba que alimenta o tanque que, por sua vez, é medida em volts. A saída desejada é o estado seguinte do sistema, ou seja, o nível seguinte da coluna de água no tanque. Desta forma, a estrutura utilizada para obter os resultados equivale à estrutura MISO do capítulo 3. Alguns ensaios foram realizados com o sistema de tanques para mostrar as características da técnica e testar algumas das formas práticas de como a técnica pode ser aplicada.

Para esta seção, considerou-se um sistema de tanques como uma caixa preta onde se tem conhecimento apenas das variáveis de entrada do sistema e da saída produzida. Em seguida, uma identificação caixa cinza é realizada com conhecimentos da estrutura física do tanque. Variações destas estratégias serão empregadas com o intuito de mostrar características específicas da técnica apresentada sobre vários aspectos.

O conjunto de treinamento será o mesmo para todos os experimentos e é constituído por amostras contendo o nível atual, a tensão aplicada na bomba e o nível seguinte. Este conjunto foi obtido em malha aberta, com a utilização do programa de comunicação com a planta e é composto por pouco mais de 10000 (dez mil) amostras, adquiridas quando um sinal aleatório era sorteado para a tensão da bomba que atuava durante um intervalo de tempo também aleatório. A figura 5.7 mostra tanto o nível quanto a tensão aplicada na bomba. Note, na figura, que nenhum filtro de dados é utilizado com relação ao sinal proveniente do sensor, que apresenta erros de leitura, alguns com valores relevantes, como o da amostra 2011, e que não foram descartados para a aprendizagem. Como pode ser observado, este conjunto de aprendizagem busca percorrer todo o intervalo de excursão das variáveis e é utilizado pelo algoritmo de retropropagação do erro para encontrar a combinação ótima dos modelos lineares de cada regra do sistema.




Figura 5.7: Nível obtido (acima), com destaque para amostra 2011, e tensão aplicada na bomba (abaixo) pertencente ao conjunto utilizado no treinamento.

Na identificação caixa preta nenhuma informação, além dos estados das entradas e da saída da planta, é conhecida pelo usuário. Ainda assim, é possível encontrar os intervalos de excursão de cada variável e dividi-los em partições. Para o sistema de tanque com estrutura MISO, teríamos para a primeira entrada, X (estado atual do tanque), um intervalo de excursão que vai de 0 (zero) à 50 centímetros, correspondente ao nível do tanque. Para a segunda entrada, Y , o intervalo de excursão vai de 0 (zero) à 12 volts, que é a tensão aplicada na bomba.

Partindo da condição inicial com $X_0 = 0$ cm e seguindo o procedimento descrito no capítulo 3, escolhe-se valores para as entradas que alteram o sistema de forma que grande parte dos estados da planta seja excitada. Desta forma, escolhendo como entrada a constante $Y_k = 8$ volts, encontramos o gráfico ilustrado na figura 5.8. Analisando esta figura, pode-se aproximar o seu comportamento por 3 retas, ou seja, 3 regiões em X , $L1 = [0 \ 15]$, $L2 = [15 \ 35]$ e $L3 = [35 \ 50]$.

O passo seguinte consiste em dividir o intervalo de excursão da segunda entrada da estrutura em partições. Para este passo, constroem-se gráficos de variação de estado do sistema em função da entrada para cada uma das partições consideradas no primeiro passo.




Figura 5.8: Comportamento do sistema quando $Y_k = 8$ volts (contínuo), modelos lineares aproximados com particionamento manual de X (tracejado). L_1 , L_2 e L_3 são as partições de X .

Assim, a variação do estado deve ser analisada em cada partição separadamente, gerando três gráficos: o primeiro para a partição $L_1 = [0 \ 15]$, o segundo para $L_2 = [15 \ 35]$ e um terceiro para $L_3 = [35 \ 50]$.

A metodologia empregada para a realização do segundo passo consistiu em estabilizar o sistema em um ponto pertencente à primeira partição, como em 7 cm, e calcular o tempo necessário para atingir uma variação de no máximo 5 cm, com Y assumindo valores de 0 à 12 volts. Para a segunda partição, o sistema foi estabilizado em 25 centímetros e calculou-se o tempo de chegar a uma variação de 5 cm com Y também variando de 0 à 12 volts. Por fim, para a terceira partição, estabilizou-se em 40 centímetros e calculou-se o tempo para atingir uma variação de 5 centímetros com a mesma variação de Y . A partir da escolha de retas para aproximar os gráficos do comportamento do sistema para a segunda entrada, podem-se encontrar as divisões necessárias para definir distintos modelos lineares. Os gráficos da figura 5.9 mostram o comportamento da variação de X em função dos valores de Y para cada uma das partições de X . Note uma não linearidade em duas regiões de todos os gráficos, entre zero e dois volts e entre dez e doze, proveniente da saturação da bomba tanto em baixa quanto em alta tensão. O comportamento não linear do gráfico

da partição $L3$ pode ser justificado pela maior quantidade de água nesta região, o que torna mais relevante a influência de não linearidades como a pressão na mangueira de alimentação.




Figura 5.9: Comportamento da variação do nível (X_k) para cada partição em função dos valores de tensão Y_k .

Para o primeiro ensaio caixa preta, optou-se por não considerar o comportamento não linear do sistema para Y_k . Consequentemente, o intervalo de excursão de Y será representado por uma única partição, M1, e modelos lineares (ou seja, retas), irão representar o comportamento da variação do nível (X_k) em função da tensão (Y_k). Com o cruzamento das partições de entrada de forma equivalente à inferência *fuzzy*, obtém-se três regras para identificar o sistema, ou seja, três modelos lineares. Em ensaios posteriores, a não linearidade de Y_k será considerada de duas formas distintas e em ambas o intervalo de excursão de Y será dividido em 3 partições, o que dará um total de 9 regras para cada um dos seus identificadores.

5.3.1 Identificador caixa preta com 3 regras (CP3R)

No desenvolvimento do primeiro identificador, considerou-se que um único modelo linear seria suficiente para aproximar cada um dos gráficos da segunda entrada. Desta

forma, o intervalo de excursão de Y será representado por uma única partição, $M1$, e é esperado que algumas das não linearidades desprezadas durante este procedimento sejam acrescentadas ao sistema pela interpolação dos modelos lineares em uma etapa posterior.

A base de regras é formada pelo cruzamento das regiões das entradas. Assim, com 3 partições para a primeira entrada: $L1$, $L2$ e $L3$, e uma partição para a segunda: $M1$, a base de regras será formada por 3 regras: $L1 \times M1$, $L2 \times M1$ e $L3 \times M1$. Cada uma destas regras irá concluir um modelo linear distinto que será encontrado através da utilização do algoritmo de mínimos quadrados (LSE).

Considerando que a regra $L1 \times M1$ irá concluir o modelo linear $R1$, os valores de X_k e Y_k devem pertencer às regiões $L1$ e $M1$, respectivamente, para se obter o modelo linear $R1$ da regra.

A figura 5.10 apresenta um gráfico com os valores de X_{k+1} , nível desejado do tanque, e outro com os de Y_k , tensão aplicada, pertencentes às regiões em intersecção da regra $L1 \times M1$ e que foram utilizados para gerar o modelo linear $R1$. Esta figura ainda apresenta o gráfico de \hat{X}_{k+1} formado quando as mesmas entradas são aplicadas ao modelo linear $R1$ encontrado para a região (tracejado).




Figura 5.10: Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) com $R1$. Abaixo, a tensão Y_k utilizada em cada amostra.

A segunda e a terceira regra concluem dois outros modelos lineares, $R2$ e $R3$, e são

formadas pelo cruzamento das partições $L2$ com $M1$ e $L3$ com $M1$, respectivamente. As figuras 5.11 e 5.12 mostram os valores de X_{k+1} e de Y_k , assim como os valores de \hat{X}_{k+1} quando os modelos lineares $R2$ e $R3$ são utilizados substituindo o sistema, para cada uma das amostras de entrada.




Figura 5.11: Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) com $R2$. Abaixo, a tensão Y_k utilizada em cada amostra.

Observe que os modelos lineares encontrados para aproximar as regiões são precários e esta deficiência é resultado das simplificações consideradas durante a obtenção desses modelos. Em uma fase posterior, a técnica irá agregar algumas não linearidades, desprezadas pelo identificador, combinando outros modelos com características próximas a cada região e é esperado que a combinação ótima destes modelos abrande o erro encontrado. Note que o ruído de alta frequência na leitura do sensor foi extinto sem necessidade de um tratamento específico para o sinal, pois a ordem reduzida do modelo utilizado não é capaz de identificar as componentes de alta frequência presentes no sinal original.

A tabela 5.1 mostra os modelos lineares encontrados para as regras $L1 \times M1$, $L2 \times M1$ e $L3 \times M1$ deste primeiro identificador. Lembre-se que no sistema *fuzzy* estes modelos correspondem às funções Sugeno de primeira ordem e, de acordo com a técnica proposta, nenhuma adaptação automática destes modelos irá ocorrer em etapas seguintes.




Figura 5.12: Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) com $R3$. Abaixo, a tensão Y_k utilizada em cada amostra.

Assim, algum ajuste de dados, como a desconsideração de amostras evidentemente ruidosas, eliminação dos sinais relativos ao atraso do acionamento do sistema ou mesmo sinais adquiridos em regiões de saturação, podem ser realizados durante a obtenção dos dados para gerar modelos lineares. Tais considerações não foram relevantes para o sistema em questão e não foram aplicadas.

Tabela 5.1: Modelos lineares das funções Sugeno encontrados pelo LSE para CP3R.

	$L1$	$L2$	$L3$
$M1$	$0,974169X_k + 0,056614Y_k$	$0,993763X_k + 0,028481Y_k$	$0,997026X_k + 0,019832Y_k$

Observando os modelos lineares, nota-se que o modelo $R1$ da regra $L1 \times M1$ possui o termo de Y_k influenciando o modelo com mais intensidade, se comparado com os modelos $R2$ e $R3$. Esta característica já era esperada, pois a primeira região possui menor volume e o nível varia mais rapidamente para pequenos valores de tensão.

Seguindo o procedimento descrito no capítulo 4, tem-se que os mesmos conjuntos de dados utilizados para a obtenção dos modelos lineares podem ser utilizados para iniciar

as funções de pertinência de entrada. Para cada partição de cada entrada irá haver uma função de pertinência e seus parâmetros podem, então, ser encontrados. A tabela 5.2 mostra os valores iniciais dos parâmetros das funções de pertinência em formato de sino encontrados para a entrada cujo intervalo de excursão foi dividido em partições.

Tabela 5.2: Parâmetros iniciais das funções de pertinência de entrada em formato de sino para CP3R.

	<i>a</i>	<i>b</i>	<i>c</i>
L1	7,7662	0,5090	6,6998
L2	9,5513	0,5000	22,2335
L3	9,5513	0,5005	41,3359

Como a segunda entrada possuía apenas uma função de pertinência, esta foi considerada constante em 1, com a finalidade de evitar lacunas durante a aprendizagem e simplificar os cálculos. A figura 5.13 ilustra o formato inicial das funções de pertinência da primeira entrada. Note que o centro das funções de pertinência (parâmetro *c*) será a esperança estatística dos dados utilizados para gerar os modelos lineares e o cruzamento entre as funções de pertinência, a princípio, ocorre quando estas atingem o valor de 0.5. Porém, como os centros não são simetricamente distanciados e as funções em forma de sino possuem o lado esquerdo simétrico ao lado direito, em relação ao centro, este valor pode variar conforme a distância entre duas funções de pertinência aumente ou diminua. Por este motivo, o cruzamento da primeira com a segunda função de pertinência, da esquerda para a direita, ocorre em 0,53, no lugar de ocorrer em 0,5. Espera-se que a retropropagação do erro proceda com o ajuste destas funções para uma interpolação ótima, minimizando os efeitos das aproximações realizadas.

Para a aprendizagem, foi utilizado o conjunto de dados apresentado na figura 5.7. Este conjunto de dados deve passar pelo maior número de estados possíveis da planta e o algoritmo de aprendizagem deve ajustar as funções de pertinência, parâmetros *a*, *b* e *c*, para que a interpolação dos modelos lineares encontrados anteriormente seja ótima. Note que a combinação de modelos lineares passa a ser não-linear, ou seja, algumas não linearidades desprezadas para encontrar os modelos lineares de cada regra podem ser adicionadas ao identificador através da etapa de aprendizagem.

Após o treinamento com 3000 (três mil) épocas, as funções de pertinência adquiriram o formato ótimo ilustrado na figura 5.14 e que são referentes aos dados da tabela 5.3. Analisando as funções de pertinência, observou-se que elas tendem a variar sensivelmente a posição dos centros e tornar maior o grau de compatibilidade da entrada próximo ao centro, reduzindo a interpolação suave que existia entre os modelos no formato inicial. Os modelos lineares *R1*, *R2* e *R3*, foram produzidos para os intervalos [0 15], [15 35] e [35 50], respectivamente. Com a otimização, verifica-se que o primeiro modelo deve atuar com maior intensidade no intervalo de 1 a 11, o segundo de 11 a 33 e o terceiro de 33 a 50.

Outra característica observada nos gráficos é que a função de pertinência para a terceira regra atua com mais intensidade que a da segunda no intervalo de 0 a 5 cm, o que




Figura 5.13: Forma inicial das funções de pertinência do CP3R.

pode ser uma tentativa de amenizar o erro causado pela não linearidade nesta região do sistema.

Tabela 5.3: Parâmetros ótimos das funções de pertinência de entrada em CP3R.

	a	b	c
L1	3,814153	1,681471	8,803385
L2	13,538425	7,849105	21,667833
L3	13,497787	1,148555	38,019955

Para a validação do identificador obtido, um novo conjunto de dados foi utilizado. Este conjunto de dados percorre algumas regiões do sistema de modo a evidenciar características próprias da técnica proposta. A figura 5.15 mostra 3 gráficos. Um deles é chamado de experimental e corresponde ao sinal de validação utilizado. O outro é o resultado obtido com o identificador utilizando a métrica proposta e recebe a nomenclatura de ANFIS. Já o último, denominado de Linear, é o resultado obtido com um identificador utilizando uma métrica clássica em que aplica 100% do modelo linear com menor distância euclidiana entre os centros das funções de pertinência e as entradas atuais do sistema.




Figura 5.14: Forma otimizada das funções de pertinência do CP3R.

Para uma comparação mais justa entre ANFIS e Linear, optou-se em utilizar para o identificador denominado de Linear os mesmos modelos lineares utilizados no ANFIS e, assim, aumentar o número de modelos na mesma medida que o ANFIS. Os centros das funções de pertinência já otimizadas são utilizadas por Linear evitando que outros dados além dos encontrados para os modelos ótimos sejam utilizados para a validação.

Analisando os gráficos de Linear e ANFIS, observa-se que no início os identificadores se comportam de forma equivalente, pois ambos estão utilizando apenas o primeiro modelo, $R1$. Quando o nível aumenta, então o ANFIS passa a utilizar um pouco do segundo modelo, $R2$, e isto torna o comportamento distinto do Linear que sempre utiliza 100% de um modelo linear, enquanto o ANFIS pode utilizar proporções de cada modelo. Durante a execução das simulações não são realizadas trocas de informações entre os identificadores que sempre são realimentados por seu próprio estado atual simulado.

No instante em que a tensão Y_k passa de 12 para 6 volts, ambos os identificadores estão em aproximadamente 11 cm. Com este nível, observa-se no gráfico das funções de pertinência ótimas, figura 5.14, que para o ANFIS a função de pertinência da partição $L2$ passa a ser mais ativa, ou seja, o modelo linear $R2$ da regra $L2 \times M1$ passa a ser mais utilizado do que o $R1$. Já para o Linear, o chaveamento entre os modelos $R1$ e $R2$ ocorrerá em 15,2356 cm, que é a metade da distância entre os centros das funções de pertinência $L1$




Figura 5.15: Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CP3R.

e $L2$, ou seja, o identificador Linear, neste estado, continua utilizando o modelo $R1$. Desta forma, os comportamentos dos identificadores se distanciam, voltando a se aproximar novamente apenas na amostra 350. Note que neste instante o identificador Linear continua a utilizar o modelo $R1$, mas agora com tensão de 10 volts que é capaz de alterar do modelo $R1$ para o seguinte. Como $R1$ possui comportamento com maior influência da tensão, então o gráfico de Linear se aproxima e até ultrapassa o valor do sinal experimental e do ANFIS.

Da mesma forma que no início da validação, observe que à partir de 40 cm ambos os identificadores, Linear e ANFIS, utilizam um único modelo linear, o $R3$. Com isso seus comportamentos passam a ser idênticos.

Na amostra 410 um ruído mais expressivo é medido pelo sensor em Experimental. Como os identificadores não utilizam dados da planta durante a validação, então este sinal não influencia no comportamento de ANFIS ou de Linear.

Por volta de 35 cm e com tensão Y_k de zero volt, os gráficos de Linear e ANFIS voltam a se distanciar e desta vez a transição do modelo $R3$ para o $R2$ é o responsável. Após aplicar sete volts teremos que ANFIS estará em 32 cm e utilizará predominantemente $R2$, enquanto Linear utilizará o modelo $R3$ já que o chaveamento ocorre apenas em 29,8439

cm e ele está no estado de 33 cm e descendo.

Finalmente, é bom observar que o comportamento precário do identificador ANFIS em algumas regiões pode ser melhorado se os modelos lineares reproduzirem com mais fidelidade cada uma destas regiões.

Uma alternativa para aumentar a precisão do identificador é aumentar o número de funções de pertinência de cada entrada, fazendo com que um número maior de regras seja criado e, conseqüentemente, um número maior de modelos lineares possa ser interpolado.

5.3.2 Identificador caixa preta com 9 regras (CP9R)

No desenvolvimento de um novo identificador, considerou-se que três partições em Y possibilitariam uma melhor representação dos gráficos da segunda entrada. Desta forma, o intervalo de excursão de Y será representado por três partições $M1$, $M2$ e $M3$. Ainda assim existem não linearidades desprezadas durante este procedimento.

A divisão do intervalo de excursão da segunda entrada (Y) pode ocorrer em alguns pontos distintos. Observando o gráfico da variação do estado do sistema em função da segunda entrada (figura 5.16), verificou-se uma necessidade de divisão nas seguintes partições: $M1=[0, 2]$, $M2=[2, 4]$ e $M3=[4, 12]$. Porém, caso não fosse possível a obtenção dos gráficos, um ensaio com a separação em partições simétricas $M1=[0, 4]$, $M2=[4, 8]$ e $M3=[8, 12]$, também foi realizado. As figuras 5.16 e 5.17 mostram a divisão do intervalo de excursão em partições para a análise gráfica e para o caso simétrico, respectivamente, e exemplos de modelos lineares para aproximar os gráficos medidos da variação de X em função dos valores de Y para cada partição.

A fim de simplificar a nomenclatura dos testes realizados neste trabalho, o identificador com divisão simétrica do intervalo de excursão de Y será chamado de CP9RS. Já o identificador com divisão baseada na análise gráfica do comportamento de Y será chamado de CP9RG.

Para pequenas tensões é esperado que CP9RG reproduza o sistema com mais fidelidade que o CP9RS. Já para tensões elevadas, o CP9RS leva vantagem, pois a combinação de modelos lineares pode levar a uma representação melhor já que estão mais bem distribuídos naquela área.

A base de regras é formada pelo cruzamento das partições das entradas. Assim, com 3 partições para a primeira entrada e 3 para a segunda, a base de regras será formada por 9 regras. Cada uma destas regras irá concluir um modelo linear distinto que será encontrado através da utilização do algoritmo de mínimos quadrados (LSE).

Para aplicar o algoritmo LSE, um conjunto de dados será encontrado para cada regra, ou seja, para cada cruzamento das partições das entradas. Note que os conjuntos de dados obtidos para as regras dos identificadores podem ser distintos para regras equivalentes, pois são coletados de partições com limites diferentes. Desta forma, modelos lineares para as regras equivalentes podem ser diferentes.

A tabela 5.4 mostra os modelos lineares encontrados tanto para o CP9RS quanto para o CP9RG. Para o primeiro caso, CP9RS, note as semelhanças entre os modelos encontrados para as regras $L2 \times M2$ e $L2 \times M3$ e para as regras $L3 \times M2$ e $L3 \times M3$. Esta informação também sugere que as duas últimas partições ($M2$ e $M3$) do caso simétrico podem ser




Figura 5.16: Divisão da segunda entrada em três regiões utilizando informações gráficas.

substituídas por uma única partição. Porém, esta substituição faria com que os modelos das regras L1xM2 e L1xM3 também fossem iguais, aumentando a imprecisão do identificador. Analisando os modelos encontrados para o segundo identificador, CP9RG, observa-se que as partições *M2* e *M3* ainda guardam alguma semelhança, porém os valores divergem um pouco mais.

Espera-se que, com estes modelos, mais informações possam ser passadas ao identificador e, assim, maiores são as expectativas de que o sistema a ser identificado seja bem reproduzido no instante inicial da aprendizagem. Porém, o custo de obtenção destas informações pode ser muito elevado e não justificar uma análise mais detalhada do comportamento do sistema ou mesmo aumentar de forma absurda a complexidade para implantação da técnica. Além disso, por se tratar de um sistema não linear, nada impede que o identificador com um número menor de informações iniciais tenha uma aprendizagem mais rápida e obtenha um modelo mais próximo do esperado.

As funções de pertinência podem ser inicializadas utilizando o mesmo conjunto de dados empregado para gerar os modelos lineares. De acordo com o capítulo 4, as funções de pertinência terão seus centros encontrados a partir da esperança dos dados adquiridos em cada partição. A abertura de cada uma destas funções será encontrada em função da distância entre os centros, de forma que na metade da distância entre duas funções de




Figura 5.17: Divisão da segunda entrada em três regiões simétricas.

pertinência adjacentes a ativação seja igual a 0,5 (50%) para ambas. Da mesma forma que o CP3R, se o espaçamento entre os centros for assimétrico, a ativação em ambos os lados da função de pertinência fica comprometida com a função em forma de sino. As alternativas para contornar este problema envolvem a mudança do formato das funções de pertinência ou a escolha de apenas um dos lados para garantir a ativação de 0,5. Observe que esta última alternativa pode levar ao aparecimento de lacunas entre as funções de pertinência, devendo ser implementada com atenção.

A tabela 5.5 mostra os dados iniciais encontrados para as funções de pertinência em que a escolha de um dos lados (o direito) foi utilizada para garantir o valor de 0,5 no encontro das funções de pertinência. Observe que o parâmetro c , centro das funções de pertinência, para L1, L2 e L3 possuem seus correspondentes valores semelhantes tanto em CP9RS quanto em CP9RG. Já para M1, M2 e M3, o parâmetro c de CP9RG e CP9RS possui diferença considerável. Esta diferença é resultado dos conjuntos de dados terem médias distintas, pois possuem um valor quando a divisão é simétrica e possuem outro valor quando a divisão é baseada na análise gráfica da influência da segunda entrada no comportamento do sistema.

Após iniciar as funções de pertinência, um novo conjunto de dados foi utilizado para a otimização do identificador através da retropropagação do erro. Lembre-se que esta

Tabela 5.4: Modelos lineares encontrados para os identificadores CP9RS e CP9RG.

CP9RS			
	L1	L2	L3
M1	$0,987765X_k + 0,039832Y_k$	$0,993496X_k + 0,040243Y_k$	$0,997197X_k + 0,021276Y_k$
M2	$0,988546X_k + 0,041306Y_k$	$0,996046X_k + 0,025497Y_k$	$0,997613X_k + 0,019033Y_k$
M3	$0,983110X_k + 0,043275Y_k$	$0,996602X_k + 0,022419Y_k$	$0,997692X_k + 0,017804Y_k$
CP9RG			
	L1	L2	L3
M1	$0,990600X_k + 0,003571Y_k$	$0,994759X_k + 0,008167Y_k$	$0,997356X_k + 0,009354Y_k$
M2	$0,989401X_k + 0,032955Y_k$	$0,993984X_k + 0,033256Y_k$	$0,996678X_k + 0,027545Y_k$
M3	$0,989486X_k + 0,038659Y_k$	$0,995089X_k + 0,027442Y_k$	$0,997877X_k + 0,016922Y_k$

otimização afetará apenas as funções de pertinência e estas são responsáveis por interpolar os modelos lineares encontrados para cada regra. Desta forma, a otimização das funções de pertinência otimiza, de forma indireta, a interpolação entre os modelos lineares.

A tabela 5.6 mostra os parâmetros das funções de pertinência após a aprendizagem por retropropagação do erro dos mais de 10000 pontos de treinamento. A aprendizagem com cerca de 3000 épocas despendeu, aproximadamente, 28 minutos (três vezes mais tempo que o CP3R, com 9 minutos) para o hardware, processador *Mobile AMD Sempron*TM 3500+ e 1 Gigabyte de memória RAM. O aumento do custo computacional é notável e coincidiu com o aumento do número de variáveis ajustáveis do sistema, CP9RS e CP9RG possuem 3 vezes mais variáveis ajustáveis que CP3R, para o mesmo número de épocas. Além deste aumento, os modelos com 9 regras possuíam uma maior complexidade para inicializar a técnica.

As figuras 5.18 e 5.19 ilustram as funções de pertinência encontradas para os dois ensaios realizados. Observe as funções de pertinência da entrada Nível, que corresponde ao estado atual da planta. Nas duas primeiras funções de pertinência os ajustes levaram a formatos similares para ambos os ensaios, já a terceira função de pertinência foi afetada pelas diferenças na segunda entrada. A segunda entrada possui funções de pertinência que divergem bastante, pois as regiões estão centradas em pontos distintos. Note que a terceira função de pertinência do CP9RS é utilizada com maior intensidade de zero à, aproximadamente, 2,2 volts, o que leva a crer na necessidade de uma nova região para esta representação. No caso do ensaio com análise gráfica, as funções de pertinência não possuem a característica apresentada pelo ensaio simétrico, porém, a imprecisão em relação à utilização do modelo para tensões acima de 9 volts leva a crer que o identificador não será muito conciso nesta região.

Em seguida, procedeu-se com a validação dos identificadores encontrados. Comparando apenas o gráfico de Linear das figuras 5.20 e 5.21, nota-se uma diferença causada pela disposição dos centros e o tipo de modelo linear encontrado para as regiões. Observe que o gráfico de Linear ilustrado em 5.21 é mais próximo do valor de Experimental que o gráfico de Linear em 5.20 e este resultado deve-se, principalmente, a uma melhor distribuição de regiões para o CP9RG do que o CP9RS em relação ao comportamento do

Tabela 5.5: Estado inicial das funções de pertinência para CP9RS e para CP9RG.

CP9RS			
	<i>a</i>	<i>b</i>	<i>c</i>
L1	8,8340	0,5	8,1945
L2	8,1936	0,5	25,8627
L3	8,1936	0,5	42,2498
M1	1,7487	0,5	2,5170
M2	1,8466	0,5	6,0144
M3	1,8466	0,5	9,7076

CP9RG			
	<i>a</i>	<i>b</i>	<i>c</i>
L1	8,2916	0,5	7,7507
L2	9,1533	0,5	24,3340
L3	9,1533	0,5	42,6405
M1	1,0604	0,5	0,9852
M2	1,7328	0,5	3,1062
M3	1,7328	0,5	6,5717

sistema. Linear, assim como no ensaio CP3R, é um identificador multimodelos cuja seleção do modelo a ser utilizado a cada instante é realizada com base na distância euclidiana dos centros das funções de pertinência ótimas que, por sua vez, são utilizadas no ANFIS. Desta forma, para o CP9RS e para CP9RG existem nove modelos lineares que poderão ser selecionados, mas somente o que possuir a menor distância euclidiana dos valores de entrada em relação aos centros das funções de pertinência será o escolhido. Observe que o número de modelos lineares em Linear aumenta quando o número de modelos lineares no ANFIS aumenta e a otimização das funções de pertinência também otimizam a escolha do modelo em Linear.

Ao analisar a figura 5.20 desde seu início, observa-se que o comportamento de Linear é equivalente ao de ANFIS enquanto doze volts são aplicados. Porém, quando seis volts são aplicados, a transição entre alguns modelos ocorre e os comportamentos passam a ser distintos. Diferente do ANFIS em que a transição ocorre suavemente de modelo para modelo, o Linear realiza o chaveamento entre modelos causando a distinção entre o comportamento dos identificadores. Comportamento similar também é apresentado na figura 5.21 com o CP9RG em relação ao seu Linear equivalente.

Comparando a validação de ANFIS em CP9RS e em CP9RG, observa-se que em CP9RG ele obteve um menor erro em relação ao valor de Experimental. Este fato mostra que a análise gráfica rendeu resultado. Porém, se comparado com o ANFIS encontrado em CP3R, que utiliza apenas 3 modelos, o resultado dos identificadores com 9 regras deixa a desejar.

Diferentemente do conjunto de treinamento e da análise gráfica utilizada para gerar e otimizar os modelos, o conjunto de validação não evidencia todo intervalo de excursão das variáveis, acumulando um erro que se propaga desde o início até o fim das simulações.

Tabela 5.6: Estado ótimo das funções de pertinência para os identificadores CP9RS e CP9RG.

CP9RS			
	<i>a</i>	<i>b</i>	<i>c</i>
L1	9,249006	1,313278	7,057820
L2	10,696989	5,409769	24,289494
L3	6,304610	6,190595	42,418526
M1	0,524432	2,818671	2,988686
M2	2,794024	8,349296	5,752787
M3	0,188266	0,293175	11,827670
CP9RG			
	<i>a</i>	<i>b</i>	<i>c</i>
L1	8,764553	1,216706	8,154754
L2	9,649620	5,583755	25,255886
L3	14,873714	3,767448	37,395840
M1	0,562042	6,253105	1,529439
M2	0,321976	2,355825	2,230736
M3	1,040061	2,283268	6,049226

Analisando apenas o comportamento da validação onde a tensão é igual a três volts, tem-se o gráfico da figura 5.22 que mostra um intervalo em que o comportamento do CP9RG é mais próximo do Experimental que o do CP3R.

Para a análise mais precisa em relação aos gráficos de validação obtidos, utilizamos a comparação numérica entre os resultados. Os dois métodos de comparação numérica analisados são: a integração absoluta do erro (IAE) e a integração quadrática do erro (ISE). A tabela 5.7 mostra os resultados com os métodos de comparação numérica para todos os ensaios realizados até o momento. Analisando esta tabela nota-se a superioridade do identificador CP3R em todos os métodos propostos. Porém, sua deficiência com sinais baixos de tensão fica evidente quando é analisada apenas esta região de validação. Ao comparar CP9RG com CP9RS, verifica-se que a análise gráfica rendeu uma redução de erro, pois distribui suas funções de pertinência com relação ao comportamento do sistema enquanto CP9RS distribui simetricamente no intervalo de excursão.

A tabela 5.7 também apresenta a comparação numérica para os identificadores com métrica simplificada denominada de Linear e que faz correspondência apenas aos centros ótimos encontrados. Observe que a utilização desta simplificação gera um erro mais elevado, se comparado com a métrica ANFIS proposta, em todas as situações. Dentre os lineares, o CP9RGL apresentou um resultado muito próximo ao CP3RL no IAE e melhor no ISE, ou seja, o CP9RGL opera mais distante do valor de Experimental, mas com menores sobre sinais.

Por se tratar de uma identificação não linear, nada garante que quanto mais informações forem passadas para o identificador mais exato e rápido é encontrado o resultado final. Porém, em algumas condições é necessária uma análise aprofundada das entradas.

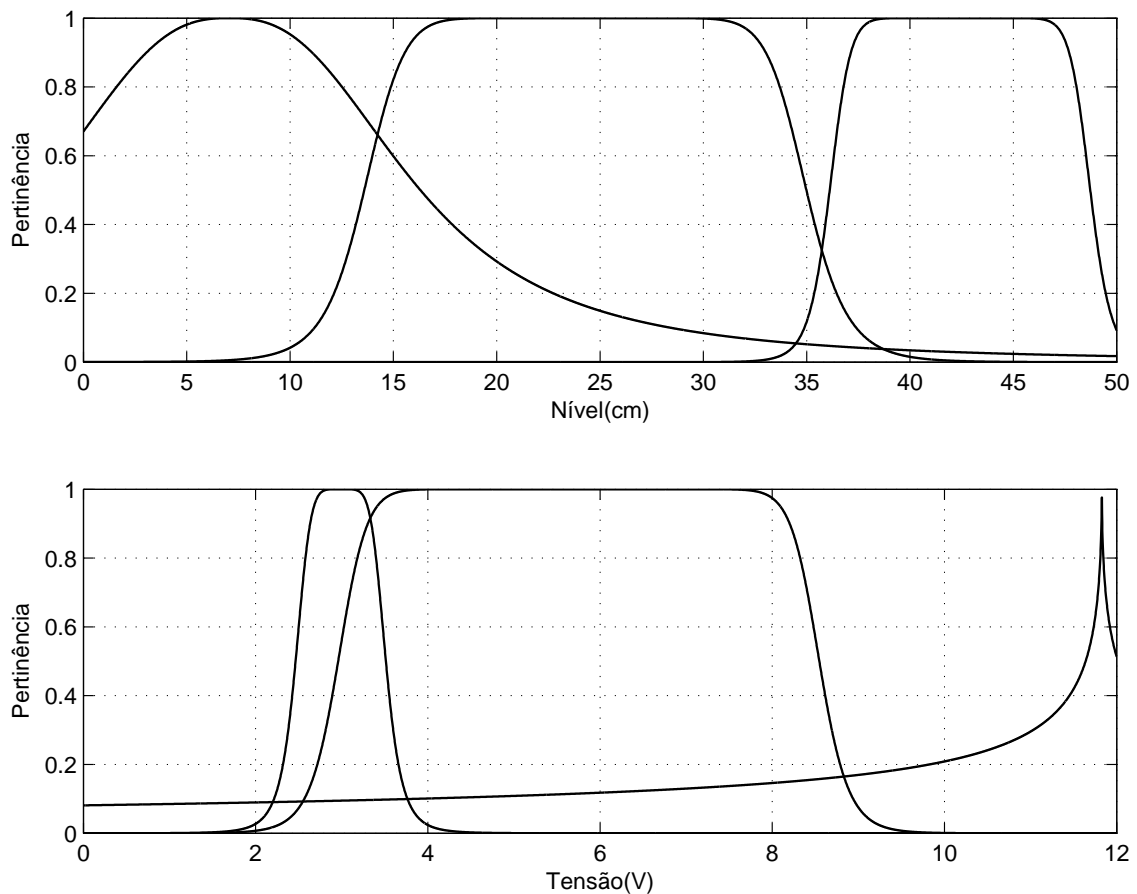


Figura 5.18: Forma otimizada das funções de pertinência do CP9RS.

Considerando o exemplo hipotético em que no sistema com múltiplas seções a tensão aplicada aumenta a vazão da bomba até determinado valor e após este valor a vazão da bomba começa a reduzir. Neste exemplo, existe a necessidade de divisão do intervalo de excursão da entrada com a representação de pelo menos um modelo linear para a região de aumento da vazão e outro modelo linear para representação de redução.

Baseado no que foi exposto, algumas informações sobre o comportamento do sistema podem ser introduzidas durante o desenvolvimento da técnica, selecionando partições, por exemplo, baseando-se apenas na característica do sistema. O sistema de tanque com múltiplas seções projetado possui várias seções bem definidas e este tipo de informação pode ser utilizada para gerar partições da entrada X , que corresponde ao nível. Os ensaios realizados com o identificador sendo criado utilizando informações do sistema serão denominados de identificação caixa cinza.

5.4 Resultado da Identificação Tipo Caixa Cinza

A identificação caixa cinza consiste em considerar o formato do sistema e definir regiões utilizando algumas características físicas que possam servir de base para a definição

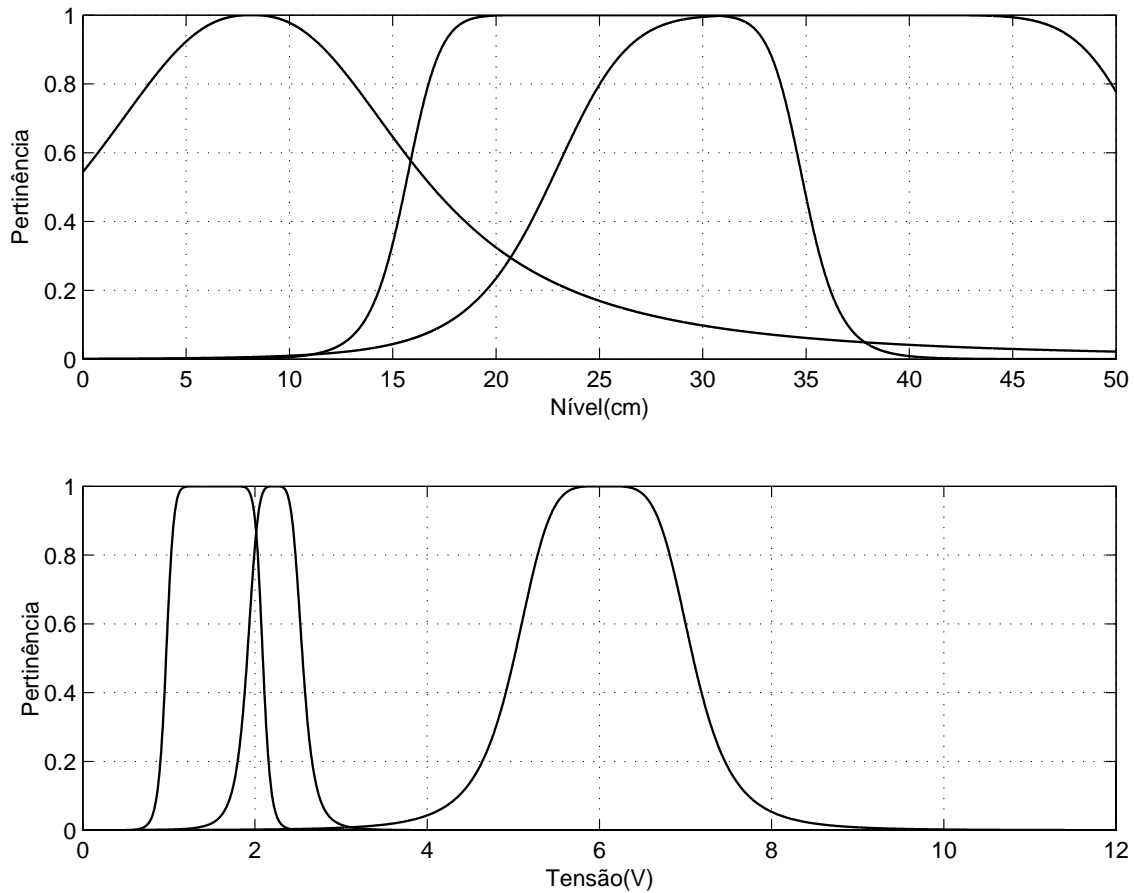


Figura 5.19: Forma otimizada das funções de pertinência do CP9RG.

de partições. Observe que neste tipo de identificação não será utilizada a análise gráfica, mas será utilizada uma análise física do sistema. O sistema projetado possui 5 seções bem definidas, como mostra a figura 5.1. Estas seções podem ser utilizadas para definir as partições da primeira entrada do identificador, que é o nível atual do sistema. O primeiro ensaio caixa cinza será realizado utilizando 3 seções do tanque a ser identificado, o segundo ensaio utilizará todas as 5 seções e o último ensaio utilizará apenas 2 seções. A segunda entrada, a tensão da bomba, não será dividida em partições a fim de concentrar o estudo no número de partições da primeira entrada e pelo fato da análise em relação à divisão da segunda entrada já ter sido realizada na identificação caixa preta já apresentada.

Para simplificar a nomenclatura e evitar ambiguidades, os intervalos das seções do tanque serão denominados de regiões. Assim, para a primeira entrada teremos as regiões $L1$, $L2$, $L3$, $L4$ e $L5$.

A estrutura utilizada para os ensaios com a identificação caixa cinza é a apresentada na figura 3.6 e o número de regras será igual ao número de regiões da primeira entrada.




Figura 5.20: Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CP9RS.

5.4.1 Identificação caixa cinza com 3 regras (CC3R)

Neste ensaio o identificador utilizará 3 modelos lineares para 3 seções distintas do tanque que deseja identificar. Considerando o esquema da figura 5.1, um modelo linear será encontrado para a região $L1$, outro para $L3$ e um terceiro para a região $L5$. O número de modelos lineares coincidirá com o de regiões utilizadas e, assim, um modelo linear será encontrado para cada seção com a aplicação do LSE sobre um conjunto de pares de entrada e saída desta. Com a escolha destes modelos é esperado que as regiões intermediárias, $L2$ e $L4$, sejam aproximadas pela interpolação dos modelos adjacentes a cada região omissa.

Note que, diferentemente do ensaio caixa preta para 3 regras, CP3R, o ensaio realizado nesta seção não passa informação alguma aos modelos lineares sobre as regiões abrangidas por $L2$ e $L4$. Dados sobre estas regiões deverão ser inferidos pelo identificador apenas durante a aprendizagem com retropropagação do erro.

As figuras 5.23, 5.24 e 5.25 mostram as saídas coletadas, ou seja, o nível que a coluna de água atingiu, quando a bomba de água é submetida a diversas tensões nas regiões $L1$, $L3$ e $L5$, respectivamente. Estas figuras também ilustram a saída do modelo linear




Figura 5.21: Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CP9RG.

encontrado quando o algoritmo LSE é aplicado em relação às mesmas entradas. Já a tabela 5.8 mostra os modelos lineares encontrados para cada uma das regras e que equivalem aos polinômios Sugeno do identificador *fuzzy*.

Observe nas figuras que a tensão de entrada é aplicada de forma *off-line* para que o nível do tanque fique oscilando em torno do ponto onde se deseja definir o centro da função de pertinência. A oscilação faz com que o nível permaneça estritamente em cada região. Observe ainda que o número de pontos para encontrar o modelo linear da primeira regra é aproximadamente a metade do utilizado para encontrar os outros modelos e isto se deve ao fato das variações do sistema serem muito mais rápidas na região $L1$ do que nas demais.

As funções de pertinência foram iniciadas como descrito no capítulo 4. A tabela 5.9 apresenta os valores encontrados para a , b e c das funções de pertinência em forma de seno. Se analisarmos esta tabela e comprarmos com os dados da tabela 5.2 observamos algumas diferenças causadas pela restrição de algumas áreas para encontrar os modelos lineares.

O mesmo conjunto de dados empregado na aprendizagem caixa preta foi utilizado para o treinamento caixa cinza com 3 regras (figura 5.7). Após 3000 épocas que consumiu




Figura 5.22: Comparação do CP9RG com o CP3R.

cerca de 9 minutos de aprendizagem (para o mesmo hardware dos ensaios anteriores), chegou-se aos parâmetros ótimos apresentados na tabela 5.10 e ilustrados na figura 5.26.

As funções de pertinência produzidas neste ensaio indicam a área de atuação de cada modelo linear encontrado anteriormente. Observe que os pontos de transição entre os modelos ótimos estão em aproximadamente 6,6 cm, do primeiro para o segundo, e em 32,5 cm, do segundo para o terceiro, o que diverge um pouco da transição em 11 cm, do primeiro para o segundo, que ocorria no CP3R. Outro fato observado é que para cada função de pertinência o valor de retorno passa a ser maior quando o sinal de entrada está próximo ao centro da função de pertinência e menor quando o sinal está próximo ao centro de outra função de pertinência.

Uma característica que deve ser lembrada é que as pertinências encontradas para cada sinal de entrada, após a *fuzzyficação*, serão normalizadas em uma camada seguinte da estrutura utilizada, ou seja, o somatório das pertinências será sempre igual a um após a normalização. Então, mesmo que em 32 cm a pertinência encontrada seja aproximadamente 1 para as funções de pertinência L3 e L5, após a normalização, 50% dos modelos lineares consequentes destas partições serão utilizados.

O identificador encontrado foi executado com o mesmo conjunto de validação utili-

Tabela 5.7: Comparação numérica entre os identificadores caixa preta.

	IAE*10 ³	ISE*10 ³
CP3R	1,7931	3,9066
CP9RS	4,2275	14,414
CP9RG	3,5825	10,543
CP3RL	6,8641	47,788
CP9RSL	8,9777	66,468
CP9RGL	7,1708	43,858




Figura 5.23: Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) para $L1$. Abaixo, a tensão Y_k utilizada em cada amostra.

zados nos ensaios anteriores. O gráfico da figura 5.27 ilustra o comportamento do identificador desenvolvido com a técnica. Neste gráfico também está desenhado o comportamento de Linear obtido a partir da métrica, já comentada, com distância euclidiana dos centros, chaveando entre os modelos e utilizando 100% do modelo linear mais próximo.

Comparando o gráfico Linear da figura 5.27 com o Linear da figura 5.15, proveniente do CP3R, observa-se que o comportamento do primeiro é mais distante de Experimental e




Figura 5.24: Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) para $L3$. Abaixo, a tensão Y_k utilizada em cada amostra.

isto se deve ao formato dos modelos lineares operarem sem nenhuma informação a cerca das regiões intermediárias em CC3R. Porém, após o treinamento, informações ótimas são absorvidas pelo ANFIS que pode realizar uma interpolação ótima dos modelos, melhores até do que a do ANFIS em 5.15, em relação ao conjunto de validação utilizada.

Mesmo sem possuir algumas informações de regiões adjacentes, o identificador CC3R obtém resultados aproximados aos desejados. Assim como no identificador CP3R, no CC3R o comportamento se aproxima do linear quando o nível do tanque opera nas extremidades, utilizando apenas o modelo da regra $L1 \times M1$ quando o nível está baixo e apenas o $L5 \times M1$ quando está alto.

Dados das regiões $L2$ e $L4$ podem ser utilizados para gerar novos modelos adjacentes, porém estas regiões ainda são não-lineares e os modelos lineares encontrados serão apenas uma aproximação do comportamento real. A seguir faz-se uma análise do identificador quando 5 modelos lineares são encontrados para o sistema.




Figura 5.25: Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) para $L5$. Abaixo, a tensão Y_k utilizada em cada amostra.

5.4.2 Identificador caixa cinza com 5 regras (CC5R)

Para este ensaio 5 modelos lineares serão considerados para realizar a identificação, um para cada uma das regiões da figura 5.1 que representa o sistema. A geração de 5 modelos é resultado do cruzamento das partições das entradas, conforme explicito no capítulo 4. Desta forma, a base de regras será formada por 5 regras que implicam cinco modelos lineares.

Um conjunto de dados foi adquirido para cada uma das regiões L1, L2, L3, L4 e L5 que compõem o tanque com múltiplas seções. Os conjuntos de dados L1, L3 e L5 já foram apresentados nas figuras 5.23, 5.24 e 5.25, respectivamente. Os conjuntos para L2 e L4, correspondentes às regiões trapezoidais, estão nas figuras 5.28 e 5.29, nesta ordem. Observe que, diferentemente do ensaio anterior, informações de todas as regiões visivelmente identificáveis são passadas aos modelos lineares. Porém, existem ainda não linearidades desprezadas com a aplicação do LSE e que se espera atribuir ao modelo através da superposição de funções de pertinência na etapa de aprendizagem por retropropagação do erro.

Os modelos lineares encontrados para as regras estão apresentados na tabela 5.11.

Tabela 5.8: Modelos lineares para CC3R.

	$L1$	$L3$	$L5$
$M1$	$0,970583X_k + 0,042636Y_k$	$0,994162X_k + 0,026248Y_k$	$0,997609X_k + 0,015882Y_k$

Tabela 5.9: Valores iniciais para as funções de pertinência do CC3R.

	a	b	c
$L1$	9,900811	0,5	4,041702
$L3$	10,411991	0,5	23,843889
$L5$	10,412013	0,5	44,667667




Figura 5.26: Forma otimizada das funções de pertinência do CC3R.

Note que neste sistema, em especial, os coeficientes dos modelos próximos da base do tanque indicam uma variação menor em relação ao nível do tanque se comparado aos modelos distantes da base do tanque. Já os modelos mais distantes da base são menos influenciados pela tensão que os próximos da base. Esta monotonicidade já era esperada, pois existe um aumento contínuo do volume do tanque e que não foi perturbada pelas não-linearidades do sistema.

Tabela 5.10: Valores ótimos para o CC3R.

	a	b	c
$L1$	8,900741	2,557537	-0,894282
$L3$	15,363304	7,871778	21,131783
$L5$	14,384470	5,104640	40,699375




Figura 5.27: Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CC3R.

Com informações mais precisas entre as regiões, é esperado um identificador com menor erro para o sistema. Porém, por se tratar de um processo de aprendizagem baseado no gradiente do erro, nada garante que o identificador com erro inicial menor que o outro antes da aprendizagem gere um resultado onde o erro do primeiro é menor do que o erro do segundo após a aprendizagem.

As formas iniciais das funções de pertinência também foram encontradas com o mesmo conjunto de dados utilizados para definir os modelos lineares. Os coeficientes destas funções estão apresentados na tabela 5.12.

Após a execução do algoritmo de aprendizagem (3000 épocas em 14 minutos, sempre utilizando o mesmo hardware), as funções de pertinência adquiriram o formato apresen-




Figura 5.28: Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) para $L2$. Abaixo, a tensão Y_k utilizada em cada amostra.

tado na figura 5.30 e cujos dados são mostrados na tabela 5.13. Observe que algumas das funções de pertinência passaram a ter o intervalo de excursão mais restrito, já outras aumentaram seu intervalo de excursão em relação ao estado inicial. A função de pertinência da região $L4$ teve seu centro deslocado para próximo da função de pertinência da região $L3$, quase formando uma lacuna entre as funções de pertinência das regiões $L4$ e $L5$, o que indicaria uma indefinição de modelos e geraria erro no algoritmo. Este erro poderia ser sanado através da utilização de um novo modelo para a região ou através de novos pontos de aprendizagem que induzissem o identificador para outra configuração ótima.

O conjunto contendo dados de validação foi executado e o comportamento do identificador CC5R está lustrado na figura 5.31. Este ensaio com cinco regras mostra bem o comportamento da métrica ANFIS sugerida neste trabalho. Como pode ser observado, o gráfico de Linear na figura 5.31 é mais próximo de Experimental, pois os modelos intermediários $L2$ e $L4$ possibilitam uma transição mais suave entre os modelos mesmo sendo chaveados. A interpolação dos modelos lineares pelo ANFIS mostra uma melhora em relação à Linear e, mesmo com uma pequena divergência em relação à Experimental, a aproximação torna-se bastante satisfatória.

O uso de um número maior de modelos lineares distribuídos ao longo do intervalo




Figura 5.29: Acima, nível de X_{k+1} desejado (contínuo) e medido (tracejado) para $L4$. Abaixo, a tensão Y_k utilizada em cada amostra.

de excursão da variável pode possibilitar a melhoria da identificação do sistema. No próximo ensaio, apenas duas regiões serão utilizadas para a primeira entrada do sistema. A interpolação dos dois únicos modelos lineares irá aproximar o novo identificador da saída esperada e ilustrada por Experimental.

5.4.3 Identificador caixa cinza com 2 regras (CC2R)

Neste novo ensaio, apenas duas regiões serão consideradas para a primeira entrada: a $L1$ e a $L5$. As figuras 5.23 e 5.25 ilustram os pontos coletados para a geração dos modelos lineares das regras formadas e na tabela 5.14 os modelos lineares encontrados após a aplicação do algoritmo LSE são apresentados.

As funções de pertinência foram iniciadas como indicado no capítulo 4 e adquiriram o formato ilustrado na figura 5.32 com valores de a , b e c apresentados na tabela 5.15. Observe que para duas funções de pertinência o cruzamento de 0.5 entre estas funções pode ser garantido, mesmo para as funções em formato de sino.

Após a execução do algoritmo de retropropagação do erro durante 5 minutos, equivalente a 3000 épocas, as funções de pertinência adquiriram o formato otimizado da figura

Tabela 5.11: Modelos lineares do CC5R.

	$M1$
$L1$	$0,970583X_k + 0,042636Y_k$
$L2$	$0,988140X_k + 0,033584Y_k$
$L3$	$0,994162X_k + 0,026248Y_k$
$L4$	$0,996785X_k + 0,019517Y_k$
$L5$	$0,997609X_k + 0,015882Y_k$

Tabela 5.12: Valores iniciais para as funções de pertinência do CC5R.

	a	b	c
$L1$	4,210033	0,5	4,041772
$L2$	5,690883	0,5	12,462052
$L3$	5,121137	0,5	23,843864
$L4$	5,290836	0,5	34,086124
$L5$	5,290837	0,5	44,667755




Figura 5.30: Forma otimizada das funções de pertinência após a aprendizagem do CC5R.

Tabela 5.13: Valores ótimos para as funções de pertinência do CC5R.

	a	b	c
$L1$	4,439553	3,547615	1,819856
$L2$	5,245024	4,311769	10,222700
$L3$	9,707062	3,854814	23,121183
$L4$	5,854714	4,688988	32,412876
$L5$	3,613454	9,203249	44,415722




Figura 5.31: Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CC5R.

5.33, dados pelos valores da tabela 5.16.

Note que as funções de pertinência possuem uma maior área de atuação se comparado com os ensaios anteriores de forma que os modelos intermediários omitidos pudessem ser representados pela combinação dos dois únicos modelos introduzidos no identificador.

A validação do identificador produzido com duas regras está ilustrada na figura 5.34 e mostra que mesmo sem ter uma função linear específica para cada uma das regiões intermediárias o método interpola devidamente as únicas duas funções lineares e é capaz de reproduzir, aproximadamente, o comportamento da planta. As funções de pertinência

Tabela 5.14: Modelos lineares das funções Sugeno encontrados pelo LSE para o CC2R.

	$L1$	$L5$
$M1$	$0,970583X_k + 0,042636Y_k$	$0,997609X_k + 0,015882Y_k$

Tabela 5.15: Valores iniciais para as funções de pertinência do CC2R.

	a	b	c
$L1$	20,312778	0,503318	4,041641
$L5$	20,313087	0,501824	44,667633




Figura 5.32: Forma inicial das funções de pertinência do CC2R.

intermediária são substituídas por combinações dos modelos lineares adjacentes e reproduzem o sistema de forma significativa.

O número reduzido de variáveis para serem ajustadas pelo algoritmo de retropropagação diminui a superfície de busca do algoritmo que pode alcançar o resultado ótimo da estrutura de forma mais rápida e com menor número de mínimos locais. Porém, sua simplicidade acarreta na imprecisão do sistema. Caso os modelos lineares não fossem consecutivos, provavelmente os valores intermediários não poderiam ser aproximados e

Tabela 5.16: Valores ótimos para as funções de pertinência do CC2R.

	a	b	c
$L1$	10,622583	1,874890	-5,286252
$L5$	20,668482	0,273039	44,411743




Figura 5.33: Forma otimizada das funções de pertinência após a aprendizagem do CC2R.

as duas funções de pertinência convergiram para um identificador sem interseção entre os modelos onde um erro de identificação de modelos seria gerado durante a aprendizagem.

Analisando o gráfico Linear da figura 5.34, observa-se que em nenhum instante ocorre o chaveamento entre os dois modelos lineares existentes, pois este deveria ocorrer em 19,5627 cm, que jamais é atingido. Já no gráfico ANFIS, a transição ocorre suavemente entre os modelos, o que possibilita a mudança de um para o outro.

A tabela 5.17 mostra uma comparação numérica entre os identificadores caixa cinza analisados neste trabalho em relação ao conjunto de validação utilizado. CC3R, CC5R e CC2R correspondem aos identificadores caixa cinza encontrados para 3, 5 e 2 regras, respectivamente. Esta tabela também apresenta a comparação numérica com o identificador clássico denominado de Linear que utiliza como métrica a distância euclidiana entre os centros ótimos.




Figura 5.34: Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CC2R.

Se comparado com o ensaio CC3R, o ensaio CC2R é mais simples. Porém, o identificador possui uma região com modelo ótimo a menos e por isso pode não aproximar satisfatoriamente o modelo identificado com o modelo de validação. Esta característica já era esperada pelo fato do sistema com 3 funções de pertinência ter o conhecimento de uma região a mais do que o modelo com apenas 2 funções de pertinência.

O identificador CC5R mostra-se com um resultado inferior ao apresentado pelo CC3R, mesmo sabendo que CC5R possui modelos intermediários que facilitarão a identificação do sistema. Então, para este conjunto de validação, a interpolação de modelos adjacentes aproximou melhor a região trapezoidal (região com provável maior não linearidade) do que o uso de um modelo exclusivo para representar esta região. A identificação do sistema pode se basear não apenas em regiões de provável linearidade, como ocorre na identificação caixa cinza, e utilizar todas as informações físicas da planta para obter modelos do tipo caixa branca.

Tabela 5.17: Comparação numérica entre os identificadores caixa cinza produzidos.

	IAE*10 ³	ISE*10 ³
CC3R	1,3639	1,8997
CC5R	1,5742	2,5753
CC2R	7,6265	50,308
CC3RL	8,5603	79,258
CC5RL	4,2096	20,237
CC2RL	21,942	464,94

5.5 Resultado da Identificação Tipo Caixa Branca

A identificação do tipo caixa branca consiste em obter o modelo linear de cada região a partir das relações fenomenológicas que regem o sistema. Para o sistema de tanques da figura 5.1, os modelos podem ser encontrados para as regiões retangulares a partir da variação volumétrica do sistema dada por,

$$\dot{V} = F_{in} - F_{out}; \quad (5.2)$$

em que F_{in} = Vazão de entrada, F_{out} = Vazão de saída;

A vazão de entrada pode ser encontrada a partir da linearização dos dados que correspondem a vazão da bomba, ilustrada na figura 5.4 e representada pela equação,

$$F_{in} = K_m \cdot V_p + C; \quad (5.3)$$

em que V_p é a tensão aplicada à bomba, $K_m = 10,6517$ e $C = 17,0133$.

A vazão de saída, por sua vez, pode ser representada por,

$$F_{out} = a \cdot V_{out}; \quad (5.4)$$

em que a = Área do orifício de saída e $V_{out} = \sqrt{2gL}$ é encontrado por Bernoulli, para g = Aceleração da gravidade e L = Nível do tanque;

O volume do retângulo pode ser encontrado por,

$$V = L \cdot A; \quad (5.5)$$

Derivando a equação anterior em relação ao tempo, encontra-se:

$$\dot{V} = \dot{L} \cdot A; \quad (5.6)$$

em que \dot{L} é a Taxa de variação do nível do tanque, \dot{V} é a variação volumétrica e A é a área da base do retângulo.

Assim, a equação não linear que representa as regiões retangulares é dada por,

$$\dot{L} = -\frac{a}{A} \cdot \sqrt{2g} \cdot \sqrt{L} + \frac{K_m}{A} \cdot V_p + C; \quad (5.7)$$

Substituindo variáveis e linearizando a equação anterior, obtém-se,

$$\dot{L} = -\frac{a}{A} \sqrt{\frac{g}{2L_{po}}} L + K_m \bar{V}_p. \quad (5.8)$$

em que L_{po} é o ponto de operação para o modelo e $\bar{V}_p = \frac{V_p}{A} - \frac{C}{AK_m}$;

Aplicando a técnica de segurador de ordem zero para discretizar o modelo linear do retângulo,

$$\frac{L(k+1) - L(k)}{T} = -\frac{a}{A} \sqrt{\frac{g}{2L_{po}}} L(k) + K_m \bar{V}_p(k). \quad (5.9)$$

em que T é o período de discretização.

Assim,

$$L(k+1) = \left(1 - \frac{a}{A} \sqrt{\frac{g}{2L_{po}}} \cdot T\right) \cdot L(k) + K_m \cdot T \cdot \bar{V}_p(k). \quad (5.10)$$

5.5.1 Identificador caixa branca com 3 regras (CB3R)

Para este ensaio, 3 modelos lineares são encontrados para as regiões retangulares L1, L3 e L5 do sistema. Utilizando os modelos encontrados para as regiões dados os valores de:

$$a = 0,1855079cm^2;$$

$$T = 0,5s;$$

$$g = 980,665cm/s^2;$$

$$K_m = 10,6517(cm^3/s)/volt;$$

$$C = 17,0133;$$

$$\text{Para a região L1: } A = 100cm^2 \text{ e } L_{po} = 5cm;$$

$$\text{Para a região L3: } A = 200cm^2 \text{ e } L_{po} = 25cm;$$

$$\text{Para a região L5: } A = 300cm^2 \text{ e } L_{po} = 45cm;$$

Espera-se que a técnica interpole estes modelos e encontre uma representação ótima do sistema completo após a aplicação do algoritmo de aprendizagem durante 3000 épocas. Neste ensaio também foi utilizado o mesmo conjunto de treinamento dos ensaios anteriores.

As funções de pertinência foram iniciadas com seus centros localizados nos pontos de operações dos modelos linearizados. Para garantir que pelo menos uma função de pertinência esteja ativa em todo intervalo de excursão das entradas, usou-se $b = 0,5$ e a igual ao valor necessário para que na metade da distância entre duas funções de pertinência adjacentes, as pertinências de ambas as funções seja igual a 0,5. Os valores iniciais dos parâmetros das funções de pertinência estão dispostos na tabela 5.18.

Após a aprendizagem, as funções de pertinência adquiriram os formatos ilustrados na figura 5.35, obtidos a partir dos dados da tabela 5.19.

A validação apresentando os gráficos de Experimental, Linear e ANFIS estão na figura 5.36 e mostram que o gráfico de ANFIS é mais próximo ao Experimental que o de Linear. Porém, não aproxima tanto quanto os ensaios caixa preta e caixa cinza, também com 3

Tabela 5.18: Valores iniciais para as funções de pertinência do CB3R.

	<i>a</i>	<i>b</i>	<i>c</i>
<i>L1</i>	10,0	0,5	5,0
<i>L3</i>	10,0	0,5	25,0
<i>L5</i>	10,0	0,5	45,0




Figura 5.35: Forma otimizada das funções de pertinência do CB3R.

regras. Acredita-se que este resultado se deve a simplificação dos modelos e aproximações para as representações propostas pela técnica.

A tabela 5.20 mostra uma comparação numérica entre alguns dos identificadores analisados neste trabalho em relação ao conjunto de validação utilizado. Nesta tabela, CP3R corresponde ao identificador caixa preta com 3 regras, CP9RS é o identificador caixa preta com nove regras e com o intervalo de excursão da segunda entrada dividido simetricamente e CP9RG é o identificador caixa preta com nove regras e com o intervalo de excursão da segunda entrada dividido após a análise gráfica. CC3R, CC5R e CC2R correspondem aos identificadores caixa cinza encontrados para 3, 5 e 2 regras, respectivamente. CB3R refere-se ao identificador caixa branca com 3 regras. A solução encontrada com muitas regras pode não compensar o tempo de análise de dados para encontrar novos

Tabela 5.19: Valores ótimos para as funções de pertinência do CB3R.

	a	b	c
$L1$	9,995860	0,864377	5,700687
$L3$	3,306332	6,619004	20,542179
$L5$	11,515535	0,182735	44,294594




Figura 5.36: Acima, nível de X_{k+1} desejado (contínuo), Linear (traço-ponto) e ANFIS (tracejado). Abaixo, tensão Y_k utilizada para a validação de CB3R.

modelos. Porém, esta análise pode gerar um identificador com menor erro para o sistema.

Comparando apenas os identificadores ótimos “ANFIS” com o esperado “Experimental” de cada ensaio, o identificador que mais se aproximou e menos se aproximou do resultado esperado foi CC3R e CC2R, respectivamente. Analisando apenas os “Lineares”, CC5RL possui maior aproximação e CC2RL menor aproximação.

A identificação utilizando outros tipos de funções de pertinência é uma alternativa quando se deseja alterar a superfície de busca do algoritmo de aprendizagem sem modificar o número de modelos lineares. A interpolação pode ser realizada com maior liberdade com funções de pertinência do tipo *Left-Right MF* ou mais restritamente com funções de pertinência do tipo Gaussiana. O número de variáveis a serem ajustadas sofre

Tabela 5.20: Comparação numérica entre os identificadores produzidos.

	IAE*10³	ISE*10³
CP3R	1,7931	3,9066
CP9RS	4,2275	14,414
CP9RG	3,5825	10,543
CC3R	1,3639	1,8997
CC5R	1,5742	2,5753
CC2R	7,6265	50,308
CB3R	9,0911	82,496
CP3RL	6,8641	47,788
CP9RSL	8,9777	66,468
CP9RGL	7,1708	43,858
CC3RL	8,5603	79,258
CC5RL	4,2096	20,237
CC2RL	21,942	464,94
CB3RL	18,109	302,35

uma variação que pode aumentar o número de mínimos locais e afetar no desempenho do identificador.

A utilização de técnicas empregando redes neurais como a NNARX para aprender e simular os mesmos conjuntos de dados utilizados pelos ensaios anteriores reforça a validação da técnica proposta.

5.6 Resultado da Identificação NNARX

O pacote de redes neurais presente no MATLAB foi utilizado para representar a estrutura da NNARX com aprendizagem por η -adaptativo. A estrutura desenvolvida é constituída por três camadas: uma de entrada, uma intermediária e uma de saída. Varias configurações foram testadas para esta estrutura com número de neurônios variando na primeira e na camada intermediária. Na primeira camada da rede neural estão dispostas as entradas da rede e seus atrasos. Na segunda camada estão dispostos os neurônios intermediários, ou escondidos, que possuem funções de ativação do tipo tangente hiperbólica. Já na terceira camada existe um único neurônio de saída que possui uma função de ativação do tipo linear. Para 1, 2 e 3 atrasos considerados, obtém-se 4, 6 e 8 neurônios na camada de entrada, respectivamente. Para cada atraso, ensaios com os neurônios da camada escondida variando de 2 à 21 foram realizados.

A tabela 5.21 mostra a comparação numérica pelos métodos *IAE* e *ISE* de cada ensaio realizado com o NNARX após a aprendizagem do conjunto de treinamento, composto por mais de 10000 pares, por 3000 épocas.

Analisando a tabela 5.21, observa-se que a melhor configuração encontrada continha 2 atrasos e 15 neurônios na camada intermediária. Seu comportamento está ilustrado na figura 5.37.

Tabela 5.21: Comparação numérica entre NNARX.

Escondidos	1 atraso		2 atrasos		3 atrasos	
	$IAE * 10^3$	$ISE * 10^3$	$IAE * 10^3$	$ISE * 10^3$	$IAE * 10^3$	$ISE * 10^3$
2	3,9397	26,670	6,3955	64,466	7,5929	79,912
3	65,683	532,12	7,1717	59,057	6,4701	58,475
4	6,2309	47,847	7,4777	67,000	3,5260	26,077
5	4,3253	24,635	7,5279	67,357	4,9166	33,500
6	3,6894	18,580	6,4715	46,991	6,0780	44,743
8	7,9899	65,787	2,5418	14,796	6,4756	44,493
10	2,5024	8,2814	2,4547	7,6360	7,7711	63,874
12	2,8528	11,998	2,0453	9,9115	5,1449	31,733
15	3,1655	15,173	1,6731	4,9489	7,9670	63,861
18	3,4070	15,567	1,9511	4,9718	6,2334	43,672
21	6,8867	49,251	2,3972	7,5373	2,3786	8,2974




Figura 5.37: Acima, nível de X_{k+1} desejado (contínuo) e NNARX (tracejado). Abaixo, tensão Y_k utilizada para a validação de NNARX.

Ao observar a figura de validação, nota-se que o sinal de saída do identificador é bastante próximo do encontrado por CC3R, mas é um sinal ruidoso, pois o identificador NNARX é capaz de representar também este tipo de sinal. Além da dificuldade para encontrar uma configuração inicial para identificador NNARX, as informações aprendidas pela rede ficaram difíceis de serem extraídas a partir de sua estrutura. Observou-se também que em certas situações, quando o número de neurônios intermediários aumentava, o erro do treinamento diminuía e o erro de validação aumentava. Um problema causado pelo aparecimento de ruídos durante a simulação é a possível degradação de acionadores e outros componentes eletrônicos causada pela variação abrupta de sinal.

Capítulo 6

Conclusões

Neste trabalho foi apresentada uma nova técnica de identificação de sistemas não lineares. Esta nova técnica pode ser descrita através da estratégia inteligente de múltiplos modelos em que uma métrica ANFIS é utilizada para interpolar modelos lineares de regiões bem definidas do sistema. A técnica também pode ser definida através da estrutura ANFIS que tem seus parâmetros iniciados pela técnica de múltiplos modelos e que, posteriormente, tem alguns parâmetros adaptados pelo algoritmo de aprendizagem. Indiferente ao ponto de vista utilizado, o algoritmo apresentado neste trabalho informa, passo a passo, como criar os modelos lineares, iniciar as funções de pertinência e, por fim, sugere um algoritmo de aprendizagem clássico para buscar a configuração ótima da estrutura.

Para compreender as alterações propostas, o trabalho inicia analisando as técnicas de múltiplos modelos e ANFIS, separadamente. Em seguida, realiza a união das técnicas e discute a estrutura para diversos números de entradas e saídas, mostrando como iniciar e implementar a técnica para o caso da estrutura MISO. As considerações feitas para esta estrutura podem ser generalizadas para outras com pequenas alterações. Finalmente, realiza um estudo de caso onde a idéia de identificação multimodelos com *neuro-fuzzy* (ANFIS) é utilizada.

Um sistema de tanque com múltiplas seções é projetado e desenvolvido para expor as principais características da técnica. Em sua estrutura é observado o aparecimento de regiões que possibilitam a realização de diversos ensaios com alternativas em relação à aplicação da técnica. Os resultados da identificação deste sistema de tanque pela técnica proposta, utilizando funções de pertinência em forma de sino, mostram que esta técnica aproxima de maneira satisfatória o modelo identificado, e quando comparado com o resultado obtido por um identificador com múltiplos modelos clássico, onde o chaveamento entre modelos ocorre por distância euclidiana, verifica-se, em todos os testes realizados, um melhor desempenho do identificador que utiliza a técnica inteligente. Ensaios em que modelos intermediários não são introduzidos no sistema são realizados e é observado que estes modelos serão compostos por combinações dos modelos lineares existentes. Como não ocorre alteração da estrutura ou dos modelos lineares, a identificação ainda garante tanto a simplicidade do modelo desenvolvido quanto a aproximação ótima do sistema real.

A técnica desenvolvida neste trabalho é utilizada sem qualquer informação a respeito do sistema de tanque a ser identificado (identificação caixa preta), com alguma informação da interface física do sistema (identificação caixa cinza) e a partir das relações

fenomenológicas do sistema (identificação caixa branca). Além do uso destas configurações, ensaios com uma rede neural do tipo NNARX foi realizado e o resultado de cada uma das identificações foi comentado mostrando as características de suas aplicações.

Ensaio mostram que a interpolação de modelos adjacentes pode, em determinadas ocasiões, gerar resultados melhores do que os encontrados para modelos específicos em regiões de não-linearidade. A técnica desenvolvida teve sua estrutura iniciada de duas formas na identificação do tipo caixa preta: por análise gráfica e por simetria entre funções de pertinência. Os ensaios mostraram que a análise gráfica é mais dispendiosa para inicializar, pois necessita de gráficos que mostrem o comportamento do sistema na presença de variações dos sinais de entrada. Porém esta análise pode levar a um resultado mais próximo ao esperado.

Para trabalhos futuros as funções de pertinência poderão ser assimétricas, de forma que a interpolação dos sistemas lineares ocorra independentemente em cada lado do centro. Novas plantas com aplicações industriais e outros algoritmo de aprendizagem podem ser utilizados com o intuito de descobrir os algoritmos tanto de linearização quanto os de aprendizagem mais apropriados às características da métrica proposta, de forma geral e no caso específico de cada sistema. Notou-se que a identificação de um sistema variante no tempo a partir da análise gráfica pode induzir o projetista a desenvolver modelos desnecessários para o identificador. Como uma possível solução para este problema, um estudo sobre a automatização da análise gráfica junto com uma análise da validação pode ser realizado, de modo que modelos redundantes fossem eliminados. Trabalhos sobre a obtenção automática do número de modelos lineares e de formato das funções de pertinência também podem ser produzidos, já que é através destas estruturas que definimos a forma inicial do identificador e, com uma técnica apropriada, pode-se produzir um identificador mais preciso e de menor complexidade em relação às suas ações.

Referências Bibliográficas

- Aguirre, Luis Antonio (2007), *Introdução à Identificação de Sistemas*, 3ª edição, UFMG, Minas Gerais, Brasil.
- Akhlaghi, Peyman, Amir Reza Kashanipour & Karim Salahshoor (2008), 'Intelligent fault diagnosis of distillation column system based on pca and multiple anfis', *IEEE Conference on Cybernetics and Intelligent Systems* pp. 905–910. 21-24 de setembro, Chengdu, China.
- Apkarian, J. (1995), *A Comprehensive and Modular Laboratory for Control Systems Design and Implementation*, 1ª edição, Quanser Consulting Handbook.
- Arslan, Erdem, Mehmet C. Çamurdan, Ahmet Palazoglu & Yaman Arkun (2004), 'Multi-model control of nonlinear systems using closed-loop gap metric', *America Control Conference* pp. 2374–2378. 30 de junho - 2 de julho, Massachusetts, EUA.
- Bao-ping, Chen & Ma Zeng-qiang (2009), 'Short-term traffic flow prediction based on anfis', *International Conference on Communication Software and Networks* pp. 791–793. 27-28 de Fevereiro, Macau, China.
- Barroso, Leônidas Conceição, Magali Maria A. Barroso, Frederico Ferreira Campus Filho, Márcio Luiz B. Carvalho & Miriam Lourenço Maia (1987), *Cálculo Numérico (com aplicações)*, 2ª edição, HARBRA, São Paulo, Brasil.
- Camacho, E. F. & C.Bordons (2004), *Model Predictive Control*, 2ª edição, Springer-Verlag, Nova York, EUA.
- Campos, Mario César M. M. & Herbert C. G. Teixeira (2007), *Controladores Típicos de Equipamentos e Processos Industriais*, 1ª edição, Edgard Blücher, São Paulo, Brasil.
- Cavalcanti, Anderson L. O. (2008), *Análise e Desenvolvimento de Controladores Preditivos Multivariáveis Baseados em Multi-Modelos Bilineares*, Tese de doutorado, Universidade Federal do Rio Grande do Norte, Natal, RN.
- Cavalcanti, Anderson L. O., André Laurindo Maitelli & Adhemar B. Fontes (2008), 'A phase margin metric for multi-model multivariable mpc', *16th Mediterranean Conference on Control and Automation* pp. 1874–1879. 25-27 de junho, Corsica, França.
- Chen, Chi-Tsong (1999), *Linear System Theory and Design*, 3ª edição, Oxford University.

- Chiu, Stephen L. (1994), 'Fuzzy model identification based on cluster estimation', *Intelligent and Fuzzy Systems* **2**, 267–278.
- Coelho, Antonio Augusto Rodrigues & Leandro dos Santos Coelho (2004), *Identificação de Sistemas Dinâmicos Lineares*, 1ª edição, Editora da UFSC, Florianópolis.
- Ding, Wen & Deliang Liang (2008), 'Modeling of a 6/4 switched reluctance motor using adaptive neural fuzzy inference system', *IEEE Transactions on Magnetics* **44**(7), 1796–1804.
- Fontes, Adhemar B., André Laurindo Maitelli & Anderson L. O. Cavalcanti (2007), 'Generalized predictive control based in multivariable bilinear multi-model', *8th International IFAC Symposium on Dynamics and Control of Process Systems* **3**, 91–96. Cancun, México.
- Foss, B. A., T. A. Johansen & A. V. Sorensen (1995), 'Nonlinear predictive control using local models – applied to a batch fermentation process', *Control Eng. Practice* **3**(3), 389–396.
- Gabriel, Oscar Filho (2004), Contribuições à Análise de Robustez de Sistemas de Controle usando Redes Neurais, Tese de Doutorado, Tese de doutorado, Universidade Federal do Rio Grande do Norte, Natal, RN.
- Galán, O., J. A. Romagnoli, Y. Arkun & A. Palazoglu (2000), 'On the use of gap metric for model selection in multi-linear model-based control', *American Control Conference* pp. 3742–3746. 28-30 de junho, Chicago, Illinois, EUA.
- Giovanini, L., M. Benosman & A. Ordys (2005), 'Adaptive control using multiple models switching and tuning', *International Conference on Industrial Electronics and Control Applications* pp. 1–8. junho, Quito, Equador.
- Habibi, Jalal, Behzad Moshiri & Ali Khaki Sedigh (2006), 'Performance benefits of hybrid control design for switched linear systems', *SICE-ICASE International Joint Conference* pp. 920–925. 18-21 de outubro, Busan, Coreia do Sul.
- Haykin, Simon (2001), *Redes Neurais - Princípios e Prática*, 2ª edição, Bookman, Porto Alegre, Brasil.
- Instruments, National (2005), 'Ni 6023e/6024e/6025e family specifications'. Último acesso, 29-05-2010.
*<http://www.ni.com/pdf/manuals/370719c.pdf>
- Instruments, National (2006), 'Low-cost e series multifunction daq – 12 or 16-bit, 200 ks/s, 16 analog inputs'. Último acesso, 29-05-2010.
*http://www.ni.com/pdf/products/us/4daqsc202-204_ETC_212-213.pdf
- Jang, Jyh-Shing Roger & Chuen-Tsai Sun (1995), 'Neuro-fuzzy modeling and control', *Proceedings of the IEEE* **83**(3), 378–406.

- Jang, Jyh-Shing Roger, Chuen-Tsai Sun & Eiji Mizutani (1997), *Neuro-Fuzzy and Soft Computing, A Computational Approach to Learn and Machine Intelligence*, 1ª edição, Prentice-Hall.
- Johansen, Tor A. & Robert Babuška (2003), ‘Multiobjective identification of takagi-sugeno fuzzy models’, *IEEE Transactions on Fuzzy Systems* **11**(6), 847–860.
- Khadangi, Ehsan, Hossein Riahi Madvar & Mohammad Mehdi Ebadzadeh (2009), ‘Comparison of anfis and rbf models in daily stream flow forecasting’, *2nd International Conference on Computer, Control and Communication* pp. 1–6. 17-18 de fevereiro, Karachi, Paquistão.
- Konstantinov, K. & T. Yoshida (1989), ‘Physiological state control of fermentation processes’, *Biotechnology and Bioengineering* **33**(9), 1145–1156.
- Liu, Jianbo & Dragan Djurdjanovic (2008), ‘Topology preservation and cooperative learning in identification of multiple model systems’, *IEEE Transactions on Neural Networks* **19**(12), 2065–2072.
- Maciejowski, J. M. (2002), *Predictive Control with Constraints*, 1ª edição, Prentice-Hall.
- Mazinan, A.H. & N. Sadati (2008), ‘Fuzzy multiple models predictive control of tubular heat exchanger’, *IEEE International Conference on Fuzzy Systems* pp. 1845–1852. 2-4 de maio, Sofia, Bulgaria.
- Motorola (1997), ‘Mpx5010 séries, integrated silicon pressure sensor’. Último acesso, 26-05-2010.
*<http://www.datasheetcatalog.org/datasheet/motorola/MPX5010GS.pdf>
- Ogata, Katsuhiko (2003), *Engenharia de Controle Moderno*, 4ª edição, Prentice-Hall.
- Orjuela, Rodolfo, Benoît Marx, José Ragot & Didier Maquin (2008a), ‘Proportional-integral observer design for nonlinear uncertain systems modelled by a multiple model approach’, *47th IEEE Conference on Decision and Control* pp. 3577–3582. 9-11 de dezembro, Cancun, México.
- Orjuela, Rodolfo, Benoît Marx, José Ragot & Didier Maquin (2008b), ‘State estimation for non-linear systems using a decoupled multiple model’, *International Journal of Modelling, Identification and Control* **4**(1), 59–67.
- Paiva, Rui Pedro Pinto Carvalho (1999), Identificação neuro-difusa, aspectos de interpretabilidade, Dissertação de mestrado, Faculdade de Ciências e Tecnologia, Universidade de Coimbra, Coimbra, Portugal.
- Quanser (2010), ‘Universal power module, 1503,1506,2405,2405-pwm, user manual’. Último acesso, 29-05-2010.
*http://www.quanser.com/english/downloads/solutions/UPM_UserManual.pdf

- Rezende, J. A. D. & André Laurindo Maitelli (1999a), 'Um esquema de neurocontrole com treinamento em tempo real aplicado ao posicionamento de um servomotor', *Simpósio Brasileiro de Automação Inteligente* . 8-10 de setembro, São Paulo, Brasil.
- Rezende, J. A. D. & André Laurindo Maitelli (1999b), 'Um estudo comparativo entre diferentes técnicas de otimização do treinamento de neurocontroladores', *IV Congresso Brasileiro de Redes Neurais* . 22-29 julho, São José dos Campos (SP), Brasil.
- Rodrigues, Marconi Câmara (2006), Técnicas inteligentes híbridas para o controle de sistemas não lineares, Dissertação de mestrado, Universidade Federal do Rio Grande do Norte, Natal, RN.
- Rodrigues, Marconi Câmara, Fábio Meneghetti U. Araújo & André Laurindo Maitelli (2009), 'Neuro-fuzzy control of nonlinear systems - application in a ball and beam system', *6th International Conference on Informatics in Control, Automation and Robotics* . 4-5 de julho, Milão, Itália.
- Smith-Murray, Roderick & T. A. Johansen (1997), *Multiple Model Approaches to Modeling and Control*, 1ª edição, CRC Press.
- Sugeno, M. & G. T. Kang (1988), 'Structure identification of fuzzy model', *Fuzzy Sets Systems*. **28**(1), 15–33.
- Tafti, Abdolreza Dehghani & Nasser Sadati (2009), 'Fuzzy clustering means data association algorithm using an adaptive neuro-fuzzy network', *Aerospace Conference* pp. 1–5. 4-8 de outubro, Nova York, EUA.
- Takagi, T. & M. Sugeno (1985), 'Fuzzy identification of systems and its applications to modeling and control', *IEEE Transactions on Systems, Man, and Cybernetics* **SMC-15**, 116–132.
- Uppal, Faisal J., Ron J. Patton & Marcin Witczak (2003), 'A hibrid neuro-fuzzy and de-coupling approach applied to the damadics benchmark problem', *IFAC Fault Detection, Supervision and Safety of Technical Processes* pp. 957–962. Junho de 2003, Washington, EUA.
- Uppal, Faisal J., Ron J. Patton & Marcin Witczak (2006), 'A neuro-fuzzy multiple-model observer approach to robust fault diagnosis based on the damadics benchmark problem', *Control Engineering Practice* **14**, 699–717.
- Venkat, Aswin N., P. Vijaysai & Ravindra D. Gudi (2003), 'Identification of complex nonlinear processes based on fuzzy decomposition of the steady state space', *Journal of Process Control* (13), 473–488.
- Vinsonneau, B., D.P. Goodall & K.J. Burnham (2005), 'Extended global total least square approach to multiple-model identification', *16th IFAC World Congress* . 4-8 de julho, Praga, República Tcheca.

- Wengang, Ji, Lou Yu, Dai Fengyan & Cao Jianshu (2008), 'Research on constant-tension control based on fuzzy multiple models', *International Symposium on Computational Intelligence and Design* pp. 112–115. 17-18 de outubro, Hubei, China.
- WenNa, Li, Wang PeiFeng & Li Yang (2009), 'A method of adaptive colored noise cancellation based on anfis', *International Conference on Image Analysis and Signal Processing* pp. 386–388. 11-12 de abril, Linhai, China.
- Xie, Hui, Fei Ma, Huifang Fan & Yanqiang Di (2009), 'Prediction of refrigerant mass flow rates through capillary tubes using adaptive neuro-fuzzy inference system', *World Congress on Computer Science and Information Engineering* **4**, 769–774. 31 de março - 2 de abril, Los Angeles, EUA.
- Yager, Ronald R. & Dimitar P. Filev (1992), 'Approximate clustering via the mountain method', *IEEE Transactions on Systems, Man, and Cybernetics* **24**(8), 1279–1284.
- Yager, Ronald R. & Dimitar P. Filev (1993), 'Learning of fuzzy rules by mountain clustering', *Proc. SPIE Conf. on Applications of Fuzzy Logic Technology* **2061**, 246–254.
- Yang, Xuhua, Huaping Dai & Youxian Sun (2003), 'A hybrid modeling method based on mechanism analysis, identification and rbf neural networks', *Systems, Man and Cybernetics, 2003. IEEE International Conference* **2**, 1310–1315. 5-8 de outubro, Washington, EUA.
- Zhai, Jianfeng, Jianyi Zhou, Lei Zhang, Jianing Zhao & Wei Hong (2009), 'The dynamic behavioral model of rf power amplifiers with the modified anfis', *IEEE Transactions on Microwave Theory and Techniques* **57**(1), 27–35.
- Zhang, X., A. Visala, A. Halme & P. Linko (1994), 'Functional state modelling approach for bioprocesses', *J. Process Control* **4**(3), 127–134.

Apêndice A

Custo do Sistema de Nível

O sistema de nível desenvolvido é constituído por vários componentes. O custo dos componentes para montar este sistema está na tabela abaixo,

Tabela A.1: Custo dos componentes que compõem o sistema de tanque.

Componente	Custo (R\$)
Tanque em acrílico	240,00
Sensor de pressão Motorola	60,00
Bomba de água	70,00
Placa de aquisição da National Instruments	1000,00
Parafusos de Tec-new (vazão do tanque)	50,00
Reservatório externo 11L	20,00
Mangueira para alimentação	3,00
Régua 50 cm	0,50
Regulador de tensão SD7805	2,50
Protoboard 840 pinos	20,00