

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
DEPARTAMENTO DE MECÂNICA COMPUTACIONAL

Detecção e Diagnóstico de Falhas em Sistemas Dinâmicos Utilizando Redes Neurais e Lógica Nebulosa

por *Belisário Nina Huallpa*
Orientador : Eurípedes Guilherme de Oliveira Nóbrega
Co-orientador : Fernando José Von Zuben

69/99

ESTE EXEMPLAR CORRESPONDE A REDAÇÃO FINAL DA
TESE DEFENDIDA POR *Belisário Nina Huallpa*
E DEFENDIDA PELA

COMISSÃO JULGADORA EM 01.06.1999

Fernando José Von Zuben
CO-ORIENTADOR



**UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
DEPARTAMENTO DE MECÂNICA COMPUTACIONAL**

Detecção e Diagnóstico de Falhas em Sistemas Dinâmicos Utilizando Redes Neurais e Lógica Nebulosa

Autor : Belisário Nina Hualpa
Orientador : Eurípedes Guilherme de Oliveira Nóbrega
Co-orientador : Fernando José Von Zuben

Curso: Engenharia Mecânica
Área de Concentração: Projeto Mecânico

Tese de Doutorado apresentada à comissão de Pós Graduação da Faculdade de Engenharia Mecânica, como requisito para a obtenção do título de Doutor em Engenharia Mecânica.

Campinas, 1999
S.P. - Brasil

UNIDADE	OC
N.º CHAMADA:	T/UNICAMP
	N62d
V.	Ex.
TOMBO BC/	41102
PROC.	278/00
C	<input type="checkbox"/>
D	<input checked="" type="checkbox"/>
PREÇO	R\$ 11,00
DATA	15-06-00
N.º CPD	

CM-00142444-9

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

N62d Nina Huallpa, Belisário
Detecção e diagnóstico de falhas em sistemas
dinâmicos utilizando redes neurais e lógica nebulosa /
Belisário Nina Huallpa.--Campinas, SP: [s.n.], 1999.

Orientadores: Eurípedes Guilherme de Oliveira
Nóbrega, Fernando José Von Zuben.

Tese (doutorado) - Universidade Estadual de
Campinas, Faculdade de Engenharia Mecânica.

1. Redes neurais (Computação). 2. Sistemas difusos.
3. Localização de falhas (Engenharia). 4. Identificação
de sistemas. 5. Estimativa de parâmetro. I. Nóbrega,
Eurípedes Guilherme de Oliveira. II. Zuben, Fernando
José Von . III. Universidade Estadual de Campinas.
Faculdade de Engenharia Mecânica. IV. Título.

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
DEPARTAMENTO DE MECÂNICA COMPUTACIONAL

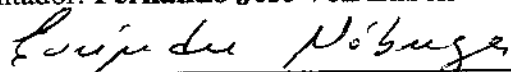
TESE DE DOUTORADO

Deteccção e Diagnóstico de Falhas em
Sistemas Dinâmicos Utilizando
Redes Neurais e Lógica Nebulosa

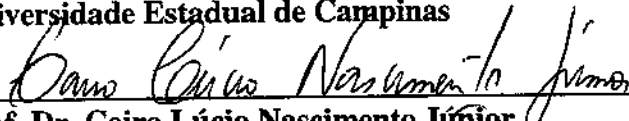
Autor : **Belisário Nina Huallpa**

Orientador: **Eurípedes Guilherme de Oliveira Nóbrega**

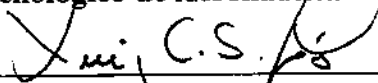
Co-orientador: **Fernando José Von Zuben**



Prof. Dr. Eurípedes Guilherme de Oliveira Nóbrega, Presidente
Universidade Estadual de Campinas



Prof. Dr. Cairo Lúcio Nascimento Júnior
Instituto Tecnológico de Aeronáutica



Prof. Dr. Luiz Carlos Sandoval Góes
Instituto Tecnológico de Aeronáutica



Prof. Dr. Robson Pederiva
Universidade Estadual de Campinas



Prof. Dr. José Roberto de França Arruda
Universidade Estadual de Campinas

Campinas, 01 de Junho de 1999

Dedicatória

Dedico este trabalho aos meus pais, professores, amigos e a todas as pessoas que serviram como estímulo ao longo do desenvolvimento do trabalho.

Agradecimentos

Este trabalho foi desenvolvido na Universidade Estadual de Campinas, na Faculdade de Engenharia Mecânica, nos Laboratórios do Departamento de Mecânica Computacional; e contou com a preciosa ajuda de muitas pessoas. Sou profundamente grato a todos os que, direta ou indiretamente, contribuíram para sua realização. Em particular, quero agradecer:

Ao professor Eurípedes Nóbrega, pela orientação, oportunidade de trabalharmos juntos e confiança depositadas.

Ao professor Fernando José Von Zuben, que além de ser co-orientador, foi um parceiro nas diversas atividades, assim como ofereceu sua amizade incondicional.

Ao professor José Roberto Arruda pelo estímulo, esclarecimentos e amizade que influenciaram muito na minha formação.

A todos os professores do Departamento de Mecânica Computacional e também aos professores da Faculdade de Engenharia Elétrica e do Instituto da Matemática e Estatística, pela amizade e pelas oportunidades de discussões abertas.

Aos amigos Khaled, Eder, Fernando, João, André, Lázaro, Walter, Brandão, Sandra, Selma e a todos os colegas do departamento pela amizade e estímulo, em especial ao Allan com quem compartilhei, no Laboratório, dois finais de ano e vários feriados.

A Luiz Felipe, Cristina, toda a minha família e amigos em geral pelo incentivo e carinho ao longo desses anos.

Aos funcionários do Departamento e da Faculdade de Engenharia Mecânica, pela cooperação.

Ao CNPq e FAEP-UNICAMP pelo apoio financeiro no desenvolvimento e divulgação científica deste trabalho, assim como à Faculdade de Engenharia Mecânica .

“What makes society turn is science, and the language of science is mathematics...”
Bart Kosko

*“And so far as the laws of mathematics refer to reality, they are not certain. And so far as they
are certain , they do not refer to the reality...”*
Albert Einstein

Sumário

Agradecimentos.....	iv
Resumo.....	xiii
Abstract.....	xiv
Lista de Figuras.....	xv

CAPÍTULO 1

Introdução	1
1.1 Definição de falha nos sistemas dinâmicos	1
1.2 Funções básicas do processo de supervisão.....	2
1.3 Sistemas de detecção e diagnóstico por redundância física.....	3
1.4 Sistemas de diagnóstico por redundância analítica	3
1.5 Tipos de perturbações	6
1.5.1 Perturbações aditivas	6
1.5.2 Perturbações multiplicativas	7
1.6 Métodos de diagnóstico de falhas baseados no modelo matemático.....	7
1.6.1 Diagnóstico de falhas por estimação de parâmetros	7
1.6.1.1 Método do erro no equacionamento	8
1.6.1.2 Método do erro na saída.....	8
1.6.2 Diagnóstico de falhas por estimação de variáveis de estado e observadores	9
1.6.3 Diagnóstico de falhas via equações de paridade.....	10

1.6.3.1 Método do erro no equacionamento	10
1.6.3.2 Método do erro na saída.....	10
1.7 Sistemas de diagnóstico baseados em conhecimento	11
1.7.1 Sistemas especialistas	12
1.7.2 Lógica nebulosa	13
1.7.3 Redes neurais artificiais	15
1.7.4 Algoritmos genéticos	16
1.8 Métodos híbridos	17
1.9 Algumas aplicações práticas.....	18
1.10 Motivação e proposta do trabalho.....	18
1.11 Organização do texto	20

CAPÍTULO 2

Conceitos básicos de redes neurais artificiais	21
2.1 Redes neurais artificiais	21
2.1.1 Redes neurais estáticas.....	22
2.1.2 Redes neurais dinâmicas.....	24
2.1.2.1 Redes neurais com dinâmica externa.....	24
2.1.2.2 Redes neurais com dinâmica interna	25
2.2 Rede de Hopfield	27
2.2.1 Modelo da rede neural de Hopfield com funções de saída de dois estados.....	28
2.2.2 Modelo da rede neural de Hopfield com funções de saída contínuas.....	30
2.3 Utilização da Rede de Hopfield na estimação de parâmetros do modelo de estado.....	33
2.4 Estimação de parâmetros	34

CAPÍTULO 3

Metodologia para o diagnóstico de falhas.....	41
--	-----------

3.1 Grafos direcionados e sinalizados.....	41
3.1.1 Tipos de relações	42
3.1.2 Modelagem das falhas de sistemas dinâmicos.....	42
3.1.3 Relação entre parâmetros físicos e parâmetros do modelo de estado.....	44
3.1.4 Propriedades transitivas do GDS	45
3.1.5 Propriedades distributivas do GDS.....	46
3.1.6 Transformação do modelo GDS em regras de inferência.....	47
3.2 Diagnóstico via lógica nebulosa	48
3.2.1 Conjuntos nebulosos	48
3.2.2 Operações com conjuntos nebulosos	52
3.2.3 Lógica nebulosa em sistemas de decisão baseados em regras.....	54
3.2.4 Classificação de padrões	55
3.2.5 Inferência utilizando o operador max-min.....	55
3.2.6 Aplicação da lógica nebulosa no diagnóstico de falhas em sistemas dinâmicos.....	57
3.2.6.1 Definição do conjunto-universo.....	58
3.2.6.2 Definição dos subconjuntos nebulosos	58
3.2.6.3 Determinação das funções de pertinência.....	59
3.2.6.4 Determinação das regras de inferência	59

CAPÍTULO 4

Sistema de detecção e diagnóstico	61
4.1 Diagnóstico de falhas em sistemas dinâmicos	61
4.2 Módulo de estimação de parâmetros do modelo de estado	61
4.2.1 Configuração resultante do módulo de estimação	63
4.2.2 Extensões junto à configuração resultante da rede de Hopfield generalizada.....	65
4.2.2.1 Ajuste das capacitâncias da rede de Hopfield.....	65
4.2.2.2 Ajuste dos coeficientes de inclinação da função de saída dos neurônios	66
4.2.2.3 Emprego de retardo no processo de estimação de parâmetros	68

4.2.3	Implementação do módulo de estimação de parâmetros	71
4.2.3.1	Bloco Matriz P-Q.....	71
4.2.3.2	Processamento algébrico.....	72
4.2.3.3	Rede dinâmica.....	72
4.2.3.4	Ajuste de capacitâncias	72
4.2.3.5	Ajuste de coeficientes de inclinação da função não-linear	73
4.2.3.6	Retardo	73
4.3	Módulo de pré-processamento.....	74
4.3.1	Bloco Diag_0	75
4.3.2	Bloco Diag_1	75
4.3.3	Bloco Eval.....	76
4.3.4	Problemas de ordem de grandeza no bloco Diag_0.....	77
4.4	Módulo de diagnóstico.....	79
4.4.1	Modelagem de falhas de sistemas dinâmicos via grafos direcionados e sinalizados	79
4.4.2	Diagnóstico via lógica nebulosa	82
4.4.2.1	Valores nominais	83
4.4.2.2	Universo de discurso.....	83
4.4.2.3	Subconjuntos nebulosos.....	83
4.4.2.4	Regras nebulosas.....	85
4.4.2.5	Mecanismo de inferência	88
4.4.2.6	Classificação de falhas	89

CAPÍTULO 5

Resultados e discussões.....	91
5.1 Exemplo clássico de um sistema massa-mola-amortecedor	91
5.1.1 Processo de estimação de parâmetros	91

5.1.2	Processo de detecção de perturbações bruscas nos parâmetros do modelo de estado	96
5.1.2.1	Perturbação no parâmetro físico k_1	97
5.1.2.2	Perturbação no parâmetro físico k_2	101
5.1.3	Parâmetro de sensibilidade que regula a aceitação de uma perturbação permanente... ..	103
5.2	Modelagem qualitativa de diagnóstico de falhas permanentes em sistemas dinâmicos utilizando modelos de grafos direcionados sinalizados	105
5.3	Regras de inferência.....	106
5.4	Diagnóstico de falhas permanentes em sistemas dinâmicos utilizando lógica nebulosa	106
5.4.1	Diagnóstico via lógica binária para uma perturbação permanente no parâmetro físico c_1	107
5.4.2	Diagnóstico via lógica binária para uma perturbação permanente no parâmetro físico c_2	109
5.5	Diagnóstico de falhas permanentes em sistemas dinâmicos utilizando lógica nebulosa	110
5.5.1	Desempenho do método de diagnóstico utilizando lógica nebulosa para uma perturbação permanente no parâmetro físico c_1	111
5.5.2	Desempenho do método de diagnóstico utilizando lógica nebulosa para uma perturbação permanente no parâmetro físico c_2	112
5.5.3	Comparação dos métodos de diagnóstico utilizados	112
5.6	Exemplo de um sistema de vibração torcional	114
5.6.1	Modelo de espaço de estado do sistema dinâmico	114
5.6.2	Processo de estimação dos parâmetros do modelo de estado	116
5.6.3	Modelo GDS para o sistema dinâmico da Figura 5.25	116
5.6.4	Construção de regras nebulosas.....	116
5.6.5	Evolução de parâmetros do modelo de estado para uma perturbação permanente no parâmetro c	117

5.6.6	Evolução do sistema de diagnóstico nebuloso para uma perturbação no parâmetro c .	117
5.6.7	Falha no sensor responsável pela medida da variável de estado θ_2 .	119
5.6.8	Evolução da estimação dos parâmetros do modelo de estado para uma perturbação no sensor de medida da variável de estado θ_2 .	119
5.6.9	Evolução do diagnóstico para a perturbação no sensor de medida da variável de estado θ_2 .	119
5.6.10	Evolução do diagnóstico quando existe ausência do sinal no sensor de medida da variável de estado θ_2 .	121
5.6.11	Evolução do diagnóstico na ausência do sinal no sensor de medida da variável de estado θ_2 .	121
5.7	Mudança do ponto de operação de um motor CC: sistema físico real	122
5.7.1	Representação linear do motor CC	122
5.7.2	Simulação de uma falha caracterizada pela mudança do ponto de operação	123
5.7.3	Evolução dos parâmetros do modelo de estado após o processamento	124
5.7.4	Diagnóstico utilizando lógica nebulosa	125
5.7.4.1	Regras de inferência	125
5.8	Identificação de sistemas dinâmicos não-lineares	127
5.8.1	Exemplo do pêndulo simples	127
5.8.2	Exemplo do pêndulo duplo	130
5.9	Comparação entre o estimador neural recursivo e o estimador adaptativo RLS	133

CAPÍTULO 6

Conclusões	135
------------	-----

Apêndice A: Diagnóstico de falhas via identificação de parâmetros	139
---	-----

Apêndice B: Diagnóstico de falhas via equações de paridade	143
Apêndice C: Diagnóstico de falhas via estimação de estados e observadores	147
Apêndice D: Diagnóstico de falhas baseado em conhecimento.....	153
Referências Bibliográficas.....	167
Índice do Autor	181

Resumo

Nina Huallpa, Belisário, *Detecção e Diagnóstico de Falhas em Sistemas Dinâmicos Utilizando Redes Neurais e Lógica Nebulosa*. Campinas, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 1999, Tese (Doutorado).

Métodos de detecção e diagnóstico de falhas têm sido muito estudados ultimamente, como resultado da demanda por sistemas de maior confiabilidade. Neste trabalho, adotam-se métodos de inteligência computacional, em uma configuração que faz uso de redes neurais artificiais e lógica nebulosa para a monitoração de sistemas dinâmicos representados por modelos de estado adequadamente dimensionados. Os parâmetros do modelo de estado são estimados recursivamente utilizando uma rede neural recorrente do tipo Hopfield, à qual foram adicionados mecanismos de otimização. As saídas do estimador são sintomas submetidos a um módulo de pré-diagnóstico, o qual discrimina perturbações nos valores identificados para os parâmetros, detectando a falha. Um terceiro módulo é utilizado para executar o diagnóstico propriamente dito, através de um método de inferência baseado em lógica nebulosa. A base de conhecimento é determinada a partir da interpretação de grafos direcionados e sinalizados, que relacionam os parâmetros físicos aos parâmetros do modelo de estado. Além de simulações em diversos sistemas lineares invariantes no tempo, a configuração foi testada também em sistemas variantes no tempo e com não-linearidades suaves, incluindo sistemas artificiais e do mundo real. Os resultados obtidos permitem concluir que os métodos desenvolvidos podem ser aplicados com sucesso a diversos tipos de sistemas dinâmicos.

Palavras-Chave

Detecção e diagnóstico de falhas, identificação neural, redes neurais recorrentes, lógica nebulosa.

Abstract

Nina Huallpa, Belisário, *Detection and Diagnosis of Faults in Dynamic Systems Using Neural Networks and Fuzzy Logic*. Campinas, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 1999, (PhD) Dissertation.

Fault detection and diagnosis methods have been intensively studied lately, as a result of the demand for systems of greater reliability. In this work, computational intelligence methods were adopted, in a configuration that uses artificial neural networks and fuzzy logic for monitoring dynamic systems represented by state-space models of adequate dimension. The parameters of the model are recursively estimated using a Hopfield-type recurrent neural network, endowed with additional optimization mechanisms. The outputs of the estimator are taken as symptoms submitted to a pre-diagnostic module, in order to establish the nominal reference parameter values. A third module is used to implement the diagnosis itself, based on a fuzzy inference method. The knowledge base is determined by means of a signed directed graph, that represents the relations among the physical parameters and the parameters of the state-space model. Besides several simulations using time-invariant linear systems, the configuration was also tested in the presence of time-varying dynamics and smooth nonlinearities including artificial and real world systems. The results guide to the conclusion that the developed methods can be successfully applied to a wide range of dynamic systems.

Keywords:

Fault detection and diagnosis, recursive identification, recurrent neural networks, fuzzy logic.

Lista de Figuras

1.1 Processo de supervisão	3
1.2 Diagrama esquemático geral de diagnóstico de falhas baseado em modelo	5
1.3 Diagnóstico de falhas por redundância analítica	5
1.4 Perturbações aditivas em um sistema dinâmico	6
1.5 Perturbações multiplicativas em um sistema dinâmico	7
1.6 Método do erro no equacionamento	8
1.7 Método do erro na saída.....	9
1.8 Observadores de estado	9
1.9 Método do erro no equacionamento	10
1.10 Método do erro na saída.....	11
1.11 Sistemas de diagnóstico baseados em conhecimento	12
1.12 Lógica nebulosa e geração de resíduos adaptativos	14
1.13 Identificação e diagnóstico usando lógica nebulosa.....	15
1.14 Detecção de falhas via redes neurais artificiais	16
1.15 Detecção de falhas via algoritmos genéticos	17
2.1 (a) Rede neural multicamada. (b) rede de funções de base radial	23
2.2 Rede neural com dinâmica externa produzida por.....	25
2.3 (a) Rede neural com recorrência total. (b) Rede neural com recorrência parcial	26
2.4 Rede neural de Hopfield: modelo de limiares de dois estados e dinâmica discreta.	27
2.5 Convergência da rede neural de Hopfield para os estados estáveis $(-1,1)$ e $(1,-1)$	29
2.6 Rede neural de Hopfield: modelo de saída contínua e tempo contínuo.....	30
2.7. (a) Função de ativação do neurônio. (b) Função inversa da função de ativação do neurônio. (c) A contribuição da função de saída do neurônio na função energia.....	31

3.1 Representação do GDS	41
3.2 Tipos de relações em um GDS.....	42
3.3 Relações entre parâmetros físicos e parâmetros do modelo de estado	44
3.4 Propriedades transitivas do GDS	46
3.5 Propriedade distributiva.....	47
3.6 Transformação do GDS em regras de inferência: (i) relação positiva, (ii) relação negativa, (iii) relação nula.....	48
3.7 Exemplo de conjuntos clássicos	49
3.8 (a) Conjunto clássico, (b) Conjunto nebuloso	51
3.9 Definição de funções de pertinência.....	51
3.10 Representação tridimensional da operação de interseção: $A = A_x \cap A_y$	53
3.11 Configuração básica de um sistema nebuloso para tomada de decisão.....	55
3.12 Inferência nebulosa segundo Mamdani	56
3.13 Lógica nebulosa no diagnóstico de falhas de sistemas dinâmicos.....	58
3.14 Exemplos do mecanismo de ativação de regras.....	59
4.1 Diagrama geral do sistema de diagnóstico	61
4.2 Estimação de parâmetros do modelo de estado por Rede Neural de Hopfield.....	64
4.3 Comportamento dos pesos sinápticos ao longo do tempo	69
4.4 Comportamento de uma das saídas do estimador neural	71
4.5 Diagrama esquemático do módulo de estimação.....	73
4.6 Módulo de pré-processamento.....	74
4.7 Pré-processamento: (a) Saída do estimador neural, (b) derivada da saída do estimador neural, (c) detecção de perturbações, (d) eliminação de perturbações devido ao estimador neural, (e) detecção de perturbações permanentes (a saída do estimador neural está apresentada em tracedado).	78
4.8 Pré-processamento: normalização logarítmica	79
4.9 Sistema dinâmico massa-mola-amortecedor.....	80
4.10 Modelo qualitativo do sistema.....	82

5.20 Desempenho do diagnóstico, para uma perturbação permanente no parâmetro físico c_2 , utilizando lógica binária.	110
5.21 Desempenho de diagnóstico por lógica nebulosa para uma perturbação permanente no parâmetro físico c_1	111
5.22 Desempenho de diagnóstico por lógica nebulosa para a perturbação permanente no parâmetro físico c_2	112
5.23 Comparação entre os métodos de diagnóstico para a perturbação permanente no parâmetro físico c_1 : lógica binária (--) e lógica nebulosa ().	113
5.24 Comparação entre os métodos de diagnóstico para a perturbação permanente no parâmetro físico c_2 : lógica binária (--) e lógica nebulosa ().	114
5.25 Sistema clássico de vibração torcional	114
5.26 Modelo GDS para o sistema dinâmico da 5.25	116
5.27 Desempenho do estimador de parâmetros do modelo de estado para uma perturbação permanente no parâmetro físico c	118
5.28 Desempenho do diagnóstico nebuloso para uma perturbação no parâmetro c	118
5.29 Falha no instrumento (a) ruído introduzido simulando uma falha no sensor de medida da variável de estado θ_2 , (b) efeito da perturbação na saída do sensor	119
5.30 Efeitos na estimação de parâmetros para uma perturbação que simula uma falha no sensor de medida da variável de estado θ_2	120
5.31 Evolução do sistema de diagnóstico nebuloso para uma perturbação no sensor de medida da variável de estado θ_2	120
5.32 - falha no instrumento: perturbação que simula ausência do sinal no sensor de medida da variável de estado θ_2	121
5.33 Evolução do sistema de diagnóstico nebuloso para a ausência do sinal no sensor de medida da variável de estado θ_2	122
5.34 Modelo linear de um motor CC	122
5.35 Estimação de parâmetros do modelo de estado dado pela equação (5.12)	124

5.36 Desempenho do processo de detecção de perturbação permanente nos parâmetros do modelo de estado do motor CC.....	125
5.37 Desempenho do diagnóstico por lógica nebulosa para a perturbação permanente devido a uma mudança do ponto de operação.....	127
5.38 Pêndulo simples (demonstração do MATLAB).	128
5.39 Parâmetros estimados	129
5.40 Comportamento do parâmetro a_{21} no tempo.....	129
5.41 Comparação entre a saída do sistema dinâmico e a saída do estimador.....	130
5.42 Modelo do pêndulo duplo (demonstração do MATLAB)	130
5.43 Parâmetros estimados do modelo do pêndulo duplo	132
5.44 Comportamento do parâmetro a_{41} no tempo.....	132
5.45 Comparação entre a saída do modelo e a saída do estimador.....	133
5.46 Comparação entre o estimador recursivo neural e estimador adaptativo RLS.....	134

Capítulo 1

Introdução

Neste capítulo são apresentados os conceitos básicos envolvidos em processos de detecção e diagnóstico de falhas em sistemas dinâmicos, incluindo uma descrição dos métodos mais conhecidos e das tendências futuras. Conclui-se apresentando uma breve descrição do conteúdo do presente texto.

1.1 Definição de falha nos sistemas dinâmicos

No geral, dentro do que se entende por *sistemas automatizados*, exige-se que sejam confiáveis, seguros e econômicos. Algumas das funções destes sistemas devem indicar a ocorrência no processo de estados indesejados ou não-permitidos, para propiciar atitudes, de maneira automatizada ou através da intervenção humana, visando evitar paralisações, acidentes ou danos irreversíveis ao processo. Neste sentido, pode-se dizer que uma falha num sistema dinâmico é um desvio não-permitido (fora da condição normal de comportamento) numa das características ou numa das propriedades em pelo menos um dos parâmetros ou variáveis do sistema. Na literatura científica, existe a preocupação em definir alguns conceitos ou termos importantes, que podem ajudar a esclarecer o conceito de falha:

- *Monitoração*: É a ação de *vigiar* de maneira contínua (*on-line*) as variáveis mensuráveis e observáveis do sistema dinâmico. Anomalias no sistema são reconhecidas com algum grau de tolerância, e irão alimentar sistemas de alarme disparados automaticamente ou por um operador, quando for considerado necessário.

- *Proteção automática*: É o processo no qual, em caso de ser detectado um estado de alto risco na monitoração do sistema dinâmico, inicia-se automaticamente uma ação contrária ou reação junto ao processo, de modo a promover a reversão do quadro de risco no sentido de evitar acidentes.
- *Supervisão com diagnóstico de falhas*: Baseados no processo de monitoração do sistema dinâmico, algumas características das variáveis são quantificadas e avaliadas. As informações geradas permitem diagnosticar as possíveis falhas, ponto de partida para a tomada de decisões, visando o funcionamento *saudável* (normal) do sistema dinâmico.

Os dois primeiros itens são necessários em qualquer processo dinâmico, sendo básicos, simples e práticos. Entretanto, eles atuam apenas quando é detectada uma grande variação ou desvio fora dos padrões normais de trabalho. Esta restrição na atuação pode ser desvantajosa e até perigosa em determinadas situações, já que grandezas sujeitas a variações inferiores às consideradas de risco podem produzir consequências indesejadas, como impedir que um sistema opere em condições de menor custo ou menor desgaste. E em geral, o que se quer é a detecção e diagnóstico de eventos de maneira rápida e segura. Assim, o item *supervisão com diagnóstico de falhas* vem ganhando importância por se ocupar com a detecção e diagnóstico imediato de: falhas abruptas; falhas que variam lentamente com o tempo; falhas nos estados transitórios; falhas devido aos componentes do sistema; falhas nos atuadores; e falhas nos sensores. O projeto dos sistemas de detecção e diagnóstico envolve uma série de detalhes que devem ser considerados. Como foi mencionado, o sistema de diagnóstico deve ser rápido e sensível; porém, o que fazer quando ele responde a qualquer pequena variação, detectando inclusive eventos transitórios ou até eventos falsos? Estas observações mostram o grande interesse em se estudar metodologias de detecção e diagnóstico flexíveis e ao mesmo tempo robustas.

1.2 Funções básicas do processo de supervisão

A Figura 1.1 mostra o diagrama de blocos do processo de supervisão para o diagnóstico. O bloco de monitoração tem a função de indicar as condições físicas do sistema dinâmico, geralmente já submetido a alguma ação de controle. O bloco de diagnóstico tem a função de detectar, isolar e identificar a fonte de falha. Uma vez detectada a fonte de falha, esta informação

é submetida a um processo de avaliação (bloco de avaliação) para que, em seguida, seja tomada uma ação (bloco de decisão) que pode ser caracterizada apenas pela correção de alguns dos sinais de atuação que controlam o sistema dinâmico; ou até, se for necessário, providenciar a possível paralisação do processo quando a falha for julgada de grande risco.

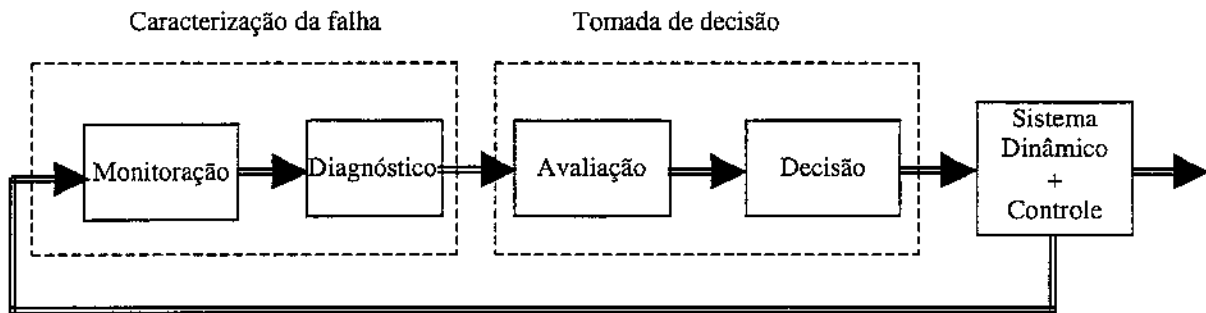


Figura 1.1 Processo de supervisão

1.3 Sistemas de detecção e diagnóstico por redundância física

Os sistemas de detecção e diagnóstico por redundância física consistem no projeto desses sistemas via *hardware*, recorrendo a um número elevado de sensores para a obtenção de informações redundantes, as quais vão permitir o uso de técnicas de correlação na determinação das possíveis falhas. O sistema de detecção e diagnóstico será tanto mais robusto quanto disponha de uma maior quantidade de informações. Porém, isto acarretará em um maior espaço necessário para instalação dos sensores de medida, além de aumentar significativamente o custo do sistema.

1.4 Sistemas de diagnóstico por redundância analítica

Com o constante progresso da tecnologia digital, a literatura internacional mostra a importância de substituir ou complementar a redundância física pela redundância analítica ou redundância via “software”, a qual consiste em representar o sistema dinâmico através de um modelo matemático que permita obter resultados semelhantes ou melhores aos obtidos utilizando a redundância física, porém com menor número de medições. No geral, as informações disponíveis são aquelas que são possíveis de serem medidas (informações de entrada/saída). A partir destas informações, pode ser obtido um modelo matemático estático ou dinâmico.

Os modelos estáticos são caracterizados através de uma representação matemática (entrada/saída), onde a saída é descrita apenas como uma função da entrada no mesmo instante de tempo. Esta relação (entrada/saída) pode ser linear ou não-linear.

Os modelos dinâmicos, por sua vez, são expressões de equações diferenciais (dinâmica contínua) ou de diferenças (dinâmica discreta) que representam sistemas em movimento, de maneira que é possível representar o comportamento temporal do sistema num determinado ponto de operação. Na verdade, um sistema dinâmico é caracterizado pelo estado atual das variáveis medidas ou observadas e pela lei de evolução no tempo dessas variáveis, de maneira que para cada estado existe uma única direção (dinâmica contínua) de movimento ou próximo estado (dinâmica discreta).

Além da representação do sistema dinâmico, não se deve esquecer da existência de sensores e atuadores, que podem ser representados também como sistemas estáticos ou sistemas dinâmicos.

As perturbações são sinais alheios à representação padrão do modelo do sistema dinâmico, sendo consideradas sinais indesejados que podem aparecer em qualquer um dos blocos indicados na Figura 1.2 (sistema dinâmico, atuadores e sensores). Para remediar ou atenuar a interferência destes sinais, é necessária a detecção precoce dos mesmos.

Então, a idéia principal é representar através de um modelo matemático um conjunto coerente de blocos apresentados na Figura 1.2. Uma vez determinado o modelo, será possível antecipar os sintomas do sistema na presença de algum evento perturbador. Estes eventos serão submetidos aos padrões de falhas e comparados, permitindo o diagnóstico de falhas. A Figura 1.2 mostra o processo de detecção de falhas baseado em modelo.

Os métodos de diagnóstico de falhas por redundância analítica (Figura 1.3) mais conhecidos são:

- Estimação de parâmetros.
- Observadores de estado.
- Equações de paridade.

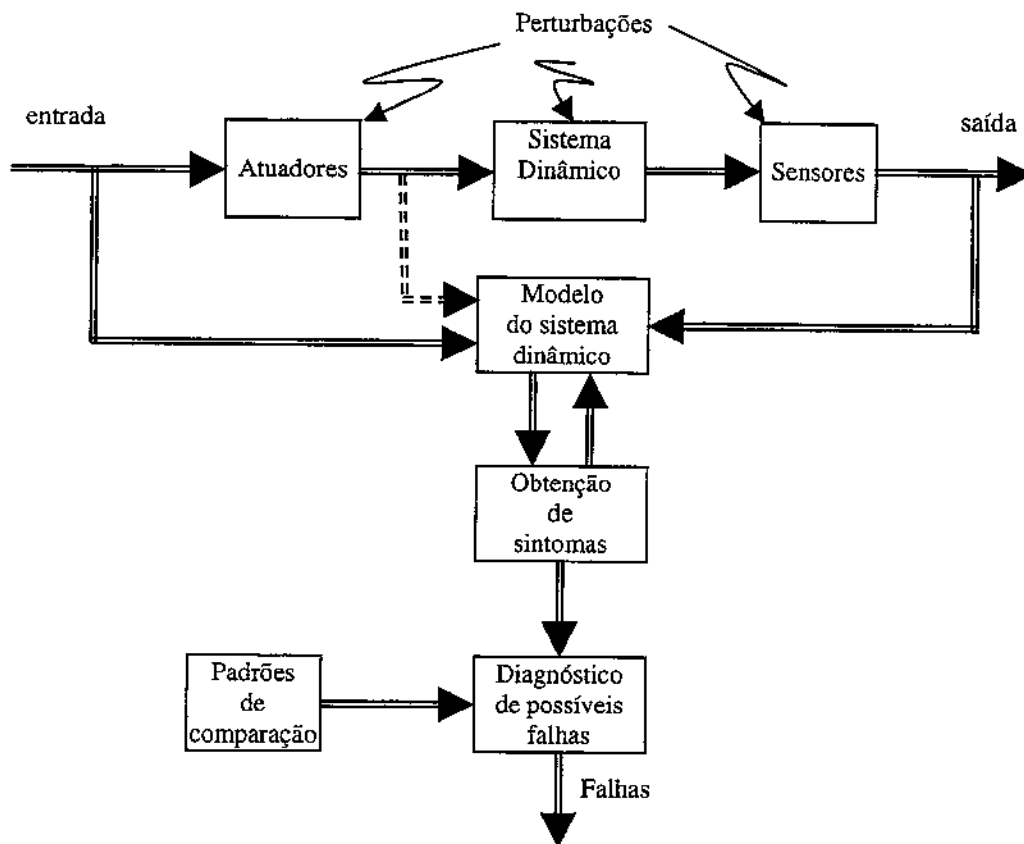


Figura 1.2 Diagrama esquemático geral de diagnóstico de falhas baseado em modelo

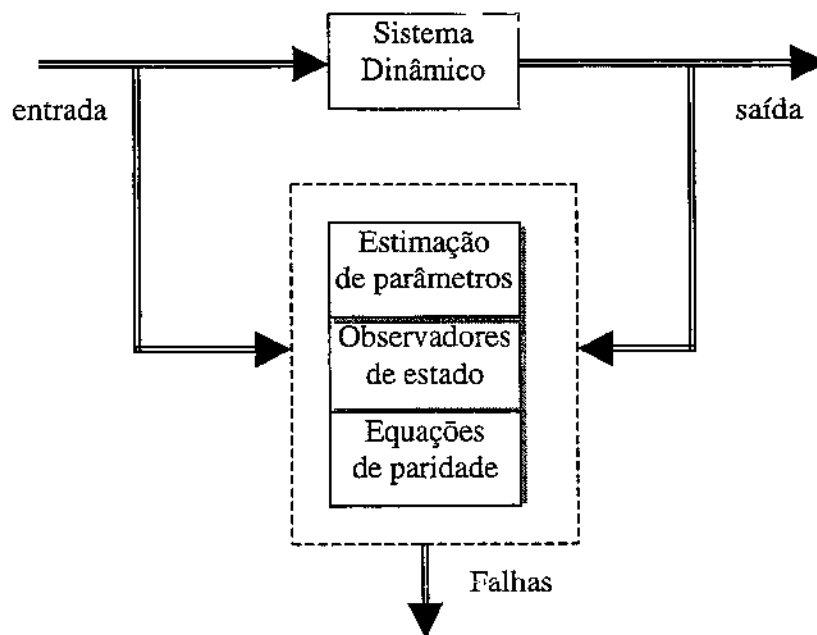


Figura 1.3 Diagnóstico de falhas por redundância analítica

Estes métodos de diagnóstico são utilizados dependendo do tipo de falha que se queira caracterizar e diagnosticar. De maneira geral, as falhas podem ter ocorrido devido aos elementos do próprio sistema, aos sensores ou aos atuadores, como é esquematizado na Figura 1.2. Se a idéia é caracterizar ou detectar falhas devido aos elementos do próprio sistema dinâmico, será conveniente utilizar o método de diagnóstico baseado na estimação de parâmetros; se a idéia é detectar falhas através das variáveis de estado, então, será mais conveniente utilizar observadores ou equações de paridade; e se a idéia é detectar algum tipo de falha específica, será conveniente utilizar filtros dedicados.

1.5 Tipos de perturbações

As perturbações, de acordo com a influência que causam no sistema dinâmico, podem ser classificadas como:

- Aditivas
- Multiplicativas

1.5.1 Perturbações aditivas

As perturbações aditivas são eventos indesejados que podem se apresentar na entrada e/ou na saída do sistema dinâmico. Sua atuação geralmente se dá, no comportamento dos sinais medidos e/ou observados, após um processo de filtragem (processos dinâmicos M e N) como se mostra na Figura 1.4.

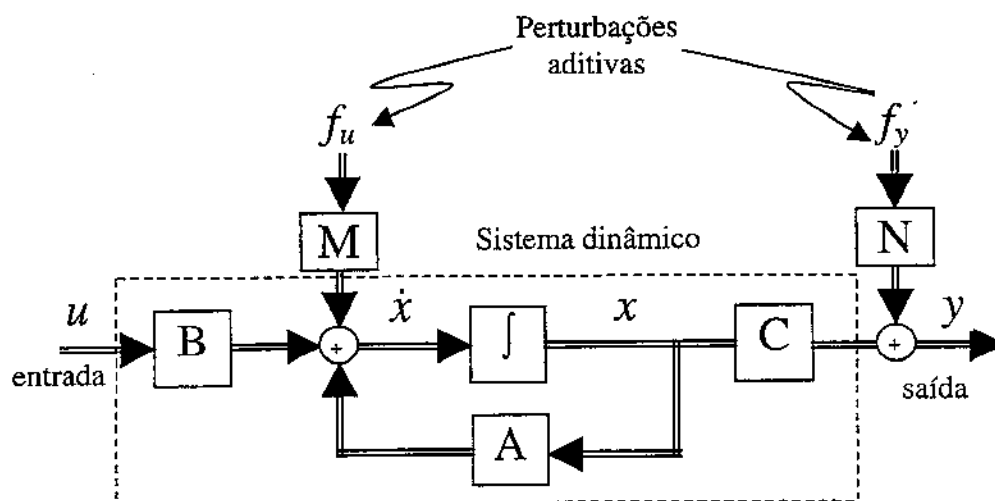


Figura 1.4 Perturbações aditivas em um sistema dinâmico

1.5.2 Perturbações multiplicativas

As perturbações multiplicativas se apresentam quando as mudanças ocorrem nos parâmetros do modelo do sistema dinâmico, isto é, uma perturbação multiplicativa promoverá alterações nos valores dos elementos das matrizes A , B e C , associadas ao modelo matemático do sistema. A representação esquemática deste tipo de perturbação é mostrada na Figura 1.5.




Figura 1.5 Perturbações multiplicativas em um sistema dinâmico

1.6 Métodos de diagnóstico de falhas baseados no modelo matemático

Como foi mencionado no item 1.4, os métodos mais conhecidos são: estimação de parâmetros, observadores de estado e equações de paridade.

1.6.1 Diagnóstico de falhas por estimação de parâmetros

Quando os parâmetros do modelo do sistema dinâmico são desconhecidos, ou conhecidos parcialmente, é apropriada a utilização de métodos de estimação de parâmetros baseados no conhecimento das informações das entradas e das saídas do sistema dinâmico. Os métodos mais conhecidos, utilizando este conceito, podem ser vistos em ISERMANN (1984, 1993), FRANK (1990), GERTLER (1988) e PATTON *et al.* (1989), e podem ser classificados como:

- Método do erro no equacionamento.
- Método do erro na saída.

1.6.1.1 Método do erro no equacionamento

Este método consiste na determinação dos polinômios $\hat{A}(s)$ e $\hat{B}(s)$ (Figura 1.6) através de minimização do *erro*. Na estimação dos polinômios mencionados, as técnicas utilizadas são: o método de quadrados mínimos (“least squares”) e o método de quadrados mínimos recursivos (“recursive least squares – RLS”) (SODERSTRÖM, 1978).

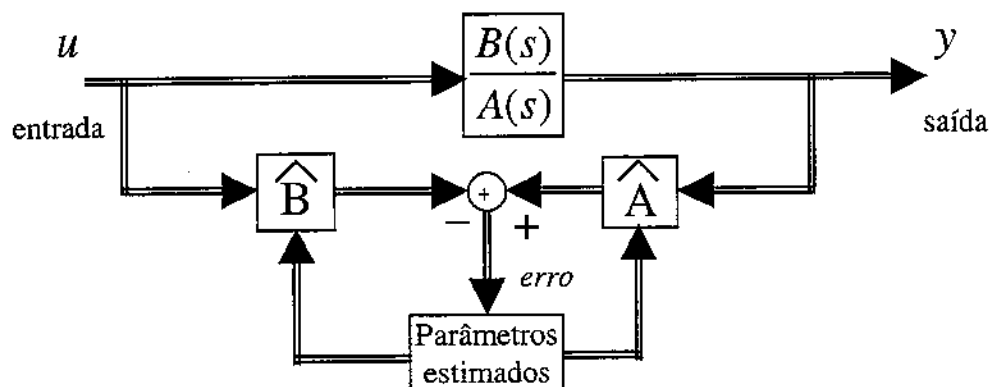


Figura 1.6 Método do erro no equacionamento

1.6.1.2 Método do erro na saída

O método do erro na saída (Figura 1.7) utiliza como *erro* a diferença entre a saída do sistema dinâmico e a saída do modelo estimado. O fundamento é semelhante ao método do erro no equacionamento, isto é, minimizar o erro visando estimar os parâmetros do modelo; porém esta minimização é baseada em métodos iterativos de otimização numérica, o que permite que este método seja também utilizado quando o sistema dinâmico apresenta não-linearidades.

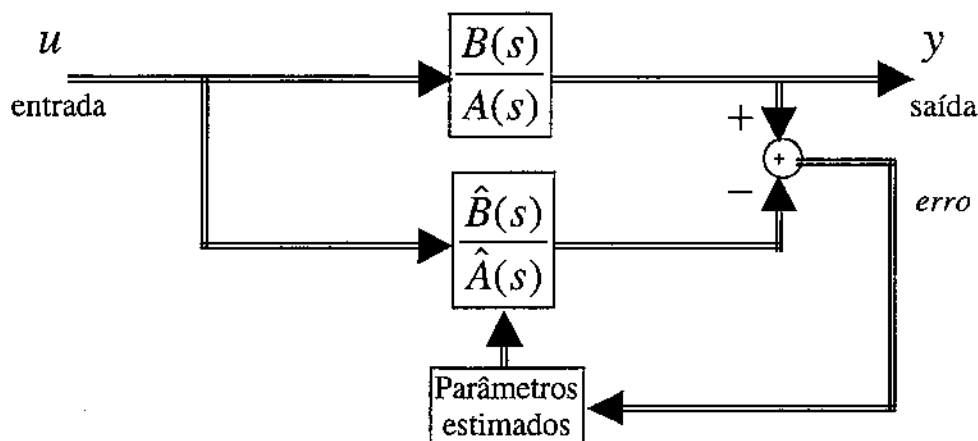


Figura 1.7 Método do erro na saída

1.6.2 Diagnóstico de falhas por estimação de variáveis de estado e observadores

Na utilização desta metodologia, assumem-se conhecidos os parâmetros do sistema dinâmico (matrizes A , B , C da Figura 1.8). Os observadores de estado são utilizados para reconstruir ou estimar as variáveis de estado de difícil acesso ou não mensuráveis (LUENBERGER, 1971). Para ser um observador estável, é necessário projetar adequadamente a matriz de realimentação H da Figura 1.8.

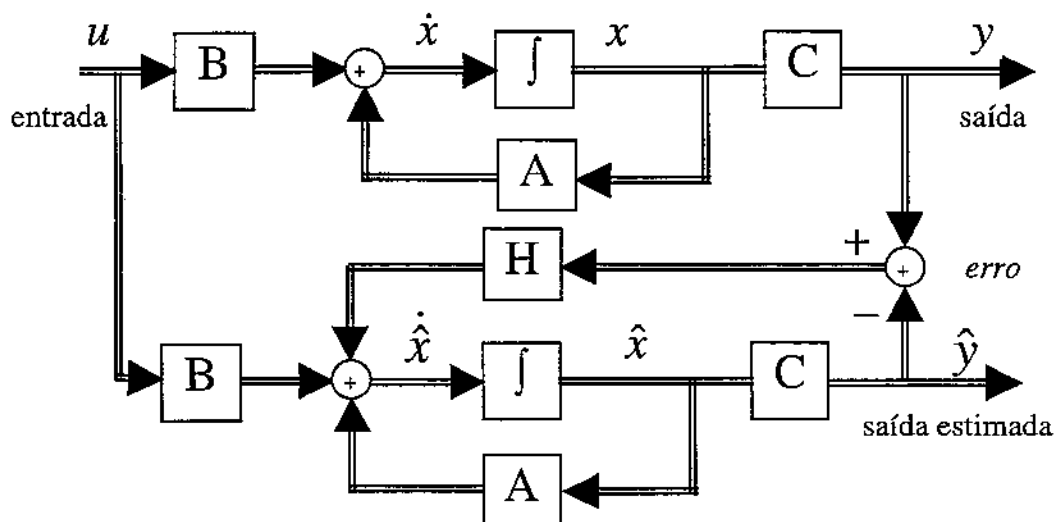


Figura 1.8 Observadores de estado

Fica evidente que esta técnica consiste na obtenção de um modelo para o sistema dinâmico, e comparando a saída do modelo com a saída medida do sistema, é obtido o resíduo (veja apêndice C), o qual é submetido a uma análise posterior (CLARK, 1978; FRANK 1990; MELO, 1998).

1.6.3 Diagnóstico de falhas via equações de paridade

Este método é baseado na obtenção prévia de um modelo fixo, a ser processado em paralelo com o sistema dinâmico, obtendo-se assim um resíduo. Usando o conceito de relações de paridade, o processo de geração de resíduos é formulado como um problema de otimização do tipo min-max (CHOW & WILLSKY, 1984; GERTLER & SINGER, 1990). Esta técnica é apropriada para falhas do tipo aditiva, isto é, falhas devidas a sensores e atuadores. As metodologias utilizadas podem ser:

- Método do erro no equacionamento
- Método do erro na saída

1.6.3.1 Método do erro no equacionamento

Este método consiste na geração do erro no equacionamento entre $B_M(s)u(s)$ e $A_M(s)y(s)$, como é mostrado na Figura 1.9. Neste método, também é necessário o conhecimento a priori dos polinômios $B_M(s)$ e $A_M(s)$.




Figura 1.9 Método do erro no equacionamento

1.6.3.2 Método do erro na saída

Neste método é necessário o conhecimento a priori da função de transferência do modelo $\frac{A_M(s)}{B_M(s)}$, ficando o modelo disposto em paralelo em relação à função de transferência do sistema dinâmico, de maneira a ser analisado o erro de saída entre o modelo e o sistema, como se mostra na Figura 1.10.




Figura 1.10 Método do erro na saída

Mais informações deste método vide no apêndice B.

1.7 Sistemas de diagnóstico baseados em conhecimento

Este tipo de sistemas de diagnóstico é bastante recente. A característica principal desta metodologia é projetar o sistema de diagnóstico na observação de determinados eventos e correlacionar estes eventos com as fontes de falha observadas em ocasiões anteriores ou adquiridas em tempo de operação. Estes métodos precisam de uma base de conhecimento rica e precisa, baseada na observação de sintomas, nos histogramas e no aprendizado acumulado.

O conhecimento heurístico é fundamentado nas leis físicas e nas leis obtidas através da experiência e validação e principalmente modelos não lineares são difíceis de serem implementados, nestas situações, sistemas de diagnóstico baseado em conhecimento tornam-se adequados (AYOUBI, 1994). Desta maneira, esta metodologia requer um longo período de ajuste do processo de inferência, já que ela será uma combinação de um projeto formal (metodologias clássicas) e de um sistema especialista cuja efetividade dependerá do conhecimento adquirido sobre o sistema dinâmico. Entre os métodos mais comuns de sistemas de diagnóstico baseados em conhecimento (Figura 1.11) encontrados na literatura, pode-se mencionar:

- Sistemas especialistas (geralmente baseados em regras).
- Redes neurais.
- Lógica nebulosa.

Um breve histórico de identificação de falhas baseada em conhecimento é mostrado no apêndice D.

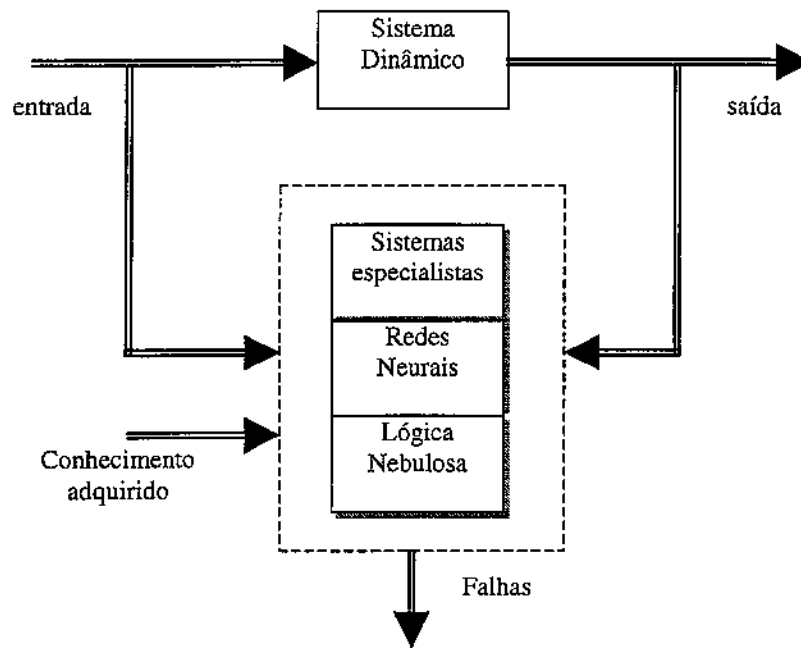


Figura 1.11 Sistemas de diagnóstico baseados em conhecimento

1.7.1 Sistemas especialistas

O diagnóstico de falhas é baseado nos fatos observados ou medidos de diferentes fontes de informação. Geralmente, estes fatos, são conhecidos como *sintomas* do sistema dinâmico ou do processo (FREYERMUTH, 1991), os quais podem ser do tipo numérico, simbólico, estatístico, etc. A representação do conhecimento pode ser feita através de regras (*SE* <antecedente>, *ENTÃO* <consequente>, árvores, redes semânticas, etc.

Os elementos mais importantes de sistemas de detecção e diagnóstico baseados em conhecimento são:

- A base de conhecimentos (fatos e regras).
- A base de dados (informações do estado atual do sistema dinâmico).
- A máquina de inferência (busca direta ou reversa).
- *Frames* de explicação (explicações mais elaboradas).

A representação do conhecimento pode ser feita também através de árvores (LEE *et al.*, 1985) que relacionam os sintomas às causas observadas pelo operador ou especialista. Este procedimento permite visualizar de maneira simples as relações existentes entre sintomas e falhas, que geralmente são traduzidos na forma de regras (IRI *et al.*, 1980, PETTI *et al.*, 1990; KRAMER and PAULOWITCH, 1987).

1.7.2 Lógica nebulosa

A lógica nebulosa é uma extensão da lógica clássica que permite representar a pertinência parcial de um elemento a um conjunto. Fica implícito que esta metodologia nos permitirá representar o conhecimento sobre um sistema ou uma variável de um sistema com um determinado *grau de certeza* ou *grau de possibilidade* que varia entre 0 e 1. Além disso, na linguagem natural, a lógica nebulosa permite representar o raciocínio aproximado com proposições imprecisas (ZADEH, 1965; KLIR & FOLGER, 1988).

Os sistemas de diagnóstico, baseados em modelos utilizados na monitoração e diagnóstico, usualmente geram um erro chamado de resíduo que é resultado da comparação entre o sinal do modelo e o sinal do sistema dinâmico. O resíduo é submetido a um processo de classificação permitindo saber se o sistema está em operação normal ou acusa a existência de alguma falha. Para classificar a situação de um determinado elemento, é necessária a utilização de limiares, os quais são escolhidos usando diferente critérios. Porém, na prática, não existem fronteiras exatas que possam indicar a pertinência do estado da variável que se está observando a um ou a outro conjunto.

Por outro lado, existem situações em que uma dada fonte de falha é reconhecida pelo operador de maneira empírica (sem modelo), apenas pela simples observação e associação de determinados sintomas a determinadas falhas.

Pelas observações expostas acima, a lógica nebulosa é uma ferramenta que se adequa e que pode ser aproveitada de diferentes maneiras: identificação, adequação de níveis de incertezas dos sintomas, diagnóstico.

A identificação de falhas via lógica nebulosa consiste no reconhecimento de padrões que podem ser padrões associados a falhas ou padrões associados ao funcionamento normal do sistema dinâmico. Estes padrões nebulosos são definidos através das funções de pertinência que caracterizam o modelo. O sinal obtido diretamente ou indiretamente do sistema dinâmico será comparado com o modelo nebuloso definido a priori, e a partir desta comparação será feito um julgamento indicando o grau de certeza da existência ou da inexistência de falha.

O modelo nebuloso é representado através de regras do tipo SE <antecedente>, ENTÃO <consequente> que descrevem a relação entre o comportamento de algumas variáveis e as possíveis falhas.

Até o momento, esta metodologia tem sido utilizada de diferentes maneiras. Assim, por exemplo: VACHKOV & MATSUYAMA (1992) utilizam a lógica nebulosa para representar a planta de maneira explícita e comparam diretamente os sintomas da planta com os do modelo. SCHNEIDER & FRANK (1996) e FRANK & DING (1997) (veja Figura 1.12) aplicam a lógica nebulosa para obter um limiar de falha adaptativo. DEXTER (1995) e DEXTER & BENOARTES (1997) utilizam a lógica nebulosa para obter o modelo da planta explicitamente descrevendo os sintomas tanto para operações da planta com falha quanto sem falha (veja Figura 1.13).

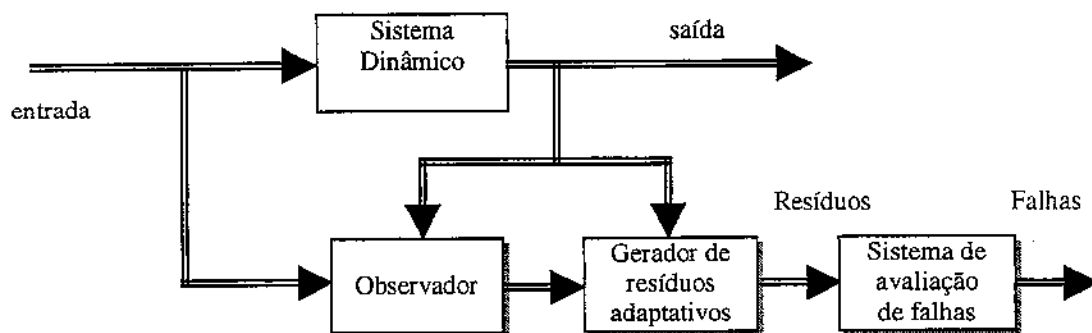


Figura 1.12 Lógica nebulosa e geração de resíduos adaptativos

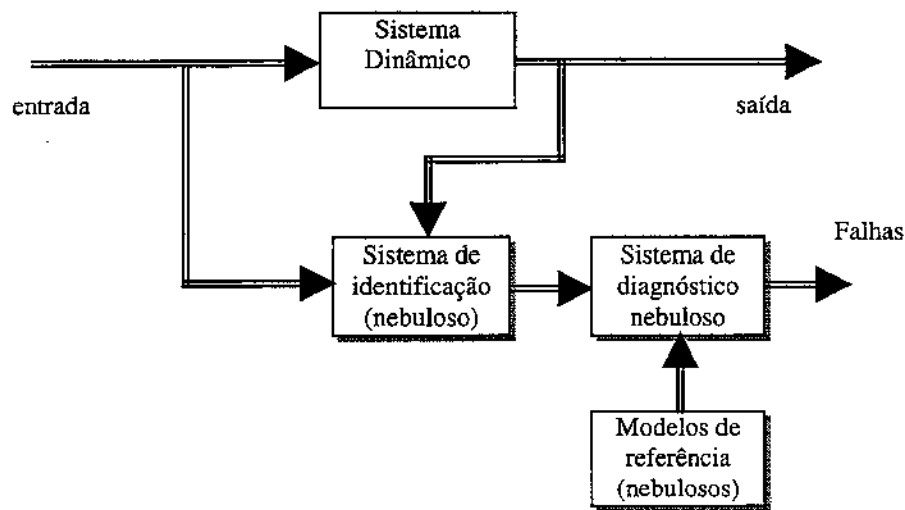


Figura 1.13 Identificação e diagnóstico usando lógica nebulosa

1.7.3 Redes neurais artificiais

As redes neurais artificiais baseiam-se na organização e comportamento fundamental do cérebro. O neurônio artificial imita as características básicas de um neurônio biológico. Essencialmente, cada neurônio representa um processador que é ativado proporcionalmente à soma das entradas ponderadas pelos pesos sinápticos. Estes neurônios podem ser organizados em camadas e são conectados de maneira que as informações se propagam através da rede em direção à saída. Atualmente, existem diferentes arquiteturas, que são escolhidas em função da aplicação dada à rede neural.

Nos últimos anos tem-se utilizado as redes neurais artificiais para representar o conhecimento e reconhecer padrões de falhas em plantas. A idéia é emular o operador, que define relações entre medidas e observações sensoriais (visuais, auditivas ou tato) com as diferentes falhas da planta (Figura 1.14). Em outras palavras, é feito um mapeamento do espaço de sintomas no espaço de decisões relacionado com a existência ou não de falhas.

Arquiteturas de redes neurais de vários tipos foram utilizadas visando a detecção de falhas: HOSKINS *et al.* (1988, 1991) utilizam a rede neural multicamada para diagnóstico em processos químicos simples e complexos, visando mostrar a habilidade de classificação da rede neural na presença de ruído. NAIDU *et al.* (1990) usam uma rede neural multicamada para detectar falhas de sensores em sistemas de controle de processos e comparam com a técnica do erro quadrático de

integral finita além de mostrarem a habilidade da rede neural em capturar características não-lineares e a possibilidade de realizar *treinamento on-line*. SORSA *et al.* (1991, 1993) mostram a capacidade de uma rede neural no diagnóstico de um reator químico, e estudam as diferentes arquiteturas (multicamada, *counterpropagation*, funções de base radial e mapas de Kohonen), concluindo que a arquitetura de uma rede neural multicamada é a mais apropriada. POLYCARPOU & HELMICKI (1995) apresentam uma forma automática de projetar um sistema de detecção e acomodação usando aproximadores *on-line* via redes neurais (redes multicamadas e funções de base radial). MAKI & LOPARO (1997) mostram a utilização de redes neurais multicamadas em fases transitórias dos sistemas, que dependem do tempo. DEMETRIOU & POLYCARPOU (1998) utilizam uma rede neural multicamada para o diagnóstico de falhas incipientes em sistemas dinâmicos. MARCU *et al.* (1997,1998) propõem uma rede neural multicamada dinâmica para a geração de resíduos e uma rede neural multicamada estática para a classificação de falhas.

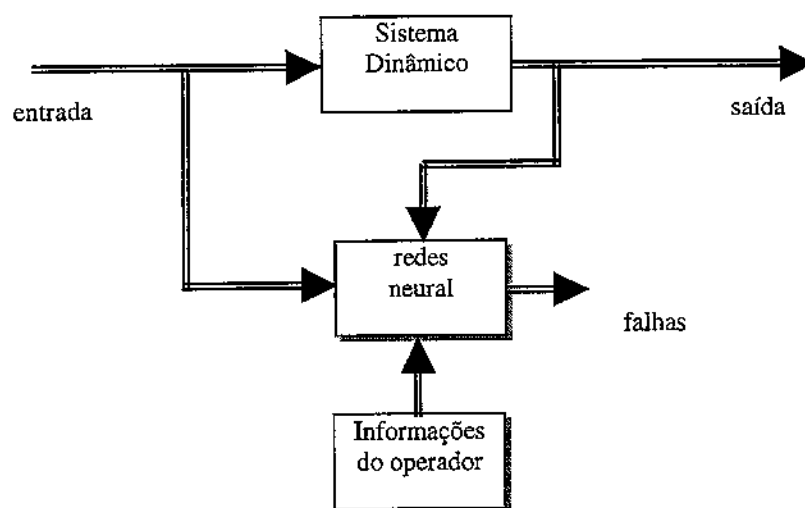


Figura 1.14 Detecção de falhas via redes neurais artificiais

1.7.4 Algoritmos genéticos

Os algoritmos genéticos são técnicas de inteligência artificial inspiradas na teoria da evolução de Darwin. Dado um problema, procura-se uma solução, codificada geneticamente, cuja qualidade é avaliada através de uma função objetivo. O algoritmo gera aleatoriamente uma população inicial de candidatos solução, e após muitas gerações, obtidas através da aplicação de operadores genéticos junto aos indivíduos da população, serão geradas soluções próximas ao esperado.

Os algoritmos genéticos foram pesquisados por biólogos e matemáticos, com ênfase nas décadas de 30 e 60, mas somente em 1975 foram devidamente formalizados por HOLLAND em seu livro *Adaptation in Natural and Artificial Systems*. Desde então, esta ferramenta vem sendo aplicada nos mais diversos problemas de otimização (GOLDBERG, 1989).

Na área de diagnóstico, esta ferramenta é utilizada por PATTON *et al.* (1997) na obtenção de um gerador de resíduos robusto (veja Figura 1.15), otimizando índices que sejam sensíveis à falhas e, ao mesmo tempo, capazes de rejeitar falsos alarmes.

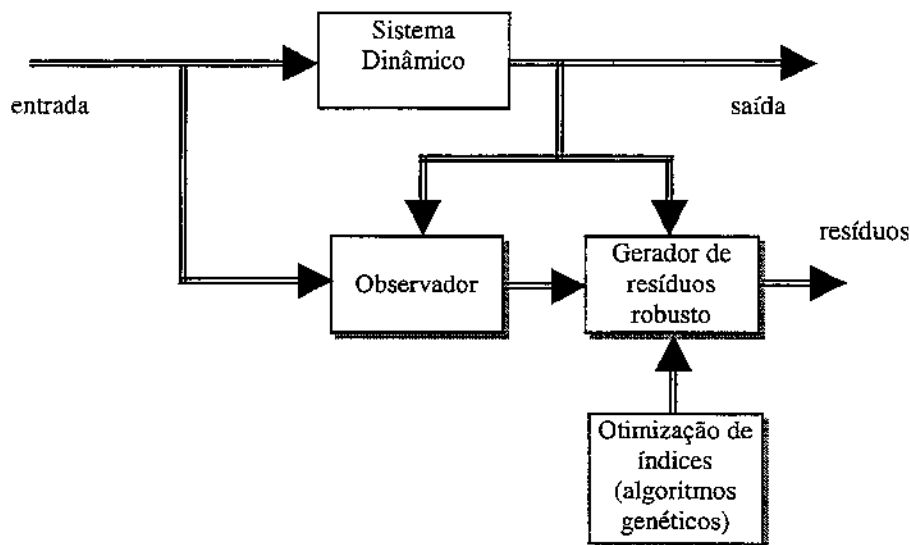


Figura 1.15 Detecção de falhas via algoritmos genéticos

1.8 Métodos híbridos

A tendência dos métodos mais modernos de diagnóstico de falhas é a fusão das diferentes técnicas, bastante exploradas mas pouco eficientes na robustez e aplicabilidade para qualquer planta ou sistema dinâmico. Assim, por exemplo, SCHNEIDER & FRANK (1996) utilizam o observador para a geração de sintomas e a lógica nebulosa para projetar o limiar robusto de decisão. FÜSSEL *et al.* (1997) e CAMINHAS (1997) propõem redes do tipo *neuro-fuzzy*, onde uma falha é tratada como um problema de classificação de padrões.

1.9 Algumas aplicações práticas

A seguir, são apresentados alguns exemplos de aplicações práticas utilizando técnicas baseadas em conhecimento e suas extensões (sistemas especialistas, redes neurais, lógica nebulosa, algoritmos genéticos e métodos híbridos):

- Sistema de diagnóstico para o módulo de injeção de combustível em máquinas de alta velocidade utilizando a teoria nebulosa (PHAM & WU, 1994).
- Detecção de falhas em unidades de ar condicionado utilizando modelos qualitativos em sistemas de ar condicionado (GLASS *et al.*, 1995).
- Diagnóstico de falhas em trocadores de calor de processos químicos utilizando redes nebulosas (BALLE & NELLES, 1997).
- Diagnóstico de falhas em atuadores eletromecânicos usando redes *neuro-fuzzy* (PFEUFER & AYOUBI, 1995).
- Diagnóstico de falhas em sistemas de transporte de calor de reatores químicos usando redes neurais (LEGER *et al.*, 1998).
- Diagnóstico de falhas em um sistema de ar condicionado utilizando lógica nebulosa (DEXTER & BENOURETS, 1997).

1.10 Motivação e proposta do trabalho

Em aplicações da engenharia em geral na última década, o uso de técnicas não convencionais, como redes neurais e a lógica nebulosa, tem se mostrado altamente competitivo e de fácil integração. A combinação ou complementação destas duas ferramentas representam procedimentos poderosos para processar e integrar informações de natureza quantitativa e qualitativa (ZADEH, 1998).

As redes neurais foram utilizadas de diferentes maneiras em problemas de identificação e estimação de sistemas, principalmente as redes estáticas, bastante exploradas por NARENDRA & PARTHASARATHY (1990). Porém, dada a limitação desta arquitetura na identificação de sistemas dinâmicos, foram propostas a utilização de informações passadas de maneira recursiva (LEVIN & NARENDRA, 1995) ou de redes recorrentes dinâmicas (KOSMATOPOULOS *et al.*, 1995; DELGADO *et al.*, 1995, ZHANG & FADALI, 1996). O estudo de redes neurais recorrentes na estimação de

parâmetros de sistemas dinâmicos é recente (CHU *et al.*, 1990; SHOURESHI & CHU, 1993, RAOL, 1995).

Por outro lado, o conhecimento que estabelece o relacionamento entre causa e efeito é uma técnica amplamente explorada no artigo de TZAFESTAS (1989), e a sua utilização em diagnóstico implica racionalidade entre sintomas e falhas através de regras lógicas. Este conhecimento normalmente é adquirido através de observações empíricas e repetitivas no qual o usuário ou o perito poderá contribuir na construção das regras lógicas (ULIERU & ISERMANN, 1993). Uma grande parte deste conhecimento será inexato, impreciso e incerto, permitindo desta maneira fazer uso de técnicas de raciocínio aproximado. Dado o potencial em termos de generalidade, flexibilidade e tolerância na manipulação de informações imprecisas ou incertas encontradas em sistemas de diagnóstico, a lógica nebulosa é uma ferramenta candidata para observar variáveis ou parâmetros que variam em sistemas de diagnóstico.

A proposta deste trabalho é utilizar uma rede neural dinâmica recorrente, baseada na arquitetura de Hopfield, visando a estimação recursiva de parâmetros do modelo de estado. A rede neural é condicionado de maneira a torna-la eficiente na identificação do sistema dinâmico. Para atingir este objetivo são propostos, ajustar ou adaptar parâmetros da rede neural como: os coeficientes da função de saída não-linear da rede neural e um retardo que permita aumentar a probabilidade da estimação desejada. De maneira que a aplicação da rede neural é baseada no modelo do sistema dinâmico, e serão tratados: sistemas lineares estacionários, não-estacionários (sistemas cujos parâmetros variam no tempo), sistemas não-lineares e sistemas do mundo real (bancada experimental de motor DC). Em seguida, os parâmetros estimados são monitorados para detectar mudanças significativas, que são traduzidas na forma de eventos transitórios ou permanentes. As duas etapas anteriores fornecerão informações ao sistema de diagnóstico baseado em raciocínio aproximado via lógica clássica e via lógica nebulosa, e serão realizadas as comparações entre ambas as metodologias de diagnóstico.

1.11 Organização do texto

O trabalho é dividido em 6 capítulos:

- No capítulo em questão, foi realizado um levantamento sobre os conceitos ligados a diagnóstico, também foi feito um levantamento acerca das diferentes estratégias de diagnóstico, clássicas e não-convencionais, assim como as novas tendências.
- No capítulo 2, são estudadas as redes neurais estáticas e dinâmicas. Particularmente, é realizado um estudo sucinto sobre as redes de Hopfield e a sua aplicação na estimação de parâmetros do modelo de estado. São descritas também as contribuições no que diz respeito à otimização de parâmetros da rede neural.
- No capítulo 3, são estudados e adaptados os grafos direcionados e sinalizados que realizam o mapeamento do espaço dos parâmetros do modelo de estado no espaço de parâmetros físicos que compõem a estrutura do sistema dinâmico. A seguir, são estudados os conceitos básicos de lógica nebulosa e a sua aplicação no diagnóstico de falhas de sistemas dinâmicos.
- No capítulo 4, é descrita a implementação de todo o sistema de diagnóstico composto pelo módulo de estimação de parâmetros do modelo de estado, seguido pelo módulo de pré-processamento dos parâmetros estimados, que os condiciona e detecta os eventos permanentes e transitórios, e finalmente o módulo de diagnóstico baseado em lógica nebulosa.
- No capítulo 5, são obtidos e analisados resultados em 4 exemplos: a) Um sistema clássico massa-mola para simulação de falhas em alguns dos parâmetros físicos e análise de desempenho de detecção e diagnóstico do sistema proposto. b) Um sistema de vibração torcional, onde além de se realizarem estudos semelhantes aos do sistema anterior, são realizadas simulações de falhas em sensores. c) Um motor de corrente contínua (experimental) é representado por um modelo linear e estudado mudando o ponto de operação e a maneira como se interpreta o sistema de diagnóstico. d) Os modelos não-lineares de um pêndulo simples e um pêndulo duplo são representados como sistemas variantes no tempo emulando não-linearidades suaves, cujos parâmetros variantes no tempo são estimados pelo estimador neural.
- No capítulo 6, são feitas as considerações e avaliações finais para cada módulo e comentários gerais sobre os resultados obtidos. Após uma análise conclusiva, são apresentadas sugestões para trabalhos futuros.

Capítulo 2

Conceitos básicos de redes neurais artificiais

O propósito deste capítulo é a apresentação de conceitos básicos de redes neurais artificiais e em particular das redes neurais recorrentes, com ênfase nas redes de Hopfield e sua aplicação na identificação de sistemas dinâmicos e estimação de parâmetros do modelo de estado associado.

2.1 Redes neurais artificiais

As redes neurais artificiais são modelos simplificados que são inspirados no neurônio biológico. O modelo inicial, proposto pelo neurofisiologista WARREN MCCULLOCH e pelo estudioso da lógica matemática WALTER PITTS (1943), passou por diversas extensões visando aproximar cada vez mais o comportamento do neurônio biológico. Assim, por exemplo, HEBB (1949) contribuiu com um método de aprendizagem, e ROSENBLATT (1962) propôs uma generalização, batizada de "Perceptron", e provou o teorema de aprendizagem do modelo de MCCULLOCH & PITTS, que até hoje é empregado como o modelo básico de um neurônio artificial. Entretanto, MINSKY & PAPERT (1969) mostraram importantes limitações do Perceptron, na forma como ele vinha sendo empregado, utilizando teoremas matemáticos rigorosos.

Somente após uma década, com o modelo de uma rede neural dinâmica proposto por HOPFIELD (1982), e com o desenvolvimento de um algoritmo de treinamento para um perceptron de múltiplas camadas (RUMELHART *et al.*, 1986) é que foi possível superar as limitações verificadas e reativar a utilização das redes neurais artificiais em aplicações relacionadas com reconhecimento de padrões e otimização (WIDROW & WINTER, 1988; HECHT-NIELSEN, 1990; NARENDRA & PARTHASARATHY, 1990; HUSH & HORNE, 1993).

Algumas características importantes presentes em arquiteturas específicas de redes neurais artificiais, podem ser resumidas como segue:

- Aproximador universal: O perceptron de múltiplas camadas apresenta a capacidade de aproximar arbitrariamente bem qualquer função não linear contínua definida em um universo compacto (HORNIK *et al.*, 1989).
- Processamento paralelo e distribuído: O fluxo de informação em redes neurais artificiais é do tipo paralelo e distribuído, isto é, os neurônios realizam processamento simultâneo e o sinal de saída de cada neurônio é distribuído para outros neurônios através de conexões sinápticas.
- Aprendizagem e generalização: As redes neurais conseguem representar conhecimento pela reação a estímulos e são capazes de estender o conhecimento adquirido inclusive para estímulos diferentes daqueles utilizados no treinamento.
- Representação multidimensional: As redes neurais artificiais são capazes de processar sistemas de múltiplas entradas e múltiplas saídas.

As redes neurais podem ser classificadas, segundo a conectividade, como redes neurais estáticas (não recorrentes) e redes neurais dinâmicas (recorrentes).

2.1.1 Redes neurais estáticas

As redes neurais estáticas caracterizam-se por não terem memória dinâmica (HUSH & HORNE, 1993; WASSERMAN, 1989), no sentido de que as saídas de uma rede neural deste tipo são funções que dependem apenas das entradas atuais e não das entradas ou saídas anteriores. As arquiteturas de redes neurais estáticas mais representativas são as redes do tipo perceptron multicamadas ("multilayer perceptron" (MLP)) e as redes de funções de base radial ("radial basis function network" (RBF)). Na Figura 2.1.a é mostrada a estrutura de uma rede neural multicamada genérica, onde o vetor de entradas alimenta os neurônios da primeira camada, as saídas dos neurônios da primeira camada alimentam os neurônios da segunda camada e assim por diante. Geralmente, a saída de cada neurônio da camada l é conectada a todos os neurônios da camada $l+1$. Na ilustração da Figura 2.1.a, têm-se 4 camadas, com 2 camadas intermediárias (camadas escondidas), sendo que a camada de entrada realiza apenas a distribuição dos sinais de entrada, sem modificá-los, para todos os neurônios da primeira camada escondida. O principal

algoritmo de treinamento para as redes MLP está baseado no processo de retropropagação ou “backpropagation” (RUMELHART *et al.*, 1986). Uma das aplicações mais utilizadas é a classificação de padrões, e foi demonstrado que qualquer função contínua que representa a fronteira de discriminação entre padrões pode ser aproximada por uma rede neural MLP com uma única camada escondida, se houver suficiente quantidade de neurônios (HORNIK *et al.*, 1989).

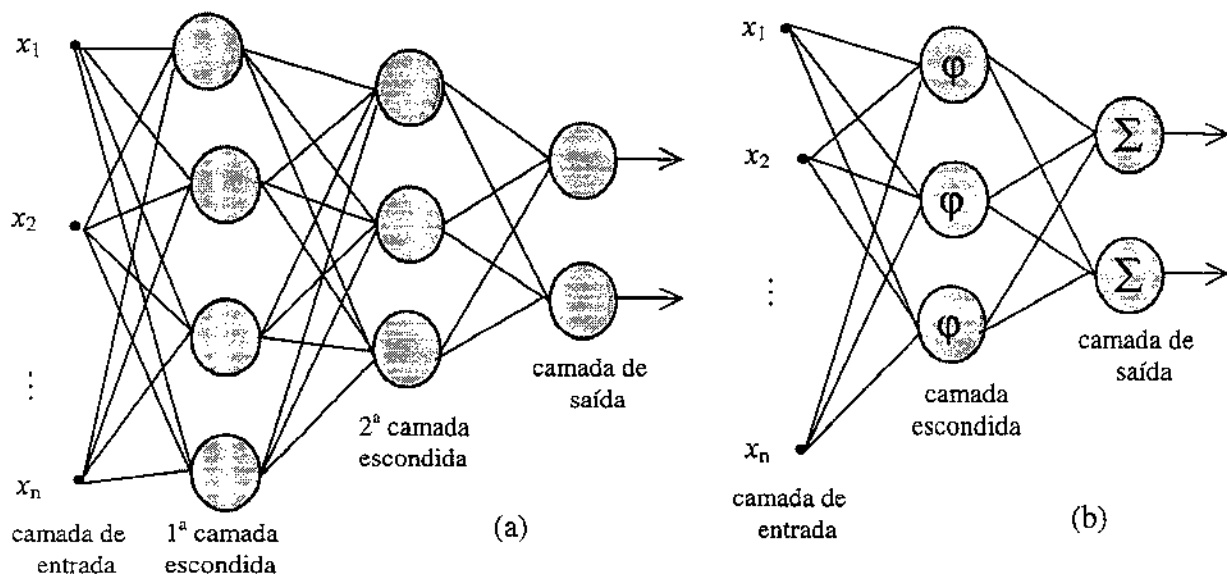


Figura 2.1 (a) Rede neural multicamada. (b) Rede de funções de base radial

As redes neurais de funções de base radial caracterizam-se por terem apenas 3 camadas: uma camada de entrada, uma camada escondida e uma camada de saída (Figura 2.1.b). As saídas da rede RBF produzem uma combinação linear das funções de ativação dos neurônios, avaliadas na camada intermediária. As funções de ativação dos neurônios da camada escondida são funções do tipo gaussiana ou qualquer outra função de base radial, de modo que cada unidade produz uma resposta significativa somente quando os estímulos da entrada estão localizados na região próxima ao centro da gaussiana, isto é, as funções de ativação produzem respostas localizadas, de acordo com os estímulos das entradas.

As principais diferenças entre as redes RBF e as redes MLP são:

- As redes RBF têm uma única camada intermediária, enquanto uma rede MLP pode ter mais de uma camada intermediária.
- Em uma rede RBF, as funções de ativação dos neurônios da camada intermediária são não-lineares e as funções de ativação dos neurônios da camada de saída são lineares. Em redes MLP, as funções de ativação dos neurônios das camadas intermediárias são todas não-lineares, e as funções de ativação dos neurônios da camada de saída podem ser lineares ou não-lineares, dependendo da aplicação.
- Na rede RBF, cada unidade da camada intermediária avalia a distância entre o vetor de entrada e o centro da função de base radial caracterizando a unidade em particular. Na rede MLP, cada unidade avalia o produto interno entre o vetor de entrada e o vetor de pesos sinápticos associado (HAYKIN, 1999).

2.1.2 Redes neurais dinâmicas

As redes neurais dinâmicas, também conhecidas como redes recorrentes, têm a capacidade de processar informações do tipo espaço-temporal. As equações da rede neural dinâmica são descritas por equações diferenciais ou por equações de diferenças .

2.1.2.1 Redes neurais com dinâmica externa

As redes MLP podem emular as redes dinâmicas utilizando os atrasos de extensão finita dos sinais de entrada e saída (NARENDRA & ANNASWAMY, 1989).

Na Figura 2.2, observa-se que a saída $y(k+1)$ é uma função das saídas anteriores $y(k)$, $y(k-1)$, ..., $y(k-n)$, da entrada $x(k)$ e das entradas em instantes anteriores, $x(k-1)$, ..., $x(k-m)$. Isto é,

$$y(k+1) = f(x(k), x(k-1), \dots, x(k-m), y(k), \dots, y(k-n)) \quad (2.1)$$

conhecida também como "time delay neural network (TDNN)" e bastante explorada por NARENDRA & PARTHASARATHY (1990) na identificação de sistemas dinâmicos não-lineares de diversos tipos.

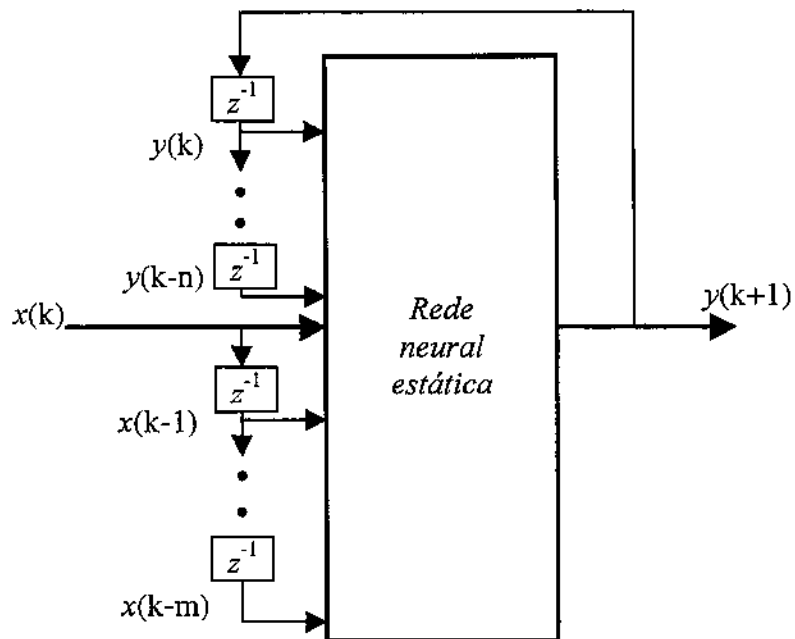


Figura 2.2 Rede neural com dinâmica externa produzida por linhas de atraso dos sinais de entrada e saída.

O número de atrasos é função das características dinâmicas do sistema, podendo ser determinado a partir de métodos de estimação da ordem da dinâmica do sistema (LJUNG, 1987; ROLAIN *et al.*, 1997). Pode-se observar que, caso as funções de ativação sejam lineares, a TDNN é equivalente a um filtro linear digital de resposta infinita (tipo IIR).

Uma outra maneira de representar redes neurais dinâmicas é através do emprego de realimentações internas, gerando dispositivos de memória interna.

2.1.2.2 Redes neurais com dinâmica interna

As redes neurais com dinâmica interna podem ser representadas através da formulação por espaço de estados, na forma:

$$\begin{aligned} z(k+1) &= f(z(k), x(k)), \quad z(0) \text{ dado} \\ y(k) &= g(z(k), x(k)) \end{aligned} \quad (2.2)$$

onde $z(k)$ e $x(k)$ são o estado interno e a entrada da rede dinâmica respectivamente; as funções $f(\cdot)$ e $g(\cdot)$, podem ser funções lineares ou não lineares dependendo das funções de ativação adotadas

para os neurônios. De acordo com a equação (2.2), não há a necessidade de entradas e saídas compondo uma linha de derivação de atrasos na definição da próxima saída, conseqüentemente existirá uma redução no espaço de dados de entrada. De acordo com o tipo de recorrência, as redes neurais com dinâmica interna podem ser classificadas como: redes totalmente recorrentes (Figura 2.3.a) ou redes parcialmente recorrentes (Figura 2.3.b). Nas redes neurais totalmente recorrentes, cada neurônio representa um estado interno do modelo (WILLIAMS & ZIPSER, 1989; DRAYE *et al.*, 1996), sendo que esta arquitetura mostrou problemas de instabilidade e convergência lenta no processo de treinamento (TSOI & BACK, 1994). Nas redes neurais com recorrência parcial existem os chamados *neurônios de contexto*, que fazem o papel de memória interna do modelo (ELMAN, 1990). No modelo de Elman, no primeiro estágio, os sinais da camada de entrada e da camada de contexto são propagados em direção à camada de saída; no próximo estágio, a informação obtida na saída dos neurônios da camada intermediária é armazenada nos neurônios de contexto.

O modelo de Elman mostra-se adequado na modelagem de sistemas dinâmicos lineares invariantes no tempo (PHAM & LIU, 1992), podendo também ser estendido para a modelagem de sistemas dinâmicos não-lineares (VON ZUBEN, 1996).




Figura 2.3 a) Rede neural com recorrência total. b) Rede neural com recorrência parcial

2.2 Rede de Hopfield

A rede neural de Hopfield é provavelmente o modelo de rede neural dinâmica mais conhecido (HOPFIELD, 1982; 1984). Esta arquitetura se caracteriza por ser totalmente recorrente e por ter uma única camada, onde todos os neurônios estão interligados, como mostra a Figura 2.4, no caso da dinâmica discreta.

As características mais importantes da rede neural de Hopfield podem ser resumidas como:

- a dinâmica é de natureza assíncrona, similar àquela verificada em neurônios biológicos.
- a matriz de pesos é simétrica.
- pode ser utilizado como memória associativa ou memória endereçável por conteúdo, que consiste em restaurar um padrão armazenado em resposta à apresentação de uma informação incompleta ou informação ruidosa.




Figura 2.4 Rede neural de Hopfield: modelo de limiares de dois estados e dinâmica discreta.

A entrada de cada neurônio provém de duas fontes: as externas (b_1, b_2, \dots, b_n), e a realimentação das saídas dos neurônios (v_1, v_2, \dots, v_n) ponderadas pelos pesos sinápticos ($w_{11}, w_{12}, \dots, w_{nn}$), onde w_{ij} pode ser interpretado biologicamente como a força ou peso de interconexão sináptica entre o neurônio i e o neurônio j (HOPFIELD, 1982).

2.2.1 Modelo da rede neural de Hopfield com funções de saída de dois estados

O modelo original da rede neural de Hopfield, chamado também de modelo de dois estados, pode ser representado como:

$$\begin{aligned} v_j &\rightarrow v_j^0 \text{ se } \sum_{i=1}^N w_{ji} v_i + b_j < U_j, i \neq j \\ v_j &\rightarrow v_j^1 \text{ se } \sum_{i=1}^N w_{ji} v_i + b_j \geq U_j, i \neq j \end{aligned} \quad (2.3)$$

onde U_j é o limiar do neurônio j . Estas duas regras significam que o próximo estado do neurônio j pode ir para o estado "0" ou para o estado "1" dependendo da satisfação ou não da condição de limiar. Neste modelo, as conexões são assumidas simétricas ($w_{ij} = w_{ji}$) e os pesos de auto-realimentação são nulos ($w_{ii} = 0$). Estas condições garantem que, em estado estacionário, a dinâmica da rede de Hopfield apresente apenas pontos fixos.

Hopfield descreve a dinâmica do modelo recorrente em termos de uma função de energia, que depende do estado de interconexão entre os neurônios, do estado de ativação das saídas dos neurônios e dos valores dos pesos sinápticos; ele demonstra que, na medida em que as saídas dos neurônios mudam, a energia decresce monotonicamente até que um mínimo local de energia seja encontrado. Isto pode ser exemplificado, considerando um sistema físico descrito pelo vetor de estados u : Se o sistema tem pontos de equilíbrio u_1, u_2, \dots, u_n e o sistema começa em um estado $u_i + \Delta$, após um tempo finito o sistema convergirá para o estado u_i (HOPFIELD, 1982), onde Δ representa uma pequena perturbação. Isto é, uma rede neural dinâmica é dominada pelos estados estáveis que servem de atratores. Após um tempo finito, a rede convergirá ao atrator mais próximo do estado inicial. Em uma aplicação de memórias endereçáveis por conteúdo, o estado inicial é associado ao "conhecimento parcial" ou ruidoso e o estado final ao "conhecimento total" ou purificado, conceito que pode ser estendido para outras aplicações.

A convergência aos estados estáveis foi demonstrada por HOPFIELD (1984) utilizando a função energia definida como:

$$E = -\frac{1}{2} \sum_{j=1}^N \left(\sum_{\substack{i=1 \\ i \neq j}}^N w_{ji} v_i + b_j \right) v_j \quad (2.4)$$

A variação de energia ΔE , devido à mudança do estado apenas do neurônio j , é dada por:

$$\Delta E = - \left(\sum_{\substack{i=1 \\ i \neq j}}^N w_{ji} v_i + b_j \right) \Delta v_j \quad (2.5)$$

O valor de Δv_j é positivo se e somente se o valor entre parênteses é positivo (equação (2.3)); e Δv_j será negativo se e somente se o valor entre parênteses é negativo. Desta maneira ΔE será sempre negativo garantindo a convergência da rede neural.

A Figura 2.5 (ilustração do comportamento temporal dos estados da rede de Hopfield) apresenta as trajetórias de estados da rede a partir de pontos de partida escolhidos aleatoriamente na vizinhança dos pontos de equilíbrio, ilustrando assim, a convergência da rede de Hopfield aos pontos estáveis ou atratores, localizados em $(-1,1)$ e $(1,-1)$ neste caso particular.




Figura 2.5 Convergência da rede neural de Hopfield para os estados estáveis $(-1,1)$ e $(1,-1)$

A convergência é quase imediata quando os pontos de partida estão próximos dos pontos estáveis, e mais demorada quando os pontos de partida estão nas regiões de maior incerteza, por exemplo, na vizinhança de $(-1,-1)$ e $(1,1)$.

2.2.2 Modelo da rede neural de Hopfield com funções de saída contínuas

Será analisada a seguir a saída de cada neurônio j da rede neural de Hopfield como uma função contínua, monotonicamente crescente, tal que: $v_j \in (v_j^{\min}, v_j^{\max})$ e u_j é tomado como o estado do neurônio j ($j = 1, 2, \dots, n$), veja Figura 2.6, onde a dinâmica é assumida de tempo contínuo. O sinal de saída do neurônio j , dado por v_j , é considerada como o resultado de uma filtragem não-linear aplicada ao estado u_j . As características mais importantes do comportamento desta configuração são mostradas na Figura 2.7, onde a Figura 2.7.a representa a função de ativação contínua e monotonicamente crescente; a Figura 2.7.b, representa a função inversa; e a Figura 2.7.c, a contribuição do neurônio j na função energia da rede.

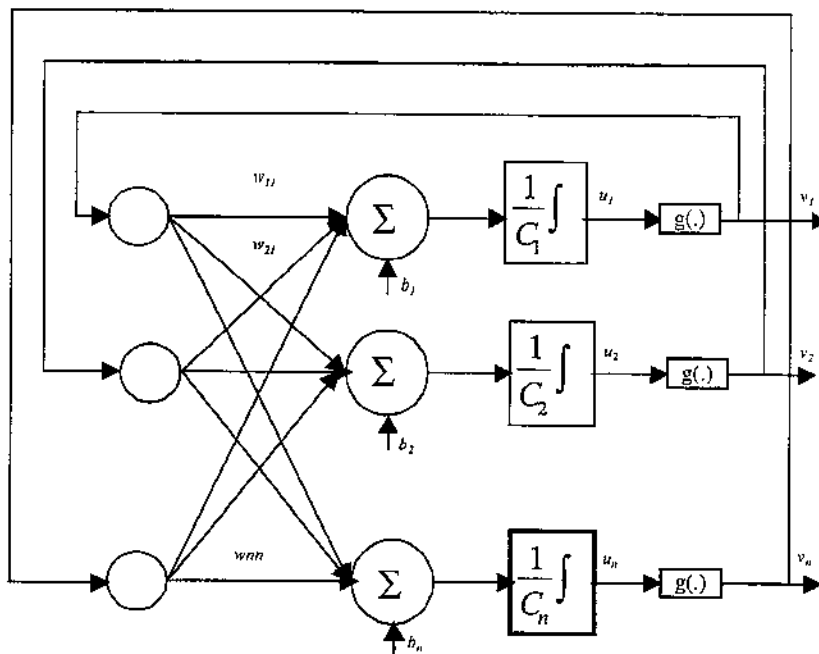


Figura 2.6 Rede neural de Hopfield: modelo de saída contínua e tempo contínuo

O modelo contínuo da rede neural de Hopfield generalizada, proposto pelo próprio HOPFIELD (1984), é dado por:

$$C_j \frac{du_j(t)}{dt} + \frac{u_j(t)}{R_j} = \sum_{i=1}^N w_{ji} v_i + b_j \quad (2.6)$$

e a função de ativação inversa assume a forma:

$$u_j(t) = g_j^{-1}(v_j) \quad (2.7)$$

onde u_j é o estado do neurônio j , v_i é o valor da saída do neurônio i , w_{ji} é o peso de conexão da saída do neurônio i ao neurônio j , b_j é o valor do *bias* no neurônio j , C_j e R_j são os valores da capacitância e da impedância (resistência), respectivamente, associadas ao neurônio j .




Figura 2.7. (a) Função de ativação do neurônio. (b) Função inversa da função de ativação do neurônio. (c) A contribuição da função de saída do neurônio na função energia.

A equação (2.6) pode ser reescrita como:

$$\frac{du_j(t)}{dt} = -\frac{u_j(t)}{C_j R_j} + \frac{1}{C_j} \left(\sum_{i=1}^N w_{ji} v_i + b_j \right) \quad (2.8)$$

Considerando um valor de $C_j R_j$ suficientemente alto, o primeiro termo do segundo membro pode ser desprezado, de modo que a equação (2.8) fica reduzida a:

$$\frac{du_j(t)}{dt} = \frac{1}{C_j} \left(\sum_{i=1}^N w_{ji} v_i + b_j \right) \quad (2.9)$$

É possível analisar a convergência da rede utilizando a função energia da rede de Hopfield, definida como:

$$E_H = -\frac{1}{2} \sum_{j=1}^N \sum_{i=1}^N \frac{1}{C_j} w_{ji} v_i v_j - \sum_{j=1}^N \frac{1}{C_j} b_j v_j \quad (2.10)$$

A variação da energia em relação ao tempo é dada por:

$$\frac{dE_H}{dt} = -\frac{1}{2} \sum_{j=1}^N \sum_{i=1}^N \frac{1}{C_j} w_{ji} \frac{dv_i}{dt} v_j - \frac{1}{2} \sum_{j=1}^N \sum_{i=1}^N \frac{1}{C_j} w_{ji} v_i \frac{dv_j}{dt} - \sum_{j=1}^N \frac{1}{C_j} b_j \frac{dv_j}{dt}$$

utilizando a condição de simetria:

$$\frac{dE_H}{dt} = -\sum_{j=1}^N \sum_{i=1}^N \frac{1}{C_j} w_{ji} v_i \frac{dv_j}{dt} - \sum_{j=1}^N \frac{1}{C_j} b_j \frac{dv_j}{dt}$$

agrupando,

$$\frac{dE_H}{dt} = -\sum_{j=1}^N \left(\sum_{i=1}^N \frac{1}{C_j} w_{ji} v_i \frac{dv_j}{dt} - \frac{1}{C_j} b_j \frac{dv_j}{dt} \right)$$

$$\frac{dE_H}{dt} = -\sum_{j=1}^N \frac{1}{C_j} \left(\sum_{i=1}^N w_{ji} v_i - b_j \right) \frac{dv_j}{dt}$$

Usando a relação dada pela equação (2.9) tem-se:

$$\frac{dE_H}{dt} = -\sum_{j=1}^N \frac{du_j}{dt} \frac{dv_j}{dt} \quad (2.11)$$

Utilizando a equação (2.7) e aplicando a regra da cadeia obtém-se:

$$\frac{du_j}{dt} = \frac{dg_j^{-1}(v_j)}{dv_j} \frac{dv_j}{dt} \quad (2.12)$$

Observa-se que a função $g_j^{-1}(v_j)$ (Figura 2.7. (b)) é monotonicamente crescente, conseqüentemente a função $\frac{dg_j^{-1}(v_j)}{dv_j}$ é sempre positiva. Substituindo a equação (2.12) em (2.11) tem-se,

$$\frac{dE_H}{dt} = -\sum_{j=1}^N \left(\frac{dg_j^{-1}(v_j)}{dv_j} \frac{dv_j}{dt} \right) \frac{dv_j}{dt} = -\sum_{j=1}^N \left(\frac{dg_j^{-1}(v_j)}{dv_j} \right) \left(\frac{dv_j}{dt} \right)^2 \quad (2.13)$$

acarretando que a variação da energia no tempo será sempre negativa, ou nula quando a variação das saídas no tempo também forem nulas.

$$\frac{dE_H}{dt} \leq 0, \quad \frac{dE_H}{dt} = 0 \rightarrow \frac{dv_j}{dt} = 0, \text{ para todo } j \quad (2.14)$$

A equação (2.14) nos mostra que a função energia E_H , definida na equação (2.10), representa uma função de Liapunov da rede neural dinâmica (TANK & HOPFIELD, 1986), cuja evolução no tempo será governada por estados “atratores” e convergirá a um desses estados, conforme já mencionado, denominados pontos fixos da dinâmica.

2.3 Utilização da Rede de Hopfield na estimação de parâmetros do modelo de estado

A rede neural de Hopfield pode ser utilizada na estimação de parâmetros de um modelo de estado de um sistema dinâmico (CHU *et al.*, 1990; SHOURESHI & CHU, 1993; RAOL, 1994, 1995). Esta hipótese é baseada na associação da variação da função energia de Hopfield, dada pela equação (2.10), e uma função objetivo associada à estimação de parâmetros do modelo de estado.

A variação da energia de Hopfield a partir da equação (2.10) com relação às suas saídas não lineares é dada por:

$$\frac{\partial E_H}{\partial v_j} = -\sum_{i=1}^N \frac{1}{C_j} w_{ji} v_i - \frac{1}{C_j} b_j$$

de onde,

$$\frac{\partial E_H}{\partial v_j} = -\frac{1}{C_j} \left(\sum_{i=1}^N w_{ji} v_i + b_j \right) \quad (2.15)$$

Como a função energia da rede de Hopfield é sempre decrescente no tempo, até atingir um valor de mínimo local, então sua associação a uma função objetivo que meça o erro de estimação de parâmetros vai levar à minimização deste erro. Neste caso, as saídas da rede de Hopfield vão estar diretamente associadas às estimativas dos parâmetros do modelo de estado.

As matrizes de pesos sinápticos serão funções das variáveis de estado, das suas derivadas e da excitação externa.

2.4 Estimação de parâmetros

Assumindo que a estrutura do modelo paramétrico a ser identificado é expressa pelo modelo linear de espaço de estados:

$$\begin{aligned} \dot{x} &= Ax + Bu \\ y &= Cx \end{aligned} \quad (2.16)$$

onde $C \in \mathbb{R}^{n \times n}$ é a matriz identidade, $x \in \mathbb{R}^n$ é o vetor de estados, $u \in \mathbb{R}^m$ é o vetor de entrada, $A \in \mathbb{R}^{n \times n}$ e $B \in \mathbb{R}^{n \times m}$ são matrizes de parâmetros a determinar, com A assintoticamente estável, o vetor de estados pode ser estimado como segue:

$$\dot{\hat{x}} = \hat{A}x + \hat{B}u \quad (2.17)$$

onde \hat{A} e \hat{B} são as matrizes de parâmetros estimados. A dinâmica do erro entre o vetor de estados real e o vetor de estados estimado é dada por:

$$\dot{e} = \dot{x} - \dot{\hat{x}} = \dot{x} - \hat{A}x - \hat{B}u \quad (2.18)$$

Visando minimizar simultaneamente as taxas do erro de todos os estados, é possível criar a seguinte função de energia, baseada no erro quadrático médio:

$$E = \frac{1}{T} \text{tr} \int_0^T \frac{1}{2} \dot{e}^T \dot{e} dt \quad (2.19)$$

onde $\text{tr}(\cdot)$ é o traço de uma matriz. Substituindo a equação (2.18) na equação (2.19) tem-se:

$$E = \frac{1}{2T} \text{tr} \int_0^T (\dot{x} - \hat{A}x - \hat{B}u)^T (\dot{x} - \hat{A}x - \hat{B}u) dt \quad (2.20)$$

Expandindo o produto em seus termos constituintes resulta:

$$E = \frac{1}{2T} \text{tr} \int_0^T (\dot{x}^T \dot{x} - \dot{x}^T \hat{A}x - \dot{x}^T \hat{B}u - x^T \hat{A}^T \dot{x} + x^T \hat{A}^T \hat{A}x + x^T \hat{A}^T \hat{B}u - u^T \hat{B}^T \dot{x} + u^T \hat{B}^T \hat{A}x + u^T \hat{B}^T \hat{B}u) dt \quad (2.21)$$

e aplicando as seguintes propriedades de traço:

$$\begin{aligned} \text{tr}(ab) &= \text{tr}(ba) \\ \text{tr}(ab) &= \text{tr}(a^T b^T) \end{aligned} \quad (2.22)$$

temos:

$$E = \frac{1}{2T} \text{tr} \int_0^T (\dot{x}^T \dot{x} - \hat{A}x\dot{x}^T - \hat{B}u\dot{x}^T - \hat{A}x\dot{x}^T + \hat{A}x\dot{x}^T \hat{A}^T + \hat{B}u\dot{x}^T \hat{A}^T - \hat{B}u\dot{x}^T + \hat{B}u\dot{x}^T \hat{A}^T + \hat{B}u\dot{x}^T \hat{B}^T) dt$$

de onde resulta:

$$E = \frac{1}{2T} \text{tr} \int_0^T (\dot{x}^T \dot{x} - 2\hat{A}x\dot{x}^T - 2\hat{B}u\dot{x}^T + \hat{A}x\dot{x}^T \hat{A}^T + 2\hat{B}u\dot{x}^T \hat{A}^T + \hat{B}u\dot{x}^T \hat{B}^T) dt \quad (2.23)$$

Derivando a função de energia E em relação às matrizes \hat{A} e \hat{B} , e utilizando uma outra propriedade do traço dada por $\frac{\partial(\text{tr}(ab))}{\partial b} = a^T$, então:

$$\frac{\partial E}{\partial \hat{A}} = \frac{1}{2T} \text{tr} \int_0^T (-2(\dot{x}\dot{x}^T)^T + (\dot{x}\dot{x}^T \hat{A}^T)^T + \hat{A}\dot{x}\dot{x}^T + 2\hat{B}\dot{u}\dot{x}^T) dt \quad (2.24)$$

$$\frac{\partial E}{\partial \hat{A}} = \frac{1}{2T} \text{tr} \int_0^T (-2\dot{x}\dot{x} + 2\hat{A}\dot{x}\dot{x}^T + 2\hat{B}\dot{u}\dot{x}^T) dt \quad (2.25)$$

$$\frac{\partial E}{\partial \hat{A}} = \frac{1}{T} \text{tr} \int_0^T (\hat{A}\dot{x}\dot{x}^T + \hat{B}\dot{u}\dot{x}^T - \dot{x}\dot{x}) dt \quad (2.26)$$

De modo equivalente, derivando E em relação a \hat{B} , tem-se:

$$\frac{\partial E}{\partial \hat{B}} = \frac{1}{2T} \text{tr} \int_0^T (-2(\dot{u}\dot{x}^T)^T + 2\hat{A}\dot{x}\dot{u}^T + (\dot{u}\dot{u}^T \hat{B}^T)^T + \hat{B}\dot{u}\dot{u}^T) dt \quad (2.27)$$

$$\frac{\partial E}{\partial \hat{B}} = \frac{1}{2T} \text{tr} \int_0^T (-2\dot{x}\dot{u}^T + 2\hat{A}\dot{x}\dot{u}^T + 2\hat{B}\dot{u}\dot{u}^T) dt \quad (2.28)$$

$$\frac{\partial E}{\partial \hat{B}} = \frac{1}{T} \text{tr} \int_0^T (\hat{A}\dot{x}\dot{u}^T + \hat{B}\dot{u}\dot{u}^T - \dot{x}\dot{u}^T) dt \quad (2.29)$$

Rescrevendo a matriz $\frac{\partial E}{\partial \hat{A}}$ como elementos na forma de vetores-linha, tem-se:

$$\frac{\partial E}{\partial \hat{A}} = \begin{bmatrix} \frac{\partial E}{\partial \hat{a}_1} \\ \frac{\partial E}{\partial \hat{a}_2} \\ \vdots \\ \frac{\partial E}{\partial \hat{a}_n} \end{bmatrix}, \text{ e } \frac{\partial E}{\partial \hat{B}} = \begin{bmatrix} \frac{\partial E}{\partial \hat{b}_1} \\ \frac{\partial E}{\partial \hat{b}_2} \\ \vdots \\ \frac{\partial E}{\partial \hat{b}_m} \end{bmatrix} \quad (2.30)$$

onde cada vetor-linha é dado por:

$$\left\{ \begin{array}{l} \frac{\partial E}{\partial \hat{a}_1} = \frac{1}{T} tr \int_0^T (\hat{a}_1 x x^T + \hat{b}_1 u x^T - \dot{x}_1 x^T) dt \\ \frac{\partial E}{\partial \hat{a}_2} = \frac{1}{T} tr \int_0^T (\hat{a}_2 x x^T + \hat{b}_2 u x^T - \dot{x}_2 x^T) dt \\ \dots \\ \dots \\ \frac{\partial E}{\partial \hat{a}_n} = \frac{1}{T} tr \int_0^T (\hat{a}_n x x^T + \hat{b}_n u x^T - \dot{x}_n x^T) dt \end{array} \right. \quad (2.31)$$

Estes vetores-linha podem ser ordenados em vetores-coluna, transpondo-os:

$$\left\{ \begin{array}{l} \frac{\partial E}{\partial \hat{a}_1^T} = \frac{1}{T} tr \int_0^T (x x^T \hat{a}_1^T + x u^T \hat{b}_1^T - x \dot{x}_1^T) dt \\ \frac{\partial E}{\partial \hat{a}_2^T} = \frac{1}{T} tr \int_0^T (x x^T \hat{a}_2^T + x u^T \hat{b}_2^T - x \dot{x}_2^T) dt \\ \dots \\ \dots \\ \frac{\partial E}{\partial \hat{a}_n^T} = \frac{1}{T} tr \int_0^T (x x^T \hat{a}_n^T + x u^T \hat{b}_n^T - x \dot{x}_n^T) dt \end{array} \right. \quad (2.32)$$

onde cada vetor $\frac{\partial E}{\partial \hat{a}_i^T}$, $i = 1, 2, \dots, n$, tem dimensão $n \times 1$. As expressões da equação (2.33) podem

ser representadas matricialmente na forma:

$$\begin{bmatrix} \frac{\partial E}{\partial \hat{a}_1^T} \\ \frac{\partial E}{\partial \hat{a}_2^T} \\ \vdots \\ \frac{\partial E}{\partial \hat{a}_n^T} \end{bmatrix} = \frac{1}{T} \int_0^T \begin{bmatrix} xx^T & 0 & \dots & 0 & xu^T & 0 & \dots & 0 \\ 0 & xx^T & \dots & 0 & 0 & xu^T & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & xx^T & 0 & 0 & \dots & xu^T \end{bmatrix} \begin{bmatrix} \hat{a}_1^T \\ \hat{a}_2^T \\ \vdots \\ \hat{a}_n^T \\ \hat{b}_1^T \\ \hat{b}_2^T \\ \vdots \\ \hat{b}_n^T \end{bmatrix} dt - \frac{1}{T} \int_0^T \begin{bmatrix} x\dot{x}_1 \\ x\dot{x}_2 \\ \vdots \\ x\dot{x}_n \end{bmatrix} dt \quad (2.33)$$

onde o vetor-coluna do membro da esquerda tem dimensão $n^2 \times 1$. De maneira equivalente,

$$\begin{cases} \frac{\partial E}{\partial \hat{b}_1^T} = \frac{1}{T} \text{tr} \int_0^T (ux^T \hat{a}_1^T + uu^T \hat{b}_1^T - \dot{x}_1 u^T) dt \\ \frac{\partial E}{\partial \hat{b}_2^T} = \frac{1}{T} \text{tr} \int_0^T (ux^T \hat{a}_2^T + uu^T \hat{b}_2^T - \dot{x}_2 u^T) dt \\ \dots \\ \dots \\ \frac{\partial E}{\partial \hat{b}_n^T} = \frac{1}{T} \text{tr} \int_0^T (ux^T \hat{a}_n^T + uu^T \hat{b}_n^T - \dot{x}_n u^T) dt \end{cases} \quad (2.34)$$

onde cada vetor $\frac{\partial E}{\partial \hat{b}_i^T}$, $i = 1, 2, \dots, n$ tem dimensão $m \times 1$.

O sistema de equações (2.34) pode ser representado na forma matricial como:

$$\begin{bmatrix} \frac{\partial E}{\partial \hat{b}_1^T} \\ \frac{\partial E}{\partial b_2^T} \\ \vdots \\ \frac{\partial E}{\partial b_n^T} \end{bmatrix} = \frac{1}{T} \int_0^T \begin{bmatrix} ux^T & 0 & \dots & 0 & uu^T & 0 & \dots & 0 \\ 0 & ux^T & \dots & 0 & 0 & uu^T & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & ux^T & 0 & 0 & \dots & uu^T \end{bmatrix} \begin{bmatrix} a_1^T \\ a_2^T \\ \vdots \\ a_n^T \\ b_1^T \\ b_2^T \\ \vdots \\ b_n^T \end{bmatrix} dt - \frac{1}{T} \int_0^T \begin{bmatrix} u\dot{x}_1 \\ u\dot{x}_2 \\ \vdots \\ u\dot{x}_n \end{bmatrix} dt \quad (2.35)$$

onde o vetor-coluna do membro esquerdo tem dimensão $(m \times n) \times I$ elementos.

Visando simplificar ainda mais as expressões (2.34) e (2.35), estas podem ser combinadas numa única expressão matricial na forma:

$$\begin{bmatrix} \frac{\partial E}{\partial \hat{a}_1^T} \\ \frac{\partial E}{\partial \hat{a}_2^T} \\ \vdots \\ \frac{\partial E}{\partial \hat{a}_n^T} \\ \frac{\partial E}{\partial \hat{b}_1^T} \\ \frac{\partial E}{\partial \hat{b}_2^T} \\ \vdots \\ \frac{\partial E}{\partial \hat{b}_n^T} \end{bmatrix} = \frac{1}{T} \int_0^T \begin{bmatrix} xx^T & 0 & \dots & 0 & xu^T & 0 & \dots & 0 \\ 0 & xx^T & \dots & 0 & 0 & xu^T & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & xx^T & 0 & 0 & \dots & xu^T \\ ux^T & 0 & \dots & 0 & uu^T & 0 & \dots & 0 \\ 0 & ux^T & \dots & 0 & 0 & uu^T & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & ux^T & 0 & 0 & \dots & uu^T \end{bmatrix} \begin{bmatrix} \hat{a}_1^T \\ \hat{a}_2^T \\ \vdots \\ \hat{a}_n^T \\ \hat{b}_1^T \\ \hat{b}_2^T \\ \vdots \\ \hat{b}_n^T \end{bmatrix} dt - \frac{1}{T} \int_0^T \begin{bmatrix} x\dot{x}_1 \\ x\dot{x}_2 \\ \vdots \\ x\dot{x}_n \\ u\dot{x}_1 \\ u\dot{x}_2 \\ \vdots \\ u\dot{x}_n \end{bmatrix} dt \quad (2.36)$$

Definindo:

$$\Phi = \begin{bmatrix} \hat{a}_1^T \\ \hat{a}_2^T \\ \vdots \\ \hat{a}_n^T \\ \hat{b}_1^T \\ \hat{b}_2^T \\ \vdots \\ \hat{b}_n^T \end{bmatrix}, \frac{\partial E}{\partial \Phi} = \begin{bmatrix} \frac{\partial E}{\partial \hat{a}_1^T} \\ \frac{\partial E}{\partial \hat{a}_2^T} \\ \vdots \\ \frac{\partial E}{\partial \hat{a}_n^T} \\ \frac{\partial E}{\partial \hat{b}_1^T} \\ \frac{\partial E}{\partial \hat{b}_2^T} \\ \vdots \\ \frac{\partial E}{\partial \hat{b}_n^T} \end{bmatrix}, P = \begin{bmatrix} xx^T & 0 & \dots & 0 & xu^T & 0 & \dots & 0 \\ 0 & xx^T & \dots & 0 & 0 & xu^T & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & xx^T & 0 & 0 & \dots & xu^T \\ ux^T & 0 & \dots & 0 & uu^T & 0 & \dots & 0 \\ 0 & ux^T & \dots & 0 & 0 & uu^T & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & ux^T & 0 & 0 & \dots & uu^T \end{bmatrix} \text{ e } Q = \begin{bmatrix} x\dot{x}_1 \\ x\dot{x}_2 \\ \vdots \\ x\dot{x}_n \\ u\dot{x}_1 \\ u\dot{x}_2 \\ \vdots \\ u\dot{x}_n \end{bmatrix} \quad (2.37)$$

a expressão (2.36) pode ser rescrita como:

$$\frac{\partial E}{\partial \Phi} = \frac{1}{T} \int_0^T P \Phi dt - \frac{1}{T} \int_0^T Q dt \quad (2.38)$$

Como Φ varia mais lentamente que E , pode-se assumir que Φ não depende do tempo,

$$\frac{\partial E}{\partial \Phi} = \frac{1}{T} \left[\int_0^T P dt \right] \Phi - \frac{1}{T} \int_0^T Q dt \quad (2.39)$$

Definindo $N = (n \times n + n \times m)$, o vetor $\frac{\partial E}{\partial \Phi}$ tem dimensão $N \times 1$, a matriz P tem dimensão $N \times N$, o

vetor Φ tem dimensão $N \times 1$ e o vetor Q tem dimensão $N \times 1$.

Capítulo 3

Metodologia para o diagnóstico de falhas

O propósito deste capítulo é apresentar os conceitos básicos de grafos direcionados e sinalizados, utilizados como ferramenta de modelagem qualitativa dos parâmetros do modelo de estado, e também conceitos básicos de lógica nebulosa, utilizados no desenvolvimento de ferramentas de diagnóstico.

3.1 Grafos direcionados e sinalizados

Um grafo direcionado e sinalizado (GDS) é uma ferramenta gráfica que permite relacionar eventos, os quais são representados por nós, interligados por ramos, os quais representam as relações existentes entre os nós. Tais relações são direcionadas, denunciando o evento-causa e o evento-efeito, e sinalizadas, indicando o tipo de relação existente entre os eventos. A Figura 3.1 ilustra os elementos básicos de um GDS, onde observa-se o evento-causa, o evento-efeito, a direção entre eles e o sinal de relação entre os eventos.

Esta técnica gráfica tem sido bastante explorada no diagnóstico de processos químicos (IRI *et al.*, 1980; TSUGE *et al.*, 1985, SHIOZAKI *et al.*, 1985; KRAMER & PAULOWITCH, 1987).




Figura 3.1- Representação do GDS

3.1.1 Tipos de relações

Os tipos de relações que podem estar presentes em um GDS são ilustrados na Figura 3.2.

- (i) Na relação positiva, para um aumento/diminuição quantitativo no evento-causa, existirá também um aumento/diminuição quantitativo no evento-efeito.
- (ii) Na relação negativa, para um aumento/diminuição quantitativo no evento-causa, existirá uma diminuição/aumento no evento-efeito.
- (iii) Na relação nula, para um aumento ou uma diminuição quantitativa no evento-causa, não existirão consequências no evento-efeito.




Figura 3.2- Tipos de relações em um GDS

3.1.2 Modelagem das falhas de sistemas dinâmicos

As falhas em sistemas dinâmicos são difíceis de serem detectadas isoladamente no domínio do tempo. Isto porque geralmente vai existir um forte acoplamento entre o comportamento no tempo das variáveis de estado do sistema dinâmico. Por este motivo, na maioria das vezes, são utilizadas técnicas de processamento em frequência para a modelagem, ajuste de parâmetros, controle e diagnóstico (FRANK & DING, 1994).

A proposta deste trabalho é utilizar o GDS como ferramenta de modelagem qualitativa, aplicando-o junto aos parâmetros do modelo de estado (HUALLPA *et al.*, 1998, 1999). Em primeira instância, é suposto que os parâmetros (elementos da matriz do modelo de estado) são constantes e são conhecidas as relações entre os parâmetros do modelo de estado e os parâmetros físicos.

Assumindo que a estrutura do modelo paramétrico identificado é um modelo linear de espaço de estados representado pela equação (3.1)

$$\dot{x} = Ax + Bu \quad (3.1)$$

onde $x \in \mathcal{R}^n$ é o vetor de estados, $u \in \mathcal{R}^m$ é o vetor de entrada, $A \in \mathcal{R}^{n \times n}$ e $B \in \mathcal{R}^{n \times m}$ são matrizes de parâmetros do modelo de estado. Cada parâmetro do modelo de estado está relacionado ou é função de parâmetros físicos. As matrizes A e B podem ser representadas pelas notações a seguir:

$$A = \{a_{ij}\}, \quad i = 1, 2, \dots, n; \quad e \quad j = 1, 2, \dots, n$$

$$B = \{b_{ij}\}, \quad i = 1, 2, \dots, n; \quad e \quad j = 1, 2, \dots, m$$

Por outro lado, consideremos o conjunto $\Xi \in \mathcal{R}^p$ que representa os parâmetros físicos e que é definido pela equação (3.2),

$$\Xi = \{\xi_1, \xi_2, \dots, \xi_p\} \quad (3.2)$$

onde $\xi_1, \xi_2, \dots, \xi_p$ são elementos do conjunto Ξ .

As relações existentes entre os parâmetros físicos e os parâmetros do modelo de estado são definidas pelos sistemas de equações (3.3) e (3.4):

$$a_{ij} = f_{ij}(\xi_1, \xi_2, \dots, \xi_p), \quad i = 1, 2, \dots, n; \quad e \quad j = 1, 2, \dots, n \quad (3.3)$$

$$b_{ij} = g_{ij}(\xi_1, \xi_2, \dots, \xi_p), \quad i = 1, 2, \dots, n; \quad e \quad j = 1, 2, \dots, m \quad (3.4)$$

3.1.3 Relação entre parâmetros físicos e parâmetros do modelo de estado

Cada parâmetro físico pode ser transformado ou interpretado como um evento-causa principal, e cada parâmetro do modelo de estado como um evento-efeito. No trajeto entre evento-causa e evento-efeito, podem existir eventos intermediários que podem ser úteis para a redução ou distribuição do GDS. As relações básicas entre os parâmetros físicos e um parâmetro do modelo de estado são ilustradas na Figura 3.3, para um caso particular em que $a = f(\xi_1, \xi_2, \xi_3) = \xi_1 / \xi_2$.




Figura 3.3- Relações entre parâmetros físicos e parâmetros do modelo de estado

Definições

- A relação entre um parâmetro físico (evento-causa) e um parâmetro do modelo de estado (evento-efeito) é definida *positiva* (+), se a relação analítica entre os dois parâmetros for direta.

$$a = f(\xi) \propto k\xi, \quad k > 0 \quad (3.5)$$

- A relação entre um parâmetro físico (evento-causa) e um parâmetro do modelo de estado (evento-efeito) é definida *negativa* (-), se a relação analítica entre os dois parâmetros for inversa.

$$a = f(\xi) \propto \frac{k}{\xi}, \quad k > 0 \quad (3.6)$$

- A relação entre um parâmetro físico (evento- causa) e um parâmetro do modelo de estado (evento-efeito) é definida *nula* (0), se não existe relação entre os dois parâmetros.

3.1.4 Propriedades transitivas do GDS

Seja ξ o evento-causa e a o evento-efeito da primeira relação; e seja a o evento-causa e b o evento-efeito da segunda relação. Consideremos as possíveis combinações entre as duas relações:

- (i) se a relação entre o evento ξ e o evento a é positiva, e se a relação entre o evento a e o evento b é positiva, então a relação entre o evento ξ e o evento b também é positiva.

$$\begin{aligned} a &\propto k_1 \xi \quad \text{e} \quad b \propto k_2 a, \text{ com } k_1 > 0, k_2 > 0 \\ \text{então, } b &\propto k_1 k_2 \xi \end{aligned} \quad (3.7)$$

- (ii) se a relação entre o evento ξ e o evento a é positiva, e se a relação entre o evento a e o evento b é negativa, então a relação entre o evento ξ e o evento b é negativa.

$$\begin{aligned} a &\propto k_1 \xi \quad \text{e} \quad b \propto \frac{k_2}{a}, \text{ com } k_1 > 0, k_2 > 0 \\ \text{então, } b &\propto \frac{k_2}{k_1 \xi} \end{aligned} \quad (3.8)$$

- (iii) se a relação entre o evento ξ e o evento a é negativa, e se a relação entre o evento a e o evento b é positiva, então a relação entre o evento ξ e o evento b é negativa.

$$\begin{aligned}
 a &\propto \frac{k_1}{\xi} \quad \text{e} \quad b \propto k_2 a, \text{ com } k_1 > 0, k_2 > 0 \\
 \text{então, } b &\propto \frac{k_1 k_2}{\xi}
 \end{aligned}
 \tag{3.9}$$

(iv) se a relação entre o evento ξ e o evento a é negativa, e se a relação entre o evento a e o evento b é negativa, então a relação entre o evento ξ e o evento b é positiva.

$$\begin{aligned}
 a &\propto \frac{k_1}{\xi} \quad \text{e} \quad b \propto \frac{k_2}{a}, \text{ com } k_1 > 0, k_2 > 0 \\
 \text{então, } b &\propto \frac{k_2}{k_1} \xi
 \end{aligned}
 \tag{3.10}$$

Na Figura 3.4 é mostrada a propriedade transitiva de relações adjacentes. Observa-se que a regra de sinais se assemelha às regras de sinais aritméticos ou algébricos válidas, por exemplo, para produto e divisão. Isto é, se os sinais de duas relações adjacentes são iguais, o resultado será uma relação com sinal positivo; e se os sinais de duas relações adjacentes são diferentes, então, a relação resultante terá sinal negativo.




Figura 3.4- Propriedades transitivas do GDS

3.1.5 Propriedades distributivas do GDS

Um evento-efeito pode ser decomposto utilizando a propriedade distributiva da seguinte maneira:

$$\begin{aligned}
 f(\xi_1 + \xi_2, \xi_3) &\propto k \frac{\xi_1 + \xi_2}{\xi_3} = k \frac{\xi_1}{\xi_3} + k \frac{\xi_2}{\xi_3}, \quad k > 0 \\
 f(\xi_1 + \xi_2, \xi_3) &= f(\xi_1, \xi_3) + f(\xi_2, \xi_3)
 \end{aligned}
 \tag{3.11}$$

o qual pode ser ilustrado por grafos, como mostra a Figura 3.5.




Figura 3.5- Propriedade distributiva

A propriedade distributiva é muito importante, pois em muitas situações apenas é necessário analisar a veracidade de um dos eventos-fonte ou a veracidade de dois eventos-fonte simultaneamente.

3.1.6 Transformação do modelo GDS em regras de inferência

Uma relação entre dois eventos do modelo GDS pode ser transformado em uma regra de inferência como mostra a Figura 3.6.

Observa-se na Figura 3.6-(i), que, se a relação entre dois eventos é positiva, então dado um acréscimo/decréscimo no evento-causa, teremos como conclusão também um acréscimo/decréscimo no evento-efeito. Na Figura 3.6-(ii), quando a relação é negativa; para um acréscimo/decréscimo do evento-fonte, tem-se como conclusão um decréscimo/acrécimo no evento-efeito. E na Figura 3.6-(iii), quando a relação é nula, para um acréscimo/decréscimo no evento-causa, tem-se como conclusão nenhuma perturbação no evento-efeito.

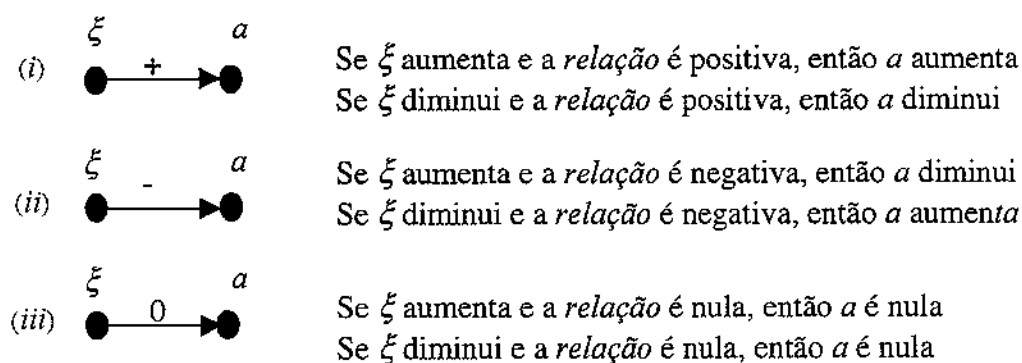


Figura 3.6- Transformação do GDS em regras de inferência: (i) relação positiva, (ii) relação negativa, (iii) relação nula.

3.2 Diagnóstico via lógica nebulosa

3.2.1 Conjuntos nebulosos

O conceito de conjuntos nebulosos é uma generalização da teoria clássica de conjuntos e foi introduzido por ZADEH (1965, 1973). Na teoria clássica de conjuntos o contorno ou a fronteira está bem definida. Por exemplo, sejam os conjuntos de pares ordenados (x,y) definidos como:

$$U = \{(x,y) \in \mathbb{R}^2 / -10 \leq x \leq 10, -10 \leq y \leq 10\} \quad (3.12)$$

$$A = \{(x,y) \in \mathbb{R}^2 / -5 \leq x \leq 5, -5 \leq y \leq 5\} \quad (3.13)$$

$$B = \{(x,y) \in \mathbb{R}^2 / x < -5 \text{ ou } x > 5, -10 \leq x \leq 10, y < -5 \text{ ou } y > 5, -10 \leq y \leq 10\} \quad (3.14)$$

onde U é o conjunto-universo (retângulo maior), A é o retângulo menor e B é a região externa que não contém o retângulo menor. Os conjuntos definidos em (3.12), (3.13) e (3.14) são representados na Figura 3.7.




Figura 3.7- Exemplo de conjuntos clássicos

Observa-se que qualquer ponto que não pertence ao conjunto A , pertencerá ao conjunto B ; da mesma maneira, qualquer ponto que pertence ao conjunto A , não pertencerá ao conjunto B . Em conclusão, um elemento que pertence ao conjunto universo U , pertence ao conjunto A ou ao conjunto B , porém não pode pertencer a ambos os conjuntos. Assim, por exemplo, o par $(5,001, 0)$ pertence ao conjunto B e o par $(5, 0)$ pertence ao conjunto A . Na maioria das situações da vida real sempre é permitida uma margem de erro para ambos os conjuntos, isto é, existe um "compartilhamento" de pertinência dos elementos que estiverem na fronteira entre ambos os conjuntos. Em outras palavras, a fronteira entre tais conjuntos é "nebulosa".

A teoria de conjuntos nebulosos visa considerar este tipo de interpretação, de maneira que a transição de pertinência e não pertinência a um determinado conjunto seja feita de maneira gradual. Esta transição gradual pode ser caracterizada através de *funções de pertinência* que definem o grau de pertinência do elemento a um determinado conjunto. Esta maneira de caracterização permite utilizar expressões lingüísticas como, por exemplo, "região interna", "região externa". Neste sentido, a teoria de conjuntos nebulosos flexibiliza a rigidez da teoria clássica de conjuntos introduzindo o conceito de nível ou "grau de pertinência". Então, pode-se interpretar a teoria de conjuntos nebulosos como uma expansão da teoria clássica de conjuntos. A teoria de conjuntos nebulosos requer que cada elemento do conjunto-universo seja acompanhado

pelo grau de pertinência a um determinado subconjunto nebuloso. Assim, por exemplo, considerem-se os conjuntos redefinidos através das equações (3.12), (3.13) e (3.14) como conjuntos de pares que pertencem à "região interna" e "região externa" respectivamente, onde o conjunto Universo é o plano \mathfrak{R}^2 , onde x varia de -10 a +10 e y varia de -10 a +10. Então, as expressões das equações (3.12), (3.13) e (3.14) podem ser definidas como:

$$U = \{((x, y), 1) / (x, y) \in \mathfrak{R}^2, -10 \leq x \leq 10, -10 \leq y \leq 10\} \quad (3.15)$$

$$A = \{((x, y), \mu_A(x, y)) / (x, y) \in U\} \quad (3.16)$$

$$B = \{((x, y), \mu_B(x, y)) / (x, y) \in U\} \quad (3.17)$$

onde μ_A é o grau de pertinência ao conjunto A e μ_B é o grau de pertinência ao conjunto B . O grau de pertinência é definido no intervalo $[0, 1]$, onde o valor "0" representa o menor grau de pertinência, e o valor "1" representa o maior grau de pertinência. No geral, a função de pertinência pode ser interpretada como uma função de mapeamento dos elementos do conjunto universo nos subconjuntos nebulosos, com um determinado grau de pertinência. Os conjuntos clássicos definidos pelas equações (3.13) e (3.14) podem ser redefinidos sob a concepção da teoria clássica de conjuntos como:

$$A = \{((x, y), 1) \in \mathfrak{R}^2 / -5 \leq x \leq 5, -5 \leq y \leq 5\} \quad (3.18)$$

$$B = \{((x, y), 1) \in \mathfrak{R}^2 / x < -5 \text{ ou } x > 5, -10 \leq x \leq 10, y < -5 \text{ ou } y > 5, -10 \leq y \leq 10\} \quad (3.19)$$

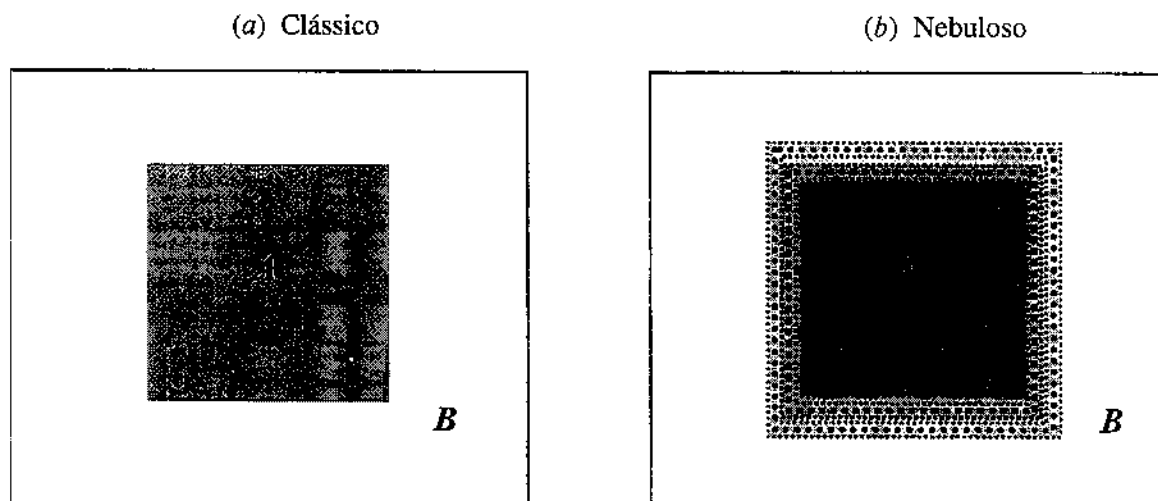


Figura 3.8- (a) conjunto clássico, (b) conjunto nebuloso

A Figura 3.8-(a), representa as equações (3.20) e (3.21), onde as duas regiões são bem definidas e separadas de maneira rígida. Na Figura 3.8-(b), não existe a separação rígida e bem definida dos contornos. A divisão entre o conjunto A e o conjunto B é “nebulosa”, no sentido de que existe uma transição gradual de um conjunto para o outro. Esta transição gradual é realizada através de *funções de pertinência*, definidas de acordo com a Figura 3.9.




Figura 3.9- Definição de funções de pertinência

Observa-se que as funções de pertinência são do tipo trapezoidal. Os subconjuntos nebulosos A_x e A_y atingem o valor "1" na região central e o valor "0" nos extremos, e os subconjuntos nebulosos B_{1x} , B_{2x} , B_{1y} e B_{2y} atingem o valor "1" num dos extremos e o valor "0" no outro extremo. Outros tipos de funções de pertinência que podem ser utilizadas são, as funções triangular, gaussiana, sigmoidal, etc.

3.2.2 Operações com conjuntos nebulosos

Na teoria clássica de conjuntos, as operações mais utilizadas entre os conjuntos são interseção, união e complemento. Na teoria de conjuntos nebulosos existem operadores análogos definidos inicialmente por ZADEH (1965). No exemplo da Figura 3.9, observa-se que o conjunto nebuloso B_x pode ser obtido da união dos conjuntos B_{1x} e B_{2x} ou $B_x = B_{1x} \cup B_{2x}$, da mesma maneira $B_y = B_{1y} \cup B_{2y}$. Intuitivamente, pode-se dizer que a união de dois conjuntos nebulosos é o menor conjunto nebuloso que contém ambos os conjuntos.

$$\mu_{B_x}(x) = \max(\mu_{B_{1x}}(x), \mu_{B_{2x}}(x)) = \mu_{B_{1x}}(x) \vee \mu_{B_{2x}}(x) \quad (3.20)$$

$$\mu_{B_y}(y) = \max(\mu_{B_{1y}}(y), \mu_{B_{2y}}(y)) = \mu_{B_{1y}}(y) \vee \mu_{B_{2y}}(y) \quad (3.21)$$

onde o operador $\max(\cdot)$ é um tipo de operador de união para conjuntos nebulosos, sendo assim uma *norma-s*.

A região representada pelo conjunto nebuloso A da Figura 3.9 pode ser utilizada para ilustrar a interseção dos conjuntos A_x e A_y , isto é, $A = A_x \cap A_y$. Observa-se nesta figura, as projeções dos conjuntos nebulosos A e B nos eixos X e Y , respectivamente. Procurando uma melhor visualização, ilustra-se o conjunto A em 3 dimensões na Figura 3. 10. Observa-se que na região central, a função de pertinência atinge o valor máximo e nos contornos da interseção diminui gradativamente os valores da função de pertinência. A interseção dos conjuntos nebulosos de A_x e A_y é dada por:




Figura 3. 10- Representação tridimensional da operação de interseção: $A = A_x \cap A_y$

$$\mu_A(z) = \min(\mu_{A_x}(x), \mu_{A_y}(y)) = \mu_{A_x}(x) \wedge \mu_{A_y}(y), \quad (3.22)$$

da mesma maneira, a região externa representada pelo conjunto nebuloso B pode ser dada por $B = B_x \cap B_y$,

$$\mu_B(z) = \min(\mu_{B_x}(x), \mu_{B_y}(y)) = \mu_{B_x}(x) \wedge \mu_{B_y}(y) \quad (3.23)$$

A interseção dos conjuntos nebulosos A_x e A_y pode ser interpretada como o maior conjunto nebuloso de A_x e A_y que é contido em ambos os conjuntos. O operador $\min(.)$ é um tipo de operador de interseção para conjuntos nebulosos, sendo assim uma *norma-t*.

O complemento de um conjunto nebuloso pode ser definido por:

$$\mu_{\bar{A}}(z) = 1 - \mu_A(z) \quad (3.24)$$

É importante salientar que *norma-t* e *norma-s* comportam definições mais abrangentes na literatura (DUBOIS, 1980).

3.2.3 Lógica nebulosa em sistemas de decisão baseados em regras

Nos sistemas de decisão baseados em regras, a ativação de uma regra é efetivada se os antecedentes são verdadeiros ou satisfeitos. Estas regras são ativadas uma a uma sequencialmente. Se duas regras forem ativadas simultaneamente, então, deve ser acionado um procedimento que permita resolver o conflito. Nos sistemas baseados na lógica nebulosa não se tem este problema, porque cada regra tem um determinado grau de satisfação e em função dos graus de pertinência dos subconjuntos nebulosos de seus antecedentes. Desta maneira, muitas regras podem ser ativadas ao mesmo tempo, mas com diferentes graus de satisfação. Por outro lado a lógica nebulosa possibilita aproximar o raciocínio intuitivo, no sentido de que, se antecedentes implicam conclusões, então antecedentes semelhantes implicarão também conclusões semelhantes.

Para o exemplo da Figura 3.9 podem ser considerados os seguintes mecanismos de inferência nebulosa:

premissa 1: $x \text{ é } A_x' \text{ e } y \text{ é } A_y'$

premissa 2: se $x \text{ é } A_x$ e $y \text{ é } A_y$ então $z \text{ é } A$ (3.25)

conclusão: $z \text{ é } A'$

onde A_x , A_y e A são valores lingüísticos definidos por conjuntos nebulosos que atribuem graus de pertinência aos elementos dos conjuntos-universo (universo de discurso) X , Y e Z , respectivamente. A *premissa 1* pode ser interpretada como um *evento* que pode ser relacionado aos antecedentes da *premissa 2*, que representa, por sua vez, uma *regra de inferência*. A conclusão indica a semelhança da *premissa 1* em relação à *premissa 2*, isto é, a conclusão é o resultado da aplicação do mecanismo de inferência.

Quando todos os conjuntos mencionados são conjuntos nebulosos, então, o processo de inferência é conhecido como *raciocínio aproximado nebuloso* ou *modus ponens generalizado*.

O raciocínio aproximado de conjuntos nebulosos pode ser definido utilizando os operadores nebulosos *max-min* (PEDRYCS & GOMIDE, 1998) descritos nas equações (3.22) a (3.23).

$$\mu_{A'}(z) = \max \left(\min((\mu_{Ax}(x), \mu_{Ay}(y)), \mu_R) \right) \quad (3.26)$$

3.2.4 Classificação de padrões

O problema de classificação de padrões consiste na determinação da classe a qual pertence um determinado padrão, que se pode intuir como um mapeamento do domínio de *entrada* para o domínio da *saída* (Figura 3.11).

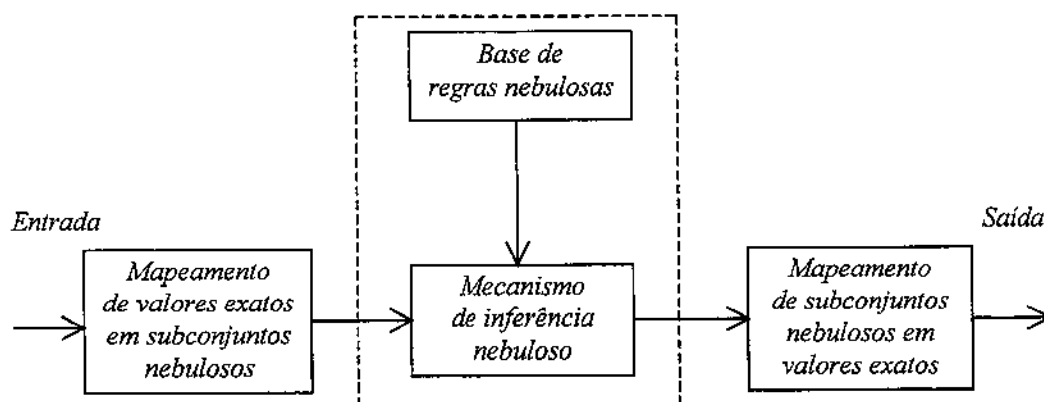


Figura 3.11- Configuração básica de um sistema nebuloso para tomada de decisão

Os valores numéricos não-nebulosos da entrada são mapeados nos subconjuntos nebulosos. Os valores mapeados são processados pelo sistema de inferência cuja estrutura básica é composta de uma base de regras nebulosas e o mecanismo de inferência, que realiza o procedimento de tomada de decisão baseado nas regras nebulosas. A conclusão determinada pelo mecanismo de inferência é mapeada ou transformada num valor numérico não-nebuloso que chega a ser a saída.

3.2.5 Inferência utilizando o operador *max-min*

Diversas formas de inferência utilizando o operador *max-min* foram propostas na literatura, sendo possível destacar MAMDANI & ASSILIAN (1975) e TAKAGI & SUGENO (1983, 1985). Elas

diferenciam-se principalmente no processo de transformação dos subconjuntos nebulosos em valores numéricos não-nebulosos (LEE, 1990a, 1990b).

A Figura 3.12, mostra duas regras com dois antecedentes cada uma. Os conjuntos-universo dos antecedentes são X e Y , e o conjunto-universo da conclusão é Z . A primeira regra tem como antecedentes os subconjuntos nebulosos A_1 , B_1 e como conclusão o subconjunto nebuloso C_1 ; a segunda regra tem como antecedentes os subconjuntos nebulosos A_2 e B_2 e como conclusão o subconjunto nebuloso C_2 .




Figura 3.12- Inferência nebulosa segundo Mamdani

Consideram-se os valores x e y na entrada do sistema de inferência nebuloso. Estes valores de entrada são projetados sobre os subconjuntos nebulosos até encontrar as interseções com cada uma das funções de pertinência. Estas interseções são projetada sobre as funções de pertinência dos subconjuntos nebulosos das conclusões. Escolhe-se o operador nebuloso *min* para a conjunção dos antecedentes em cada regra, isto é, o menor valor de interseção na regra. Assim, na primeira regra, o menor valor corresponde ao subconjunto nebuloso B_1 , e na segunda regra, o menor valor corresponde ao subconjunto nebuloso A_2 . Estes valores escolhidos são projetados sobre os conjuntos nebulosos das conclusões C_1 e C_2 , obtendo-se novos conjuntos C'_1 e C'_2 respectivamente. A seguir, é realizado o processo de agregação, utilizando-se o operador *max*, que é o maior valor de pertinência entre os conjuntos C'_1 e C'_2 visando obter-se um único conjunto C' . Se a idéia é obter um único valor numérico não-nebuloso, então obtém-se o centróide da área do conjunto resultante C' , o qual é projetado sobre o conjunto universo da conclusão Z .

3.2.6 Aplicação da lógica nebulosa no diagnóstico de falhas em sistemas dinâmicos

A lógica nebulosa é utilizada como ferramenta de diagnóstico de falhas em sistemas dinâmicos (Figura 3.13). Os parâmetros do modelo de estado são estimados e pré-processados detectando perturbações sofridas pelo sistema dinâmico. As variáveis de saída do bloco de pré-processamento são interpretadas como *sintomas* do sistema de diagnóstico nebuloso.

A partir dos sintomas obtidos na saída do bloco de pré-processamento e dos valores estimados são obtidos os valores nominais. Com os valores nominais determinados, são definidos os conjuntos *universo de discurso* para cada parâmetro do modelo de estado.

Uma vez definidos os conjuntos universo de discurso, tanto dos antecedentes quanto dos conseqüentes, são construídos os subconjuntos nebulosos dos antecedentes e dos conseqüentes. Os valores nominais que servem como referência, as regras de inferência e os valores dos parâmetros estimados são elementos básicos do mecanismo de decisão nebulosa. A saída do sistema de decisão nebulosa determina a possível causa de falha.

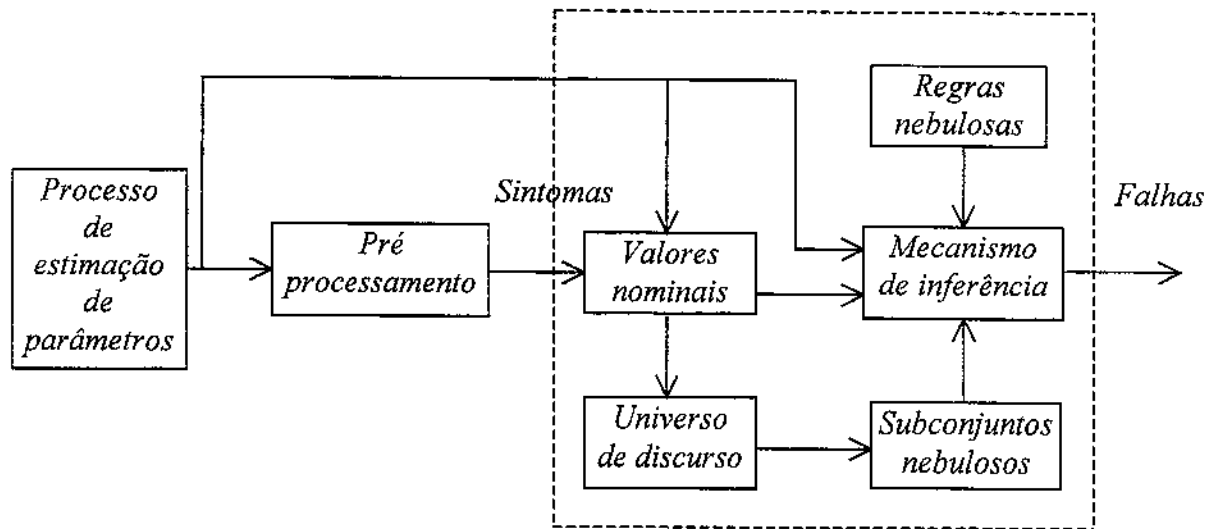


Figura 3.13- Lógica nebulosa no diagnóstico de falhas de sistemas dinâmicos

3.2.6.1 Definição do conjunto-universo

Os conjuntos *universo de discurso* dos antecedentes são determinados em função dos valores nominais de cada parâmetro do modelo de estado: uma vez determinado o valor nominal, é dada uma margem à esquerda e à direita do valor nominal. Esta margem é definida em função das observações realizadas no processo de monitoração. Assim, por exemplo, se um dos parâmetros do modelo de estado tem valor nominal a_{nom} , e são previstas ou observadas variações de até 20% com relação ao valor nominal, então o conjunto universo estará definido no intervalo $[a_{nom} - 0.2 * a_{nom}, a_{nom} + 0.2 * a_{nom}]$. É importante deixar claro que a variação em relação ao valor nominal é definida de forma independente para cada parâmetro do modelo de estado. Os conjuntos *universo de discurso* das conclusões dependerão apenas da resolução e do número de subconjuntos nebulosos.

3.2.6.2 Definição dos subconjuntos nebulosos

Os subconjuntos nebulosos dos antecedentes são definidos de acordo com as observações das variações em cada um dos valores nominais e recebem valores lingüísticos como "variação para cima", "variação para baixo" e "sem variação" ou "aumento", "diminuição" e "variação nula" respectivamente. O número de subconjuntos nebulosos de uma regra varia de acordo com a relação entre os parâmetros do modelo de estado e os parâmetros físicos. O subconjunto nebuloso do conseqüente recebe valores lingüísticos associados ao nome do parâmetros físico que é considerado como fonte de perturbação ou falha.

3.2.6.3 Determinação das funções de pertinência

As funções de pertinência dos antecedentes são definidas como sendo funções sigmoidais ou funções gaussianas. Os subconjuntos nebulosos de valor lingüístico "variação para cima" são funções sigmoidais para a direita, os subconjuntos nebulosos de valor lingüístico "variação para baixo" são funções sigmoidais para a esquerda, e os subconjuntos nebulosos de valor lingüístico "sem variação" são afinados com os valores nominais de maneira que o centro da função gaussiana é igual ao valor nominal.

As funções de pertinência dos conseqüentes são definidas como do tipo gaussiana, onde a largura e a curvatura são escolhidas de maneira independente para dada uma das conclusões. Os valores lingüísticos dos subconjuntos nebulosos são associados a nomes de possíveis fontes de falha.

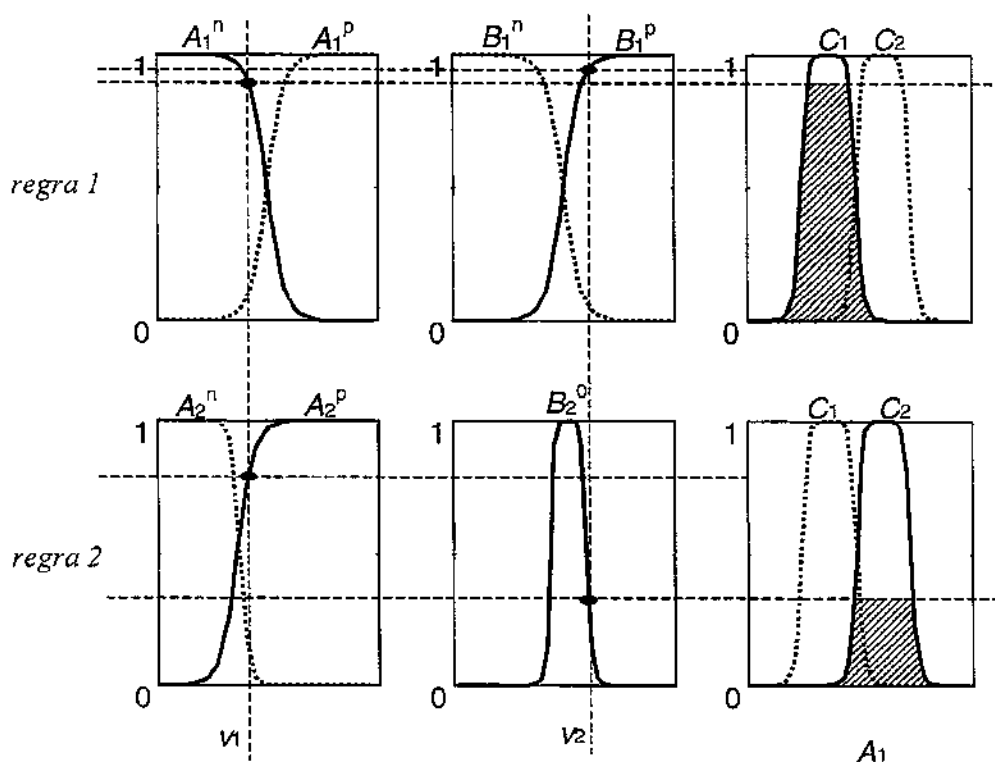


Figura 3.14- Exemplos do mecanismo de ativação de regras

3.2.6.4 Determinação das regras de inferência

As regras de inferência são determinadas de acordo com a relação do modelo existente entre o parâmetro do modelo de estado e o parâmetro físico. Assim, por exemplo, na Figura 3.14 as regras são:

regra 1: Se v_1 pertence a A_1^n e v_2 pertence a B_1^p então w pertence a C_1 (3.27)

regra 2: Se v_1 pertence a A_2^p e v_2 pertence a B_2^0 então w pertence a C_2 (3.28)

Na regra 1, A_1^n é o subconjunto nebuloso de A_1 com "variação para baixo", B_1^p é o subconjunto nebuloso de B_1 com "variação para cima" e C_1 é o subconjunto nebuloso considerado como fonte de perturbação. Na regra 2, A_2^p é o subconjunto nebuloso de A_2 com "variação para cima", B_2^0 é o subconjunto nebuloso de B_2 "sem variação" e C_2 é o subconjunto nebuloso considerado como fonte de perturbação. Utilizando a composição *max-min* tem-se:

$$\mu_{C_1}(w) = \max_w \left(\min_v ((\mu_{A_1^n}(v_1), \mu_{B_1^p}(v_2)), \mu_R) \right) \quad (3.29)$$

$$\mu_{C_2}(w) = \max_w \left(\min_v ((\mu_{A_2^p}(v_1), \mu_{B_2^0}(v_2)), \mu_R) \right) \quad (3.30)$$

onde

- v_1 e v_2 são os parâmetros estimados do modelo de estado
- os subconjuntos nebulosos dos antecedentes são definidos como

$$\begin{aligned} \mu_{A_i^n}(v_i) &= \frac{1}{1 + e^{-a_i(v_i - c_i)}}, \text{ função sigmoide} \\ \mu_{A_i^p}(v_i) &= e^{-a_i \left(\frac{v_i - c_i}{\sigma_i} \right)^2}, \text{ função gaussiana} \end{aligned} \quad (3.31)$$

onde a_i controla a inclinação, σ_i a largura e c_i o centro da função.

- Os subconjuntos nebulosos dos conseqüentes que caracterizam as fontes de perturbação são do tipo,

$$\mu_{B_q}(w) = e^{-\left(\frac{w - c_q}{\sigma_q} \right)^2}, \text{ função gaussiana} \quad (3.32)$$

onde σ_q é a largura e c_q é o centro da função de pertinência.

Capítulo 4

Sistema de detecção e diagnóstico

O propósito deste capítulo é apresentar a metodologia utilizada na estimação de parâmetros do modelo de estado seguida pela detecção e diagnóstico de falhas em sistemas dinâmicos.

4.1 Diagnóstico de falhas em sistemas dinâmicos

Conforme apresentado na Figura 4.1, o diagrama genérico do sistema de diagnóstico de falhas é constituído de 3 módulos principais: módulo de estimação de parâmetros do modelo de estado, módulo de pré-processamento e módulo de diagnóstico.




Figura 4.1- Diagrama geral do sistema de diagnóstico

4.2 Módulo de estimação de parâmetros do modelo de estado

Este módulo tem por objetivo estimar os parâmetros do modelo de estado utilizando um estimador recursivo não-linear baseado em rede neural de Hopfield.

A variação da energia de Hopfield com relação às saídas da rede neural é dada pela equação (2.15),

$$\frac{\partial E_H}{\partial v_j} = -\frac{1}{C_j} \left(\sum_{i=1}^N w_{ji} v_i + b_j \right), \text{ para } j = 1, 2, \dots, N$$

isto é:

$$\begin{cases} \frac{\partial E_H}{\partial v_1} = -\frac{1}{C_1} \left(\sum_{i=1}^N w_{1i} v_i + b_1 \right) \\ \frac{\partial E_H}{\partial v_2} = -\frac{1}{C_2} \left(\sum_{i=1}^N w_{2i} v_i + b_2 \right) \\ \dots \\ \dots \\ \frac{\partial E_H}{\partial v_N} = -\frac{1}{C_N} \left(\sum_{i=1}^N w_{Ni} v_i + b_N \right) \end{cases}$$

passando os valores das capacitâncias para o primeiro membro e rescrevendo em forma matricial tem-se:

$$\begin{bmatrix} C_1 \frac{\partial E_H}{\partial v_1} \\ C_2 \frac{\partial E_H}{\partial v_2} \\ \vdots \\ C_N \frac{\partial E_H}{\partial v_N} \end{bmatrix} = - \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1N} \\ w_{21} & w_{22} & \dots & w_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ w_{N1} & w_{N2} & \dots & w_{NN} \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_N \end{bmatrix} - \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_N \end{bmatrix} \quad (4.1)$$

Para facilitar a representação matricial consideremos todas as capacitâncias unitárias, e nomeando as matrizes como:

$$\frac{\partial E_H}{\partial V} = \begin{bmatrix} \frac{\partial E_H}{\partial v_1} \\ \frac{\partial E_H}{\partial v_2} \\ \vdots \\ \frac{\partial E_H}{\partial v_N} \end{bmatrix}, \quad W = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1N} \\ w_{21} & w_{22} & \dots & w_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ w_{N1} & w_{N2} & \dots & w_{NN} \end{bmatrix}, \quad V = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_N \end{bmatrix}, \quad B = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_N \end{bmatrix}$$

de forma que, a equação (4.1) pode ser representada como:

$$\frac{\partial E}{\partial V} = -WV - B \quad (4.2)$$

Por outro lado, a partir da equação (2.39), que descreve a variação da função energia em relação aos parâmetros do sistema dinâmico Φ :

$$\frac{\partial E}{\partial \Phi} = \frac{1}{T} \left(\int_0^T P dt \right) \Phi - \frac{1}{T} \left(\int_0^T Q dt \right) \quad (4.3)$$

É possível estabelecer uma associação direta entre a função energia e as saídas da rede neural de Hopfield respectivamente com a função objetivo de um estimador recursivo e os parâmetros do sistema dinâmico (equações (4.2) e (4.3)). É importante salientar que para tanto é necessário aguardar a convergência dos pesos sinápticos e *bias* da rede de Hopfield dados por:

$$W = - \left(\frac{1}{T} \right) \left(\int_0^T P dt \right) \quad (4.4)$$

e

$$B = \left(\frac{1}{T} \right) \left(\int_0^T Q dt \right) \quad (4.5)$$

onde W é a matriz de pesos sinápticos e B o vetor *bias* da rede neural de Hopfield.

4.2.1 Configuração resultante do módulo de estimação

Na Figura 4.2, observa-se que as informações necessárias e suficientes para a estimação de parâmetros do modelo de estado via rede de Hopfield são a entrada do sistema dinâmico, as variáveis de estado e suas derivadas em relação ao tempo.

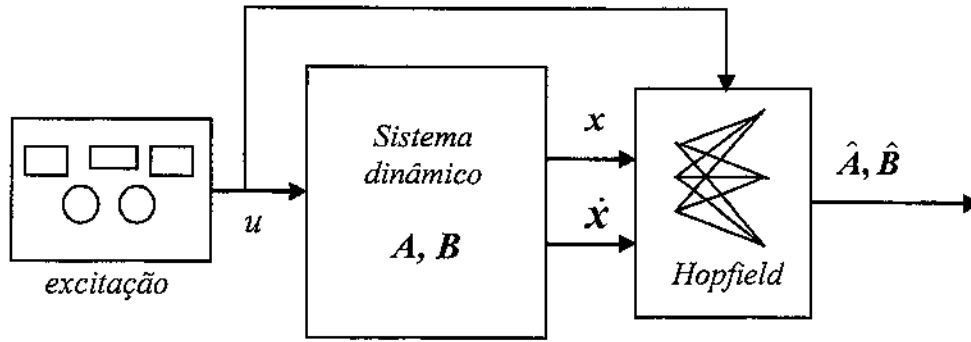


Figura 4.2. Estimação de parâmetros do modelo de estado por Rede Neural de Hopfield

As saídas dos neurônios da rede neural estão associadas aos parâmetros do modelo de estado da seguinte maneira: a saída do neurônio 1 está associada ao parâmetro a_{11} , a saída do neurônio 2 está associada ao parâmetro a_{12} , a saída do neurônio n está associada ao parâmetro a_{1n} , a saída do neurônio $n+1$ está associada ao parâmetro a_{21} , a saída do neurônio $2 \times n$ está associada ao parâmetro a_{2n} , a saída do neurônio n^2 está associada ao parâmetro a_{nn} , a saída do neurônio n^2+1 está associada ao parâmetro b_{11} , a saída do neurônio n^2+2 está associada ao parâmetro b_{12} , a saída do neurônio n^2+m está associada ao parâmetro b_{1m} , a saída do neurônio n^2+m+1 está associada ao parâmetro b_{21} , a saída do neurônio $n^2+2 \times m$ está associada ao parâmetro b_{2m} , e assim sucessivamente até a saída do neurônio $n^2+n \times m$, que está associada ao parâmetro b_{nm} . Independentemente da maneira como for definida a associação, o número total de neurônios necessários será de $N = n^2 + nm$.

A função de saída não-linear de cada neurônio é escolhida como sendo (RAOL, 1995):

$$v_j = \rho_j \tanh\left(\frac{\lambda_j}{2} u_j\right) \quad (4.6)$$

onde ρ_j é o ganho e λ_j é a inclinação da função tangente hiperbólica. Estes dois parâmetros são muito importantes para conseguir a robustez e aprimoramento na convergência das respostas do estimador. É importante salientar que a amplitude da saída de cada neurônio varia entre $+\rho_j$ e $-\rho_j$. Se λ_j é grande, a função não-linear se aproxima de uma função degrau, denominada função sinal.

4.2.2 Extensões junto à configuração resultante da rede de Hopfield generalizada

Em virtude da necessidade de produzir taxas de convergência diferenciadas para cada neurônio da rede de Hopfield, como ficará evidenciado no projeto do estimador de parâmetros a ser apresentado mais adiante, procede-se a seguir como uma extensão dos resultados até aqui apresentados para o caso em que é possível otimizar os valores das capacitâncias e os valores dos coeficientes de inclinação de cada neurônio da rede, em lugar de definir os seus valores de maneira prévia e arbitrária. Aspectos adicionais referentes à motivação e aos resultados de aplicação das técnicas de otimização descritas nas próximas três subseções podem ser encontrados em HUALLPA *et al.* (1997, 1998b).

4.2.2.1 Ajuste das capacitâncias da rede de Hopfield

Considerando uma rede neural com N neurônios, a equação dinâmica referente ao j -ésimo neurônio é dada pela equação (2.9), onde a saída de cada neurônio v_j ($j=1,...,N$) é dada pelo mapeamento não-linear da equação (4.6).

A partir da equação (2.10), pode-se obter a variação da energia em relação à capacitância C_j , de maneira que,

$$\frac{\partial E_H}{\partial C_j} = -\frac{1}{2} \left[\frac{\partial \left(\frac{du_j}{dt} \right)}{\partial C_j} v_j + \frac{du_j}{dt} \frac{\partial v_j}{\partial C_j} \right] \quad (4.7)$$

Manipulando cada termo envolvido na derivada em relação a C_j , no lado direito da equação (4.7), resulta:

$$\frac{\partial \left(\frac{du_j}{dt} \right)}{\partial C_j} = -\frac{1}{C_j^2} \left(\sum_{i=1}^N w_{ji} v_i + b_j \right) = -\frac{1}{C_j} \frac{du_j}{dt}, \quad (4.8)$$

e a variação da saída do neurônio j em relação a C_j pode ser expressa na forma:

$$\frac{\partial v_j}{\partial C_j} = \frac{\partial v_j}{\partial u_j} \frac{\partial u_j}{\partial C_j} = -\frac{\lambda_j}{2} \frac{\rho_j^2 - v_j^2}{\rho_j} \frac{u_j}{C_j}. \quad (4.9)$$

Vale salientar que o estado interno u_j de cada neurônio é dado por

$$u_j = \frac{1}{C_j} \int \left[\sum_{i=1}^N (w_{ji} v_i) + b_j \right] dt \quad (4.10)$$

Substituindo as equações (4.8), (4.9) e (4.10) na equação (4.7), tem-se:

$$\frac{\partial E_H}{\partial C_j} = \frac{1}{2C_j} \frac{du_j}{dt} \left\{ v_j + \frac{\lambda_j}{C_j} \frac{\rho_j^2 - v_j^2}{2\rho_j} \int \left[\sum_{i=1}^N (w_{ji} v_i) + b_j \right] dt \right\} \quad (4.11)$$

O mínimo da função energia E_H em relação a C_j , obedece à condição de estacionariedade

$\frac{\partial E_H}{\partial C_j} = 0$, permitindo obter o valor ótimo da capacitância para o j -ésimo neurônio na forma:

$$C_j^* = -\frac{\lambda_j \frac{\rho_j^2 - v_j^2}{2\rho_j} \int \left[\sum_{i=1}^N (w_{ji} v_i) + b_j \right] dt}{v_j} \quad (4.12)$$

Isto implica que o valor da capacitância adaptativa varia de acordo com a equação (4.12). É importante notar que os valores iniciais das capacitâncias são unitários, sendo que estes valores geralmente vão decrescendo ao longo do tempo até que a rede neural atinja o estado estacionário.

4.2.2.2 Ajuste dos coeficientes de inclinação da função de saída dos neurônios

O ajuste dos coeficientes de inclinação da função de saída não-linear do j -ésimo neurônio, dada pela equação (4.6), pode ser otimizado a partir da equação (2.10), onde a variação da energia em relação à inclinação λ_j , é dada por:

$$\frac{\partial E_H}{\partial \lambda_j} = -\frac{1}{2} \left[\frac{\partial \left(\frac{du_j}{dt} \right)}{\partial \lambda_j} v_j + \frac{du_j}{dt} \frac{\partial v_j}{\partial \lambda_j} \right] \quad (4.13)$$

Realizando operações em cada termo envolvido nas derivadas em relação a λ_j , no lado direito da equação (4.13), resulta:

$$\frac{\partial \left(\frac{du_j}{dt} \right)}{\partial \lambda_j} = \frac{\partial \left(\frac{du_j}{dt} \right)}{\partial v_j} \frac{\partial v_j}{\partial \lambda_j} = \frac{1}{C_j} w_{jj} \frac{\partial v_j}{\partial \lambda_j}, \quad (4.14)$$

e

$$\frac{\partial v_j}{\partial \lambda_j} = \frac{1}{2} \frac{\rho_j^2 - v_j^2}{\rho_j} u_j. \quad (4.15)$$

substituindo as equações (4.14) e (4.15) na equação (4.13), tem-se:

$$\frac{\partial E_H}{\partial \lambda_j} = -\frac{1}{2} \left[\frac{1}{C_j} w_{jj} \frac{1}{2} \frac{\rho_j^2 - v_j^2}{\rho_j} u_j v_j + \frac{du_j}{dt} \frac{1}{2} \frac{\rho_j^2 - v_j^2}{\rho_j} u_j \right]$$

Simplificando, resulta:

$$\frac{\partial E_H}{\partial \lambda_j} = -\frac{1}{4} \frac{1}{C_j} \frac{\rho_j^2 - v_j^2}{\rho_j} \left[w_{jj} v_j + C_j \frac{du_j}{dt} \right] u_j \quad (4.16)$$

Substituindo a equação dinâmica da rede de Hopfield (equação (2.9)), obtém-se:

$$\frac{\partial E_H}{\partial \lambda_j} = -\frac{1}{4} \frac{1}{C_j} \frac{\rho_j^2 - v_j^2}{\rho_j} \left[w_{jj} v_j + \sum_{i=1}^N (w_{ji} v_i) + b_j \right] u_j \quad (4.17)$$

Para atualizar o coeficiente de inclinação, utiliza-se o seguinte critério:

$$\text{Se } \frac{\partial E_H}{\partial \lambda_j}(t-1) * \frac{\partial E_H}{\partial \lambda_j}(t) \geq 0, \text{ então } \lambda_j(t) = (1 + \gamma)\lambda_j(t-1) \quad (4.18)$$

$$\text{Se } \frac{\partial E_H}{\partial \lambda_j}(t-1) * \frac{\partial E_H}{\partial \lambda_j}(t) < 0, \text{ então } \lambda_j(t) = (1 - \gamma)\lambda_j(t-1) \quad (4.19)$$

onde a constante γ (coeficiente de ajuste) é escolhido no intervalo $[0, 1]$.

Este critério de atualização é empírico e comumente empregado em métodos iterativos de otimização: na superfície do hiperplano, se a taxa de variação da energia em relação ao coeficiente angular no instante t e no instante $(t-1)$ têm os mesmos sinais, então se está na região de convergência, e para acelerar esta convergência é acrescido o valor de γ ao valor do coeficiente de inclinação (equação (4.18)). Se a taxa de variação em relação ao coeficiente de inclinação da função não-linear entre os instantes t e $(t-1)$ são opostos, então não se está na região de convergência e conseqüentemente é conveniente realizar o decremento no valor do coeficiente de inclinação (equação (4.19)).

4.2.2.3 Emprego de retardo no processo de estimação de parâmetros

Para aumentar a probabilidade de convergência do estimador, é conveniente a utilização de um retardo que terá a função de adiar o instante de realimentação. Isto é, até o instante de ativação do retardo, a rede de Hopfield não recebe a informação de saída, apenas sendo alimentada no modo *feedforward*. Após a ativação do retardo, a rede também recebe o conhecimento da saída através de ligações que são reinjetadas na rede (modo *backward*). O tempo de espera necessário para ativar o retardo dependerá do sistema que está sendo estimado. Em sistemas lentos, o retardo pode ser ativado assim que é aplicado o estimador; em outros casos, é conveniente esperar um tempo suficiente para que a rede de Hopfield encontre a região de convergência para os pesos sinápticos (veja equações (4.4) e (4.5)).

Deve-se enfatizar aqui que a razão para o emprego do retardo é o fato de haver duas convergências em jogo. Uma é a dos pesos da rede, que vão definir a superfície de energia, e a outra é a das saídas da rede, que vão convergir para um mínimo desta superfície de energia. A forma com que os pesos da rede de Hopfield serão ajustados aumenta a possibilidade de que o ponto de mínimo da superfície de energia vai coincidir com o valor do vetor de parâmetros do modelo de estado. Enquanto os pesos não convergirem, esta associação entre o mínimo da superfície de energia e o valor do vetor de parâmetros não se estabelece.

Para ilustrar o parágrafo anterior, utiliza-se o exemplo do trabalho de CHU *et al.* (1990), que tem 6 parâmetros a serem estimados. Sob as mesmas condições (capacitâncias e coeficiente de inclinação da função de saída dos neurônios), é obtidos o comportamento da saída do estimador recursivo para diferentes retardos explicados neste mesmo item. A Figura 4.3 ilustra o comportamento de alguns pesos sinápticos, ao longo do tempo, para uma excitação do tipo degrau.




Figura 4.3 – Comportamento dos pesos sinápticos ao longo do tempo

Observa-se que todos os pesos sinápticos são inicializados com valores nulos e começam a convergir para o valor final após aproximadamente 2 segs. Alguns pesos atingirão o valor final antes que outros. Assim, por exemplo, o peso sináptico w_{12} atinge o valor final antes que os outros pesos sinápticos.

Deve estar claro que os pesos sinápticos não dependem do instante em que a realimentação é ativada, pois os pesos sinápticos são funções apenas das variáveis de estado, das suas derivada e da excitação; por este motivo, o comportamento dos pesos será sempre o mesmo independente do instante de ativação da realimentação.

Neste exemplo, a realimentação (retardo), foi ativada nos instantes de tempo $t_0 = 0.0$ segs. (sem retardo), $t_1 = 1.0$ seg., $t_2 = 1.5$ segs., $t_3 = 2.5$ segs. e $t_4 = 3.5$ segs., como é mostrado na Figura 4.4. Nesta figura é mostrado o comportamento da saída do neurônio 2, que estima o segundo parâmetro (a_{12}) cujo valor final ao qual deve convergir a saída do neurônio 2 é 12.56.

Na Figura 4.4, observa-se que, ao não empregar nenhum retardo, o valor final é atingido após aproximadamente 6 segs.; já utilizando um retardo de 1.0 seg., o valor final é atingido após aproximadamente 5 segs., com um retardo de 1.5 segs., foi obtido o melhor resultado, e com valores de retardo de 2.5 segs. e 3.5 segs., observa-se um sobresinal (“overshoot”) no momento da ativação da realimentação, o que implica num aumento no tempo de convergência; pois a rede de Hopfield está entrando na fase de saturação, e conseqüentemente irá aumentar o tempo de convergência na saída da rede neural. A amplitude do sobresinal é maior quanto mais saturado estiverem os pesos sinápticos.




Figura 4.4 – Comportamento de uma das saídas do estimador neural

Então, pode-se dizer que, para este exemplo em particular, o tempo conveniente para obter o menor tempo de convergência fica em torno de 2 segs. As outras saídas do estimador tiveram o mesmo padrão de comportamento, variando apenas nas amplitudes do sobresinal.

4.2.3 Implementação do módulo de estimação de parâmetros

Para facilitar o desenvolvimento, este módulo é subdividido em 3 blocos chamados de: *Matriz P-Q*, *Processamento algébrico* e *Rede dinâmica* (veja Figura 4.5).

4.2.3.1 Bloco Matriz P-Q

No bloco *Matriz P-Q*, obtêm-se as matrizes P e Q de acordo com o sistema de equações (2.36). Estas matrizes são associadas às matrizes de pesos sinápticos W e B da rede neural de Hopfield de acordo com as equações (4.4) e (4.5). Como variáveis de entrada neste bloco, são utilizados x , \dot{x} e u , que são respectivamente os vetores de variáveis de estado do sistema

dinâmico, de suas derivadas e de entrada de excitação. A matriz P é alimentada pelos vetores x e u ; e a matriz Q é alimentada pelos vetores x , \dot{x} e u (equações (2.36)). As principais operações realizadas neste bloco são:

- Geração das matrizes P e Q de acordo com as equações (2.36).
- Realização das operações de integração das matrizes P e Q para obtenção das matrizes de pesos sinápticos, W e B , da representação da rede neural de Hopfield, dadas pelas equações (4.4) e (4.5), respectivamente.

4.2.3.2 Processamento algébrico

As matrizes W e B , obtidas no item anterior, e o vetor de saída v da rede neural são utilizados como elementos de entrada deste bloco. A matriz W é multiplicada pelo vetor de saída v da rede neural. O resultado é adicionado ao vetor B que desempenha o papel de polarização da rede neural (veja Figura 2.6).

4.2.3.3 Rede dinâmica

O bloco *rede dinâmica* tem como entrada o vetor de saída do bloco *Processamento algébrico* e como saída a resposta v da rede neural. O bloco de saída tem 3 estágios importantes: $f(\cdot)$ (mapeador não-linear), *ajuste de capacitâncias* e *ajuste de coeficientes de inclinação*.

4.2.3.4 Ajuste de capacitâncias

O ajuste de capacitâncias da rede neural é realizado de maneira automática, de acordo com a equação (4.12), utilizando como entradas as informações obtidas na saída do bloco *Processamento algébrico*, a amplitude máxima p da função não-linear $f(\cdot)$ e o vetor de saída v da rede neural.

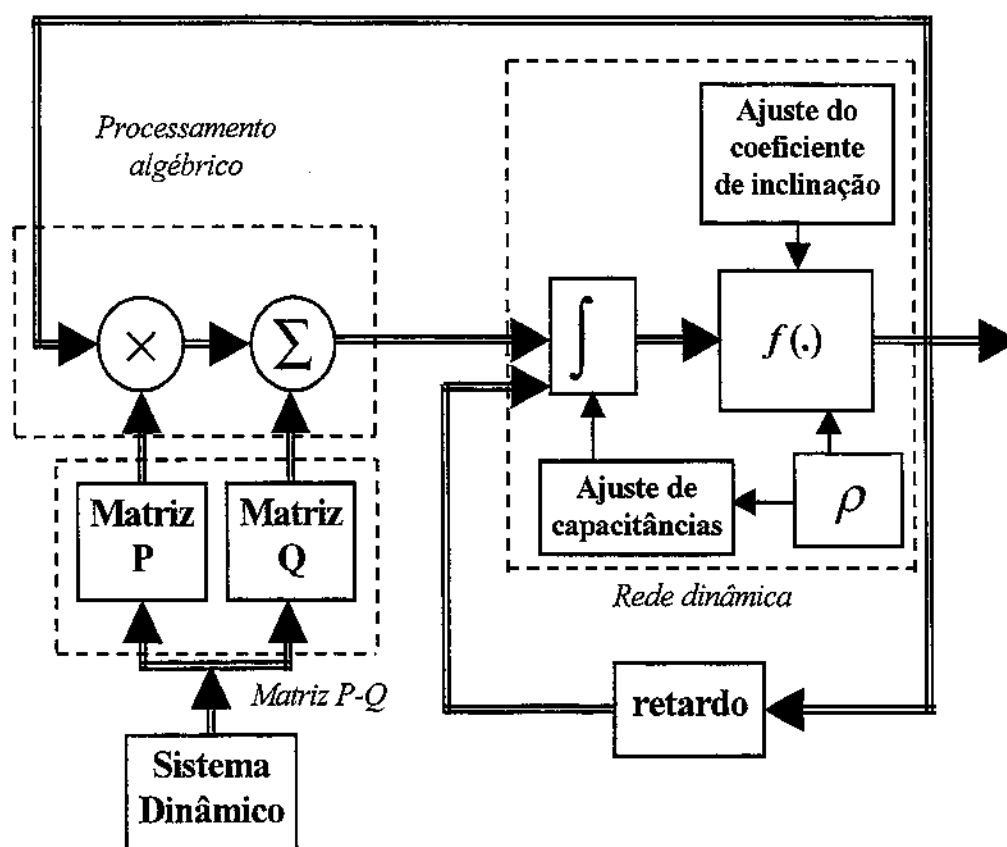


Figura 4.5 - Diagrama esquemático do módulo de estimação

4.2.3.5 Ajuste de coeficientes de inclinação da função não-linear

O ajuste de coeficientes de inclinação da função não-linear é feito de acordo com as equações (4.18) e (4.19), que permitem o acréscimo ou decréscimo do valor do coeficiente de inclinação, o qual está, por sua vez, diretamente associado à aceleração ou desaceleração do processo de convergência da estimação.

4.2.3.6 Retardo

Este bloco tem por objetivo específico, a determinação do instante de ativação da realimentação da saída da rede neural para garantir a convergência. Em primeira instância, apenas são ativados o bloco *matriz P-Q* e o bloco *Processamento algébrico*, por um tempo suficiente para permitir a convergência dos pesos sinápticos. Após a estabilização dos pesos da rede neural, é ativada a entrada do bloco *rede dinâmica* que permite a realimentação da saída do bloco de

Processamento algébrico, como mostra a Figura 4.5, desta maneira garante-se a convergência da rede de Hopfield para o estado correto. O instante de ativação da realimentação depende da dinâmica do sistema dinâmico, cujos parâmetros estão sendo estimados.

4.3 Módulo de pré-processamento

Os sinais obtidos na saída do estimador neural (parâmetros do modelo de estado) são pré-processados antes de serem submetidos ao processo de diagnóstico propriamente dito (ver Figura 4.1). O estágio de pré-processamento é subdividido nos blocos principais mostrados na

Figura 4.6. Junto ao sinal de saída do estimador neural, é aplicado um operador de derivação que tem por objetivo caracterizar mudanças bruscas. O sinal derivado serve como entrada do bloco Diag_0, que tem por objetivo caracterizar qualquer tipo de perturbação. A saída do bloco Diag_0 serve como entrada do bloco Diag_1. O bloco Diag_1 tem por objetivo caracterizar apenas variações do sistema dinâmico, retirando variações devidas à dinâmica do estimador. O sinal de saída dos blocos Diag_1 e Diag_0 e o sinal de saída do estimador são os sinais de entrada do bloco Eval. O bloco Eval tem por objetivo caracterizar os sintomas do sinal obtido na saída do estimador neural (parâmetros estimados pré-processados).

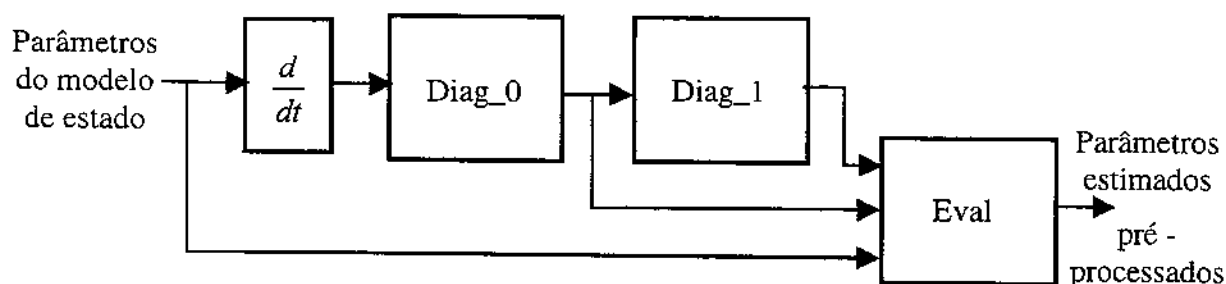


Figura 4.6 - Módulo de pré-processamento

Ainda, antes de os sinais serem submetidos ao estágio de pré-processamento, são realizadas filtragens (quando forem necessárias) que permitam uma melhoria na qualidade do sinal.

Nas Figura 4.7-(a) e Figura 4.7-(b) são representadas uma das saídas do estimador neural (o valor estimado de um dos parâmetros do modelo de estado) e a sua derivada no tempo, respectivamente. Observa-se que existem perturbações em duas instâncias. A primeira

perturbação é devido à dinâmica do estimador neural que, quando ativado, parte de uma condição inicial arbitrária, e a segunda é devido a uma perturbação num dos parâmetros físicos do sistema dinâmico.

4.3.1 Bloco Diag_0

As derivadas dos parâmetros do modelo de estado são utilizadas como entradas do bloco Diag_0. Na Figura 4.7-(b) é representada a derivada de uma das saídas do estimador neural e este sinal serve como entrada do bloco Diag_0. Neste bloco, uma janela deslizante percorre o sinal de entrada (derivada da saída do estimador neural), sendo calculada a média das diferenças das amostras do instante $k + 1$ e do instante k da janela. O resultado é comparado com um valor de *limiar* escolhido. Se o valor da média for maior que o valor do *limiar*, por m vezes consecutivas (onde m deve ser previamente especificado), então, a saída do bloco Diag_0 será ativada; caso contrário, a saída será desativada. A Figura 4.7-(c), mostra o comportamento da saída do bloco Diag_0. Resumindo, este bloco tem por objetivo detectar qualquer tipo de perturbação observada pela janela deslizante, sendo possível calibrar a sensibilidade da detecção pelo ajuste do limiar e do parâmetro m .

4.3.2 Bloco Diag_1

Este bloco tem por objetivo diferenciar a perturbação devida à dinâmica do estimador neural daquela perturbação efetivamente sofrida pelo sistema dinâmico. Isto é, toda vez que é aplicado o estimador neural, a primeira perturbação é assumida como sendo gerada pelo próprio estimador, que parte de uma condição inicial arbitrária, e as próximas perturbações são assumidas como sendo um resultado das perturbações externas ao sistema dinâmico. Sabe-se que o bloco Diag_0 detecta todas as perturbações, isto é, toda vez que acontece alguma perturbação, este bloco gera um sinal ativo (nível 1), caso contrário é gerado um sinal inativo (nível 0). A saída do bloco Diag_0 é utilizada como sinal de entrada do bloco Diag_1. Este sinal é observado até detectar a primeira descida do sinal de entrada, o que significa que o estimador atingiu a convergência (partiu da condição inicial arbitrária e evoluiu até indicar o valor efetivo dos parâmetros) e conseqüentemente não existe mais a perturbação devido à dinâmica do estimador. Para confirmar esta primeira descida é realizada uma comparação com base em um número

suficiente de amostras, isto é, a partir da detecção da primeira descida, são comparadas as próximas amostras para confirmar o evento de descida. A Figura 4.7-(c), mostra que a saída do bloco Diag_1 está no *nível* 0 até o momento em que acontece a primeira descida da saída do bloco Diag_0. A partir da detecção da primeira descida do sinal de entrada, a saída do bloco Diag_1 será sustentada no *nível* 1, indicando que qualquer outra perturbação será causada por uma perturbação externa ao sistema dinâmico.

4.3.3 Bloco Eval

O bloco Eval tem por objetivo detectar níveis estacionários, chamados posteriormente de valores nominais. As condições necessárias para obter-se os valores nominais são: no sinal de saída do bloco Diag_0 deve existir uma transição do nível 1 para o nível 0 e o sinal de saída do bloco Diag_1 deve estar no nível 1. Se as condições necessárias não estão em vigor, então, a saída do sinal do bloco Eval é mantida no nível anterior, caso contrário, o nível de saída muda para o novo valor de saída do estimador neural.

As perturbações detectadas podem ser permanentes ou transitórias. As perturbações permanentes são aquelas nas quais o valor da saída do estimador anterior à perturbação é significativamente diferente do valor após o processo de convergência. As perturbações consideradas transitórias apresentam como característica o fato do valor final ser próximo ou igual ao valor anterior à perturbação. Na Figura 4.7-(e) mostra-se, passo a passo, a saída do bloco Eval. Observa-se que, nos instantes anteriores à convergência, o valor de saída do estimador neural, está no nível 0.

Uma vez que o estimador neural atinge a convergência, a saída do bloco Eval é atualizada ao valor de saída do estimador neural, sendo este considerado como *valor nominal*. Se nos próximos instantes é detectada uma perturbação, a saída do bloco Eval será mantida com o valor anterior à perturbação até que seja detectada a nova fase de convergência. Se, este novo valor for suficientemente próximo ao valor anterior à perturbação, então terá existido apenas uma perturbação do tipo transitória. Caso contrário, terá existido uma perturbação do tipo permanente. O bloco Eval conta também com um parâmetro que controla a sensibilidade da atualização de

valores nominais. Isto é, a atualização pode ser feita sem necessidade de chegar a uma convergência perfeita. Porém, esta consideração traria problemas no sentido de que pode apenas ter ocorrido uma perturbação transitória, e não uma perturbação permanente. Este erro de classificação traria problemas na fase de diagnóstico, sendo que a perturbação transitória poderia vir a ser interpretada como uma perturbação permanente.

Por outro lado, se é adotada uma sensibilidade menor no processo de detecção de perturbação, o diagnóstico poderá ser muito demorado; e em muitas situações isto pode não ser conveniente. Portanto, a calibração do pré-processador deve ser ajustada de acordo com a natureza da aplicação e com o tipo de desempenho desejado.

4.3.4 Problemas de ordem de grandeza no bloco Diag_0

Em algumas situações, existem grandes diferenças relacionadas com a ordem de grandeza dos valores dos parâmetros do modelo de estado. Isto é, existe um mau condicionamento ou problemas de escala entre os valores nos parâmetros do modelo. As consequências destes problemas traduzem-se num conflito na eleição de valores *limiares* satisfatórios para todos os casos, sendo impossível antecipá-los completamente.

Uma das maneiras seria a de normalizar os valores dos parâmetros, mas dependendo da estratégia de normalização, levaria a enfatizar alguns dos valores e outros não. A proposta deste trabalho é utilizar uma normalização logarítmica, de maneira que são enfatizados tanto valores de peso maior quanto valores de peso menor.




Figura 4.7 - Pré-processamento: (a) Saída do estimador neural, (b) derivada da saída do estimador neural, (c) detecção de perturbações, (d) eliminação de perturbações devido ao estimador neural, (e) detecção de perturbações permanentes (a saída do estimador neural está apresentada em tracejado).

A Figura 4.8 mostra o comportamento dos parâmetros tendendo aos valores estacionários. Observa-se que a escala do parâmetro a é bem superior à escala do parâmetro b , e por outro lado observa-se, em ambos os casos, a atenuação de valores altos e a amplificação de valores

pequenos, de maneira que, usando o logaritmo dos valores dos parâmetros, ambos os casos se mostram passíveis de serem analisados ou comparados sob o mesmo limiar.

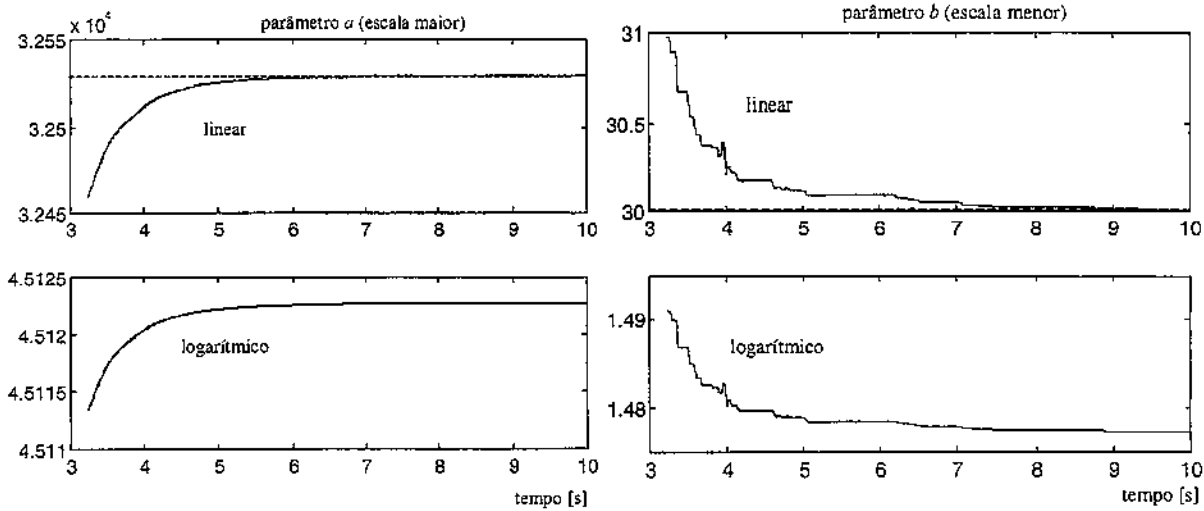


Figura 4.8 - Pré-processamento: normalização logarítmica

4.4 Módulo de diagnóstico

O módulo de diagnóstico tem dois estágios importantes:

- Modelagem qualitativa de falhas de sistemas dinâmicos via grafos direcionados e sinalizados.
- Detecção e diagnóstico de falhas utilizando lógica nebulosa.

4.4.1 Modelagem de falhas de sistemas dinâmicos via grafos direcionados e sinalizados

Para realizar a modelagem de falhas em sistemas dinâmicos é necessário o conhecimento prévio dos parâmetros físicos que participam na definição do comportamento dinâmico do sistema. Assumindo que a estrutura do modelo paramétrico de identificação tem a forma de um modelo linear de espaço de estados representado pela equação (4.20):

$$\dot{x} = Ax + Bu \quad (4.20)$$

onde $A \in \mathbb{R}^{n \times n}$ e $B \in \mathbb{R}^{n \times m}$ são matrizes de parâmetros, podendo ser representadas na forma:

$$A = \{a_{ij}\}, \quad i = 1, 2, \dots, n; \quad e \quad j = 1, 2, \dots, n \quad (4.21)$$

$$B = \{b_{ij}\}, \quad i = 1, 2, \dots, n; \quad e \quad j = 1, 2, \dots, m \quad (4.22)$$

então, cada parâmetro do modelo de estado está relacionado ou é função de parâmetros físicos, os quais formam o conjunto $\Omega \in \mathbb{R}^p$.

$$\Omega = \{\xi_1, \xi_2, \dots, \xi_p\} \quad (4.23)$$

onde, $\xi_1, \xi_2, \dots, \xi_p$ são elementos do conjunto Ω .

É possível expressar formalmente esta dependência como segue:

$$\left. \begin{aligned} a_{ij} &= f_{ij}(\xi_1, \xi_2, \dots, \xi_p), \quad i, j = 1, 2, \dots, n \\ b_{ij} &= g_{ij}(\xi_1, \xi_2, \dots, \xi_p), \quad i, j = 1, 2, \dots, n \end{aligned} \right\} \quad (4.24)$$

Esta relação funcional dependerá do modelo do sistema dinâmico. Por exemplo, seja o sistema dinâmico clássico massa-mola-amortecedor (Figura 4.9):




Figura 4.9 – Sistema dinâmico massa-mola-amortecedor

cuja equação dinâmica é dada na forma:

$$m\ddot{x} + c\dot{x} + kx = u \quad (4.25)$$

onde x é o deslocamento e u é a força externa.

Uma possível representação na forma de modelo de estado é:

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ -\frac{k}{m} & -\frac{c}{m} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{1}{m} \end{bmatrix} u \quad (4.26)$$

onde $x_1 = x$ e $x_2 = \dot{x}$.

Os possíveis eventos fontes de perturbação seriam a rigidez k , o amortecimento c e a massa m , e a relação entre os parâmetros físicos e os parâmetros do modelo de estado são:

$$\begin{aligned} a_{11} &= 0, a_{12} = 1, a_{21} = f_{21}(k, m) = -\frac{k}{m}, a_{22} = f_{22}(c, m) = -\frac{c}{m} \\ b_1 &= 0, b_2 = g_2(m) = \frac{1}{m} \end{aligned} \quad (4.27)$$

A representação qualitativa via grafos direcionados e sinalizados é apresentada na Figura 4.10.




Figura 4.10 – Modelo qualitativo do sistema

Estão sendo considerados, na Figura 4.10, apenas os parâmetros mais influentes, excluindo os parâmetros do modelo de estado que não dependem dos parâmetros físicos (a_{11} , a_{12} e b_1).

4.4.2 Diagnóstico via lógica nebulosa

Uma vez realizada a representação qualitativa, relacionando os parâmetros do modelo de estado com os parâmetros físicos (no exemplo, representado pela Figura 4.10), passa-se ao módulo de diagnóstico via lógica nebulosa, representado pela Figura 4.11.

Os sinais de entrada ao módulo de diagnóstico são os parâmetros do modelo de estado que são interpretados como *sintomas*. Os sintomas podem ser classificados como sintomas referenciais que são obtidos após o estágio de pré-processamento e os sintomas dos parâmetros monitorados pelo estimador que representarão os valores *crisp*.

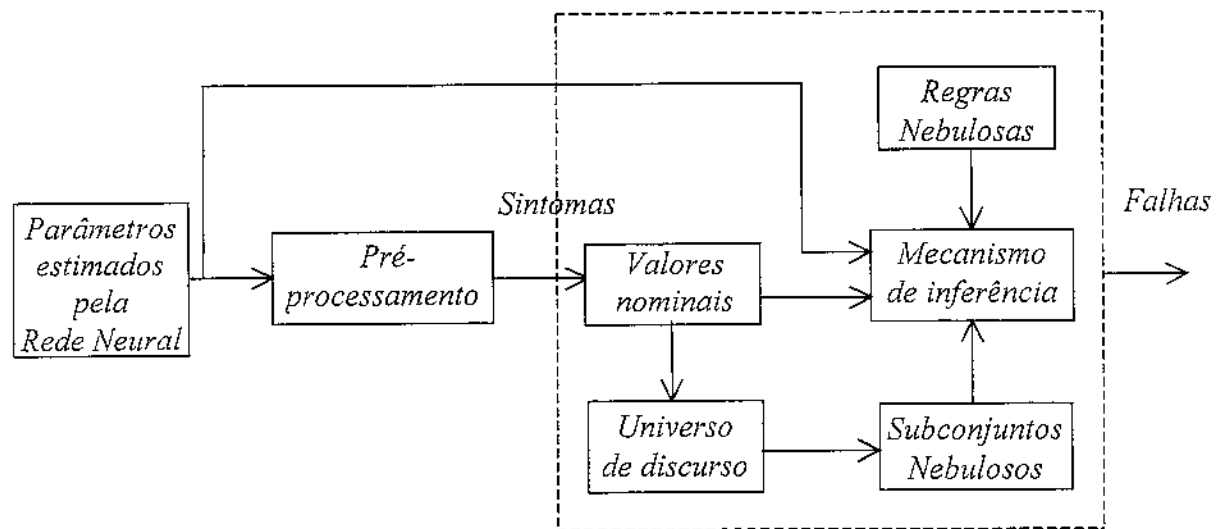


Figura 4.11 - Diagrama esquemático do bloco de diagnóstico nebuloso

A seguir, serão descritos cada um dos blocos do módulo de diagnóstico nebuloso (Figura 4.11).

4.4.2.1 Valores nominais

Uma vez atingida a convergência dos valores de saída do estimador neural, são determinados os chamados valores nominais, que são os valores de parâmetros de referência, sobre os quais serão estruturados os conjuntos universo de discurso para cada parâmetro.

4.4.2.2 Universo de discurso

Conhecidos os valores nominais, são definidos a seguir os conjuntos universo de discurso para cada parâmetro, sendo o valor nominal o centro da faixa do universo que cobre o intervalo $[v_{\text{nom}} - \delta, v_{\text{nom}} + \delta]$. O valor de δ é definido previamente em função das possibilidades de variações máxima e mínima associadas a cada parâmetro.

4.4.2.3 Subconjuntos nebulosos

Para cada universo de discurso dos antecedentes, são definidos os subconjuntos nebulosos que são 3 para cada um dos parâmetros, os quais são nomeados como segue: variação positiva, variação negativa e variação nula. Na Figura 4.12, mostram-se os 3 subconjuntos nebulosos e as suas respectivas funções de pertinência. Observa-se que, se houver um deslocamento à direita,

existirá uma *variação positiva*, se o deslocamento for à esquerda, existirá uma *variação negativa* e, se não houver nenhum deslocamento, então existirá uma *variação nula*.




Figura 4.12 - Definição dos subconjuntos nebulosos dos antecedentes

As funções de pertinência utilizadas para os subconjuntos *variação negativa* e *variação positiva* são do tipo sigmóide:

$$\mu(v) = \frac{1}{1 + e^{a(v-c)}}, \text{ variação negativa} \quad (4.28)$$

$$\mu(v) = \frac{1}{1 + e^{-a(v-c)}}, \text{ variação positiva} \quad (4.29)$$

onde c é o ponto de maior inclinação e a é o coeficiente de inclinação. A função de pertinência do subconjunto *variação nula* é do tipo gaussiana:

$$\mu(v) = e^{-a\left(\frac{v-c}{b}\right)^2} \quad (4.30)$$

onde a controla a largura, b a inclinação e c o centro.

Os consequentes são caracterizados pelas possíveis fontes de falha (parâmetros físicos), que no exemplo são m , k e c . Os consequentes são agrupados num único universo de discurso e

subdivididos em partes iguais. A localização de cada parâmetro é indiferente, sendo independente um parâmetro dos outros. As funções de pertinência são do tipo:

$$\mu(w) = e^{-\alpha \left(\frac{w - w_0}{b} \right)^2} \quad (4.31)$$

onde w_0 é o centro da função, α controla a largura e b controla a inclinação da função.




Figura 4.13 - Definição dos conjuntos das possíveis fontes de falha (conseqüentes)

Enfatiza-se que os parâmetros das funções de pertinência (inclinação e largura) são predefinidos em função da sensibilidade do parâmetro do modelo de estado em questão. O universo de discurso dos conseqüentes é definido num único conjunto.




4.4.2.4 Regras nebulosas

Uma maneira clássica de obter as regras de inferência é utilizar as tabelas que relacionam as variáveis que servem como antecedentes às variáveis que servem como conseqüentes. Os antecedentes são associados aos parâmetros do modelo de estado representados por subconjuntos nebulosos, e os conseqüentes são associados aos parâmetros físicos. No conjunto de variáveis definido, como antecedentes são considerados apenas os parâmetros mais significativos. No exemplo, são os parâmetros a_{21} , a_{22} e b_2 , os quais podem sofrer uma *variação negativa* (N), *variação nula* (Z) ou *variação positiva* (P). Os conseqüentes são representados através de

parâmetros físicos que são as possíveis fontes de falha; a massa m , o coeficiente de amortecimento c e o coeficiente de rigidez k .

Nas regras nebulosas representadas na Tabela 1, apenas são interessantes 3 possíveis regras, sendo as demais de conclusão desconhecida. Neste sentido, não convém analisar todas as combinações possíveis porque a maioria delas não contribui para a conclusão final. Visando reduzir o número de regras propõe-se a utilização de grafos direcionados e sinalizados, que nos permitem seleccionar as regras mais influentes.

Tabela 1- Regras Nebulosas

$b_2 = N$					$b_2 = Z$					$b_2 = P$				
		a_{21}					a_{21}					a_{21}		
		N	Z	P			N	Z	P			N	Z	P
a_{22}	N		x	x	a_{22}	N	x		x	a_{22}	N	x	x	x
	Z	x	x	x		Z	x	x			Z	x	x	x
	P	x	x	x		P	x	x	x		P	x	x	x

Obs. O conseqüente de valor x indica que a conclusão é desconhecida.

As regras nebulosas são obtidas a partir da modelagem qualitativa via grafos direcionados e sinalizados, que relacionam os parâmetros do modelo de estado com os parâmetros físicos. No exemplo, para obter as regras nebulosas utiliza-se o modelo da Figura 4.10. As possíveis regras obtidas a partir do modelo seriam:

Regra 1:

SE $a_{21} \left(-\frac{k}{m} \right)$ tem uma *variação negativa* E $a_{22} \left(-\frac{c}{m} \right)$ tem uma *variação negativa* E $b_2 \left(\frac{1}{m} \right)$

tem uma *variação negativa* ENTÃO a perturbação ocorreu no parâmetro m .

Regra 2:

SE a_{21} tem uma *variação positiva* E a_{22} tem uma *variação nula* E b_2 tem uma *variação nula*
ENTÃO a perturbação ocorreu no parâmetro k .

Regra 3:

SE a_{21} tem uma *variação nula* E a_{22} tem uma *variação positiva* E b_2 tem uma *variação nula*
ENTÃO a possível perturbação ocorreu no parâmetro c .

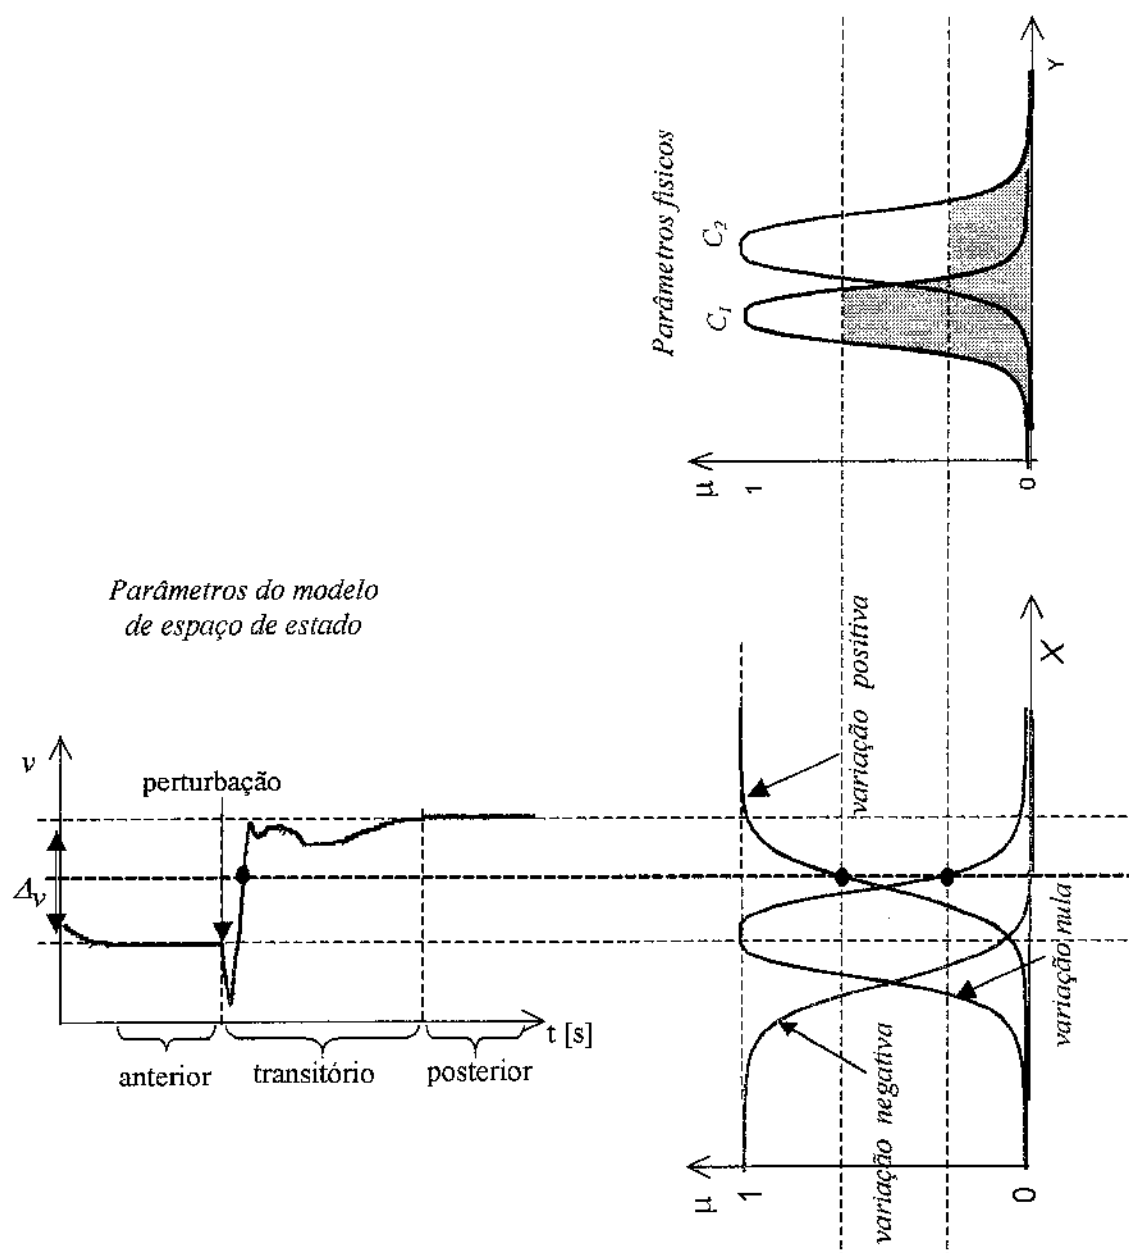


Figura 4.14 - Mapeamento dos parâmetros estimados sobre os conjuntos nebulosos

4.4.2.5 Mecanismo de inferência

Este bloco tem como entrada: os subconjuntos nebulosos já predefinidos, os valores nominais que são os parâmetros referenciais, o conjunto de parâmetros físicos como possíveis fontes ou causas dos eventos de perturbação, o conjunto de regras que relaciona os parâmetros do modelo de estado com o conjunto de parâmetros físicos e os parâmetros estimados recursivamente pela rede de Hopfield. A Figura 4.14 ilustra o mapeamento dos valores estimados sobre os subconjuntos nebulosos.

As funções de pertinência dos subconjuntos nebulosos são definidas de acordo com a sensibilidade do parâmetro estimado. Na ilustração da Figura 4.14, o parâmetro v sofre um acréscimo Δv . Esta variação é mapeada no sistema de diagnóstico sobre os subconjuntos nebulosos. Observa-se que inicialmente o parâmetro do modelo de estado tem o valor nominal (região *anterior*) que, mapeado nos subconjuntos nebulosos, é interpretado com um alto valor de pertinência ao subconjunto *variação nula* (próximo a 1) e com pequeno valor de pertinência para os subconjuntos *variação positiva* e *variação negativa* (próximo a 0).

Em seguida, passa-se à região onde o parâmetro v sofre um evento de perturbação (região *transitória*). Neste estágio, o valor do parâmetro v oscila e sofre um acréscimo Δv . O módulo de diagnóstico mapeará estas variações nas regiões onde estão definidos os subconjuntos *variação nula* e *variação positiva*. Inicialmente terá associado um alto valor de pertinência ao subconjunto *variação nula* e que irá diminuindo aos poucos, e existirá um efeito inverso com o subconjunto *variação positiva*, isto é, associará inicialmente um pequeno valor de pertinência que irá aumentando ao longo do tempo.

No estágio pós-transitório ou estado *posterior*, o parâmetro do modelo de estado se estabilizou em $v + \Delta v$. Este novo valor será mapeado ou associado pelo módulo com um alto valor de pertinência (próximo a 1) ao subconjunto *variação positiva*, sendo insignificante os valores de pertinência associados aos outros subconjuntos (*variação nula* e *variação negativa*).

4.4.2.6 Classificação de falhas

Uma vez mapeados todos os parâmetros do modelo de estado no modelo qualitativo, e uma vez submetidos ao processo de comparação com os subconjuntos definidos a priori, são acionadas as regras de inferência utilizando os operadores nebulosos de implicação e agregação obtendo-se como conclusão os parâmetros físicos associados aos eventos perturbadores. Como medida de possibilidade utiliza-se a técnica clássica de inferência *max - min* de Mamdani, cuja operação está ilustrada na Figura 4.13:

$$\mu_C(Y) = \overbrace{\max_Y}^{\text{agregação}} \left(\overbrace{\min_X}^{\text{implicação}} ((\mu_{A_i \text{ simul}}(X_i), \mu_{B_j \text{ simul}}(X_j)), \mu_R) \right) \quad (4.32)$$

Por exemplo, no modelo qualitativo da Figura 4.10, a *REGRA*, que tem como possível fonte de falha o parâmetro m , tem como antecedentes os parâmetros a_{21} , a_{22} e b_2 onde: X_1 é o universo de discurso para o parâmetro a_{21} , X_2 é o universo de discurso para o parâmetro a_{22} e X_3 é o universo de discurso para o parâmetro b_2 . O conseqüente é o parâmetro m , cujo universo de discurso é Y .

A regra lógica utilizada é:

$$SE \ a_{21} \left(-\frac{k}{m} \right) \text{ tem uma } \textit{variação negativa} \ E \ a_{22} \left(-\frac{c}{m} \right) \text{ tem uma } \textit{variação negativa} \ E \ b_2 \left(\frac{1}{m} \right)$$

tem uma *variação negativa ENTÃO* a perturbação ocorreu no parâmetro m .

Aplicando Mamdani, tem-se a regra nebulosa dada por:

$$\mu_m(Y) = \max_Y \left(\min_X ((\mu_{a_{21}^n}(X_1), \mu_{a_{22}^n}(X_2), \mu_{b_2^n}(X_3)), \mu_R) \right) \quad (4.33)$$

onde o índice n representa uma relação negativa.

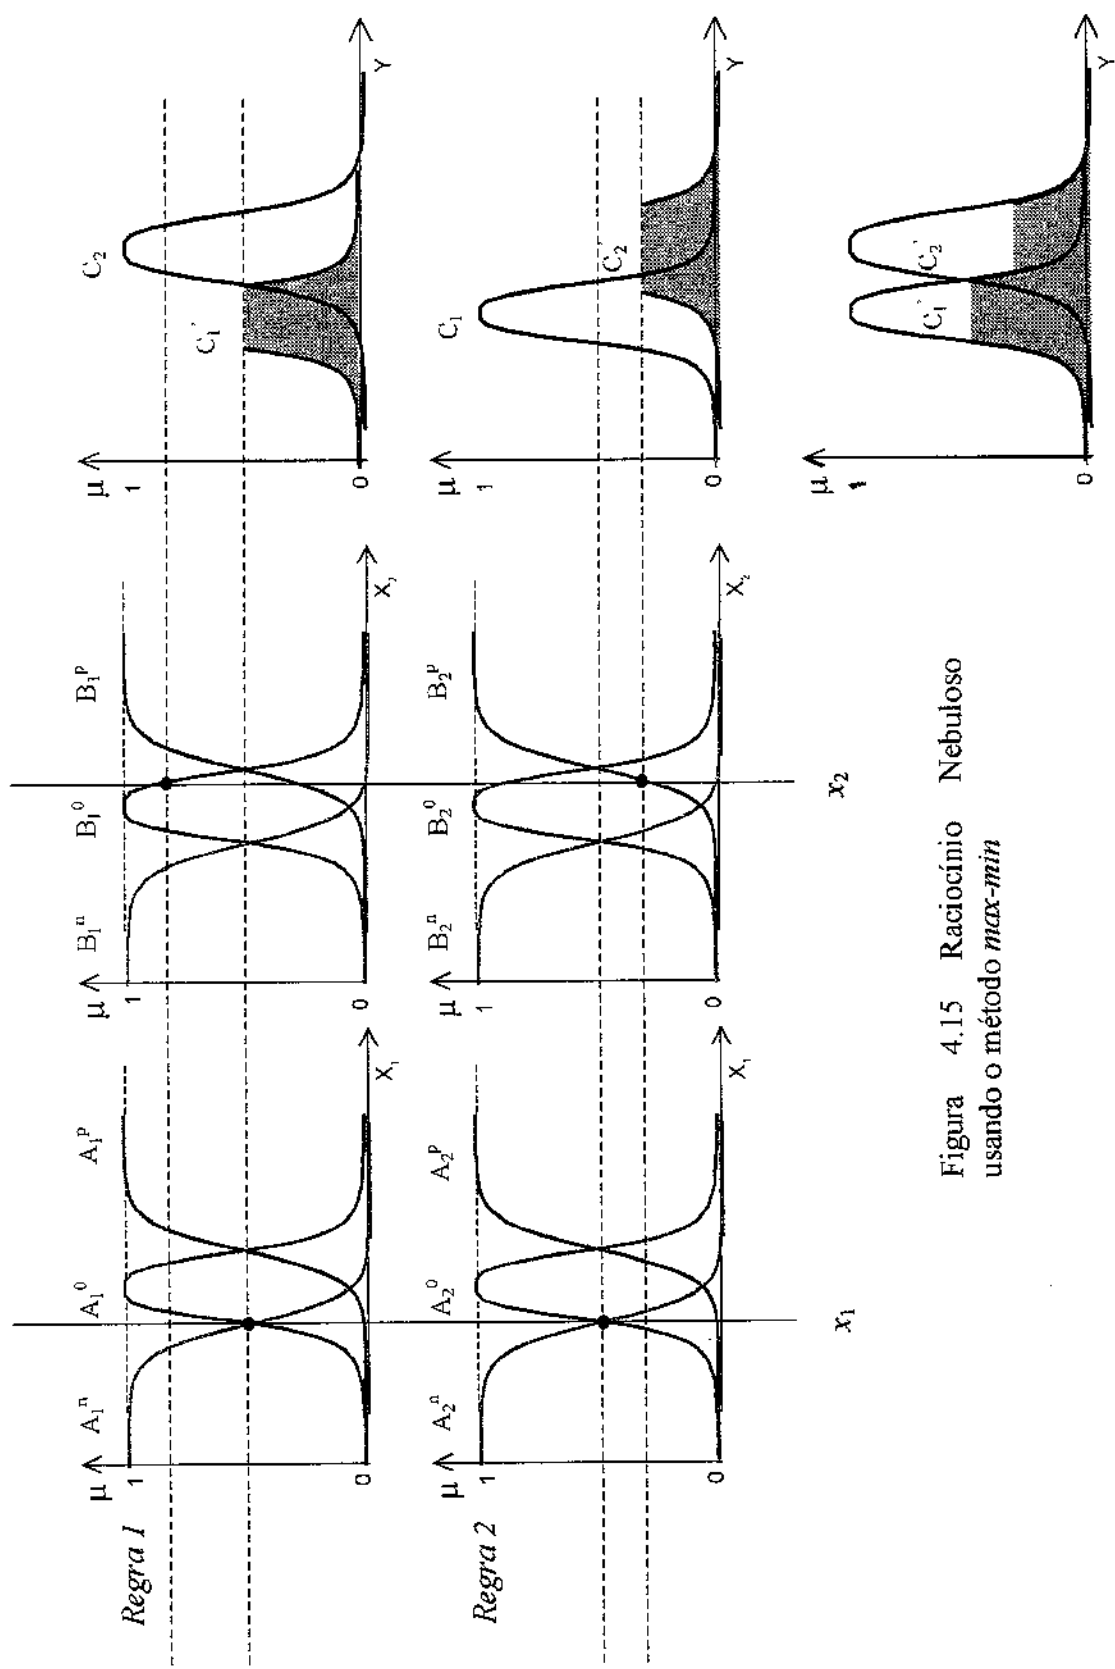


Figura 4.15 Raciocínio Nebuloso usando o método *max-min*

Capítulo 5

Resultados e discussões

Neste capítulo, são apresentados os resultados mais significativos obtidos na fase de estimação de parâmetros do modelo de estado, no processamento dos parâmetros estimados e na determinação das possíveis fontes de perturbações. Estes resultados são extensíveis também a problemas de identificação que requerem o emprego de técnicas de observadores de estados.

5.1 Exemplo clássico de um sistema massa-mola-amortecedor

5.1.1 Processo de estimação de parâmetros

Um sistema dinâmico clássico, com dois graus de liberdade, linear e de corpo rígido, é mostrado na Figura 5.1. Duas massas são interconectadas por molas e amortecedores, a primeira massa é fixada à parede, também por molas e amortecedores, e a segunda massa recebe uma força externa.




Figura 5.1- Sistema dinâmico de dois graus de liberdade

As variáveis x_1 e x_2 são as posições e u é a força externa aplicada à segunda massa. Neste caso, as equações de movimento são:

$$\begin{aligned} m_1 \ddot{x}_1 + (c_1 + c_2) \dot{x}_1 + (k_1 + k_2)x_1 - c_2 \dot{x}_2 - k_2 x_2 &= 0 \\ m_2 \ddot{x}_2 + c_2 \dot{x}_2 + k_2 x_2 - c_2 \dot{x}_1 - k_2 x_1 &= u \end{aligned} \quad (5.1)$$

A representação no modelo de espaço de estados é dado por:

$$\dot{[x]} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ -\frac{k_1 + k_2}{m_1} & \frac{k_2}{m_1} & -\frac{c_1 + c_2}{m_1} & \frac{c_2}{m_1} \\ \frac{k_2}{m_2} & -\frac{k_2}{m_2} & \frac{c_2}{m_2} & -\frac{c_2}{m_2} \end{bmatrix} [x] + \begin{bmatrix} 0 \\ 0 \\ 0 \\ \frac{1}{m_2} \end{bmatrix} [u], \quad (5.2)$$

sendo $[x] = \begin{bmatrix} x_1 \\ x_2 \\ \dot{x}_1 \\ \dot{x}_2 \end{bmatrix}$. Adotando os seguintes valores para os parâmetros (SHAHAM & HASSUL, 1993)

$$m_1 = 10kg, m_2 = 20kg, c_1 = c_2 = 120 \frac{Ns}{m},$$

$$k_1 = 1000 \frac{N}{m}, k_2 = 200 \frac{N}{m}$$

, resulta:

$$\dot{[x]} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ -120 & 20 & -24 & 12 \\ 10 & -10 & 6 & -6 \end{bmatrix} [x] + \begin{bmatrix} 0 \\ 0 \\ 0 \\ 100 \end{bmatrix} [u]. \quad (5.3)$$

São considerados três casos de problema de estimação, todos com $u=rand(t)$, onde $rand(t)$ é uma função que produz valores aleatórios (vide manual de MATLAB®) distribuídos uniformemente no intervalo $[0, 1]$. Este tipo de entrada foi escolhido para garantir uma excitação persistente, a qual é necessária em qualquer processo de estimação, independente da ferramenta

escolhida (NARENDRA & ANNASWAMY, 1989). Os valores dos parâmetros λ_j e C_j da rede de Hopfield ($\frac{du_j(t)}{dt} = \frac{1}{C_j} \left(\sum_{i=1}^N w_{ji} v_i + b_j \right)$ e $v_j = \rho_j \tanh\left(\frac{\lambda_j u_j}{2}\right)$) considerados neste exemplo são fixos ou ajustáveis. Nos casos 1 e 2, são utilizados parâmetros fixos, e no casos 3 e 4, parâmetros ajustáveis (veja as equações 4.12, 4.18 e 4.19).

Caso1: Com $\rho_j = 1000$, $\lambda_j = 0.001$, $C_j=1$, ($j=1, \dots, N$), e w_{ij} ($i=1, \dots, n$; $j=1, \dots, N$) inicializados com valores nulos, e ativando a rede neural dinâmica de Hopfield em $t=0$ seg., obtêm-se os resultados apresentados na Figura 5.2.

Pode-se verificar que não se obteve uma taxa de convergência aceitável (quando comparada com a constante de tempo do sistema), sendo que em alguns casos nem houve convergência para os valores desejados, pois alguns neurônios atingiram o estado de saturação (ver a curva A na Figura 5.2).




Figura 5.2- Desempenho do processo de estimação de parâmetros: caso 1

Caso 2: Com $\rho_j = 1000$, $\lambda_j = 0.001$, $C_j=1$ ($j=1,\dots,N$) e w_{ij} ($i=1,\dots,n$; $j=1,\dots,N$) inicializados com valores nulos, e ativando a realimentação da rede neural de Hopfield em $t=5s$, obtêm-se os resultados mostrados na Figura 5.3.

Neste caso, a rede neural de Hopfield teve tempo suficiente para capturar a informação necessária do sistema dinâmico a ser identificado. Como consequência, foi realizada uma estimação de parâmetros acurada, aliada a um perfil de convergência bastante suave. No entanto, a taxa de convergência ainda é baixa para propósitos práticos.




Figura 5.3 - Desempenho do processo de estimação de parâmetros: caso 2

Caso 3. Com $\rho_j = 1000$, $\lambda_j = 0.001$, $C_j=0.3$ ($j=1,\dots,N$) e w_{ij} ($i=1,\dots,n$; $j=1,\dots,N$) inicializados com valores nulos, e ativando a rede neural de Hopfield em $t=5s$, obtêm-se os resultados apresentados na Figura 5.4, onde são indicados os parâmetros do modelo de espaço de estados que estão sendo estimados. Esta indicação não havia sido feita nas estimações realizadas e mostradas através da Figuras 5.2 e 5.3 por ainda não apresentarem o resultado final de convergência do processo de estimação.




Figura 5.4- Desempenho do processo de estimação de parâmetros: caso 3

Caso 4. Como o processo de otimização aqui empregado é inerentemente recursivo, também podem ser identificados parâmetros que variam no tempo. O requisito fundamental reside na taxa de convergência da rede neural de Hopfield, a qual deve ser maior que a taxa de variação dos parâmetros. Sem dúvida, este é o principal fator para atestar a importância de se ajustar otimamente os valores das capacitâncias C_j ($j=1,\dots,N$). Neste caso, escolhendo valores mais apropriados para as capacitâncias C_j ($j=1,\dots,N$), obteve-se uma taxa de convergência muito superior. A adoção de valores distintos e otimamente definidos para cada C_j ($j=1,\dots,N$) pode conduzir a resultados ainda melhores, pois representam uma iniciativa no sentido de explorar ao máximo toda a flexibilidade proporcionada pelo modelo dinâmico da rede de Hopfield.

Usando $C_j=0.3$ ($j=1,\dots,N$), a Figura 5.5 mostra o desempenho da rede neural de Hopfield no acompanhamento *on-line* do parâmetro a_{42} , sujeito a uma variação senoidal em torno do seu valor nominal: $a_{42} = a_{42}^{nom} + 0.5 \cdot \sin(2 \cdot \pi \cdot 0.025 \cdot t)$. Repare que todos os outros parâmetros devem ser estimados simultaneamente pela rede neural de Hopfield (eles não são apresentados na Figura 5.5

por propósitos de visualização). Os resultados apresentados neste trabalho são extensíveis também a problemas de identificação em que o vetor de variáveis de estado não é completamente acessível (HUALLPA *et al.*, 1997a), exigindo o emprego de técnicas de observadores de estados (KREISSELMEIER, 1977; SHOURESHI & CHU, 1993).




Figura 5.5- Desempenho do processo de estimação de parâmetros: sistema não-estacionário

5.1.2 Processo de detecção de perturbações bruscas nos parâmetros do modelo de estado

As saídas da rede neural de Hopfield servem como entradas do módulo de detecção de perturbações estruturais do sistema dinâmico. A Figura 5.6 mostra a convergência inicial dos parâmetros do modelo de estado. Como pode ser observado, o estimador é ativado após três segundos.

Foi dado esse tempo para que a rede neural pudesse extrair convenientemente a informação do sistema dinâmico (HUALLPA *et al.*, 1997), sujeito a uma condição de excitação persistente $u(t)$ (NARENDRA & ANNASWAMY, 1989). Este atraso no instante de início da ativação do estimador produz consequências favoráveis à qualidade e robustez do processo de estimação, pois impede

que estimativas sejam obtidas enquanto o estimador encontra-se em processo de extração das primeiras informações junto ao sistema dinâmico. A desinformação inicial do estimador poderia conduzir à divergência dos valores estimados, como apresentado na Figura 5.2.




Figura 5.6- Desempenho do processo de estimação de parâmetros sem perturbação

5.1.2.1 Perturbação no parâmetro físico k_1

A Figura 5.7 mostra o desempenho do mesmo estimador de parâmetros empregado para produzir os resultados da Figura 5.6, porém existindo agora uma perturbação permanente a partir de 15 segundos. Neste caso foi simulado a perturbação permanente no parâmetro físico k_1 .

Observa-se que o parâmetro físico k_1 terá influência apenas no parâmetro $a_{31} = \frac{k_1 + k_2}{m_1}$ da representação do modelo de estado como pode ser observado na equação (5.2). Repare que uma perturbação no parâmetro físico k_1 afetará diretamente o comportamento da variável x_1 .

Como o estimador só tem acesso ao valor no tempo desta variável e de sua primeira derivada, da equação (5.2) deduz-se que, em princípio, todos os outros parâmetros, além de k_1 , são candidatos em potencial a serem responsáveis pela perturbação, o que explica as variações

transitórias junto a outros parâmetros do modelo de estado (veja Figura 5.7). Os valores dos parâmetros do modelo de estado, anteriores e posteriores ao instante de perturbação, são detalhados na Tabela 5.1. Observa-se que o único parâmetro que muda é a_{31} , como esperado. O comportamento dos módulos do processo de detecção é mostrado nas suas três fases: **Diag_0**, **Diag_1** e **Eval**, na Figura 5.8.




Figura 5.7. Desempenho do processo de estimação de parâmetros com perturbação permanente em um dos parâmetros físicos (10% do seu valor inicial).

Tabela 5.1 – Valores na saída do estimador para uma perturbação no parâmetro k_1

Parâmetro	Valor	Valor
a_{31}	-120	-110
a_{32}	20	20
a_{33}	-24	-24
a_{34}	12	12
a_{41}	10	10
a_{42}	-10	-10
a_{43}	6	6
a_{44}	-6	-6

Como pode ser observado na Figura 5.8, o primeiro módulo, denominado **Diag_0**, tem como saída inicial o nível "0", indicando a ausência de perturbação. Mas assim que o estimador é

ativado no instante de $t = 3$ segs., este módulo vai ter sua saída chaveada para o nível "1", indicando a presença de algum tipo de perturbação (neste caso, devido à condição inicial inadequada do estimador). Em aproximadamente $t = 10$ segs., muda de novo para o nível "0". Isto porque o estimador concluiu o processo de detecção da condição de operação do sistema, produzindo estimativas estáveis a partir deste ponto (enquanto não ocorrerem novas perturbações). No instante $t = 15$ segs., a saída do módulo **Diag_0** apresenta novamente o nível "1" indicando a ocorrência de algum tipo de perturbação, e continua neste estado até aproximadamente $t = 20$ segs., quando oscila (indicando indecisão) e finalmente entra de novo no estado estável "0", indicando que não existe mais perturbação.

O módulo **Diag_1** tem por objetivo eliminar a primeira perturbação, que é sempre devido à condição inicial inadequada do estimador. Na Figura 5.8, observa-se que a saída deste módulo se mantém no nível "0" até aproximadamente $t = 10$ segs., quando ocorre a primeira descida da saída do módulo **Diag_0**, isto é, no momento em que o estimador começa a indicar a convergência para um estado estável.




Figura 5.8 - Desempenho do processo de detecção nas suas três fases

É importante salientar que existe uma fase transitória em que vários parâmetros do modelo de estado são candidatos à perturbação. Porém a fase **Eval** determina que parâmetros foram realmente afetados, desprezando aqueles considerados candidatos falsos (HUALLPA *et al.*, 1997b). Observa-se também que a saída da fase **Eval**, após ter conferido a presença de uma perturbação continuada, considera este novo valor como referência para os próximos eventos.

A Figura 5.9 mostra perturbações múltiplas nos parâmetros do modelo de estado. Estas perturbações dependerão da relação existente entre os parâmetros do modelo de estado e os parâmetros físicos. Neste exemplo, ocorreu uma diminuição nos parâmetros físicos k_2 e c_2 , de maneira que houve também uma diminuição (em módulo) de todos os parâmetros do modelo de estado afetados.




Figura 5.9- Desempenho do processo de estimação para múltiplas perturbações

5.1.2.2 Perturbação no parâmetro físico k_2

Promove-se agora uma perturbação, no instante $t = 15$ segs., no parâmetro físico k_2 . De acordo com a equação (5.2), esta perturbação afetará os parâmetros do modelo de estado a_{31} , a_{32} , a_{41} e a_{42} , conforme mostra a Figura 5.9.

Nas Figuras 5.10 e 5.11 mostra-se o desempenho de detecção das fases **Diag_0**, **Diag_1** e **Eval** para os parâmetros do modelo de estado a_{31} e a_{41} , respectivamente, para uma perturbação contínua no parâmetro físico k_2 . Observa-se nitidamente a importância da fase **Eval** que avalia cada um dos parâmetros perturbados e a responsabilidade que ela tem na aceitação ou rejeição de uma perturbação considerada permanente. As Figuras 5.12 e 5.13, mostram que os parâmetros do modelo de estado a_{33} e a_{44} apresentam-se inicialmente como possíveis fontes de perturbação permanente, porém esta possibilidade é descartada pela fase **Eval** por não existir uma forte tendência afirmativa. Se a fase **Eval** não fosse considerada seria impossível a diferenciação entre uma perturbação permanente e uma perturbação transitória.




Figura 5.10- Desempenho de detecção de variação no parâmetro a_{31} , dada a perturbação em k_2




Figura 5.11- Desempenho de detecção de variação no parâmetro a_{31} , dada a perturbação em k_2




Figura 5.12- Desempenho de detecção de variação no parâmetro a_{33} , dada a perturbação em k_2




Figura 5.13- Desempenho de detecção de variação no parâmetro a_{34} , dada a perturbação em k_2

5.1.3 Parâmetro de sensibilidade que regula a aceitação de uma perturbação permanente

A fase **Eval** contém um parâmetro de sensibilidade β que regula o processo de aceitação ou não do novo valor do parâmetro do modelo de estado após a detecção de uma perturbação. A perturbação pode ser detectada ao final do processo de convergência da estimação, como mostra a Figura 5.14. Esta situação é considerada apropriada quando se procura aumentar a confiança na existência de uma perturbação. Já em situações em que se procura detectar variações no menor tempo possível, então é conveniente utilizar um menor valor de sensibilidade β , o que é mostrado na Figura 5.15. Observa-se nesta figura que, assim que foi detectada uma perturbação significativa, esta é rapidamente caracterizada como uma perturbação permanente. Observe que as perturbações promovidas junto ao sistema dinâmico são idênticas nos casos tratados (veja Figura 5.14 e Figura 5.15).




Figura 5.14 - Detecção da perturbação permanente ao final do processo de convergência




Figura 5.15 - Detecção da perturbação permanente imediatamente após seus primeiros efeitos

5.2 Modelagem qualitativa de diagnóstico de falhas permanentes em sistemas dinâmicos utilizando modelos de grafos direcionados sinalizados

Após a estimação de parâmetros do modelo de estado e a determinação daqueles que sofreram uma perturbação permanente, é realizado o diagnóstico utilizando em primeira instância o método de *grafos direcionados sinalizados* (GDS), que para o exemplo da Figura 5.1 é dado através do modelo qualitativo representado pela Figura 5.16, o qual relaciona os parâmetros do modelo de estado com os parâmetros físicos.




Figura 5.16 - Modelo do grafo direcionado sinalizado para gerar as regras de inferência

Esta associação é realizada utilizando a equação (5.2) e as ligações relacionais (cada qual podendo ser direta ou inversa) existentes entre nós vizinhos, permitindo a obtenção do modelo de GDS (HUALLPA *et al.*, 1998a, HUALLPA *et al.*, 1999). Assim, por exemplo, entre os nós k_1 e k_1/m_1 existe uma relação positiva, porém a relação entre os nós m_1 e k_1/m_1 é negativa (ver Figura 5.16),

da mesma maneira se diz que a relação dos nós k_1/m_1 e k_2/m_1 em relação ao nó $(k_1 + k_2)/m_1$ é positiva, e assim sucessivamente.

5.3 Regras de inferência

Utilizando o modelo GDS são determinadas as regras de inferência que permitirão definir uma possível fonte causadora de uma falha. As duas primeiras linhas da matriz da equação (5.2) não são levadas em consideração porque os elementos da matriz do modelo de estado não estão relacionados com as possíveis fontes de falha, de maneira que apenas as duas últimas linhas são consideradas.

1. SE a_{31} E a_{32} E a_{33} E a_{34} E apresentam uma variação negativa ENTÃO a possível fonte de falha é m_1 .
2. SE a_{31} apresenta uma variação positiva E a_{32} apresenta uma variação nula ENTÃO a possível fonte de falha é k_1 .
3. SE a_{33} apresenta uma variação positiva E a_{34} apresenta uma variação nula ENTÃO a possível fonte de falha é c_1 .
4. SE a_{41} E a_{42} E a_{43} E a_{44} apresentam uma variação negativa ENTÃO a possível fonte de falha é m_2 .
5. SE a_{31} apresenta uma variação positiva E a_{32} apresenta uma variação positiva E a_{41} apresenta uma variação positiva ENTÃO a possível fonte de falha é k_2 .
6. SE a_{33} apresenta uma variação positiva E a_{34} apresenta uma variação positiva E a_{43} apresenta uma variação positiva ENTÃO a possível fonte de falha é c_2 .

5.4 Diagnóstico de falhas permanentes em sistemas dinâmicos utilizando lógica nebulosa

Os sinais de saída da rede neural de Hopfield, correspondentes aos parâmetros do modelo de estado, são utilizados como entrada do bloco de processo de detecção de perturbação permanente, o qual diferencia perturbações permanentes de perturbações transitórias. Após este processo de diferenciação, é realizado o processo de diagnóstico. O processo de diagnóstico proposto consiste em utilizar as técnicas de lógica binária (baseada na inteligência artificial clássica) e lógica nebulosa.

Em primeira instância o diagnóstico é realizado utilizando lógica binária, tendo como conhecimento a base as regras de inferência do item 5.3. A saída do bloco de diagnóstico via lógica binária será ativada, representada por "+1", e inibida, representada por "0". A ativação de uma saída está associada à existência de uma perturbação permanente vinculada ao parâmetro que representa esta saída. De maneira semelhante, a inibição de uma saída está associada à não existência ou a uma perturbação transitória no parâmetro físico que representa esta saída.

5.4.1 Diagnóstico via lógica binária para uma perturbação permanente no parâmetro físico c_1

Como primeiro exemplo de observação do desempenho do método de diagnóstico via lógica binária, submete-se o parâmetro físico c_1 a uma perturbação permanente. De acordo com a equação (5.2), espera-se que o único elemento a ser afetado seja o parâmetro do modelo de estado a_{33} , sendo que os outros parâmetros sofrem apenas perturbações transitórias. Para observar melhor este fato, na Figura 5.17 são mostrados alguns dos parâmetros do modelo de estado, inclusive o parâmetro a_{33} , que é o elemento de interesse. A linha contínua representa o valor estimado e a linha tracejada representa o valor detectado pela fase **Eval**, que determina a aceitação ou não de um novo valor referencial após uma perturbação. Observa-se que a perturbação no sistema dinâmico inicia-se no instante $t = 15$ segs. O bloco **Eval** valida ou detecta a perturbação após 5 segs., aproximadamente, depois de ocorrida a perturbação. Desta maneira, espera-se que o diagnóstico seja realizado após a validação do bloco **Eval**.

A Figura 5.18 mostra o desempenho do sistema de diagnóstico via lógica binária para uma perturbação permanente no parâmetro físico c_1 . Observa-se que o diagnóstico esperado é obtido somente ao término do processo de detecção de uma perturbação permanente, que ocorre aproximadamente no instante $t = 20$ segs., momento em que a fase transitória de estimação termina. Observa-se também que a não existência de uma perturbação permanente é representada pelo sistema de diagnóstico com o valor "0", enquanto que uma falha ou uma perturbação permanente é representada com o valor "+1".




Figura 5.17– Evolução de alguns valores dos parâmetros do modelo de estado quando o parâmetro físico c_1 é submetido a uma perturbação permanente




Figura 5.18 – Desempenho do diagnóstico, para uma perturbação permanente no parâmetro físico c_1 , utilizando lógica binária.

5.4.2 Diagnóstico via lógica binária para uma perturbação permanente no parâmetro físico c_2

Como segundo exemplo de observação do desempenho do método de diagnóstico em discussão, é aplicada ao parâmetro físico c_2 uma perturbação permanente. De acordo com a equação (5.2), espera-se que os parâmetros do modelo de estado a_{33} , a_{34} , a_{43} e a_{44} sofram perturbações permanentes. A Figura 5.19 mostra apenas o comportamento que corresponde à última linha da matriz dos parâmetros do modelo de estado da equação (5.2). A linha contínua representa o valor estimado e a linha tracejada representa o valor detectado pela fase **Eval** que determina a aceitação ou não de um novo valor referencial após uma perturbação.




Figura 5.19 – Evolução da última linha da matriz dos parâmetros do modelo de estado quando o parâmetro físico c_2 é submetido a uma perturbação permanente




Figura 5.20 – Desempenho do diagnóstico, para uma perturbação permanente no parâmetro físico c_2 , utilizando lógica binária.

A Figura 5.20 mostra o desempenho do sistema de diagnóstico para uma perturbação permanente no parâmetro físico c_2 . Observa-se que o diagnóstico esperado é obtido somente ao término do processo de detecção (HUALLPA *et al.*, 1999) de uma perturbação permanente que ocorre aproximadamente no instante $t = 20$ segs., que é o momento em que a fase transitória de estimação termina. Observa-se também que o parâmetro físico c_1 apresentou-se em princípio como um possível candidato a ser fonte da perturbação. Isto ocorreu porque o parâmetro do modelo de estado a_{33} é também função do parâmetro físico c_1 . Apesar de terem ocorrido perturbações transitórias nos outros parâmetros do modelo de estado, o método de diagnóstico mostrou-se insensível a este tipo de evento, conforme desejado.

5.5 Diagnóstico de falhas permanentes em sistemas dinâmicos utilizando lógica nebulosa

Nesta seção, o processo de diagnóstico irá empregar técnicas baseadas em lógica nebulosa, no lugar de lógica binária.

5.5.1 Desempenho do método de diagnóstico utilizando lógica nebulosa para uma perturbação permanente no parâmetro físico c_1

Para uma perturbação no parâmetro c_1 (HUALLPA *et al.*, 1998a), cujo efeito nos parâmetros do modelo de estado é apresentado na Figura 5.17, foram obtidos resultados mostrados na Figura 5.21.




Figura 5.21 - Desempenho de diagnóstico por lógica nebulosa para uma perturbação permanente no parâmetro físico c_1 .

Na Figura 5.21 observa-se a evolução do diagnóstico de uma perturbação permanente no parâmetro físico c_1 . O parâmetro físico k_1 , é inicialmente considerado como um outro possível candidato a ter sofrido uma perturbação permanente. Porém, após alguns segundos esta possibilidade é descartada caracterizando apenas uma perturbação transitória. Os outros parâmetros, como c_2 e k_2 , não se apresentam em nenhuma circunstância como candidatos a terem sofrido uma perturbação.

5.5.2 Desempenho do método de diagnóstico utilizando lógica nebulosa para uma perturbação permanente no parâmetro físico c_2

Para uma perturbação no parâmetro físico c_2 no instante $t = 15$ segs., as consequências e o processo de detecção de perturbações nos parâmetros do modelo de estado são mostrados na Figura 5.22.




Figura 5.22 - Desempenho de diagnóstico por lógica nebulosa para a perturbação permanente no parâmetro físico c_2 .

5.5.3 Comparação dos métodos de diagnóstico utilizados

Na Figura 5.23 é mostrado e comparado o desempenho dos métodos de diagnóstico utilizados para uma perturbação permanente no parâmetro físico c_1 . Observa-se que o diagnóstico utilizando lógica nebulosa mostra inicialmente que os parâmetros físicos c_1 e k_1 são candidatos a terem sofrido uma perturbação permanente, após alguns segundos (3 segs. aproximadamente), o diagnóstico mostra que o único parâmetro físico que sofreu uma perturbação permanente foi c_1 . O diagnóstico por lógica binária depende principalmente do grau de sensibilidade de detecção realizada pelo bloco **Eval** (veja Figura 5.17). Neste caso em particular, o instante de ativação

ocorreu no instante $t = 20$ segs., e o diagnóstico foi correto indicando o parâmetro físico c_1 como o elemento que sofreu uma perturbação permanente.

De maneira semelhante ao caso tratado no parágrafo anterior, na Figura 5.24 é mostrado e comparado o desempenho dos métodos de diagnóstico utilizados para uma perturbação permanente no parâmetro físico c_2 . Observa-se, que o diagnóstico via lógica nebulosa é mais rápido que o diagnóstico via lógica binária nos dois casos. Além disso, é mostrado que o diagnóstico via lógica binária não identificou a falha correta imediatamente, mostrando inicialmente o parâmetro c_1 como fonte de falha. O diagnóstico via lógica nebulosa é efetuado corretamente 2 segs. após a perturbação ao qual foi submetido o sistema dinâmico, enquanto que com a utilização da lógica binária demorou em torno de 5 segs.

Em geral, o diagnóstico via lógica nebulosa mostrou-se mais eficiente que o diagnóstico via lógica binária. O principal motivo é que o diagnóstico via lógica binária requer que o sistema ingresse no estado estável, enquanto o diagnóstico utilizando lógica nebulosa começa a mostrar algumas conclusões (resposta de diagnóstico) logo após a detecção da perturbação nos parâmetros do modelo de estado, sem a necessidade de ter que esperar até a estabilização no novo estado.




Figura 5.23 – Comparação entre os métodos de diagnóstico para a perturbação permanente no parâmetro físico c_1 : lógica binária (--) e lógica nebulosa (—).




Figura 5.24 – Comparação entre os métodos de diagnóstico para a perturbação permanente no parâmetro físico c_2 : lógica binária (--) e lógica nebulosa (—).

5.6 Exemplo de um sistema de vibração torcional

5.6.1 Modelo de espaço de estado do sistema dinâmico

No sistema dinâmico apresentado na Figura 5.25, o motor faz girar a carga que consiste de duas polias de momentos de inércia J_1 e J_2 , respectivamente, acopladas por um eixo de rigidez k e fator de amortecimento c .




Figura 5.25 – Sistema clássico de vibração torcional

As variáveis θ_1 e θ_2 representam as posições angulares das polias e u é a corrente aplicada ao motor. A dinâmica do sistema é dada pela equação (5.4). Além dos parâmetros físicos e mecânicos, considera-se o parâmetro de acoplamento eletromecânico, representado por k_a .

$$\begin{cases} J_1 \ddot{\theta}_1 + c\dot{\theta}_1 - c\dot{\theta}_2 + k\theta_1 - k\theta = k_a u \\ J_2 \ddot{\theta}_2 - c\dot{\theta}_1 + c\dot{\theta}_2 - k\theta_1 + k\theta = 0 \end{cases} \quad (5.4)$$

A partir da equação (5.4), é construída a representação por espaço de estados, dada pela equação (5.5), onde como variáveis de estado foram escolhidos os deslocamentos angulares θ_1 e θ_2 e as velocidades angulares $\dot{\theta}_1$ e $\dot{\theta}_2$.

$$\begin{bmatrix} \dot{x} \end{bmatrix} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ -\frac{k}{J_1} & \frac{k}{J_1} & -\frac{c}{J_1} & \frac{c}{J_1} \\ \frac{k}{J_2} & -\frac{k}{J_2} & \frac{c}{J_2} & -\frac{c}{J_2} \end{bmatrix} \begin{bmatrix} x \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ \frac{k_a}{J_1} \\ 0 \end{bmatrix} \begin{bmatrix} u \end{bmatrix}, \text{ onde } \begin{bmatrix} x \end{bmatrix} = \begin{bmatrix} \theta_1 \\ \theta_2 \\ \dot{\theta}_1 \\ \dot{\theta}_2 \end{bmatrix}. \quad (5.5)$$

Adotando o conjunto de valores dos parâmetros físicos na forma:

$$J_1 = 10/9, J_2 = 10, c = 0.1, k = 1, k_a = 1 \quad (5.6)$$

A substituição dos valores dos parâmetros presentes no sistema de equações (5.6) na equação (5.5) produz a equação (5.7):

$$\begin{bmatrix} \dot{x} \end{bmatrix} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ -0.9 & 0.9 & -0.09 & 0.09 \\ 0.1 & -0.1 & 0.01 & -0.01 \end{bmatrix} \begin{bmatrix} x \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix} \begin{bmatrix} u \end{bmatrix}. \quad (5.7)$$

5.6.2 Processo de estimação dos parâmetros do modelo de estado

Como estimador de parâmetros do modelo de estado é utilizada a rede neural de Hopfield, com 20 neurônios de saída e uma entrada. A entrada é do tipo aleatória ($u=10 \text{ rand}(t)$), onde $\text{rand}(t)$ produz valores aleatórios distribuídos uniformemente no intervalo $[0, 1]$, para garantir uma excitação persistente. Os parâmetros da função não-linear dos neurônios têm amplitude $\rho_j = 1000$ e coeficiente de inclinação inicial $\lambda_j = 0.001$.

5.6.3 Modelo GDS para o sistema dinâmico da Figura 5.25

O sistema dinâmico da Figura 5.25 tem seu modelo GDS (HUALLPA *et al.*, 1998b) mostrado na Figura 5.26, onde os nós finais correspondem aos parâmetros do modelo de estado e os nós de partida (fontes) correspondem aos parâmetros físicos.




Figura 5.26 - Modelo GDS para o sistema dinâmico da Figura 5.25

5.6.4 Construção de regras nebulosas

Para construir as regras nebulosas, são utilizados os elementos da matriz de estado da equação (5.5) e o modelo GDS da Figura 5.26. Os elementos da matriz de estado são dados pelas relações:

$$\begin{aligned} a_{31} &= -a_{32} = f_1(k, J_1); & a_{33} &= -a_{34} = f_3(c, J_1) \\ a_{41} &= -a_{42} = f_2(k, J_2); & a_{43} &= -a_{44} = f_4(c, J_2) \end{aligned} \quad (5.8)$$

e algumas regras de inferência nebulosas são como as que seguem:

SE a_{31} apresenta uma variação positiva E a_{41} apresenta uma variação positiva ENTÃO a possível fonte de falha é k .

SE a_{33} apresenta uma variação positiva E a_{43} apresenta uma variação positiva ENTÃO a possível fonte de falha é c .

SE a_{31} apresenta uma variação negativa E a_{32} apresenta uma variação negativa E a_{33} apresenta uma variação negativa E a_{34} apresenta uma variação negativa ENTÃO a possível fonte de falha é J_1 .

5.6.5 Evolução de parâmetros do modelo de estado para uma perturbação permanente no parâmetro c

O parâmetro físico c (coeficiente de amortecimento) é submetido a uma perturbação permanente do tipo degrau no instante $t = 30$ segs., sendo que a Figura 5.27 apresenta o comportamento do processo de estimação envolvendo alguns parâmetros do modelo de estado. Observa-se a não existência de perturbações nos parâmetros a_{31} e a_{32} , enquanto os parâmetros a_{33} e a_{34} apresentam perturbações permanentes. Os sintomas apresentados pelos parâmetros do modelo de estado, indicam que o diagnóstico apenas dependerá do sistema de diagnóstico nebuloso.

5.6.6 Evolução do sistema de diagnóstico nebuloso para uma perturbação no parâmetro c

Utilizando as regras de inferência para o diagnóstico nebuloso, obtidas a partir das relações (5.8), algumas das possíveis fontes de falha ao longo do tempo são mostradas na Figura 5.28. Observa-se que a falha é detectada já em torno de $t = 32$ segs. confirmando definitivamente a partir de $t = 38$ segs.




Figura 5.27 – Desempenho do estimador de parâmetros do modelo de estado para uma perturbação permanente no parâmetro físico c




Figura 5.28 - Desempenho do diagnóstico nebuloso para uma perturbação no parâmetro c

5.6.7 Falha no sensor responsável pela medida da variável de estado θ_2

Uma falha no sensor que mede a variável θ_2 é simulada como mostrado na Figura 5.29. A falha é simulada adicionando um sinal aleatório (Figura 5.29 (a)) cujo efeito no sinal de saída do sensor é mostrado na Figura 5.29 (b). Observa-se que a perturbação é adicionada no instante $t = 30$ segs. Os efeitos na estimação de parâmetros do modelo de estado serão imediatos, já que o processo de estimação de parâmetros estimados depende diretamente das variáveis medidas.




Figura 5.29 - Falha no instrumento (a) ruído introduzido simulando uma falha no sensor de medida da variável de estado θ_2 , (b) efeito da perturbação na saída do sensor

5.6.8 Evolução da estimação dos parâmetros do modelo de estado para uma perturbação no sensor de medida da variável de estado θ_2

Os efeitos na estimação de parâmetros do modelo de estado devido a uma perturbação que simula uma falha no sensor de medida da variável de estado θ_2 é mostrada na Figura 5.30 (HUALLPA *et al.*, 1998b). Observa-se nitidamente a influência da falha do sensor na estimação de todos os parâmetros diretamente vinculados à variável θ_2 do modelo de estado (linha 4 da matriz de estado da equação (5.5)).

5.6.9 Evolução do diagnóstico para a perturbação no sensor de medida da variável de estado θ_2

Observa-se, na Figura 5.25, que a variável de estado θ_2 está acoplada estruturalmente aos parâmetros físicos J_2 , k e c . Intuitivamente qualquer um desses parâmetros poderia ser culpado como possível fonte de falha embora nenhum destes parâmetros seja a causa efetiva. As regras

nebulosa mais sensíveis serão ativadas e os conseqüentes destas regras serão indicados como fontes da falha.




Figura 5.30 - Efeitos na estimação de parâmetros para uma perturbação que simula uma falha no sensor de medida da variável de estado θ_2




Figura 5.31 - Evolução do sistema de diagnóstico nebulosa para uma perturbação no sensor de medida da variável de estado θ_2

A Figura 5.31 mostra a evolução do sistema de diagnóstico nebulosa para a perturbação no sensor de medida da variável de estado θ_2 . Observa-se que em ambos os casos, existe a acusação dos dois parâmetros como fontes de falhas, sendo de 50% a possibilidade de uma falha devido ao parâmetro k , e as possibilidades de falha devido ao parâmetro c varia intermitentemente chegando em alguns instantes até 90%, e em outros a 0%.

5.6.10 Evolução do diagnóstico quando existe ausência do sinal no sensor de medida da variável de estado θ_2

Na Figura 5.32, observa-se a simulação da ausência do sinal a partir do instante $t = 30$ segs. no sensor de mediada da variável θ_2 . De maneira semelhante pode-se pensar que a falha será atribuída a um ou mais parâmetros do modelo de estado, detectando desta maneira a falha, porém sem poder localizá-la, já que o diagnóstico sempre irá indicar parâmetros do sistema como fontes de falha.




Figura 5.32 - Falha no instrumento: perturbação que simula ausência do sinal no sensor de medida da variável de estado θ_2 ,

5.6.11 Evolução do diagnóstico na ausência do sinal no sensor de medida da variável de estado θ_2

Observa-se, na Figura 5.33, que a ausência do sinal no sensor de medida da variável de estado θ_2 , manifesta-se como sendo uma falha devido aos parâmetros k e c do modelo de estado.

Além das situações mostradas nos itens 5.6.8 e 5.6.10, outras situações foram simuladas, tendo como resultado que falhas devido a sensores manifestam-se como falhas devido a parâmetros do modelo de estado.




Figura 5.33 - Evolução do sistema de diagnóstico nebulosa para a ausência do sinal no sensor de medida da variável de estado θ_1

5.7 Mudança do ponto de operação de um motor CC: sistema físico real

5.7.1 Representação linear do motor CC

O motor CC apresentado na Figura 5.34 é representado por um modelo linear, dado pela equação (5.9):

$$v_a(t) = R_a i_a + L_a \frac{di_a}{dt} + K_b \frac{d\theta_m}{dt} \quad (5.9)$$

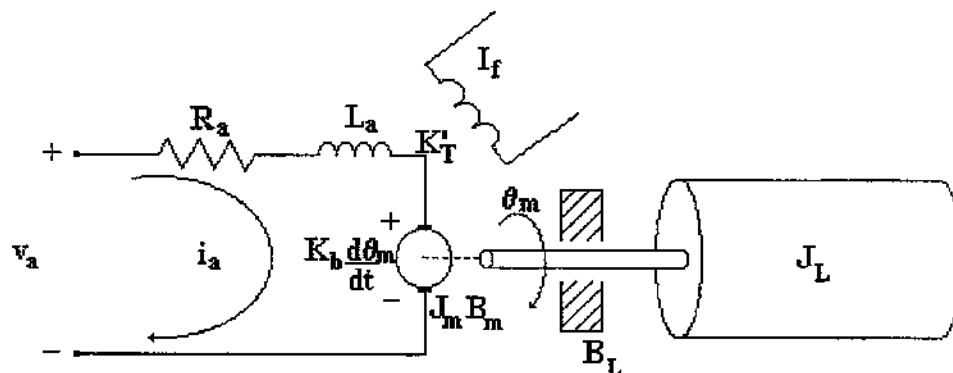


Figura 5.34 - Modelo linear de um motor CC

onde $K_b \frac{d\theta_m}{dt}$ é a força contra-eletromotriz, que é proporcional à velocidade do motor.

A corrente passando pelas bobinas gera um torque que é proporcional à corrente, isto é,

$$T(t) = K_T i_a. \quad (5.10)$$

A parte mecânica pode ser representada pela equação

$$J \frac{d^2\theta_m}{dt^2} + B \frac{d\theta_m}{dt} = T(t) \quad (5.11)$$

onde $J = J_m + J_l$, é a soma das inércias do motor e da carga, enquanto que $B = B_m + B_l$ é a soma dos atritos do motor e da carga.

Utilizando as equações (5.10) e (5.11), temos:

$$\frac{d^2\theta_m}{dt^2} = -\frac{B}{J} \frac{d\theta_m}{dt} + \frac{K_T}{J} i_a. \quad (5.12)$$

Com isso, o modelo de estado tem apenas dois parâmetros a serem considerados $a = -\frac{B}{J}$ e

$$b = \frac{K_T}{J}.$$

5.7.2 Simulação de uma falha caracterizada pela mudança do ponto de operação

A Figura 5.35 mostra os parâmetros estimados pela rede neural de Hopfield, a partir de sinais medidos em uma bancada rotativa (BRANDÃO, 1999).




Figura 5.35 - Estimação de parâmetros do modelo de estado dado pela equação (5.12)

Observa-se que os sinais estão corrompidos por ruído. Para melhorar a qualidade do sinal é utilizada uma janela retangular de três segundos de comprimento na qual o sinal é filtrado eliminando os eventos espúrios. Por outro lado, é possível observar, na Figura 5.35, uma perturbação permanente nos dois parâmetros do modelo de estado após $t = 30$ segs. Esta perturbação permanente é devido à mudança do ponto de operação e não devido a uma falha em algum dos parâmetros físicos. O fato é que a linearização do sistema dinâmico em torno do novo ponto de operação conduz a novos valores para os parâmetros do modelo de estado.

5.7.3 Evolução dos parâmetros do modelo de estado após o processamento

A Figura 5.36 mostra o desempenho do bloco de detecção de perturbação permanente, que neste caso é caracterizada por uma mudança de ponto de operação no motor CC. A linha contínua corresponde aos parâmetros estimados (saída da rede neural de Hopfield) e a linha tracejada corresponde à resposta do bloco **Eval**.




Figura 5.36 - Desempenho do processo de detecção de perturbação permanente nos parâmetros do modelo de estado do motor CC

5.7.4 Diagnóstico utilizando lógica nebulosa

5.7.4.1 Regras de inferência

Neste exemplo, tem-se três parâmetros físicos (J , B e K_T) que seriam as três possíveis fontes de falha interna. Considerando que o sistema é não-linear, tem-se aqui a emulação de uma falha devido a uma mudança do ponto de operação (PO).

As regras de inferência necessárias para determinar a causa de uma perturbação permanente têm como antecedentes os parâmetros do modelo de estado e como conseqüentes os três parâmetros físicos e o ponto de operação.

As regras mencionadas são as seguintes:

- 1 SE a apresenta uma variação negativa E b apresenta uma variação negativa ENTÃO a possível fonte de falha é J .
- 2 SE a apresenta uma variação positiva E b apresenta uma variação negativa ENTÃO a possível fonte de falha é C ou PO .

- 3 SE *a* apresenta uma variação nula E *b* apresenta uma variação nula ENTÃO a possível fonte de falha é *K_T*.
- 4 SE *a* apresenta uma variação positiva E *b* apresenta uma variação positiva ENTÃO a possível fonte de falha é *PO*.
- 5 SE *a* apresenta uma variação positiva E *b* apresenta uma variação negativa ENTÃO a possível fonte de falha é *PO*.
- 6 SE *a* apresenta uma variação negativa E *b* apresenta uma variação positiva ENTÃO a possível fonte de falha é *PO*.

Obs.: Estas regras devem atuar junto com outras regras para caracterizar falha.

Em virtude do sistema de diagnóstico ter sido projetado para atribuir a causa de qualquer perturbação permanente aos parâmetros físicos do sistema dinâmico, uma mudança no ponto de operação será vista simplesmente como um parâmetro físico fictício do sistema dinâmico.

A Figura 5.37 mostra o desempenho do diagnóstico por lógica nebulosa para a perturbação permanente devido a uma mudança no ponto de operação. A perturbação devido aos coeficientes de inércia e atrito é praticamente nula em todo instante, ficando apenas como possível candidato o coeficiente de acoplamento eletromecânico, que após a fase transitória volta ao nível nulo. Vale ressaltar que todas as regras que têm a mesma conclusão passam por um operador nebuloso do tipo *OR*.




Figura 5.37 - Desempenho do diagnóstico por lógica nebulosa para a perturbação permanente devido a uma mudança do ponto de operação

5.8 Identificação de sistemas dinâmicos não-lineares

Como apresentado na seção anterior, é possível implementar a identificação de sistemas dinâmicos reais e não-lineares utilizando uma rede neural de Hopfield, cuja função é aproximar o modelo não-linear através de um modelo linear com parâmetros variantes no tempo. Entretanto, deve ficar claro que as não linearidades devem ser suaves.

5.8.1 Exemplo do pêndulo simples

Como primeiro exemplo utilizaremos um pêndulo simples (exemplo de demonstração do *software* MATLAB) como mostra a Figura 5.38.

A equação da dinâmica do pêndulo simples é dada por:

$$mL^2\ddot{\theta} + c\dot{\theta} + mgL\sin(\theta) = Ku \quad (5.13)$$




Figura 5.38 – Pêndulo simples (demonstração do MATLAB).

adotando $x_1 = \theta$ e $x_2 = \dot{\theta}$ na equação (5.13), tem-se:

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} x_2 \\ -\frac{g}{L} \sin(x_1) - \frac{c}{mL^2} x_2 + \frac{K}{mL^2} u \end{bmatrix} \quad (5.14)$$

considerando os valores dos parâmetros adotados no exemplo de MATLAB ($\gamma/L = 0.25$, $g = 9.8$, $c/mL^2 = 0.5$ e $K/mL^2 = 1$), e a excitação sendo uma onda quadrada de amplitude 0.5 e frequência de 0.1 Hz.

Os parâmetros estimados tiveram o comportamento mostrado na Figura 5.39. Observa-se que alguns parâmetros são constantes, enquanto outros variam no tempo. Realizando um “zoom” no parâmetro a_{21} observa-se a variação do parâmetro no tempo como se mostra na Figura 5.40. Para poder avaliar o desempenho do estimador é reconstruído o sinal de saída utilizando os parâmetros estimados (Figura 5.39) de maneira que o modelo estimado é linear variante no tempo. As saídas do modelo não-linear estacionário e do modelo linear variante no tempo são ilustradas na Figura 5.41.





Figura 5.39 – Parâmetros estimados

Figura 5.40 – Comportamento do parâmetro a_{21} no tempo




Figura 5.41 – Comparação entre a saída do sistema dinâmico e a saída do estimador

5.8.2 Exemplo do pêndulo duplo

Como um segundo exemplo, é utilizado o pêndulo duplo obtido também do ambiente MATLAB, cuja representação em diagrama de blocos é mostrada na Figura 5.42.




Figura 5.42 – Modelo do pêndulo duplo (demonstração do MATLAB)

As equações que descrevem a dinâmica do sistema são:

$$(m_1 + m_2)L_1^2\ddot{\theta}_1 + m_2L_1L_2\ddot{\theta}_2\cos(\theta_1 - \theta_2) + m_2L_1L_2\dot{\theta}_2^2\sin(\theta_1 - \theta_2) = -(m_1 + m_2)gL_1\sin(\theta_1) \quad (5.15)$$

$$m_2L_2^2\ddot{\theta}_2 + m_2L_1L_2\ddot{\theta}_1\cos(\theta_1 - \theta_2) + m_2L_1L_2\dot{\theta}_1^2\sin(\theta_1 - \theta_2) = -m_2gL_2\sin(\theta_2) \quad (5.16)$$

Fazendo $x_1 = \theta_1$, $x_2 = \theta_2$, $x_3 = \dot{\theta}_1$ e $x_4 = \dot{\theta}_2$ e reescrevendo as equações (5.15) e (5.16), tem-se:

$$\dot{x}_1 = x_3 \quad (5.17)$$

$$\dot{x}_2 = x_4 \quad (5.18)$$

$$\begin{aligned} \dot{x}_3 = & [gL_2m_1m_2\sin(x_1) - (L_2m_2)^2x_3^2\sin(x_2) - 2(L_2m_2)^2x_3x_4\sin(x_2) - (L_2m_2)^2x_4^2\sin(x_2) \\ & - L_1L_2m_2^2x_3^2\sin(x_2)\cos(x_2) - gL_2m_2^2\sin(x_2)\cos(x_1 + x_2)] / [-L_1L_2m_1m_2 - L_1L_2m_2^2\sin^2(x_2)] \end{aligned} \quad (5.19)$$

$$\begin{aligned} \dot{x}_4 = & [-gL_2m_1m_2\sin(x_1) - gL_1m_1m_2\sin(x_1)\cos(x_2) + L_1^2m_1m_2x_3^2\sin(x_2) + (L_2m_2)^2x_3^2\sin(x_2) \\ & + 2(L_2m_2)^2x_3x_4\sin(x_2) + (L_2m_2)^2x_4^2\sin(x_2) + 2L_1L_2m_2^2x_3^2\sin(x_2)\cos(x_2) + 2L_1L_2m_2^2x_3x_4\sin(x_2)\cos(x_2) \\ & + L_1L_2m_2^2x_4^2\sin(x_2)\cos(x_2) + L_1^2m_2^2x_3^2\sin(x_2)\cos^2(x_2) + gL_2m_2^2\sin(x_2)\cos(x_1 + x_2) \\ & + gL_1m_2^2\sin(x_2)\cos(x_2)\cos(x_1 + x_2) + L_1^2m_2^2x_3^2\sin^3(x_2) + gL_1m_1m_2\sin(x_1 + x_2) \\ & + gL_1m_2^2\sin^2(x_2)\sin(x_1 + x_2)] / [-L_1L_2m_1m_2 - L_1L_2m_2^2\sin^2(x_2)] \end{aligned} \quad (5.20)$$

Utilizando os valores do exemplo demonstrativo do MATLAB para o pêndulo duplo, o comportamento dos parâmetros variantes no tempo estimados pela rede neural recursiva é apresentado na Figura 5.43, e em particular o comportamento do parâmetro a_{41} no intervalo de 8 segs. a 30 segs. é mostrado na Figura 5.44.





Figura 5.43 – Parâmetros estimados do modelo do pêndulo duplo

Figura 5.44 – Comportamento do parâmetro a_{41} no tempo

Para realizar uma comparação entre o sistema não-linear e o modelo estimado, é reproduzida a saída do sistema não-linear e comparada com a saída do modelo estimado.




Figura 5.45 – Comparação entre a saída do modelo e a saída do estimador

Os últimos dois exemplos mostram a capacidade da rede de Hopfield de ser uma ferramenta capaz de representar um modelo não-linear como um modelo linear variante no tempo. Se a não-linearidade é suficientemente suave, pode-se adaptar o projeto de sistemas de diagnóstico baseados em parâmetros do modelo de estado (modelo linear) também para o tratamento de sistemas dinâmicos não-lineares.

5.9 Comparação entre o estimador neural recursivo e o estimador adaptativo RLS

A seguir, é mostrada a comparação do desempenho entre o estimador adaptativo RLS e o estimador recursivo neural (Figura 5.46) para o exemplo da Figura 5.1. A simulação foi realizada para diferentes casos comentados no item 5.2.1. Em todas as situações testadas, a convergência

do estimador RLS mostrou-se lento comparada com a convergência do estimador neural recursivo.




Figura 5.46 – Comparação entre o estimador recursivo neural e estimador adaptativo RLS.

A vantagem do estimador neural é a não existência de definição de condições iniciais rígidas como ocorre no caso do estimador RLS. No estimador RLS, é necessário definir a matriz de covariância inicial e ajustar o fator de esquecimento e o tempo de reinicialização da matriz de covariância, sendo este procedimento, em alguns casos, demorado. Para o exemplo tratado usou-se:

- Número de parâmetros = 8 (4 para o polinômio do numerador e 4 para o polinômio do denominador).
- Estimativa inicial dos parâmetros: todos nulos.
- Matriz de covariância inicial = $1 \times 10^6 I$, onde I é a matriz identidade de dimensão 8.
- Fator de esquecimento $\lambda = 0.98$.
- Tempo de reinicialização da matriz de covariância $\xi = 500$ iterações, sendo cada iteração de 0.01 seg.

Capítulo 6

Conclusões

Nesta tese, foi desenvolvida uma estratégia de detecção e diagnóstico de falhas em sistemas dinâmicos utilizando ferramentas altamente flexíveis para processamento de informação, como redes neurais recorrentes e lógica nebulosa, cujo entendimento e aplicabilidade vêm se tornando cada vez mais populares.

A rede neural recorrente (rede de Hopfield) é utilizada como ferramenta de estimação de parâmetros do modelo de estado do sistema dinâmico. Em seguida, é realizado o pré-processamento dos parâmetros estimados (filtragem) e a obtenção dos valores nominais, que posteriormente serão utilizados como padrão de referência. No mesmo bloco, são obtidos os sintomas que servem como entrada ao bloco de diagnóstico. Finalmente, no bloco de diagnóstico é utilizada a metodologia de grafos direcionados e sinalizados, que realiza o mapeamento dos parâmetros do modelo de estado nos parâmetros físicos, e que permitem a geração de regras nebulosas. Todas as implementações foram realizadas no ambiente SIMULINKTM, obedecendo sempre às limitações que seriam impostas por uma implementação prática.

A seguir traçam-se conclusões por itens:

- **Estimação**

A estimação de parâmetros empregada neste trabalho, devido à sua natureza recursiva e não-linear, pode ser aplicada tanto em sistemas estacionários quanto em sistemas não-estacionários lineares, sendo também extensível a sistemas dinâmicos com não-linearidades suaves.

O estimador foi validado considerando-se simulações computacionais e sistemas físicos reais, montados em bancada de laboratório.

A aplicação do estimador após transcorrido um intervalo mínimo de tempo, durante o qual é feito um “reconhecimento” do sistema dinâmico, garante a estimação dos parâmetros do modelo. Embora não se possa demonstrar teoricamente a propriedade de convergência para o ponto fixo “desejado”, com o retardo aumenta-se a probabilidade de que isso ocorra. Nas simulações realizadas ao longo do desenvolvimento do trabalho, a convergência ocorreu em todos os casos que usaram retardo.

Para melhorar a qualidade da convergência do estimador foram adicionados ao processo de estimação, uma atualização constante das funções de ativação da rede neural. Para isto, são ajustados automaticamente os coeficientes de capacitância e os coeficientes de inclinação da função de saída da rede de Hopfield.

O estimador neural é bem sucedido toda vez que o sistema dinâmico puder ser representado por um modelo linear no espaço de estados, mesmo que a representação seja local, o que significa que tanto sistemas lineares como sistemas com não-linearidades suaves poderão ser identificados adequadamente.

- **Pré-processamento**

Os parâmetros estimados são utilizados como sinais de entrada do bloco de pré-processamento, onde é realizado o processo de detecção de perturbações permanentes. Para realizar avaliações transitórias dos sinais, são obtidas as derivadas dos mesmos, de maneira a enfatizar perturbações de pequenas amplitudes e altas frequências. É utilizada também uma janela deslizante onde é feito um alisamento no sinal estimado. Os transitórios vinculados unicamente à dinâmica do estimador não - linear são eliminados, retirando-os desta maneira do grupo de eventos considerados como perturbações permanentes. Além disso, são rejeitadas perturbações transitórias de qualquer natureza. Para fechar o pré-processamento, existe um meio de ajuste da sensibilidade do processo de detecção, o qual regula o momento de aceitação da perturbação.

- **Diagnóstico**

Em primeira instância, são definidas as relações de eventos (*causa-efeito*) entre os parâmetros do modelo de estado e os parâmetros físicos, que são consideradas as únicas possíveis fontes de falha. Estas relações são obtidas através da modelagem qualitativa utilizando grafos direcionados e sinalizados, os quais permitirão, ainda, identificar, além das relações, os sinais das relações (*variação positiva, variação negativa, variação nula*). Baseados, nos grafos das relações entre os eventos, são definidas as regras de inferência, as quais são otimizadas utilizando as propriedades dos grafos, reduzindo o número de regras.

Os conjuntos universo de discurso de cada parâmetro são construídos tendo como referência os valores nominais obtidos na fase de pré-processamento. Os conjuntos universo são atualizados *on-line* após a detecção de uma perturbação permanente. Uma vez definidos os conjuntos universo de discurso e as funções de pertinência, os sinais são submetidos ao processo de *matching* onde são analisados e comparados visando identificar a possível fonte de falha quando for detectada uma perturbação permanente. O sistema de diagnóstico é também capaz de detectar falhas devido a outros elementos do sistema, como sensores e atuadores, embora deva atribuí-las de alguma forma, aos parâmetros do sistema.

- **Extensões e sugestões para trabalhos futuros**

Uma das limitações deste trabalho é a necessidade do conhecimento da ordem do sistema. Existem métodos que permitem determinar a ordem do sistema dinâmico (NINNESS & GOODWIN, 1995). Por outro lado, existe a necessidade do conhecimento de todos os estados no processo de estimação, o que, numa aplicação prática, nem sempre é possível. Neste sentido se faz necessária a extensão do estimador quando não se podem medir alguns estados, utilizando para tanto técnicas de observação de estados (LUENBERGER, 1971, FRANK 1990).

Neste trabalho, no processo de pré-processamento, o limiar de sensibilidade é ainda manual, o que, no monitoramento e diagnóstico *on-line*, pode não ser adequado. Por este motivo, é interessante torná-lo automático.

No processo de diagnóstico, a definição dos conjuntos-universo é ainda manual, assim como as funções de pertinência, as quais são definidas em função dos fenômenos observados e/ou simulados. Há a necessidade de utilizar um meio mais eficiente de definição de tais parâmetros, que poderia ser feito utilizando técnicas do tipo *neuro-fuzzy* ou algoritmos genéticos que são consideradas como técnicas promissoras em processos de otimização.

O sistema de grafos direcionados e sinalizados não é gerado automaticamente, neste sentido, sugere-se que se utilizem técnicas de aquisição incremental de conhecimento (RUSSELL & NORVIG, 1995) ou técnicas de geração automática de regras (WANG & MENDEL, 1992).

A utilização dos grafos é bastante restrita neste trabalho, sendo que ela pode ser aproveitada na geração do modelo qualitativo do sistema dinâmico, criando eventos “virtuais” que permitiriam um melhor entendimento na propagação de um evento *causa*, realizando um mapeamento mais elaborado entre os eventos *causa* e *efeito*.

Apêndice A

Diagnóstico de falhas via identificação de parâmetros

O propósito deste apêndice é a apresentação de conceitos básicos de detecção e diagnóstico de falhas em sistemas dinâmicos através de identificação de parâmetros.

A.1 Diagnóstico de falhas via estimação de parâmetros

Este é um dos métodos mais utilizados nos anos 80 e 90, reportados na forma de tutoriais por ISERMAN (1984, 1993) e FRANK (1990). Esta metodologia está baseada na estimação dos parâmetros do sistema dinâmico, os quais podem variar no tempo, sendo necessária a estimação de parâmetros *on-line*. O principal objetivo não é apenas detectar a falha, mas também realizar um diagnóstico para poder indicar a causa da falha. Neste sentido, é necessário ter uma boa aproximação da realidade, a qual deve ser obtida através de modelagem matemática. Por ser um método baseado em sensibilidade a perturbações, é aconselhável seu uso em falhas de degradação lenta. A Figura a.1 mostra as partes importantes desta metodologia:

- Representar o sistema dinâmico utilizando equações diferenciais:

$$a_n y^{(n)}(t) + a_{n-1} y^{(n-1)}(t) + \dots + a_1 \dot{y}(t) + y(t) = b_m u^{(m)}(t) + b_{m-1} u^{(m-1)}(t) + \dots + b_1 \dot{u}(t) + b_0 u(t) \quad (\text{a.1})$$

onde, no ponto de operação, os parâmetros do modelo são apresentados como:

$$\theta^T = [a_1, \dots, a_n : b_0, \dots, b_m] \quad (\text{a.2})$$

e as variáveis de entrada e de saídas com as suas derivadas de ordem m e n respectivamente,

$$\psi^T(t) = [-\dot{y}(t), \dots, -y^{(n)}(t) : u(t), \dots, u^{(m)}(t)] \quad (\text{a.3})$$

de maneira que

$$y(t) = \psi^T(t) \theta \quad (\text{a.4})$$

A correspondente função de transferência, utilizando a transformada de Laplace, seria:

$$G(s) = \frac{y(s)}{u(s)} = \frac{B(s)}{A(s)} = \frac{b_0 + b_1 s + \dots + b_m s^m}{1 + a_1 s + \dots + a_n s^n} \quad (\text{a.5})$$

- Uma vez conhecidos os parâmetros do modelo, a idéia é relacionar estes parâmetros com os parâmetros físicos (vetor p) do sistema dinâmico, de maneira que:

$$\theta = f(p) \quad (\text{a.6})$$

e

$$p = f^{-1}(\theta) \quad (\text{a.7})$$

- A partir das equações (a.6) e (a.7), podem ser observadas e detectadas as possíveis variações nos parâmetros p e/ou θ . Se o objetivo é conhecer o parâmetro físico que causou a falha, então, será conveniente analisar as mudanças em p , isto é, Δp . O grande desafio é encontrar a relação dada pela equação (a.7).

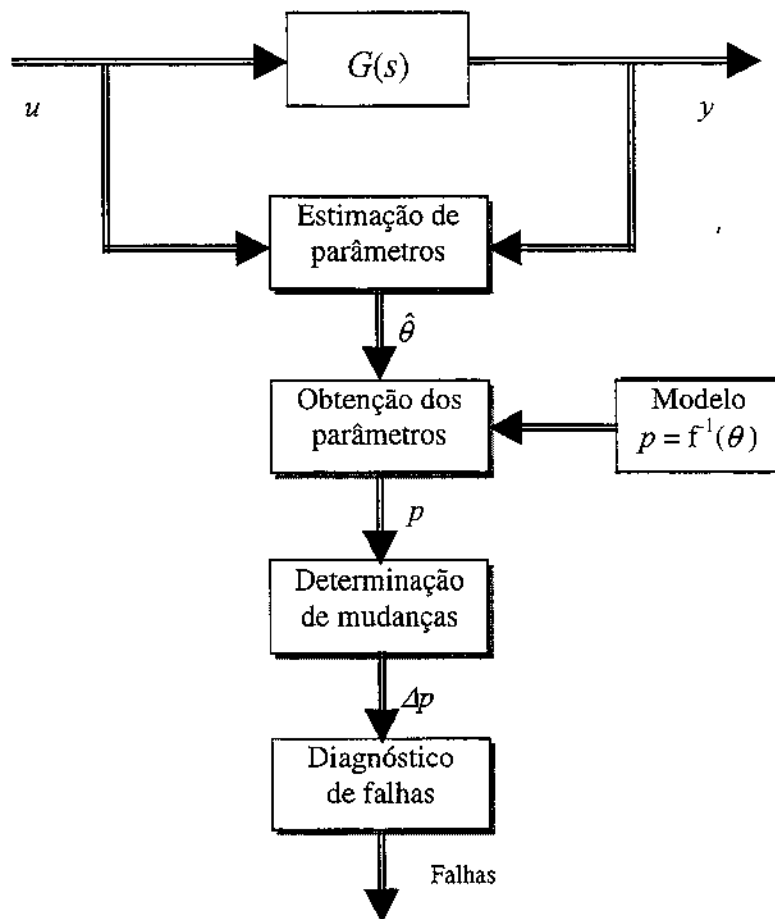


Figura a.1 Diagnóstico de falhas via estimação de parâmetros

A.2 Estimação de parâmetros

Para estimar os parâmetros, podem ser utilizados métodos conhecidos como quadrados mínimos (*least squares*: *LS*), quadrados mínimos recursivos (*recursive least squares*: *RLS*), quadrados mínimos recursivos estendidos (“recursive extended least square: *RELS*”), etc., (vide SODERSTROM *et al.* (1978)). Os algoritmos básicos de implementação do RLS para modelos discretos podem ser obtidos em HAYKIN (1996) e DONADON (1998).

Resumo do algoritmo RLS

- **Passo 1:** Inicializar a matriz de covariância, os parâmetros do modelo e o coeficiente de esquecimento.

$$P(0) = \delta^{-1} I, \text{ onde } \delta \text{ é uma constante positiva e pequena e } I \text{ é a matriz identidade} \quad (\text{a.8})$$

$$\hat{\theta}(0) = 0, \text{ parâmetros do modelo} \quad (\text{a.9})$$

$$\lambda \in (0,1), \text{ fator de esquecimento} \quad (\text{a.10})$$

- **Passo 2:** Para cada iteração ($k = 1, 2, \dots$) computar:

$$\psi^T(k) = [-y(k-1) \dots -y(k-n); u(k) \dots u(k-m)] \quad (\text{a.11})$$

- **Passo 3:** Calcular o erro:

$$e(k) = y(k) - \psi^T(k) \hat{\theta}(k-1) \quad (\text{a.12})$$

- **Passo 4:** Calcular o ganho:

$$K(k) = \frac{P(k-1)\psi(k)}{\lambda + \psi^T(k)P(k-1)\psi(k)} \quad (\text{a.13})$$

- **Passo 5:** Calcular a nova matriz de covariância:

$$P(k) = \frac{1}{\lambda} (P(k-1) - K(k)\psi^T(k)P(k-1)) \quad (\text{a.14})$$

- **Passo 6:** Estimar os parâmetros do modelo:

$$\hat{\theta}(k) = \hat{\theta}(k-1) + K(k)e(k) \quad (\text{a.15})$$

- **Passo 7:** Retornar ao passo 2 para nova iteração.

Apêndice B

Diagnóstico de falhas via equações de paridade

O propósito deste apêndice é a apresentação de conceitos básicos de detecção e diagnóstico de falhas em sistemas dinâmicos através de equações de paridade.

B.1 Diagnóstico de falhas utilizando equações de paridade

As técnicas de detecção baseadas em modelos constam de três estágios. No primeiro estágio, são gerados os *resíduos* utilizando o modelo do sistema dinâmico e observadores. Os resíduos são variáveis nulas em condições isentas de perturbações, e possuem valores não nulos na presença de alguma perturbação. Para diferenciar uma perturbação do ruído é necessário realizar um levantamento estatístico. Existem diferentes métodos de geração de resíduos (WILLSKY, 1976; ISERMANN, 1984; FRANK & DING, 1997), e um deles é com base na entrada e saída do modelo (CHOW & WILLSKY, 1984; FRANK & WÜNNENBERG, 1989; LOU *et al.*, 1986, MEDVEDEV, 1995).

Considere o modelo:

$$\dot{x}(t) = Ax(t) + Bu(t) \quad (\text{b.1})$$

e

$$y(t) = Cx(t) \quad (\text{b.2})$$

substituindo a equação (b.2) na equação (b.1) e derivando p vezes tem-se:

$$\begin{aligned}
\dot{y}(t) &= CAx(t) + CBu(t) \\
\ddot{y}(t) &= CA^2x(t) + CABu(t) + CB\dot{u}(t) \\
&\vdots \\
y^{(p)}(t) &= CA^p x(t) + CA^{p-1} Bu(t) + \dots + CBu^{(p-1)}(t)
\end{aligned} \tag{b.3}$$

Organizando na forma matricial, resulta:

$$\begin{bmatrix} y(t) \\ \dot{y}(t) \\ \ddot{y}(t) \\ \vdots \\ y^{(p)}(t) \end{bmatrix} = \begin{bmatrix} C \\ CA \\ CA^2 \\ \vdots \\ CA^p \end{bmatrix} x(t) + \begin{bmatrix} 0 & 0 & \dots & 0 & 0 \\ CB & 0 & \dots & 0 & 0 \\ CAB & CB & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ CA^{p-1}B & CA^{p-2}B & \dots & CB & 0 \end{bmatrix} \begin{bmatrix} u(t) \\ \dot{u}(t) \\ \ddot{u}(t) \\ \vdots \\ u^{(p)}(t) \end{bmatrix} \tag{b.4}$$

ou

$$Y(t) = Tx(t) + HU(t) \tag{b.5}$$

visando retirar os estados não mensuráveis, é introduzida uma matriz W , de maneira que:

$$WT = 0 \tag{b.6}$$

ficando a equação (b.5) na forma:

$$WY(t) = WHU(t) \tag{b.7}$$

de maneira que o resíduo estará dado por:

$$r(t) = WY(t) - WHU(t) \tag{b.8}$$

Isto implica que $r(t)$ será nulo em condições normais. O projeto da matriz W é fundamental para o êxito desta metodologia.

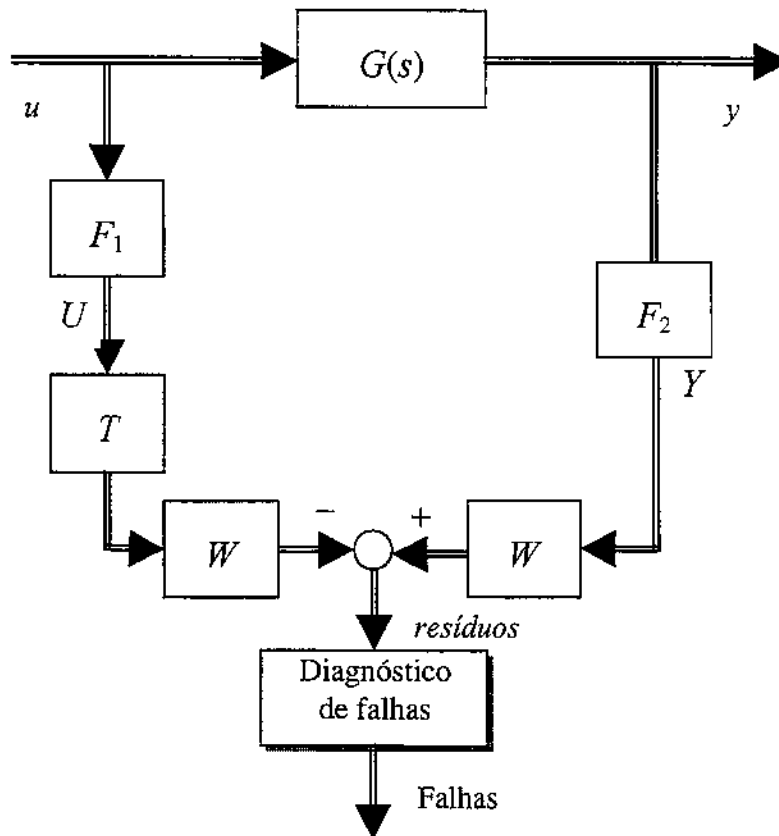


Figura b.1 Diagnóstico de falhas via equações de paridade

O projeto da matriz W dá uma certa liberdade para gerar o conjunto de resíduos. Uma maneira de se obter os elementos da matriz W , é selecionar os mesmos de forma que, uma das variáveis de saída não sofra nenhum impacto para um resíduo específico (uma maneira de se projetar W pode ser encontrada em CHIARELLO (1998)).

Uma outra maneira de descrever a metodologia de equação de paridade (GERTLER & SINGER, 1990), consiste em representar o sistema dinâmico pelo modelo ARMA, isto é,

$$B(z)u(t) = A(z)y(t) \quad (b.9)$$

onde $u(t)$ é o vetor de entrada, $y(t)$ é o vetor de saída e, $A(z)$ e $B(z)$ são as matrizes de transferência polinomiais, sendo $A(z)$ uma matriz diagonal. Esta representação é utilizada apenas em sistemas que têm modos controláveis e observáveis.

Para se obter a formulação da equação de paridade, é introduzido:

$$x(t) = \begin{bmatrix} u(t) \\ y(t) \end{bmatrix}, \quad F(z) = B(z) - A(z) \quad (\text{b.10})$$

De maneira que, a equação (b.9) transforma-se em:

$$F(z)x(t) = 0 \quad (\text{b.11})$$

O sistema real difere do sistema ideal, pois existe uma interferência na entrada que pode ser dividida em duas partes: uma delas como sendo um ruído aleatório $w(t)$ de média zero e um sinal semi-determinístico $v(t)$ representando falhas aditivas do sistema. Com estas considerações, a equação (b.9) transforma-se em,

$$B(z)u(t) + G(z)v(t) + H(z)w(t) = A(z)y(t) \quad (\text{b.12})$$

onde $G(z)$ e $H(z)$ são matrizes de transferência das interferências consideradas conhecidas.

Além disso, existe interferências nos vetores de entrada e de saída; sendo as de observação $\Delta u(t)$, $\Delta y(t)$ e as de medida $\delta u(t)$, $\delta y(t)$ respectivamente. Desta maneira, a equação (b.10) transforma-se em,

$$\tilde{x}(t) = x(t) + \Delta x(t) + \delta x(t) \quad (\text{b.13})$$

e,

$$\hat{F}(z) = F(z) + \Delta F(z) \quad (\text{b.14})$$

onde, $\Delta F(z)$ é o erro de modelagem.

A equação de paridade dada pela equação (b.11) pode, na realidade ser aplicada apenas às variáveis observadas $\tilde{x}(t)$ junto ao modelo estimado $\hat{F}(z)$, de forma que haverá um resíduo,

$$e(t) = \hat{F}(z)\tilde{x}(t) \quad (\text{b.15})$$

$$e(t) = -G(z)v(t) - H(z)w(t) + \Delta F(z)x(t) + \hat{F}(z)\Delta x(t) + \hat{F}(z)\delta x(t) \quad (\text{b.16})$$

A equação (b.16) mostra que os resíduos dependem de $w(t)$ e $\delta x(t)$ nas falhas aditivas, e de $v(t)$ e $\Delta x(t)$ no erro do modelo ($\Delta F(z)$).

Apêndice C

Diagnóstico de falhas via estimação de estados e observadores

O propósito deste apêndice é apresentar os conceitos básicos de detecção e diagnóstico de falhas em sistemas dinâmicos através de estimação de estados e observadores.

C.1 Diagnóstico de falhas utilizando observadores de estados

Esta técnica tem recebido uma atenção muito especial nos últimos anos (FRANK & DING, 1997; FRANK, (1990 e 1994); WILLSKY, 1976; CLARK *et al.* 1978a e 1978b, GUAN & SAIF, 1991). A idéia básica do observador (Figura c.1) é reconstruir as saídas do sistema a partir de um subconjunto dos estados medidos, com a ajuda de observadores ou filtros de Kalman. Utilizando a estimação de erros ou inovações como resíduos, é possível a detecção e localização das falhas.

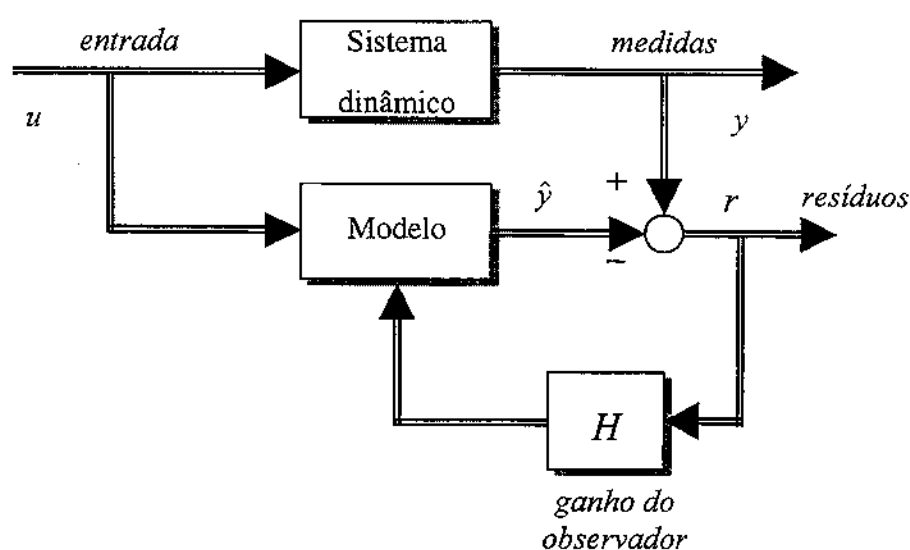


Figura c.1. Diagnóstico de falhas via observador de estado

Na Figura c.1, se o resíduo (r) for não-nulo (aqui, geralmente é adotado um limiar de significância do resíduo), indicará a presença de falha; e se ele for nulo indicará a ausência de falha.

Considere-se o sistema dinâmico dado por:

$$\dot{x}(t) = Ax(t) + Bu(t) + Ed(t) + Kf(t) \quad (c.1)$$

e

$$y(t) = Cx(t) + Fd(t) + Gf(t) \quad (c.2)$$

onde $x(t)$ são as variáveis de estado, $u(t)$ é a excitação, $y(t)$ são as saídas do sistema dinâmico, e as variáveis $d(t)$ e $f(t)$ representam entradas desconhecidas e falhas nos componentes ou nos atuadores, respectivamente, podendo ser interpretadas como perturbações junto ao sistema. O sistema estimado será representado por:

$$\dot{\hat{x}}(t) = (A - HC)\hat{x}(t) + Bu(t) + Hy(t) \quad (c.3)$$

e

$$\hat{y}(t) = C\hat{x}(t) \quad (c.4)$$

onde H é a matriz de ganho que deve ser escolhida apropriadamente. Definindo o erro na estimação de estados, $\xi = x - \hat{x}$, e o erro de estimação de saída $e = y - \hat{y}$, tem-se

$$\dot{\xi}(t) = (A - HC)\xi(t) + Ed(t) + Kf(t) - HFd(t) - HGf(t) \quad (c.5)$$

e

$$e(t) = C\xi(t) + Fd(t) + Gf(t). \quad (c.6)$$

Pode-se notar nas equações (c.5) e (c.6) que o erro de estimação depende apenas das variáveis $d(t)$ e $f(t)$, de maneira que $e(t)$ pode ser utilizado como resíduo. Quando não ocorre falha

($f(t) = 0$), o resíduo será apenas influenciado pelas entradas desconhecidas (perturbações externas); caso contrário, haverá um acréscimo no valor do resíduo denunciando a existência de uma falha. Uma maneira simples de detectar estas falhas é utilizando limiares lógicos (CLARK, 1978a e 1978b). Para evitar falsos alarmes são propostas metodologias com limiares adaptativos (SCHNEIDER & FRANK, 1996; FRANK & DING, 1997) ou projetar observadores em frequência (EMAMI-NAEINI *et al.*, 1988). A seguir, serão descritas as diferentes configurações de diagnóstico de falhas baseadas em observadores.

- **Observador simples:**

A configuração mais simples utilizada para detecção de falhas em sensores é proposta por CLARK (1978a e 1978b), onde a partir de uma única saída (a mais significativa) são reconstruídas todas as outras saídas. A comparação entre a saída atual e a saída estimada, usando o limiar estimado, permite a detecção da falha de um único sensor. A ocorrência de uma falha é indicada através da detecção de *inovação estatística* (MEHRA & PESHON, 1971) e o diagnóstico correto da falha depende do teste de múltiplas hipóteses, que pode ser resolvido utilizando a teoria de decisão Bayesiana (WILLSKY, 1976).

- **Observador dedicado**

Este tipo de observador é utilizado para detectar falhas em múltiplos sensores, de maneira que são projetados múltiplos sensores dedicados (CLARK, 1978b), onde para cada sensor existe um observador, como é esquematizado na Figura c.2.

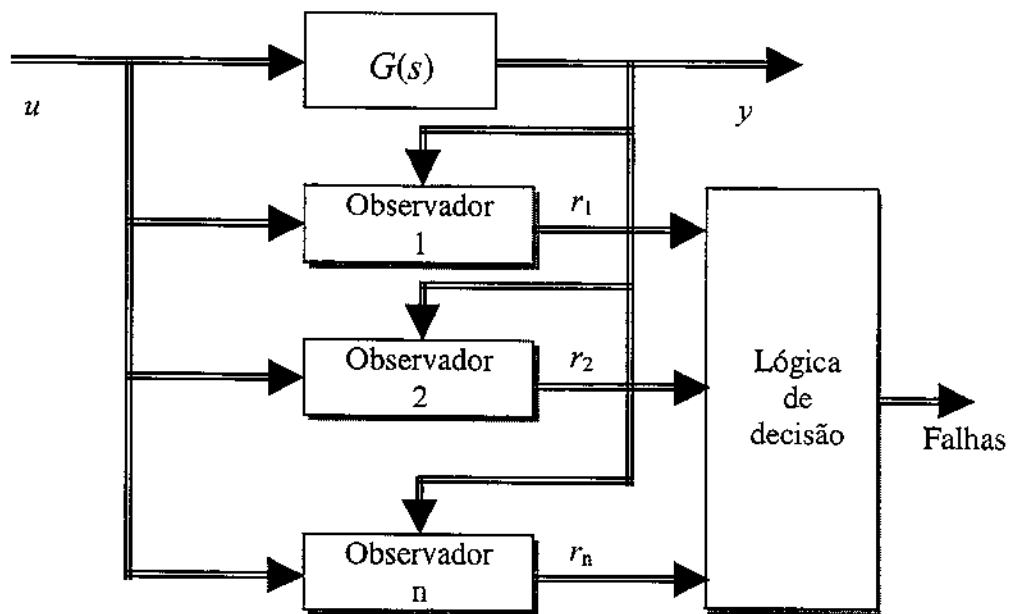


Figura c.2. Diagnóstico de falhas via observadores dedicados

Uma proposta alternativa, comentada na revisão de FRANK (1990), é que o observador de um determinado sensor é alimentado pelas informações dos outros sensores, à exceção da informação do próprio sensor, do qual se suspeita a causa da falha, isto é,

$$\begin{aligned}
 r_1(t) &= q_1(f_2, f_3, \dots, f_n) \\
 r_2(t) &= q_2(f_1, f_3, \dots, f_n) \\
 r_n(t) &= q_n(f_1, f_2, \dots, f_{n-1})
 \end{aligned}
 \tag{c.7}$$

A lógica de decisão é feita da seguinte maneira:

Se r_2, r_3, \dots, r_n são não-nulos e r_1 é nulo, então, a falha é devida a f_1 .

Se r_1, r_3, \dots, r_n são não-nulos e r_2 é nulo, então, a falha é devida a f_2 .

Se r_1, r_2, \dots, r_{n-1} são não-nulos e r_n é nulo, então, a falha é devida a f_n .

Como pode-se notar na lógica de decisão, o observador deve ser sensível a f .

C.2 Gerador robusto de resíduos

Considerando o modelo discreto, o sistema dinâmico é descrito pelas equações:

$$x_{k+1} = Ax_k + Bu_k + Ed_k + Kf_k \quad (\text{c.8})$$

e

$$y_k = Cx_k + Fd_k + Gf_k \quad (\text{c.9})$$

O observador de entradas desconhecidas é definido como:

$$z_{k+1} = Rz_k + Sy_k + Ju_k \quad (\text{c.10})$$

e o resíduo assume a forma

$$r_k = L_1 z_k + L_2 y_k \quad (\text{c.11})$$

onde,

$$\begin{aligned} \lim_{k \rightarrow \infty} r_k &= 0, \forall u, d, \quad \text{para } f_k = 0 \\ r_k &\neq 0, \quad \text{para } f_k \neq 0 \end{aligned} \quad (\text{c.12})$$

Além disso, z_k está relacionada com x_k através de,

$$z_k = Tx_k \quad (\text{c.13})$$

O erro de estimação do observador é dado por:

$$e_{k+1} = z_{k+1} - Tx_{k+1} \quad (\text{c.14})$$

que pode ser rescrito como segue:

$$e_{k+1} = Rz_k + Sy_k + Ju_k - TA x_k - Bu_k - TE d_k - TK f_k \quad (c.15)$$

Os requisitos de robustez dependem das seguintes condições:

$$\left\{ \begin{array}{l} TA - RT = SC \\ J = TB \\ TE = 0 \\ SF = 0 \\ SG \neq 0 \\ TK \neq 0 \end{array} \right. \quad (c.16)$$

Utilizando as equações (c.9) e (c.11) junto à equação (c.15) tem-se:

$$L_1 T + L_2 C = 0 \quad (c.17)$$

$$L_2 F = 0 \quad (c.18)$$

$$L_2 G \neq 0 \quad (c.19)$$

A solução deste sistema de equações é a solução do problema (maiores detalhes podem ser encontrados em PATTON *et al.*, 1989), e sem esquecer que, as falhas com constantes de tempo grandes (lentas) correm o risco de não serem detectadas, porque a robustez do observador está associada a evitar falsos alarmes de falhas (BASSEVILLE, 1988).

Apêndice D

Diagnóstico de falhas baseado em conhecimento

Este apêndice apresenta um histórico de sistemas de diagnóstico baseados em conhecimento, as suas principais características e aplicações.

D.1 Diagnóstico de falhas utilizando sistemas especialistas

No geral, os sistemas especialistas baseados em conhecimento são técnicas que emulam especialistas ou peritos em uma determinada área. É assumido que o diagnóstico de falhas em um processo ou num sistema qualquer requer uma observação constante por parte de um operador, cuja função é verificar se o sistema está funcionando corretamente ou se está fora dos padrões de operação. Além do acompanhamento da evolução do sistema, o operador deve ser capaz de indicar o que fazer numa determinada situação, qual é a sequência de passos que deve ser seguida e como interpretar os sintomas.

A importância do diagnóstico de falhas em sistemas como processos químicos, sistemas de manufatura, sistema de comunicações, circuitos eletrônicos, sistemas mecânicos, etc. é alta, já que além de manter os níveis de operação dentro de padrões de qualidade, é talvez tão ou mais importante velar pela segurança do sistema e dos operadores, impedindo catástrofes.

Os sintomas mais conhecidos pelo operador, permitem fazer um diagnóstico rápido e seguro, porém sintomas mascarados são muito difíceis de serem reconhecidos até por operadores bem treinados. Aqui é onde um diagnóstico automático se faz necessário, pois permite auxiliar o operador a detectar e identificar a fonte de falha, ou então realizar toda a tarefa sem a participação do operador.

A seguir, é feito um histórico dos diferentes sistemas de diagnóstico utilizados em diferentes áreas.

D.2 Breve histórico de diagnóstico de falhas

Os sistemas de diagnóstico baseados em conhecimento foram, em princípio, aplicados na medicina, particularmente no diagnóstico de doenças em função de sintomas apresentados pelo paciente. Assim, SHORTLIFFE (1976) lançou o sistema especialista chamado MYCIN utilizado para o diagnóstico de infecções bacterianas no sangue. MYCIN foi desenvolvido através de regras de produção e inferência reversa. Outros sistemas especialistas na área médica, embora menos conhecidos, são: AIRHEU utilizado em reumatologia, ANNA para arritmias cardíacas, etc., sendo descritos na revisão realizada por TZAFESTAS (1989).

Uma outra área de aplicação de sistemas especialistas é a detecção e diagnóstico em equipamentos eletro-eletrônicos e em sistemas de comunicação. Assim, por exemplo, DART (*Diagnostic Assistance Reference Tool*) é um sistema especialista de detecção de falhas (GENESERETH, 1984). FIS (*Fault Isolation System*) é utilizado no diagnóstico de componentes eletrônicos: amplificadores, fontes, diodos, etc. O diagnóstico é baseado utilizando processos probabilísticos (PIPITONE, 1986). NDS (*Network Diagnostic System*) é também utilizado no diagnóstico de processadores empregados em telecomunicações, modems, terminais e circuitos telefônicos (WILLIAMS *et al.*, 1983). DIAMON é utilizado na monitoração e diagnóstico de sistemas rotativos (SKATTEBOE *et al.*, 1986). RELSHELL é utilizado em sistemas tecnológicos cujos componentes apresentam deterioração gradual (GAZDIC, 1987).

D.3 Sistemas baseados em regras

A maioria dos sistemas especialistas tradicionais utilizados para a representação de conhecimento, são baseados em regras do tipo SE <antecedente> ENTÃO <consequente>, isto é:

$$\text{REGRA-}k: \text{SE } a_1 \text{ E } a_2 \dots \text{ E } a_m \text{ ENTÃO } c_1 \text{ OU } c_2 \text{ OU} \dots \text{ OU } c_n$$

onde, a_1, a_2, \dots, a_m são os antecedentes ou premissas e c_1, c_2, \dots, c_n são os consequentes ou conclusões.

D.4 Técnica de busca causal

Esta técnica é utilizada visando encontrar a provável causa ou fonte de falha. A causalidade é mapeada usando grafos cujos nós representam as variáveis de estado e a ligação entre os nós representam a influência existente entre os nós. As ligações entre os nós podem ser grandes (+) ou pequenas (-). Esta representação é atraente, pois permite a representação do comportamento do sistema através das observações empíricas ou através das leis físicas que governam o sistema, e esta representação requer apenas informações superficiais. As aplicações mais utilizadas mostram-se na monitoração, diagnóstico e controle de processos químicos (UMEDA *et al.*, 1980; KRAMER, PAULOWITCH, 1987). Esta técnica apresenta uma certeza absoluta se houver um único caminho para cada mudança de estado ao longo da propagação da falha (KRAMER, PAULOWITCH, 1987). A principal característica desta técnica consiste na possibilidade de acompanhar a propagação da falha através da árvore que representa a ligação entre os nós e a direção da propagação. Deve-se entender que nem todos os nós serão ativados para uma dada falha, mas apenas aqueles possíveis caminhos ligados ao nó perturbador.

D.5 Processamento do conhecimento

O processamento do conhecimento é tradicionalmente baseado na utilização de regras de inferência, que permitem chegar a conclusões (a partir de premissas), as quais podem representar a meta procurada ou então apenas representar uma meta intermediária. Entre os métodos de raciocínio mais utilizados podem ser mencionados o raciocínio de encadeamento direto (*forward chaining*) e o raciocínio de encadeamento reverso (*backward chaining*) (RUSSELL & NORVIG, 1995).

O método de raciocínio de encadeamento direto consiste na propagação para as diferentes metas a partir de uma premissa ou um conjunto de premissas, isto é, a partir de uma ocorrência ou conjunto de ocorrências, é adicionado um novo dado à base de conhecimento através da ativação de alguma regra. Este dado será utilizado como premissa de uma nova regra e como consequência será acrescentado mais um novo dado à base de conhecimento. Se este novo dado não for premissa de novas regras, então será encerrado o processo de implicações. Caso contrário, será

adicionado um novo dado que será utilizado como premissa de uma outra regra, e assim sucessivamente, até explorar e ativar todas as possíveis regras.

O método de raciocínio de encadeamento reverso consiste na propagação reversa das informações, isto é, a partir de uma conclusão (meta) conhecida ou supostamente verdadeira, são testadas todas as regras relacionadas a esta conclusão, percorrendo toda a árvore ou rede de regras em forma reversa, conhecendo, desta maneira, todas as causas que ocasionaram a meta, ou, apenas conhecendo a veracidade ou falsidade da meta através da confirmação ou negação das premissas ligadas à meta. Um exemplo interessante seria saber quais foram as causas que ocasionaram uma determinada falha num sistema dinâmico. Como se pode intuir, neste método serão ativadas apenas as regras relativas a uma determinada conclusão (falha). Exemplos de diagnóstico utilizando estes métodos são citados em FREYERMUTH (1991).

D.6 Técnica de busca causal via grafos direcionados e sinalizados

Esta técnica surge como um caso particular do raciocínio de encadeamento reverso, onde as causas são procuradas a partir de uma conclusão. Este tipo de manipulação de informações é conhecido como causalidade. A causalidade pode ser representada por grafos direcionados e sinalizados, onde os nós representariam a causa e o efeito, e a ligação entre ambos estaria representada por um elo ou um ramo que teria direção e sentido. No caso particular de diagnóstico em sistemas dinâmicos, os grafos direcionados e sinalizados foram utilizados, entre outros, por: IRI *et al.* (1980), UMEDA *et al.* (1980), SHIOZAKI *et al.* (1985), TSUGE *et al.* (1985), KRAMER & PAULOWITCH (1987). Utilizando os grafos direcionados e sinalizados, pode-se percorrer toda a rede, localizando as causas a partir de efeitos e vice versa.

Na Figura d.1, a causa é representada pelo nó A, os efeitos são representados pelos nós B e C; as relações entre os nós são: $A \rightarrow B$ é positiva (p), $A \rightarrow C$ é negativa (n), $B \rightarrow C$ é positiva, e $C \rightarrow B$ é positiva.

D.7 Conversão de grafos em regras lógicas

A partir dos grafos direcionados e sinalizados podem ser gerados regras lógicas (KRAMER & PAULOWITCH, 1987), onde as algumas relações (ramos) são transformadas em premissas e as

causas em conseqüentes. Os operadores lógicos (interseção, união, complemento, implicância) podem ser utilizados na sua plenitude. Assim, por exemplo, na Figura d.1, podem ser geradas as seguintes regras:

Regra 1: *SE* a relação AB é positiva *E* a relação BC é positiva, *ENTÃO* a possível causa é A, ou, *SE* (pAB) *E* (pBC) *ENTÃO* a possível causa é A

Regra 2: *SE* a relação AC é negativa *E* a relação CB é positiva, *ENTÃO* a possível causa é A ou, *SE* (nAC) *E* (pCB) *ENTÃO* a possível causa é A

Estas regras podem ser fundidas numa única regra utilizando os fundamentos das operações lógicas.

Regra 3: *SE* ((pAB) *E* (pBC)) *OU* ((nAC) *E* (pCB)) *ENTÃO* a possível causa é A.




Figura d.1. Representação de grafos direcionados e sinalizados

Deve-se tomar muito cuidado quando da existência de realimentações como a mostrada na Figura d.1. Em algumas situações (fusão de regras), é conveniente adicionar algumas restrições (condições redundantes) para evitar interpretações erradas.

D.8 Inferência lógica não-Booleana

Na análise Booleana, somente dois valores são permitidos numa hipótese, argumento que não se ajusta em muitas situações práticas, já que no diagnóstico não existe uma certeza completa. A maneira de realizar as classificações requer uma sensibilidade infinita o qual traz uma certa instabilidade ao diagnóstico. Se houver ruído de medida em torno do limiar de decisão, então haverá uma flutuação constante na decisão.

Este problema e outras dificuldades permitiram a procura por métodos de diagnóstico que levassem em consideração a existência de incertezas, tanto na medida quanto no diagnóstico. Entre os métodos que tratam incertezas pode-se mencionar:

- Inferência Bayesiana
- Redes Neurais
- Lógica Nebulosa

D.8.1 Inferência Bayesiana

A probabilidade Bayesiana conhecida também como probabilidade condicional consiste na obtenção da probabilidade a posteriori de um evento com base no conhecimento de um outro evento. Esta formulação foi proposta por Bayes:

$$p(A/B) = \frac{p(B/A) p(A)}{p(B)} \quad (\text{d.1})$$

onde o evento B é conhecido e o evento A , é o evento a ser prognosticado em função da evidência do evento B .

Esta técnica liga claramente os eventos *causa* aos eventos *efeito* através de relações que consideram graus de certeza na ocorrência de um evento *efeito*, dada a ocorrência ou observação de eventos *causa*, os quais são interpretados como *sintomas* na linguagem de diagnóstico.

De maneira geral, se houver n eventos *causa*, os quais são assumidos serem independentes entre si, a formulação de Bayes pode ser generalizada (NILSON, 1998) como:

$$p(A/B) = p(A) \prod_{i=1}^n \frac{p(B_i/A)}{p(B_i)} \quad (\text{d.2})$$

onde:

$$B = B_1 \cup B_2 \dots \cup B_n$$

Utilizando o conceito de independência entre os eventos *causa*, é possível construir redes de eventos de múltiplas entradas e múltiplas saídas. Para o sucesso na aplicação desta técnica, é necessário um bom modelo de relações entre os eventos.

No geral, pode-se obter o conhecimento da estrutura Bayesiana a partir de dados ou informações obtidas na prática. A partir destes dados, é realizada a classificação dos mesmos em função da relevância, identificação correta das variáveis que representam os eventos *efeito*, etc. Para facilitar a interpretação e obtenção de sucesso na operação de uma rede Bayesiana, ela deve estar representada por um grafo direcionado e acíclico, garantindo desta maneira a independência entre os eventos chamados de *sintomas*.

D.8.2 Redes Neurais

Como mencionado no capítulo 1, as redes neurais são compostos por neurônios os quais podem ser organizados em camadas e conectados através de ligações ponderadas de maneira que as informações se propagam através da rede em direção à saída a partir de informações de entrada.

Entre outros, HOSKINS *et al.* (1988, 1991), HIMMELBLAU *et al.* (1989), NAIDU *et al.* (1990) e SORSA *et al.* (1991, 1993) usam arquiteturas de redes neurais multicamada para detectar falhas em plantas químicas. Como exemplo, mencionaremos o problema simulado (Figura d.2) por SORSA *et al.* (1991, 1993). O problema consiste em classificar a falha num trocador de calor. As falhas selecionadas foram:

1. entrada obstruída;
2. sistema de reciclagem obstruído;
3. concentração de entrada fora dos padrões permitidos;
4. set-point do fluxo de reciclagem fora dos padrões permitidos;
5. defeito no trocador de calor;

6. problemas na catalização;
7. problemas na válvula de controle de temperatura;
8. existência de vazamento no reator;
9. medidor de fluxo de reciclagem com problemas;
10. problemas na bomba.

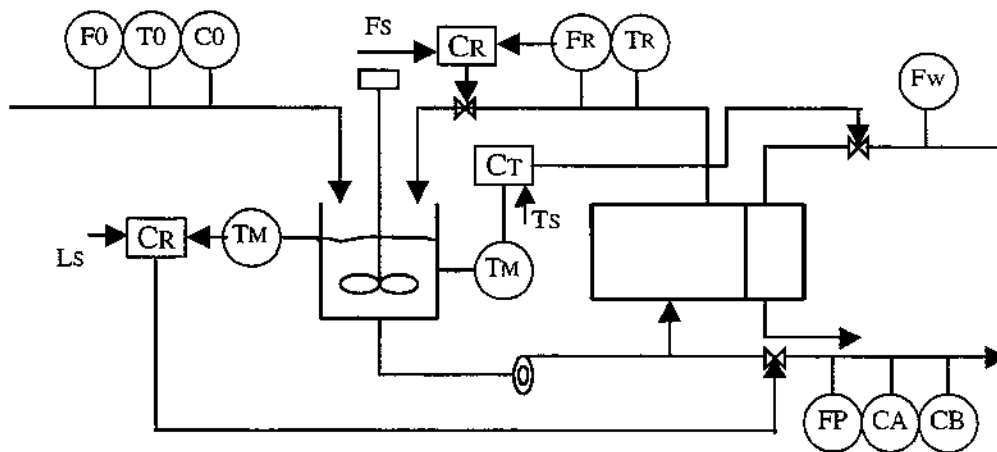


Figura d.2 Trocador de calor

O sistema identificador de falha (Figura d.3) é uma rede neural de 2 camadas com $n = 14$ entradas, $m = 4$ neurônios intermediários e $p = 10$ neurônios de saída. Foram treinadas 5000 épocas utilizando o algoritmo de retropropagação e utilizando diferentes tipos de funções de ativação.




Figura d.3 Arquitetura de uma rede neural de 2 camadas

Outras arquiteturas de rede neural também foram utilizadas (*counterpropagation*, e *radial basis function*), porém a rede neural multicamada tradicional (estática) mostrou-se confiável segundo os autores. Entretanto, as técnicas utilizadas por SORSA *et al.* (1991, 1993) não produzem bons resultados quando as características da falha são dinâmicas. Para sanar esta dificuldade, MARCU & MIREA (1997), MARCU *et al.* (1998) propõem uma rede neural multicamada dinâmica para a geração de resíduos e uma rede neural multicamada estática para a classificação de falhas (Figura d.4). A rede dinâmica é semelhante a uma rede estática, porém os pesos sinápticos são representados por filtros ARMA de diferentes ordens para os polinômios do numerador e do denominador.

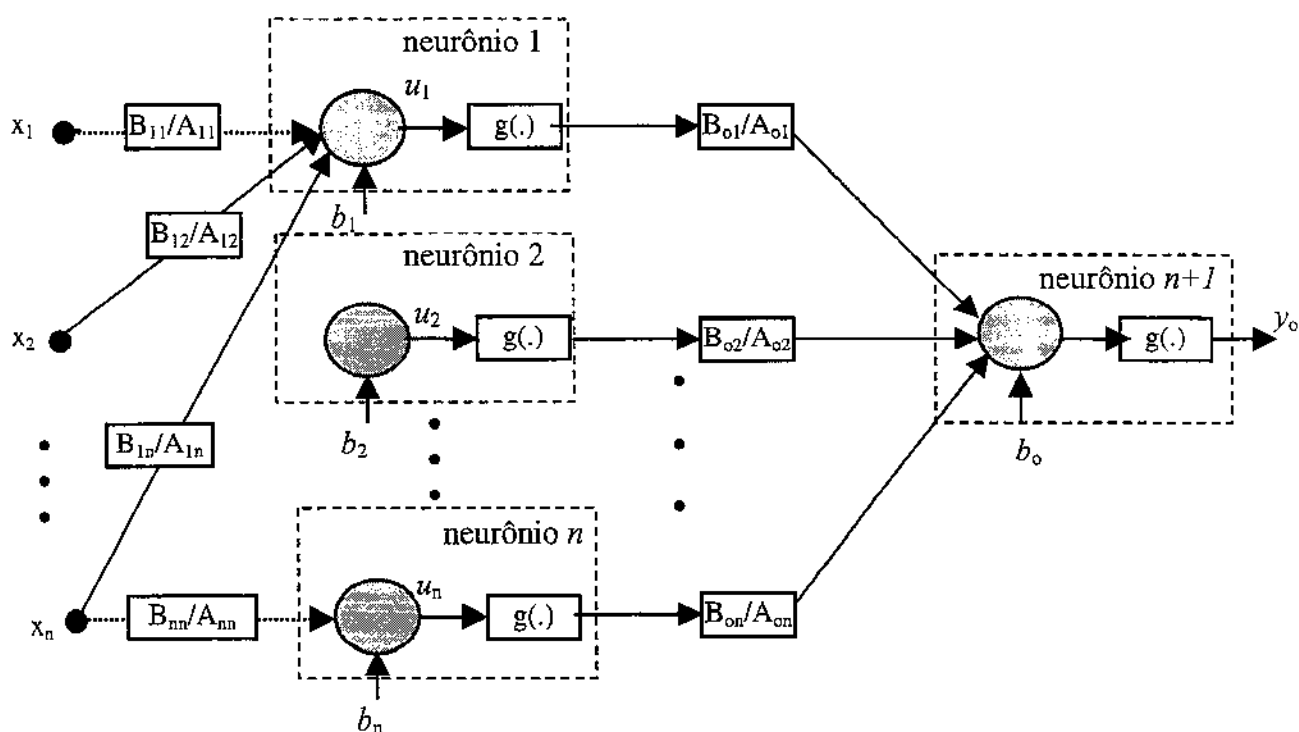


Figura d.4 Arquitetura de uma rede neural dinâmica de 2 camadas

Com esta configuração, os autores conseguiram eliminar principalmente os problemas das chamadas variações incipientes, ou variações lentas, que se apresentam principalmente em plantas químicas ou em sistemas de fluxo em recipientes interconectados.

D.9 Lógica Nebulosa

Esta ferramenta foi se impondo nos últimos tempos no ambiente do que é chamado de *raciocínio humano*, porque ela trabalha com termos lingüísticos. No que se refere a diagnóstico de falhas, os termos lingüísticos são entendidos tanto pelos engenheiros/técnicos quanto pelos operadores em plantas ou sistemas. Como mencionado nos capítulos 1, 3 e 4, esta ferramenta que em princípio representa uma extensão da lógica clássica, lida com sistemas baseados em regras de inferência. As regras de inferência são construídas com base na experiência do operador ou algum especialista que conheça o funcionamento normal e anormal do sistema.

Obviamente, o operador ou perito conhece o sistema em função das variáveis ou parâmetros que consegue medir ou observar. Estas informações podem não ser suficientes para o prognóstico da falha. Neste caso, um maior número de informações sobre o sistema implica uma maior chance do sucesso no diagnóstico. Neste sentido, nos últimos anos tem-se orientado as pesquisas visando diagnósticos robustos. Uma das maneiras é a utilização do modelo teórico do sistema integrando ou complementando às informações observadas pelo operador ou perito. ULIERU & ISERMANN (1993), BALLE & NELLES (1997) introduzem estes conceitos e aproveitam os modelos já consagrados para efeitos de diagnóstico de falha.

Como exemplo, utilizaremos o problema tratado por ULIERU & ISERMANN (1993). Esta aplicação consiste em construir um sistema de diagnóstico de falhas para um motor C.C, cuja representação dinâmica em diagrama de blocos é dada na Figura d.5. A estimação de parâmetros deste sistema já tinha sido estudado por ISERMANN (1984).

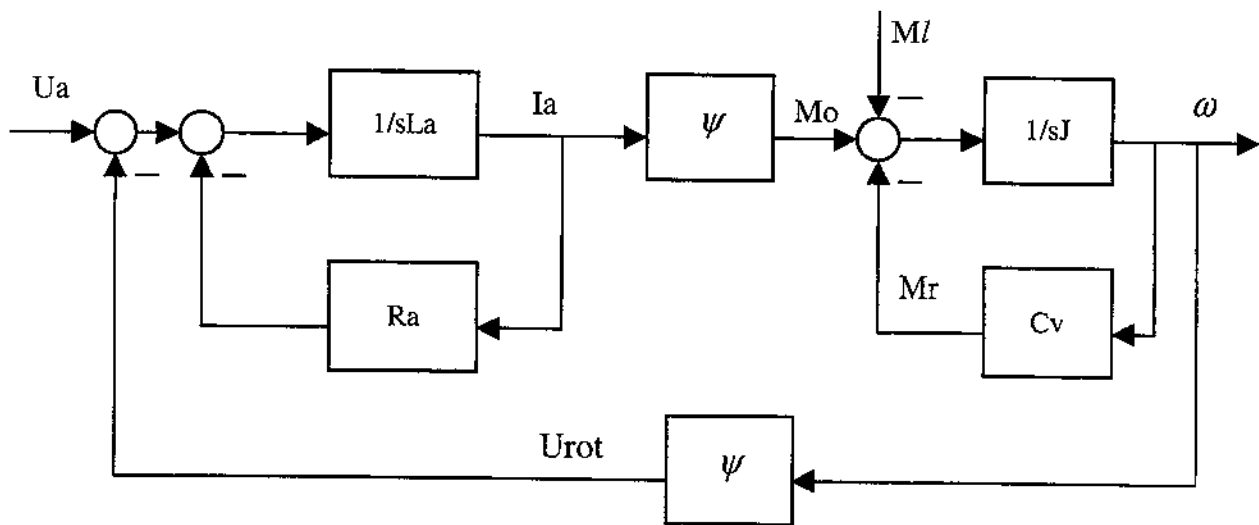


Figura d.5. Arquitetura de uma rede neural dinâmica de 2 camadas

onde:

L_a : indutância de armadura

R_a : resistência de armadura

U_a : tensão de armadura

I_a : corrente de armadura

ψ : fluxo magnético interno

J : momento de inércia

C_v : coeficiente de atrito do motor

M_r : torque de fricção

M_l : torque de carga

M_o : torque de saída

ω : velocidade angular

U_{rot} : tensão gerada

Observa-se que o diagrama de blocos é uma representação do modelo dinâmico reduzido tratado por ISERMANN (1984).

Com o conhecimento dos parâmetros e variáveis mencionados, são geradas as regras de inferência de acordo com a Tabela d.1.

Tabela d.1

	Ra	La	ψ	Mr0	Mr1	J
F1	D	MD	MD	N	N	A
F2	D	D	D	N	N	N
F3	MA	MD	N	N	N	A
F4	A	N	MD	N	N	N
•	•	•	•	•	•	•
•	•	•	•	•	•	•
F16	MA	N	MD	N	N	N

Onde a primeira coluna corresponde às possíveis falhas contempladas e a primeira linha contempla os parâmetros e variáveis que servirão como antecedentes.

As possíveis falhas podem ser:

F1: curto-circuito

F2: curto-circuito na serpentina

F3: interrupção

F4: sujeira no comutador

⋮

F16: sobrecarga

Os elementos de relação entre os antecedentes e os consequentes são valores lingüísticos como:

D: diminuído

MD: muito diminuído

A: acrescentado

MA: muito acrescentado

N: normal

As funções de pertinência dos antecedentes são definidas da seguinte maneira:




Figura d.6 Definição de subconjuntos nebulosos dos antecedentes

Então, as regras de inferência são interpretadas da seguinte maneira:

Regra 1

SE Ra é D E La é MD E ψ é MD E Mr0 é N E Mr1 é N E J é A ENTÃO a falha é F1

Regra 2

SE Ra é D E La é D E ψ é D E Mr0 é N E Mr1 é N E J é N ENTÃO a falha é F2

Regra 3

SE Ra é MA E La é MD E ψ é N E Mr0 é N E Mr1 é N E J é A ENTÃO a falha é F3

Regra 4

SE Ra é A E La é ND E ψ é MA E Mr0 é N E Mr1 é N E J é N ENTÃO a falha é F4

⋮

Regra 16

SE Ra é MA E La é N E ψ é MD E Mr0 é N E Mr1 é N E J é N ENTÃO a falha é F16

E assim sucessivamente, são construídas todas as regras de inferência. Estas regras de inferência foram obtidas a partir das equações que representam o sistema dinâmico e através das observações recolhidas em campo.

Segundo ULIERU & ISERMANN (1993), foram feitas comparações entre a lógica nebulosa e a lógica clássica obtendo-se resultados satisfatórios principalmente quando comparados nas regiões de transição entre dois subconjuntos nebulosos. As transições graduais permitiram levar em consideração as contribuições parciais dos subconjuntos nebulosos (antecedentes). Isto faz pensar que se a contribuição dos antecedentes de uma determinada regra é maior que nas outras regras, então, haverá também uma maior assimilação com a conseqüente daquela regra, de maneira semelhante uma menor contribuição dos antecedentes numa determinada regra, implicará uma menor assimilação na conseqüente dessa regra.

Desta maneira, foi demonstrado que esta ferramenta é bastante flexível e tolera níveis de subjetividade que outras ferramentas não permitem. A definição dos conjuntos nebulosos é muito importante para o sucesso da ferramenta. Isto é, a definição das inclinações (“slope”), posições, e limites são de extrema importância.

Referências Bibliográficas

AYOUBI, M., Fault Diagnosis with Dynamic Neural Structure and Application to a Turbo-Charger, *IFAC Symposium SAFEPROCESS'94, Finland*, Vol.2, pp.618-623, 1994

BALLE P., NELLES O., Exchanger based on a bank of local linear fuzzy models of subprocesses, *IFAC Symposium on AI in Real-Time Control, Malasia*, p.606-613, 1997.

BASSEVILLE, M. Detecting changes in signals and systems - A survey. *Automatica*, vol. 24, n.3, p.309-326, 1988.

BRANDÃO, J. R., Controle adaptativo auto-sintonizado de sistemas rotativos (Tese de mestrado), *FEM - UNICAMP.*, 1999.

CAMINHAS M. W., Estratégias de detecção e diagnóstico de falhas em sistemas dinâmicos (Tese de doutorado), *FEE - UNICAMP.*, 1997.

CHIARELLO, G.A., Detecção e Localização de Falhas em Sistemas Mecânicos Através da Análise de Correlações, (Tese de doutorado), *FEM - UNICAMP.*, 1998.

CHOW, E., Y., WILLSKY, A. Analytical redundancy and design of robust failure detection systems. *IEEE Transactions on Automatic Control*, vol.29, n.7, p.603-614, 1984.

CHU R., SHOURESHI R. & TENORIO M., Neural networks for system identification, *IEEE Control System Magazine*, vol.10, n.3, p.31-35, 1990.

CLARK, R. N., Instrument fault detection. *IEEE Transactions on Aerospace and Electron. Syst.*, vol.AES-14, n.4, p.456-465, 1978a.

CLARK, R. N., A simplified instrument failure detection. *IEEE Transactions on Aerospace Electron. Syst.*, vol.AES-14, n.4, p.558-563, 1978b.

DELGADO A., KAMBHAMPATI, WARWICK K, Dynamic recurrent neural network for system identification and control, *IEE proc. Control Theory and Appl.*, vol.142, n.4, p.307-314, 1995.

DEMETRIOU M. A, POLYCARPOU M.M., Incipient Fault Diagnosis of Dynamical Systems Using Online Approximators, *IEEE Transactions on Automatic Control*, vol.43, n.11, p.1612-1617, 1998.

DEXTER, A. L., Fuzzy model based fault diagnosis. *IEE Proc. Control Theory Appl.*, vol. 142, n.6, p.545-550, 1995.

DEXTER, A. L., BENOURETS, M., Model- based fault diagnosis using fuzzy matching. *IEEE Transactions on Systems, Man, and Cybernetics – Part A: Systems and Humans.*, vol.38, n.5, p.673-682, 1997.

DONADON V. L., Estudo de métodos de estimação de parâmetros aplicados ao controle adaptativo auto-sintonizado (Tese de mestrado), *FEM - UNICAMP.*, 1998.

DUBOIS, D., PRADE, H., Fuzzy sets and systems: Theory and applications, *Academic Press, London, England*, 1980.

DRAYE, J. P., PAVISIC, D. A, CHERON, G. A, LIBERT, G. A., Dynamical Recurrent Neural Networks: A Dynamical Analysis. *IEEE Transactions on Systems, Man, and Cybernetics – Part A: Systems and Humans.*, vol.26, n.5, p.692-705, 1996.

EMAMI-NAEINI, A, AKHTER, M. M., ROCK, S.M., Effect of Model Uncertainty on Failure Detection: The Threshold Selector, *IEEE Transactions on Automatic Control*, vol.33, n.12, p.1106-1115, 1988.

ELMAN, J. L., Finding structure in time, *Cognitive Science*, vol. 14, n. 2, p. 179-211, 1990.

FRANK, P. M. Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy - A survey and some new results. *Automatica*, vol.26, n.3, p.459-474, 1990.

FRANK, P., M., Ding, X. Frequency domain approach to optimally robust residual generation and evaluation for model based fault diagnosis. *Automatica*, vol.30, n.5, p.789-804, 1994.

FRANK, P., M. Enhancement of robustness in observer-based fault detection. *International Journal of Control*, vol.59, n.4, p.955-981, 1994.

FRANK, P., M., DING, X. Survey of robust residual generation and evaluation methods in observer-based fault detection systems, *Journal Proc. Control*, vol.7, n.6, p.403-424, 1997.

FRANK, P., M., WÜNNENBERG, J., Robust fault diagnosis using unknown input observer schemes, In: Patton R., Frank P., Clark R.,(Eds) *Fault Diagnosis and Dynamic Systems – PRENTICE HALL, N.Y. -USA*, p.46-98, 1989.

FREYERMUTH, B. Knowledge based incipient fault diagnosis of industrial robots, *IFAC Symposium SAFEPROCESSI, Baden – Baden, Germany*, 1991.

FÜSSEL D., BALLE P., ISERMANN R., Closed-loop fault diagnosis based on a nonlinear process model and automatic fuzzy rule generation, *Proceedings of the IFAC SAFEPROCESS 97*, p.359-364, 1997.

GAZDIC, I., RELSHELL: An Expert System Shell for Fault Diagnosis, in *System Fault Diagnosis, Related Knowledge-Based Approach*, Tzafestas, S., Singh, M., Schmidt G., Reidel, Dordrecht, vol.2, p.496-518, 1987.

GENESERETH, MR., The use of design descriptions in automated diagnosis, *Artificial Intelligence*, vol.24, p.411-436, 1984.

GERTLER, J. Survey of model-based detection and isolation in complex plants. *IEEE Control System Magazine*, 1988.

GERTLER, J., SINGER, D. A new structural framework for parity equation-based failure detection and isolation. *Automatica*, vol.26, n.2, p.381-388, 1990.

GLASS, A S, GRUBER P., ROOS M., TÖDTLI J., Qualitative Model-Based fault Detection in Air-Handling Units. *IEEE Control Systems*, p.11-22, August, 1995.

GOLDBERG D. E., Genetec Algorithms in Search, Optimization, and Machine Learning, *Addison – Wesley Publishing Company*, 1989.

GUAN, Y., SAIF, M. A novel approach to the design of unknown input observers. *IEEE Transactions on Automatic Control*, vol.36, n.5, p.632-635, 1991.

HAYKIN S., Adaptive Filter Theory, *Prentice Hall Information and System Sciences Series*, NJ, USA, 1996.

HAYKIN S., Neural Networks: A comprehensive Foundation, *Mc Miullan Publishing Company, Inc., USA*, 2nd. Ed., 1999.

HEBB, D.O, The Organization of Behaviour, *Wiley, New York, USA*, 1949.

HECHT-NIELSEN, R., Neurocomputing, *Addison Wesley, Reading, MA, USA*, 1990.

HIMMELBLAU D.M., WATANABE K., MATSUURA I., ABE M., KUBOTA M., Incipient fault diagnosis of chemical processes via artificial neural networks, *AIChE Journal*, vol.35, n.11, p.1803-1812, 1989.

HOLLAND, J.H., Adaptation in Natural and Artificial Systems, *University of Michigan Press, USA*, 1975.

HOPFIELD J.J., Neural networks and physical systems with emergent collective computational abilities, *Prceedings of the National Academy of Sciences*, 79, p.2554-2558, 1982.

HOPFIELD J.J., Neurons with a graded response have collective computational properties like those of two state neurons, *Prceedings of the National Academy of Sciences*, 81, p.3088-3092, 1984.

HORNIK K., STINHCORBE, WHITE H., Multilayer feedforward networks are universal approximators, *Neural Networks*, vol.2, p.359-366, 1989.

HOSKINS J.C., HIMMELBLAU D.M., Artificial neural networks models of knowledge representation in chemical engineering, *Comput. Chem. Eng.*, vol.12, p.881-890, 1988.

HOSKINS J.C., KALIYUR K.M., HIMMELBLAU D.M., Fault diagnosis in complex chemical plants using artificial neural networks, *AIChE Journal*, vol.37, n.1, p.137-141, 1991.

HUALLPA, B.N., E. NÓBREGA, AND F.J. VON ZUBEN, Recursive parameter identification of state-space models using Hopfield neural networks, *Proceedings of the 7th International Conference on Dynamic Problems in Mechanics, Brazil*, p. 58-60, 1997a.

HUALLPA, B.N., NÓBREGA E., AND VON ZUBEN F.J., Detection of state-space parameter perturbation using recursive nonlinear estimators, *Proceedings of the 14th Brazilian Congress of Mechanical Engineering, Brazil*, CD-ROM paper no. 487, 1997b.

HUALLPA, B.N., NÓBREGA E., AND VON ZUBEN F.J., Fault Detection in Dynamic Systems Based on Fuzzy Diagnosis. *Proceedings of the IEEE International Conference on Fuzzy Systems, Alaska*, vol. 2, p. 1482-1487, 1998a.

HUALLPA, B.N., NÓBREGA E., AND VON ZUBEN F.J., Detection and Classification of Faults in Time-Invariant Dynamic Systems, *Proceedings of XII Brazilian Automatic Control Conference – XII CBA, Brazil*, CD-ROM: vol. 5, p. 1735-1740, 1998b.

HUALLPA, B.N., NÓBREGA E., AND VON ZUBEN F.J., Permanent Fault Diagnosis in Dynamic Systems Using Signed Directed Graphs, *Proceedings of the 16th. Pan American Congress of Applied Mechanics / 8th International Conference on Dynamic Problems in Mechanics PACAM VI / DINAME 99, Brazil*, vol. 8, p.1431-1434, 1999.

HUSH D.R., HORNE B.G., Progress in supervised neural networks, *IEEE Signal processing magazine*, n.21, p.8-39, 1993.

IRI, M.K., AOKI, K., O'SHIMA, E., MATSUYAMA, H. A Graphical Approach to the Problem of Locating the Origin of System, *J. Oper. Res. Soc. Japan*, vol.23, p.295-311, 1980.

ISERMANN, R. Process fault detection based on modeling and estimation methods - A survey.. *Automatica*, vol.20, n.4, p.387-404, 1984.

ISERMANN, R. Fault diagnosis of machines via parameter estimation and knowledge processing - Tutorial paper. *Automatica*, vol.29, n.4, p.815-835, 1993.

KLIR G.J., FOLGER T.A., Fuzzy sets, uncertainty, and information, *Prentice Hall*, N.J., U.S.A., 1988.

KOSMATOPOULOS, E.B., POLYCARPOU, M.M., CHRISTODOULOU, M.A, IOANNOU, P.A, High-Order Neural Network Structures for Identification of Dynamical Systems, *IEEE Transactions on Neural Networks*, vol.6, n.2, p.422-431, 1995.

KRAMER , M. A., PAULOWITCH, JR.,B.L. ., A rule-based approach to fault diagnosis using the signed directed graph. *AIChE Journal*, vol.33, n.7, p.1067-1078, 1987.

KREISSELMEIER, G. Adaptive Observer with Exponential Rate of Convergence. *IEEE Transactions on Automatic Control*, vol. 22, no. 1, p. 2-8, 1977.

LEE C. C., Fuzzy Logic in Control Systems: Fuzzy Logic Controller-Part I, *IEEE Transsactions on systems, man and cybernetics*, vol.20, n.2,p., 1990.

LEE C. C., Fuzzy Logic in Control Systems: Fuzzy Logic Controller-Part II, *IEEE Transsactions on systems, man and cybernetics*, vol.20, n2, 419-435, 1990.

LEE W. S., Grosh D. L., Tillmann F. A, Lie C. H., Fault tree analysis, methods and applications- a review, *IEEE Transsactions on reliability*, R-34, 194-202, 1985.

LEGER R.P., GARLAND WM.J., POEHLMAN W.F.S., Fault detection and diagnosis using statistical control charts and artificial neural networks, *Artificial Intelligence in Engineering - Elsevier*, 12, p.35-47, 1998.

LEVIN, AU., NARENDRA, K.S., Recursive identification using feedforward neural networks, *Int. J. Control*, vol.61, n.3, p.533-547, 1995.

- LJUNG, L., System Identification: Theory for the User, *Englewood Cliffs, Prentice Hall, NJ, USA*, 1987.
- LOU, X., WILLSKY, A., VERGHESE, G. Optimally robust redundancy relations for failure detection in uncertain systems. *Automatica*, vol.22, n.3, p.333-344, 1986.
- LUENBERGER, D., E. An introduction to observers. *IEEE Transactions on automatic control*, vol.ac-16, n.6, p.596-602, 1971.
- MAMDANI, E.H., ASSILIAN, S., An experiment in linguistic synthesis with fuzzy logic controller, *Int. J. Man-Mach. Stud.*, vol.7, p.1-13, 1975.
- MAKI Y., LOPARO K.A , A Neural-Network Approach to Fault Detection and Diagnosis in Industrial Processes, *IEEE Transactions on Control Systems Technology*, vol.5, n.6, p.529-541, 1997.
- MARCU, T., MIREA L., Robust Detection and Isolation of Process Faults Using Neural Networks, *IEEE Control Systems*, vol.17, n.5, p.72-79, 1997.
- MARCU, T., MIREA L., FRANK, P.M., Neural Observer Schemes for Robust Detection and Isolation of Process Faults, *UKACC International Conference on CONTROL-98, IEE*, n.455, p.958-962, 1998.
- MCCULLOCH W.W., PITTS W., A logical calculus of the ideas imminent in nervous activity, *Bulletin of Mathematical Biophysics*, vol.5, p.115-133, 1943.
- MEDVEDEV, A. Fault detection and isolation by a continuous parity space method. *Automatica*, vol.31, n.7, p.1039-1044, 1995.

MEHRA, R. K., PESHON I., An innovations approach to fault detection and diagnosis in dynamic systems, *Automatica*, n.7, p.637-640, 1971.

MELO, G.P., Detecção e Localização de Falhas via Observadores de Estado de Ordem Reduzida, (Tese de doutorado), *FEM - UNICAMP.*, 1998.

MINSKY ,M.L., PAPERT, S., Perceptrons, *Cambrridge, MA: MIT Press*, 1969.

NAIDU ,S.R., ZAFIRIOU E., MCAVOY T.J., Use of neural networks for sensor failure detection in a control system, *IEEE Control System Magazine*, vol.10, p.49-55, 1990.

NARENDRA, K.S. AND ANNASWAMY, A.M. Stable Adaptive Systems, Prentice-Hall, 1989.

NARENDRA, K. S., PARTHASARATHY, K., Identification an control of dynamical systems using neural networks, *IEEE Transactions on neural networks*, vol.1, n.1, p.4-27, 1990.

NILSON NILS J., Artificial Intelligence a New Synthesis, *Morgan Kaufmann Publishers, Inc., San Francisco, CA, USA.*, 1998.

NINNESS, B. AND GOODWIN G.C., Estimation of Model Quality, *Automatica*, vol. 31, no. 12, pp. 1771-1797, 1995.

PHAM, D.T., LIU X., Dynamic system modelling using partially recurrent neural networks, *Journal of Systems Engineering*, p.134-141, 1992.

PHAM, D.T., WU M.H., Diagnosis of faults in the fuel injection system of forging machine using fuzzy sets theory, *Proc. Instn. Mech. Engr., Journal of Systems and Control Engineering*, vol.208, n.12, p.123-129, 1994.

- PATTON, R., FRANK, P., CLARK, R. Fault Diagnosis in Dynamic Systems, *Prentice Hall, UK*, 1989.
- PATTON, R. J. , CHEN, J. LIU, G.P., Robust fault detection on dynamic systems via genetic algorithms. *Proc. Inst. Mech. Engrs., Journal of Systems and Control Eng.*, vol.211, n.15, p.357-364, 1997.
- PEDRYCS W., GOMIDE F., An Introduction to Fuzzy Sets: Analysis and Design, *MIT Press, U.S.A*, 1998.
- PETTI, F. T. , KLEIN, J., DHURAJTI ,P.S., Diagnostic model processor: using deep knowledge for process fault diagnosis, *AIChE Journal*, vol.36, n.4, p.565-575, 1990.
- PFEUFER T., AYOUBI M., Fault diagnosis of electromechanical actuators using neuro-fuzzy network, *GI-Workshop "Fuzzy-Neuro-System", Darmstadt – Germany*, p.231-239, 1995.
- PIPITONE, F., The FIS Electronic Troubleshooting System, *IEEE Computer*, p.68-76, 1986.
- POLYCARPOU M.M., HELMICKI A J., Automated fault Detection and Accomodation: A Learning Systems Approach, *IEEE Transactions on Systems, Man and Cybernetics*, vol. 25, n.11, p.1447-1458, 1995.
- RAOL J.R., Neural network based parameter estimation of unstable aerospace dynamic systems, *IEE Proc. Control Theory Appl.*, vol.141, n.6, p.385-388, 1994.
- RAOL J.R., Parameter estimation of state space models by recurrent neural networks, *IEE Proc. Control Theory Appl.*, vol.142, n.2, p.114-118, 1995.

ROLAIN, Y., SCHOUKENS, J., PINTELON, R., Order Estimation for Linear Time-Invariant Systems Using Frequency Domain Identification Methods, *IEEE Transactions on Automatic Control*, vol.42, n.10, p.1408-1417, 1997.

ROSENBLATT, F., Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms, *Spartan Books, New York, USA*, 1962.

RUMELHART D.E., HINTON G.E., WILLIAMS R.J., Learning internal representations by error propagation, *Parallel distributed processing (PDP)*, vol.1:Foundations MIT Press. Cambridge, MA, p.318-362, 1986.

RUSSELL, S., NORVIG, P., Artificial intelligence-A modern approach, *Prentice Hall, NJ, USA*, 1995.

SCHNEIDER H., FRANK P. M., Observer based supervision and fault detection in robots using nonlinear and fuzzy logic residual evaluation, *IEEE Transactions on Controls Systems Technology*, vol.4, n.3, p.274-282, 1996.

SHAHAM B., HASSUL M., Control sistem design using MATLAB. *Prentice Hall, N.J. – USA* 1993.

SHIOZAKI, J., MATSUYAMA, H., O'SHIMA, E., IRI, M., An improved algorithm for diagnosis of system failures, *Comput. Chem. Eng.*, vol.9, p. 285, 1985.

SKATTEBOE, R., LIHOVD, E., HYSTAD, R.A, DIAMON: A Knowledge-Based System for Fault Diagnosis and Maintenance Planning for Rotating Machinery, *Proc. 6th. Int. Workshop on Expert Systems and Applications, France*, vol.1, p.633-647, 1986.

SHORTLIFFE, E.H., Computer-Based Medical Consultations: MYCIN, *American Elsevier/North Holland*, 1976.

SHOURESHI R., CHU R., Hopfield-Based Adaptive State Estimators. *IEEE International Conference on Neural Networks*, San Francisco, California, vol.3, p.1289-1294, 1993.

SODERSTROM T., LJUNG L., GUSTAVSSON I., A Theoretical analysis of recursive identification methods. *Automatica*, vol.14, p.231-244, 1978.

SORSA, T., KOIVO, H.N., KOIVISTO H., Neural Networks in Process Fault Diagnosis, *IEEE Transactions on Systems, Man and Cybernetics*, vol. 21, n.4, p.815-825, 1991.

SORSA, T., KOIVO, H.N., Application of artificial neural networks in process fault diagnosis, *Automatica*, vol. 29, n.4, p.843-849, 1993.

TAKAGI, T., SUGENO, M., Derivation of fuzzy control rules from human operator actions, *Proc. IFAC Symp. Fuzzy Inf., Marseille, France*, p.55-60, 1983.

TAKAGI, T., SUGENO, M., Fuzzy identification and its application to modeling and control, *IEEE Trans. Syst., Man, Cybern.*, vol. SMC-15, p.116-132, 1985.

TANK, D.W., HOPFIELD, J. J., Simple neural optimization networks: an A/D converter, signal decision circuit and linear programming circuit. *IEEE Transactions on Circuits and Systems*, vol.CAS-33, n.5, p.533-541, 1986.

TSOI, A.C., BACK, A.D., Locally recurrent globally feedforward networks: A critical review of architectures, *IEEE Transactions on neural networks*, vol.5, n.2, p.229-239, 1994.

TSUGE, Y., SHIOZAKI, J., MATSUYAMA, H., O'SHIMA, E., Fault Diagnosis Algorithms Based on the Signed Directed Graph and its Modifications, *I. Chem. Eng. Symp. Ser.*, vol.92, p. 133, 1985.

TZAFESTAS, S.G., System Fault Diagnosis Using the Knowledge-Based Methodology, *Fault Diagnosis in Dynamic Systems: Theory and Applications* by Patton R., Frank P. and Clark R., 15, p. 509-572, 1989.

ULIERU ,M., ISERMANN, R., Design of Fuzzy – Logic Based Diagnostic Model for Technical Processes, *Int. Journal of Fuzzy Sets and Systems*, vol.58, p.249-271, 1993.

UMEDA, T., KYRIYAMA, T., O'SHIMA, E., MATSUYAMA H., A graphical approach to cause and effect analysis of chemical processing systems, *Chem. Eng. Sci.*, vol.35, n.5, p.2379, 1980.

VACHKOV G., MATSUYAMA H., Fault diagnosis method by using fuzzy rule based models, *Proceedings of the 2nd International conference on Fuzzy Logic & Neural Networks, Iizuka-Japan*, p.385-388, 1992.

VON ZUBEN, F.J., Modelos paramétricos e não-paramétricos de redes neurais artificiais e aplicações, *Tese de Doutorado-UNICAMP*, 1996.

WANG, L.X., AND MENDEL J.M., Generating fuzzy rules by learning from examples, *IEEE Trans. Syst., Man, Cybern.*, vol. 22, pp. 1414-1427, 1992.

WASSERMAN, P.D., Neural computing: Theory and practice, *Van Nostrand Reinhold*, New York, NY, 1989.

WIDROW, B., WINTER, R., Neural nets for adaptive filtering and for adaptive pattern recognition, *IEEE Computer*, vol. 21, p.25-39, 1988.

WILLIAMS, R.J., ZIPSER, D., A learning algorithm for continually running fully recurrent neural networks, *Neural Computation*, vol.1, n.2, p.270-280, 1989.

WILLIAMS, T.L., ORGREN, P.J., SMITH, C.L., Diagnosis of Multiple Faults in Nationwide Communications Networks, *Proc. IJCAI-83*, p.179-181, 1983.

WILLSKY, A. S., A survey of design methods for failure detection in dynamic systems. *Automatica*, vol.12, p.601-611, 1976.

ZADEH, L. A., Fuzzy sets, *Inform. Contr.*, vol.8, p.338-353, 1965.

ZADEH, L. A., Outline of a new approach to the analysis of complex systems, *IEEE Trans. Syst. , Man, Cybern.*, vol.SMC-3, p.28-44, 1973.

ZADEH L. A., Some reflections on the anniversary of Fuzzy Sets and Systems, *Fuzzy Sets and Systems*, vol.100, p.5-7, 1998.

ZHANG, C.Q., FADALI, M.S., Nonlinear System Identification Using Gabor/Hopfield Network, *IEEE Trans. Syst. , Man, Cybern.*, vol.26, n.1, p.124-134, 1996.

Índice do autor

AYOUBI (1994), 11
BALLE & NELLES (1997), 18, 162
BASSEVILLE (1988), 152
BRANDÃO (1999), 123
CAMINHAS (1997), 17
CHIARELLO (1998), 145
CHOW & WILLSKY (1984), 10, 143
CHU *et al.* (1990), 19, 33, 69
CLARK (1978A), 9, 147, 149
CLARK (1978B), 9, 147, 149
DELGADO *et al.* (1995), 18
DEMETRIOU & POLYCARPOU (1998), 16
DEXTER (1995), 14
DEXTER & BENOURETS (1997), 14, 18
DONADON (1998), 141
DUBOIS & PRADE (1980), 54
DRAYE *et al.* (1996), 26
EMAMI-NAEINI *et al.* (1988), 149
ELMAN (1990), 26
FRANK (1990), 7, 9, 137, 139, 147, 149
FRANK & DING (1994), 42
FRANK (1994), 147

- FRANK & DING (1997), 14, 143, 147, 149
- FRANK & WÜNNENBERG (1989), 143
- FREYERMUTH (1991), 12, 156
- FÜSSEL *et al.* (1997), 17
- GAZDIC (1987), 154
- GENESERETH (1984), 154
- GERTLER (1988), 7
- GERTLER & SINGER (1990), 10, 145
- GLASS *et al.* (1995), 18
- GOLDBERG (1989), 17
- GUAN & SAIF (1991), 147
- HAYKIN (1996), 141
- HAYKIN (1999), 24
- HEBB (1949), 21
- HECHT-NIELSEN (1990), 21
- HIMMELBLAU *et al.* (1989), 159
- HOLLAND (1975), 17
- HOPFIELD (1982), 21, 27, 28
- HOPFIELD (1984), 27, 30
- HORNIK *et al.* (1989), 22, 23
- HOSKINS & HIMMELBLAU (1988), 15, 159
- HOSKINS *et al.* (1991), 15
- HUALLPA *et al.* (1997A), 65, 96
- HUALLPA *et al.* (1997B), 65, 96, 100
- HUALLPA *ET AL.* (1998A), 43, 105, 111
- HUALLPA *et al.* (1998B), 65, 116, 119
- HUALLPA *et al.* (1999), 43, 105, 110
- HUSH & HORNE (1993), 21, 22
- IRI *et al.* (1980), 13, 41, 156
- ISERMANN (1984), 7, 139, 143, 162, 163

- ISERMANN (1993), 7, 139
- KLIR & FOLGER (1988), 13
- KOSMATOPOULOS *et al.* (1995), 18
- KRAMER & PAULOWITCH (1987), 13, 41, 155, 156
- KREISSELMEIER (1977), 96
- LEE (1990A), 56
- LEE (1990B), 56
- LEE *et al.* (1985), 12
- LEGER *ET AL.* (1998), 18
- LEVIN & NARENDRA (1995), 18
- LJUNG (1987), 25
- LOU *et al.* (1986), 143
- LUENBERGER (1971), 9, 137
- MAMDANI & ASSILIAN (1975), 55
- MAKI & LOPARO (1997), 16
- MARCU & MIREA (1997), 16, 161
- MARCU *et al.* (1998), 16, 161
- McCULLOCH & PITTS (1943), 21
- MEDVEDEV (1995), 143
- MEHRA & PESHON (1971), 149
- MELO (1998), 9
- MENSKY & PAPERT (1969), 21
- NAIDU *et al.* (1990), 15, 159
- NARENDRA & ANNASWAMY (1989), 24, 93, 96
- NARENDRA & PARTHASARATHY (1990), 18, 21, 24
- NILSON NILS (1998), 158
- NINNESS & GOODWIN (1995), 137
- PHAM & LIU (1992), 26
- PHAM & WU (1994), 18
- PATTON *et al.* (1989), 7, 149

- PATTON *et al.* (1997), 17
- PETTI *et al.* (1990), 13
- PEDRYCS & GOMIDE (1998), 55
- PFEUFER & AYOUBI (1995), 18
- PIPITONE (1986), 154
- POLYCARPOU & HELMICKI (1995), 16
- RAOL (1994), 33
- RAOL (1995), 19, 33
- ROLAIN *et al.* (1997), 25
- ROSENBLATT (1962), 21
- RUMELHART *et al.* (1986), 21, 23
- RUSSELL & NORVIG, (1995), 138, 155
- SCHNEIDER & FRANK (1996), 14, 17, 149
- SHAHAM & HASSUL (1993), 92
- SHIOZAKI *et al.* (1985), 41, 156
- SKATTEBOE *et al.* (1986), 154
- SHORTLIFFE (1976), 154
- SHOURESHI & CHU (1993), 19, 33, 96
- SODERSTROM *et al.* (1978), 8, 141
- SORSA *et al.* (1991), 16, 159, 161
- SORSA & KOIVO (1993), 16, 159, 161
- TAKAGI & SUGENO (1983), 55
- TAKAGI & SUGENO (1985), 55
- TANK & HOPFIELD (1986), 33
- TSOI & BACK (1994), 26
- TSUGE *et al.* (1985), 41, 156
- TZAFESTAS (1989), 19, 154
- ULIERU & ISERMANN (1993), 19, 162, 166
- UMEDA *et al.* (1980), 155, 156
- VACHKOV & MATSUYAMA (1992), 14

- VON ZUBEN (1996), 26
- WANG & MENDEL (1992), 138
- WASSERMAN (1989), 22
- WIDROW & WINTER (1988), 21
- WILLIAMS & ZIPSER (1989), 26
- WILLIAMS *et al.* (1983), 154
- WILLSKY (1976), 143, 147, 149
- ZADEH (1965), 13, 48, 52
- ZADEH (1973), 48
- ZADEH (1998), 18
- ZHANG & FADALI (1996), 18