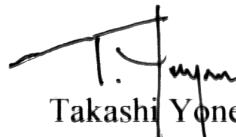


Tese apresentada à Pró-Reitoria de Pós-Graduação e Pesquisa do Instituto Tecnológico de Aeronáutica, como parte dos requisitos para obtenção do título de Doutor em Ciências no Curso de Pós-Graduação em Engenharia Eletrônica e Computação, Área de Sistemas e Controle.

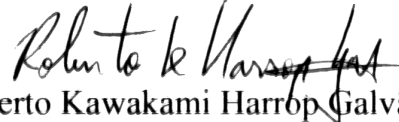
Jackson Paul Matsuura

**DETECÇÃO DE FALHAS EM SISTEMAS DINÂMICOS COM
REDES BAYESIANAS APRENDIDAS A PARTIR DE
ESTIMAÇÃO DE ESTADOS**

Tese aprovada em sua versão final pelos abaixo assinados:



Takashi Yoneyama
Orientador



Roberto Kawakami Harrop Galvão
Co-orientador

Homero Santiago Maciel
Pró-Reitor de Pós-Graduação e Pesquisa

Campo Montenegro
São José dos Campos, SP – Brasil
2006

Dados Internacionais de Catalogação-na-Publicação (CIP)
Divisão Biblioteca Central do ITA/CTA

Matsuura, Jackson Paul

Detecção de falhas em sistemas dinâmicos com redes Bayesianas aprendidas a partir de estimação de estados / Jackson Paul Matsuura.

São José dos Campos, 2006.

121f.

Tese de doutorado – Curso de Engenharia Eletrônica e Computação. Área de Sistemas e Controle – Instituto Tecnológico de Aeronáutica, 2006. Orientadores: Takashi Yoneyama e Roberto Kawakami Harrop Galvão.

1. Diagnóstico de falhas. 2. Sistemas dinâmicos. 3. Teorema de Bayes. I. Centro Técnico Aeroespacial. Instituto Tecnológico de Aeronáutica. Divisão de Engenharia Eletrônica. II. Título

REFERÊNCIA BIBLIOGRÁFICA

MATSUURA, Jackson Paul. **Detecção de falhas em sistemas dinâmicos com redes Bayesianas aprendidas a partir de estimação de estados**. 2006. 120f. Tese de Doutorado em Sistemas e Controle – Instituto Tecnológico de Aeronáutica, São José dos Campos.

CESSÃO DE DIREITOS

NOME DO AUTOR: Jackson Paul Matsuura

TÍTULO DO TRABALHO: Detecção de falhas em sistemas dinâmicos com redes Bayesianas aprendidas a partir de estimação de estados

TIPO DO TRABALHO/ANO: Tese / 2006

É concedida ao Instituto Tecnológico de Aeronáutica permissão para reproduzir cópias desta tese e para emprestar ou vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta tese pode ser reproduzida sem a autorização do autor.

Jackson Paul Matsuura
Instituto Tecnológico de Aeronáutica – ITA
Divisão de Engenharia Eletrônica – Sala 172
Pça Mal-do-Ar Eduardo Gomes, 50 – Vl. Acácias
12228-900 – São José dos Campos - SP

Detecção de Falhas em Sistemas Dinâmicos com Redes Bayesianas

Aprendidas a Partir de Estimação de Estados

Jackson Paul Matsuura

Composição da Banca Examinadora:

Prof.	Karl Heinz Kienitz	Presidente – ITA
Prof.	Takashi Yoneyama	Orientador – ITA
Prof.	Roberto Kawakami Harrop Galvão	Co-orientador – ITA
Prof.	Fábio Gagliardi Cozman	- USP
Prof.	Walmir Matos Caminhas	- UFMG
Prof.	Carlos Henrique Costa Ribeiro	- ITA

ITA

Aos meus filhos, Jackson Júnior, Jéssica e Juliana e à minha esposa Marlene.

Agradecimentos:

A Deus por me dar a capacidade e a oportunidade de realizar esse trabalho.

À minha esposa Marlene pela compreensão e pelo apoio antes e durante a execução deste trabalho.

Aos meus filhos, Jackson Júnior, Jéssica e Juliana por servirem de apoio e motivação para a realização deste trabalho.

Aos meus orientadores Prof. Dr. Takashi Yoneyama e Prof. Dr. Roberto Kawakami Harrop Galvão, não apenas pela sua orientação acadêmica, mas também por todo apoio e incentivo, prestados antes e durante a realização deste trabalho.

À Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP pelo financiamento parcial deste trabalho através do Processo 04/01942-0.

Ao Instituto Tecnológico de Aeronáutica – ITA pelo apoio durante o desenvolvimento deste trabalho.

Aos professores, amigos e colegas que contribuíram direta ou indiretamente em vários níveis com esse trabalho, e em particular aos membros da Banca Examinadora pelas suas valiosas críticas e sugestões.

Ao “Mestre” Marcelo Santiago do Amaral, que mesmo longe ainda serve de exemplo e inspiração em meus estudos.

“Las grandes ideas son aquellas de
las que lo único que nos sorprende es
que no se nos hayan ocurrido antes.”
(Noel Clarasó, escritor español, 1905-1985)

Resumo

A pronta detecção da ocorrência de falhas em sistemas dinâmicos é essencial na prevenção de condições de operação perigosas e mesmo de avaria física do sistema, o que colocaria em risco recursos valiosos, equipamento vital e vidas humanas. Os métodos convencionais de detecção de falhas, porém, esbarram em limitações de espaço físico, ausência de um modelo matemático acurado do sistema e indisponibilidade de dados sobre o comportamento do sistema operando com falhas, entre outros. Nesse trabalho é proposto e avaliado um novo método de Detecção de Falhas em Sistemas Dinâmicos que apresenta vantagens tanto qualitativas quanto quantitativas sobre os métodos já reportados na literatura. O método proposto é fácil de ser entendido em alto nível, tem grande semelhança com a supervisão humana, não necessita de equipamento adicional, não requer um modelo acurado do sistema e não precisa de informação sobre falhas anteriores no sistema, podendo ser aplicado em sistemas onde os outros métodos dificilmente apresentariam resultados satisfatórios. Na abordagem proposta, uma rede Bayesiana é aprendida a partir de valores observados do sistema operando normalmente sem falhas. Essa rede é então usada na detecção de falhas, inferindo que desvios do comportamento probabilístico aprendido como normal são causados por falhas no sistema. Os resultados obtidos com o novo método, extremamente animadores, são comparados aos obtidos com a utilização de um método baseado em redundância analítica, mostrando-se bastante superiores aos mesmos. Resultados adicionais obtidos no isolamento de falhas e na detecção de falhas de um sistema não-linear corroboram os resultados obtidos, apontando para um grande potencial de uso do método proposto.

Abstract

The prompt detection of faults in dynamic systems is essential for the prevention of dangerous operation conditions and physical damage of the system, which would put at risk valuable resources, vital equipment and human lives. The conventional fault detection methods, however, present difficulties associated to physical space, inexistence of an accurate mathematical model of the system and unavailability of data of the system operating under faults, among others. In this work a new method of Fault Detection in Dynamic Systems is proposed and evaluated, presenting both quantitative and qualitative advantages over the methods already reported in the literature. The proposed method is easy to understand in high abstraction level, has great similarity with the human supervision, does not need additional equipment, does not require an accurate model of the system and does not need any information on previous faults in the system. Therefore it can be applied in systems where other methods would hardly present satisfactory results. In the proposed approach, a Bayesian network is learned from observed values of the system operating under normal conditions (without faults). This network is then used in the fault detection, inferring that deviations of the learned probabilistic behavior are caused by faults in the system. The results obtained with the new method (very promising) are compared with those obtained with the use of a method based on analytical redundancy, showing the superiority of the proposed method. Additional results obtained with fault detection and isolation and with fault detection in a nonlinear system corroborate the results obtained in comparison to analytical redundancy, pointing to a great potential of use of the proposed method.

Sumário

Lista de Figuras

Lista de Tabelas

Lista de Abreviaturas e Siglas

1 Introdução.....	19
1.1 Motivação.....	19
1.2 Escopo.....	20
1.3 Contribuições.....	21
1.4 Organização.....	21
2 Fundamentação Teórica.....	23
2.1 Detecção de Falhas.....	23
2.2 Redes Bayesianas e Aprendizagem.....	24
2.3 Identificação em Subespaços.....	26
2.4 Curvas ROC.....	26
2.5 Métodos de Detecção de Falhas.....	27
2.5.1 Redundância Física.....	29
2.5.2 Redundância Analítica.....	30
2.5.3 Análise de Sinais.....	31
2.5.4 Sistemas Baseados em Conhecimento.....	33
2.5.5 Aprendizagem com Falhas.....	34
2.5.6 Aprendizagem sem Falhas com Reaprendizagem <i>on-line</i>	36
2.5.7 Aprendizagem sem Falhas com Verificação <i>on-line</i>	37

3 Método Proposto	39
3.1 Introdução.....	39
3.2 O Método de Detecção de Falhas	39
3.3 Verificação do Conjunto de Dados.....	43
3.4 Exemplo de Aplicação.....	44
3.5 Similaridade com Supervisão Humana.....	49
3.6 Vantagens Qualitativas	51
3.7 Alternativas à Aprendizagem de Redes Bayesianas.....	52
4 Detecção de Falhas em um Servomecanismo	58
4.1 Sistema Simulado	59
4.2 Procedimentos	63
4.3 Resultados.....	67
4.3.1 Resultados da Redundância Analítica	68
4.3.2 Resultados do Método Proposto.....	72
4.3.3 Comparações entre o Método Proposto e a Redundância Analítica.....	77
4.3.4 Aprendizagem com Quantidade Menor de Dados.....	82
4.3.5 Comparações com Métodos Alternativos de Aprendizagem	83
5 Resultados Adicionais de Detecção e Isolamento de Falhas.....	86
5.1 Dinâmica Longitudinal de Aeronave.....	86
5.2 Detecção de Falhas em Sistema Não-Linear	95
5.3 Isolamento de Falhas	101
6 Conclusão	110

6.1 Conclusões Gerais	110
6.2 Contribuições do trabalho.....	111
6.3 Trabalhos Futuros	111
Referências Bibliográficas.....	113

Lista de Figuras

FIGURA 2.1 – Exemplo de estrutura de rede Bayesiana.....	25
FIGURA 2.2 – Classificação dos Métodos de Detecção de Falhas.....	28
FIGURA 2.3 – Esquema geral para detecção de falhas com o uso de redundância analítica ..	30
FIGURA 2.4 – Esquema de detecção de falhas baseado em wavelets.....	32
FIGURA 2.5 – Rede Bayesiana para detecção de falhas em um reator de polimerização.....	33
FIGURA 2.6 – Rede neural artificial para detecção de falhas em motor de indução.	34
FIGURA 3.1 – Esquema de detecção de falhas do método proposto.....	42
FIGURA 3.2 – Circuito equivalente do servomecanismo de velocidade.....	45
FIGURA 3.3 – Estrutura da rede Bayesiana aprendida para o servomecanismo.....	48
FIGURA 3.4 – Entrada u e saída y do sistema a ser monitorado operando em condições normais.	50
FIGURA 3.5 – Entrada u e saída y do sistema sendo monitorado com uma falha ocorrendo em $t = 5,44$ segundos.....	50
FIGURA 3.6 – Exemplo de detecção de falhas com agrupamento via k -Means. (a) Vetores de operação normal do sistema. (b) Centros dos agrupamentos obtidos via k -Means. (c) Regiões correspondentes à operação normal do sistema para um limiar de proximidade d . (d) Exemplo de detecção de falha para dois vetores de operação normal, n_1 e n_2 e para dois vetores de operação na presença de uma falha, f_1 e f_2	54
FIGURA 3.7 – Exemplo de detecção de falhas com agrupamento via mapa de Kohonen. (a) Vetores de treinamento e rede de Kohonen obtida. (b) Neurônios rotulados como válidos. (c) Exemplo de vetores de operação com falha, f_1 , f_2 e f_3 . (d) Exemplos de vetores de operação normal n_1 , n_2 e n_3	56
FIGURA 4.1 – Entrada e saída do servomecanismo com ruído baixo. (a) Operação normal. (b) Falha 1 ocorrendo em $t = 3,4$ segundos. (c) Falha 2 ocorrendo em $t = 3,4$ segundos. (d) Falha 3 ocorrendo em $t = 3,4$ segundos.....	61
FIGURA 4.2 – Entrada e saída do servomecanismo com ruído médio. (a) Operação normal. (b) Falha 1 ocorrendo em $t = 3,4$ segundos. (c) Falha 2 ocorrendo em $t = 3,4$ segundos. (d) Falha 3 ocorrendo em $t = 3,4$ segundos.....	62

FIGURA 4.3 – Entrada e saída do servomecanismo com ruído alto. (a) Operação normal. (b) Falha 1 ocorrendo em $t = 3,4$ segundos. (c) Falha 2 ocorrendo em $t = 3,4$ segundos. (d) Falha 3 ocorrendo em $t = 3,4$ segundos.....	62
FIGURA 4.4 - Diagrama de Simulação do Servomecanismo.....	63
FIGURA 4.5 - Diagrama de Simulação do Servomecanismo com Observador.....	63
FIGURA 4.6 - Diagrama de Simulação das Falhas do Servomecanismo.....	64
FIGURA 4.7 – Ordens das variáveis da rede Bayesiana. (a) Canônica. (b) Inversa. (c) Mista.....	65
FIGURA 4.8 – Estrutura da rede Bayesiana aprendida.....	66
FIGURA 4.9 – Saída do servomecanismo para uma falha em $t=3,35s$	67
FIGURA 4.10 – Curvas ROC do observador de estados para nível de ruído baixo e observadores lento, médio e rápido.....	68
FIGURA 4.11 – Curvas ROC do observador de estados para nível de ruído médio e observadores lento, médio e rápido.....	69
FIGURA 4.12 – Curvas ROC do observador de estados para nível de ruído alto e observadores lento, médio e rápido.....	70
FIGURA 4.13 – Curvas ROC do observador de estados para observador lento e diferentes níveis de ruído.....	71
FIGURA 4.14 – Curvas ROC do observador de estados e das redes Bayesianas para nível de ruído baixo.....	77
FIGURA 4.15 – Curvas ROC do observador de estados e das redes Bayesianas para nível de ruído médio.....	78
FIGURA 4.16 – Curvas ROC do observador de estados e das redes Bayesianas para nível de ruído alto.....	79
FIGURA 4.17 – Valores de AUCs.....	80
FIGURA 4.18 – Tempos médios de Detecção.....	81
FIGURA 4.19 – Curvas ROC das redes Bayesianas para diferentes quantidade de dados de aprendizagem.....	83

FIGURA 4.20 – Curvas ROC dos diferentes métodos utilizados.	85
FIGURA 5.1 – Nomenclatura para o movimento longitudinal da aeronave.	87
FIGURA 5.2 – Diagrama de simulação do movimento longitudinal da aeronave 747.	88
FIGURA 5.3 – Exemplo de rajada de vento na direção x.	89
FIGURA 5.4 – Exemplo de rajada de vento na direção z.	90
FIGURA 5.5 – Variação de altitude medida pelo sensor em condições normais.	90
FIGURA 5.6 – Variação de altitude medida pelo sensor com falha em 300 s.	91
FIGURA 5.7 – Variação de altitude real com falha em 300 s.	91
FIGURA 5.8 – Estrutura da rede Bayesiana aprendida.	92
FIGURA 5.9 – Curvas ROC.	93
FIGURA 5.10 – Sinais de controle para operação normal e para falha em 300 segundos.	94
FIGURA 5.11 – Manipulador <i>Pick and Place</i>	95
FIGURA 5.12 – Função de pertinência para a entrada erro (graus).	96
FIGURA 5.13 – Função de pertinência para a entrada <i>rate</i> (graus/s).	96
FIGURA 5.14 – Função de pertinência para a saída torque (Nm).	97
FIGURA 5.15 – Regras do controlador nebuloso.	97
FIGURA 5.16 – Estrutura da rede Bayesiana aprendida.	98
FIGURA 5.17 – Curvas ROC para falha de +5° na saída.	98
FIGURA 5.18 – Curvas ROC para falha de -5° na saída.	100
FIGURA 5.19 – Curvas ROC para falha de +10° na saída.	100
FIGURA 5.20 – Curvas ROC para falha de -10° na saída.	101
FIGURA 5.21 – Diagrama do DOS para um sistema com três saídas.	103

FIGURA 5.22 – Estrutura da rede Bayesiana aprendida.....	105
FIGURA 5.23 – Curvas ROC para o DOS e para a rede Bayesiana para os três níveis de ruído e para falhas em cada um dos três sensores.....	106
FIGURA 5.24 – AUC para os três níveis de ruído e falhas em cada um dos três sensores. ..	107
FIGURA 5.25 – Tempo de detecção médio para os três níveis de ruído e para falhas nos três sensores.....	108

Lista de Tabelas

TABELA 3.1 – Parâmetros do Servomecanismo de Velocidade.....	46
TABELA 4.1 – Parâmetros estimados de um servomecanismo real.....	59
TABELA 4.2 – AUCs para o observador lento.....	70
TABELA 4.3 – Tempo médio de detecção para o observador lento.....	71
TABELA 4.4 – Estatísticas das AUCs para diferentes níveis de discretização.	72
TABELA 4.5 – Estatísticas dos tempos de detecção para diferentes níveis de discretização..	73
TABELA 4.6 – Tempo médio de processamento de um conjunto de valores.	73
TABELA 4.7 – Estatísticas das AUCs para diferentes observadores.	74
TABELA 4.8 – Estatísticas dos tempos de detecção para diferentes observadores.....	74
TABELA 4.9 – Estatísticas das AUCs para a análise de resíduos com diferentes observadores.	75
TABELA 4.10 – Estatísticas das AUCs para diferentes ordens dos nós.....	76
TABELA 4.11 – Estatísticas dos tempos de detecção para diferentes ordens dos nós.	76
TABELA 4.12 – Estatísticas das AUCs para diferentes quantidades de dados.	76
TABELA 4.13 – Estatísticas dos tempos de detecção para diferentes quantidades de dados..	76
TABELA 4.14 – AUCs para o observador de estados e para as redes Bayesianas.....	79
TABELA 4.15 – Tempo médio de detecção para o observador de estados e para as redes Bayesianas.	79
TABELA 4.16 – AUCs para os diferentes métodos utilizados.	84
TABELA 4.17 – Tempo médio de detecção para os diferentes métodos utilizados.	84
TABELA 5.1 – Resultados obtidos para o observador de estados e para as redes Bayesianas.	94

TABELA 5.2 – AUCs para detecção de falhas do sistema não-linear.....	101
TABELA 5.3 – Valores médios de AUC e tempo de detecção para as redes Bayesianas e o DOS.....	108
TABELA 5.4 – Razões de detecção de falhas, falso alarme e isolamento.....	108

Lista de Abreviaturas e Siglas

- AUC : Área sob a Curva (*Area Under Curve*)
- BNT : Pacote *Bayes Net Toolbox*
- DOS : Esquema de Observadores Dedicados (*Dedicated Observer Scheme*)
- EWD : Discretização em Intervalos Iguais (*Equal Width Discretization*)
- FPR : Taxa de Falso Positivo – (*False Positive Rate*)
- K2 : Kutató 2 - denominação de um algoritmo de aprendizagem Bayesiana
- MSBNx : Software *Microsoft Belief Networks*
- N4SID : Algoritmos Numéricos para Identificação de Sistemas em Subespaços
(*Numerical Algorithms for Subspace State Space System Identification*)
- ROC : Característica de Operação de Receptor (*Receiver Operating Characteristic*)

1 Introdução

1.1 Motivação

Em sentido amplo, uma falha pode ser interpretada como uma mudança inesperada no comportamento de um sistema (SOUZA; GALVÃO; YONEYAMA, 2000). A pronta detecção de tal ocorrência pode ser essencial para impedir uma maior deterioração do sistema, o que poderia conduzir a condições de operação perigosas e mesmo a avaria física, pondo em risco recursos valiosos, equipamento vital e vidas humanas.

Processos químicos, reatores nucleares, sistemas de transporte coletivo e veículos aeroespaciais são exemplos de sistemas dinâmicos onde uma falha não detectada pode conduzir a conseqüências econômicas, ambientais e sociais desastrosas (FRISK, 1993); (SORVA; KOIVO; KOIVISTO, 1991); (VEMURI; POLYCARPOU; CIRIC, 2001).

Um esquema adequado de detecção de falhas pode salvar as vidas de astronautas em uma nave ou estação espacial; pode ainda salvar a tripulação, os passageiros e o equipamento a bordo de uma nave espacial ou de uma aeronave (CHEN; PATTON; LIU, 1994); pode salvar os trabalhadores de uma usina nuclear (SANTOSO et al., 1999), além de toda área e população próxima à usina; pode salvar o motorista e os passageiros de um carro ou de um ônibus (CAPRIGLIONE; LIGUORI; PIETROSANTO, 2004).

Especialmente na área aeroespacial (PATTON; CHEN, 1992); (ARAVENA; CHOWDHURY, 2001); (HUSH et al., 1997); (YAIRI; KATO; HORI, 2001); (WILSON; LAGES; MAH, 2002), uma falha não detectada pode conduzir a conseqüências gravíssimas. Uma única falha pode custar uma estação espacial inteira, uma nave espacial, uma aeronave ou um foguete. Em certos casos, apenas investimentos materiais significativos são perdidos, mas no pior cenário, a tripulação e os passageiros poderiam morrer em conseqüência da não-detecção de uma única falha. As conseqüências poderiam ser ainda mais desastrosas, caso uma aeronave ou os restos de uma estação espacial ou de um foguete caíssem sobre uma área densamente povoada.

A tendência na automação de um número cada vez maior de sistemas e o crescente aumento da complexidade desses sistemas, aliados a uma crescente demanda por tolerância a falhas, eficiência, confiabilidade e segurança, têm estimulado muito o desenvolvimento da área de detecção de falhas.

Durante as últimas três décadas várias abordagens referentes à detecção de falhas foram relatadas. Parte do esforço nessa área pode ser visto nos trabalhos de Angeli e

Chatzinikolau (2004), Fenton, McGinnity e Maguire (2001), Venkatasubramanian et al. (2003a), Venkatasubramanian et al. (2003b), e Venkatasubramanian et al. (2003c).

Mais recentemente observa-se um grande esforço sendo realizado no intuito de unir as metodologias da comunidade de Detecção e Isolamento de Falhas, que tem como base de suas propostas as disciplinas de Engenharia como Teoria de Controle e Tomada de Decisão Estatística, e da comunidade de Diagnóstico de Falhas, que tem como base de suas propostas os campos da Ciência da Computação e Inteligência Artificial (BISWAS et al., 2004); (ZHAO; XU, 2004); (GENTIL; MONTMAIN; COMBASTEL, 2004); (LAMPERTU; ZANELLA, 2004); (RINNER; WEISS, 2004).

Por outro lado, a utilização de sistemas baseados em redes Bayesianas, que são uma representação compacta de distribuições de probabilidades conjuntas de um domínio, vem crescendo a cada dia nas mais diversas áreas, como Medicina (KOEHLER; NASSAR, 2002); (KWEI, 1999); (VEGAS, 1994), Engenharia Civil (CHAN, 1996), Genética (COELHO, 2002) e Educação (VALLDEPERAS, 2000). A utilização das redes Bayesianas vem crescendo também em diversos tipos de aplicações, como Sistemas Especialistas (CASTILLO; GUTIERREZ; HADI, 1997), Sistemas de Filtragem de Dados (SAHAMI et al., 1998), Sistemas de Diagnóstico (CHAN, 1996); (SILVESTRE, 2003), Classificadores (WANG; ZANIOLO, 2000), Sistemas de Análise de Dados (CHOUDREY, 2002), (DOSHI, 2001) e Sistemas de Apoio à Decisão (REIS, 2001).

Além disso, Matsuura (2003) propõe o uso de aprendizagem e de redes Bayesianas na validação de dados, apresentando resultados bastante promissores. Uma extensão natural da validação de dados seria o monitoramento de dados em tempo real, que, aplicado às medidas de sensores em sistemas dinâmicos nada mais seria do que um sistema de detecção de falhas.

Conforme exposto no capítulo 4, a aprendizagem de uma rede Bayesiana para a detecção de falhas apresenta uma grande similaridade com a supervisão humana.

1.2 Escopo

O objetivo principal deste trabalho é a proposta e a avaliação de um novo método de Detecção de Falhas em Sistemas Dinâmicos baseado na aprendizagem de redes Bayesianas. Tal aprendizagem é baseada no histórico de funcionamento normal do sistema em questão, não requerendo informações sobre situações de falha.

O potencial do método proposto será investigado qualitativa e quantitativamente em comparação com métodos de detecção de falhas já existentes, em termos de sensibilidade, taxa de falsos alarmes e tempo de detecção.

Espera-se que este trabalho sirva como base para a proposição de aprimoramentos e análises comparativas mais detalhadas.

1.3 Contribuições

Entre as contribuições mais relevantes desse trabalho, vale ressaltar:

- A proposição de um novo método de detecção de falhas em sistemas dinâmicos;
- A comparação qualitativa do método proposto com outros métodos de detecção de falhas;
- A utilização de curvas ROC (*Receiver Operating Characteristic* – Característica de Operação de Receptor) na comparação quantitativa com métodos de detecção de falhas que utilizam um valor de limiar para decidir sobre a ocorrência de uma falha no sistema;
- A comparação quantitativa entre o método proposto e a detecção de falhas através da análise de resíduo de um observador de estado;
- A comparação entre o método proposto e outros métodos de classificação com aprendizagem que poderiam ser usados na detecção de falhas;
- O estudo da viabilidade da aplicação do método, proposto inicialmente apenas para detecção de falhas em sistemas lineares, na detecção de falhas em sistemas não-lineares e no isolamento de falhas de sensores em sistemas com múltiplas saídas.

Os resultados parciais obtidos durante o desenvolvimento desse trabalho foram apresentados em quatro eventos científicos nacionais e internacionais (MATSUURA; YONEYAMA, 2004a); (MATSUURA; YONEYAMA, 2004b); (MATSUURA; YONEYAMA, GALVÃO, 2005a); (MATSUURA; YONEYAMA, GALVÃO, 2005b); (MATSUURA; YONEYAMA, GALVÃO, 2005c).

1.4 Organização

Para facilitar o entendimento do método de detecção de falhas proposto, no Capítulo 2 é feita a apresentação dos fundamentos teóricos usados neste trabalho e são apresentados alguns métodos de detecção de falhas em sistemas dinâmicos, considerados os mais relevantes ao escopo do trabalho.

No Capítulo 3 o método de detecção de falhas baseado em redes Bayesianas aprendidas é proposto e explicado, e sua utilização é exemplificada para facilitar seu entendimento. Também é realizada uma comparação qualitativa, principalmente com relação a possíveis limitações de uso, entre o método proposto e os métodos apresentados no capítulo 2. Ainda no Capítulo 3 são apresentadas outras técnicas de aprendizagem que teriam as mesmas vantagens qualitativas que o método proposto sobre os métodos apresentados no capítulo 2.

No Capítulo 4 são apresentados os procedimentos e os resultados da comparação do método proposto com a detecção de falhas via análise de resíduos e com a utilização de outras técnicas de aprendizagem em substituição às redes Bayesianas.

No Capítulo 5 são apresentados resultados de testes adicionais, como o isolamento de falhas e a detecção de falhas em sistemas não lineares.

Finalmente, no Capítulo 6, são apresentadas as conclusões e sugestões para trabalhos futuros.

2 Fundamentação Teórica

2.1 Detecção de Falhas

Conforme citado anteriormente, em sentido amplo, uma falha pode ser interpretada como uma mudança inesperada no comportamento de um sistema (SOUZA; GALVÃO; YONEYAMA, 2000). Tal ocorrência deve ser detectada o mais breve possível. Adicionalmente, um sistema de supervisão pode ainda, isolar a falha, identificar a falha e, quando possível, adaptar a operação do sistema à falha apresentada.

A detecção de falhas consiste única e exclusivamente de uma decisão binária sobre a presença ou ausência de falhas no sistema sendo monitorado. O isolamento de falhas consiste na determinação de qual componente ou subsistema está falhando, ou seja, trata da localização das falhas. A identificação de falhas consiste na estimação da extensão ou magnitude da falha, ou seja, é uma quantificação da falha apresentada. Finalmente as decisões e ações tomadas para minimizar os efeitos das falhas são normalmente denominadas de acomodação de falhas (CHEN; PATTON, 1999) (GERTLER, 1998). Muitas vezes o processo completo, desde a detecção até a acomodação de falhas é chamado de diagnóstico de falhas, ou ainda de controle tolerante a falhas.

Embora algumas abordagens de diagnóstico de falhas tentem realizar a detecção e o isolamento de falhas concomitantemente, a maioria dos métodos é dividida em pelos menos dois subsistemas distintos, onde o primeiro é responsável apenas pela detecção de falhas, acionando o segundo subsistema apenas quando uma falha é detectada (GENTIL; MONTMAIN; COMBASTEL, 2004); (JIANGBO; LILING, 2004); (LUNZE; SCHRÖDER, 2004); (ZHANG; PARISINI; POLYCARPOU, 2004).

Desse modo, apesar do diagnóstico de falhas envolver um processamento adicional, métodos que realizam somente a detecção de falhas (CHEN; PATTON; LIU, 1994); (PAIVA, 2003); (SOUZA; GALVÃO; YONEYAMA, 2000) são de grande valia. Com efeito, se a decisão binária inicial não for tomada corretamente, de nada adiantam os passos posteriores. Se uma falha não for detectada, ela não poderá ser isolada nem tampouco quantificada. Por outro lado, se a decisão binária da detecção de falhas for a presença de uma falha quando na realidade o sistema está operando normalmente, o isolamento e a identificação estarão apresentando resultados falsos.

Textos bastante abrangentes a respeito dos conceitos gerais sobre Detecção e Diagnóstico de Falhas em Sistemas Dinâmicos podem ser encontrados em Chen e Patton

(1999), Gertler (1998), Patton, Frank e Clark (1989); (2000), Basseville e Nikiforov (1993) e Venkatasubramanian et. al. (2003a); (2003b); (2003c).

2.2 Redes Bayesianas e Aprendizagem

As redes Bayesianas (PEARL, 1988) são redes de conhecimento que representam graficamente as relações probabilísticas entre as variáveis de um domínio específico. Mais especificamente, uma rede Bayesiana é composta de um grafo direcionado acíclico, onde os nós representam variáveis aleatórias de um domínio e os arcos indicam a existência de dependência probabilística entre os nós ligados. Essas dependências probabilísticas são quantificadas por funções ou tabelas de probabilidade condicional.

Nestas redes, pode-se calcular a probabilidade de um evento ocorrer (uma variável apresentar um valor) condicionado à ocorrência de outro (valores apresentados pelas outras variáveis). Elas representam a incerteza tomando por base a teoria da probabilidade, sendo uma ferramenta prática poderosa de representação do conhecimento e inferência sob condições de incerteza (CHENG; BELL; LIU 1997).

A utilização das redes Bayesianas vem crescendo muito tanto em relação aos possíveis domínios de problema quanto em relação aos tipos de aplicação (MATSUURA, 2003), inclusive na detecção e diagnóstico de falhas (CHAN, 1996); (CHIEN; CHEN; LIN, 2002); (LERNER et al., 2000); (MEHRANBOD, 2002); (SANTOSO et al., 1999).

Como uma rede Bayesiana representa um modelo probabilístico completo das variáveis do domínio, a rede contém informação suficiente para responder a todas as questões probabilísticas sobre essas variáveis. Em particular, com uma rede Bayesiana com variáveis $\{E_1, E_2, \dots, E_n\}$, é possível calcular a probabilidade do valor da variável E_i ser e_i dado que $\{E_k = e_k\}, k=1..n, k \neq i$, ou seja, a probabilidade a posteriori de E_i considerando-se como evidência o valor de todas as outras variáveis (MATSUURA, 2003). A figura 2.1 apresenta um exemplo de estrutura de rede Bayesiana com cinco variáveis.

Uma rede Bayesiana pode ser construída diretamente a partir do conhecimento de especialistas humanos ou aprendida a partir de dados históricos, mas a construção manual de uma rede Bayesiana não é uma tarefa simples, o que torna essa abordagem de uso bastante restrito. Por outro lado, em parte devido aos avanços computacionais, os métodos de aprendizagem de redes Bayesianas estão ficando cada vez mais poderosos e populares (CHENG; BELL; LIU, 1997); (COOPER; HERSKOVITZ, 1992); (KOEHLER; NASSAR, 2002).




FIGURA 2.1 – Exemplo de estrutura de rede Bayesiana.

O problema da aprendizagem de uma rede Bayesiana pode ser enunciado como: dado um conjunto de treinamento $D = \{u_1, u_2, \dots, u_m\}$, de tuplas de U , onde U é o conjunto das variáveis do domínio e cada u_i corresponde aos valores das ocorrências de cada uma das variáveis de U , encontrar a rede B que melhor se adequa a D . Para formalizar a noção de adequação da rede com relação ao conjunto de treinamento uma função custo é utilizada. Técnicas de busca heurística são então utilizadas para solucionar o problema de otimização sobre o espaço de possíveis redes (FRIEDMAN; GOLDSZMIDT, 1996).

Neste trabalho foi utilizado o algoritmo de aprendizagem K2 (COOPER; HERSKOVITZ, 1992), que se tornou bastante popular devido aos resultados obtidos quando aplicado ao conjunto de dados da rede ALARM, um “*benchmark*” amplamente aceito para os algoritmos de aprendizagem Bayesiana (KOEHLER; NASSAR, 2002).

O algoritmo K2 avalia as possíveis topologias de uma rede Bayesiana calculando a probabilidade dessa topologia gerar a base de dados em questão. O algoritmo começa assumindo que um nó não tem antecessores e incrementa o número de antecessores adicionando o antecessor que resulta no maior aumento de probabilidade da estrutura gerar a base de dados. Quando a adição de mais um antecessor ao nó não aumenta mais a probabilidade, o nó pára de receber antecessores e o algoritmo faz o mesmo para o nó seguinte.

Uma breve introdução teórica sobre as redes Bayesianas pode ser encontrada em Matsuura (2003) e uma introdução teórica mais detalhada pode ser encontrada em Pearl (1988).

2.3 Identificação em Subespaços

Caso um modelo matemático do sistema a ser monitorado não esteja disponível, várias técnicas podem ser usadas para a obtenção do mesmo. Nesse trabalho, quando necessário foi utilizada a Identificação em Subespaços.

Nos últimos anos a Identificação em Subespaços tem se tornado bastante popular e atraído bastante atenção. Tal interesse se deve à habilidade de produzir modelos em espaços de estados de sistemas lineares multivariáveis diretamente a partir de dados de entrada e saída do sistema (VAN OVERSCHEE; DE MOOR, 1994). Tais métodos têm sua origem na teoria clássica de realização em espaço de estados e apresentam resultados numericamente confiáveis.

Basicamente, a partir de um conjunto de valores de entrada e saída os métodos de Identificação em Subespaços determinam qual realização apresenta a maior probabilidade de gerar as mesmas saídas (ou o menor erro quadrático na saída) dadas as entradas do sistema. O procedimento de geração e de avaliação das possíveis realizações é que varia de um método para outro. Uma visão geral dos métodos de Identificação em Subespaços e algumas comparações entre eles podem ser encontradas em Viberg (1995) e em Shi e MacGregor (2001).

2.4 Curvas ROC

Vários métodos de detecção de falhas, inclusive o método proposto nesse trabalho, fazem uso de um valor de limiar para tomar a decisão da presença ou ausência de falhas. Caso o valor de uma variável ou o resultado de um cálculo (a diferença entre os valores de duas variáveis, por exemplo) esteja acima (ou abaixo) do valor de limiar a decisão de presença de falha é tomada. Caso contrário o sistema estaria operando normalmente.

É claro que o desempenho de métodos que utilizam um limiar depende diretamente da correta escolha desse limiar. Caso o limiar seja escolhido erroneamente, o método pode não detectar nenhuma falha ou emitir constantemente falsos alarmes de falha enquanto o sistema opera normalmente.

Dessa forma, uma comparação entre métodos que utilizam valores de limiar poderia ser tendenciosa caso fossem utilizados limiares fixos para os mesmos. As curvas ROC podem ser usadas para contornar o problema de escolha de limiar para propósitos comparativos.

As curvas ROC são definidas como um gráfico da sensibilidade de um teste como ordenada versus a taxa de falso positivo (FPR – *false positive rate*) como a abscissa. Elas são

uma ferramenta bastante efetiva para avaliar o desempenho de testes de diagnóstico (PARK; GOO; JO, 2004).

Inicialmente desenvolvida para determinar se um receptor eletrônico é capaz de distinguir sinal de ruído satisfatoriamente (FARAGGI; REISER; 2002), a análise ROC é hoje bastante comum na medicina, particularmente na radiologia, onde é usada para quantificar a exatidão de testes de diagnóstico (VERUMI et al.; 2001); (TILBURY et al.; 2000).

As curvas ROC podem mostrar, por exemplo, a relação entre a correta identificação de pacientes doentes como doentes (sensibilidade) e a correta identificação de pacientes sadios como sadios (1-FPR).

Há uma correspondência imediata do uso de curvas ROC em medicina e em detecção de falhas. A sensibilidade na detecção de falhas é a taxa de correta detecção e a FPR é a taxa de falso alarme. Os períodos de operação normal do sistema correspondem a pacientes sadios, enquanto os períodos de operação com falha correspondem a pacientes doentes.

Para a comparação do desempenho de diferentes métodos de detecção de falhas, as curvas ROC podem ser construídas variando-se o valor de limiar de detecção desde o valor que apresente a menor taxa de falso alarme até o valor que apresente a maior taxa de correta detecção. Com as taxas de correta detecção e de falso alarme para esses diferentes valores de limiar de detecção constrói-se a curva ROC de cada método de detecção de falhas.

Uma das medidas mais populares associada às curvas ROC é a área sob a curva (AUC - *area under curve*) (VERUMI et al., 2001); (PARK et al., 2004); (FARAGGI; REISER, 2002) A AUC é uma medida do desempenho global de um teste de diagnóstico e é interpretada como um valor médio de sensibilidade para todos os valores de especificidade (1-FPR). Quanto mais próximo a AUC estiver da unidade, melhor é o desempenho global do teste. Um teste com uma AUC unitária é um teste perfeitamente acurado.

2.5 Métodos de Detecção de Falhas

Durante as últimas três décadas um grande número de abordagens relacionadas com a detecção e o diagnóstico de falhas foi relatada. Muitas delas são baseadas em redundância analítica (CAPRIGLIONE; LIGUORI; PIETROSANTO, 2004); (CHEN; PATTON; LIU, 1994); (FRISK, 1993); (PATTON; FRANK; CLARK, 1989); (PERSIN et al., 2002); (SIMANI; FANTUZZI; BEGHELLI, 2000); (DING et al., 2005) ou no treinamento de redes neurais artificiais (FORTUNA et al., 1999); (GULEZ; KARLIK; VAKKAS, 1996); (HUSH et al., 1997); (JAKUBEK; STRASSER, 2002); (SORSA; KOIVO; KOIVISTO, 1991);

(BACCARINI; MENEZES; CAMINHAS, 2003); (FURTADO et al., 2005) ou ainda em redes *Neurofuzzy* (CAMINHAS; TAVARES; GOMIDE, 1996); (CAMINHAS et al., 1997); (CAMINHAS; TAKAHASHI, 2001); (CAMINHAS; TAVARES; GOMIDE, 2001); (MOK; CHAN, 2005).

Trabalhos mais recentes propõem ainda o uso de transformadas wavelets (PAIVA, 2003); (SOUZA; GALVÃO; YONEYAMA, 2000); (ZHANG; YAN, 2001) e de redes Bayesianas (CHIEN; CHEN; LIU, 2002); (LERNER et al., 2000); (MEHRANBOD, 2002); (SANTOSO et al., 1999); (RIASCOS; SIMÕES; MIYAGI, 2005).

Além disso, um grande esforço está sendo feito para unir as metodologias da comunidade de detecção e isolamento de falhas e da comunidade de diagnóstico (BISWAS et al., 2004). (GENTIL; MONTMAIN; COMBASTEK, 2004).

Apesar de já existirem algumas propostas de subdivisão dos métodos de detecção e diagnóstico de falhas em diferentes grupos (GERTLER, 1998); (VENKATASUBRAMANIAN et al., 2003a), foi aqui adotada uma nova subdivisão em sete grupos, baseada nas limitações dos métodos de detecção de falha. Tal subdivisão teve como objetivo proporcionar uma melhor comparação qualitativa desses métodos com a proposta deste trabalho. Os sete grupos são mostrados na figura 2.2.

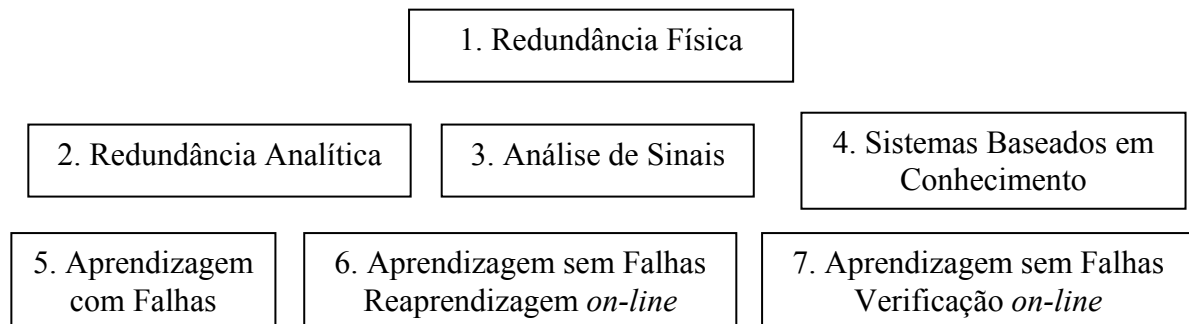


FIGURA 2.2 – Classificação dos Métodos de Detecção de Falhas.

Fazem parte do primeiro grupo (Redundância Física), além da redundância física propriamente dita, os métodos que de alguma forma utilizam equipamento adicional na detecção de falhas, como, por exemplo, sensores de limiar ou de variação de parâmetros, não essenciais ao funcionamento do sistema. No segundo grupo (Redundância Analítica) se enquadram os métodos que utilizam a redundância analítica propriamente dita, ou seja, os métodos que comparam a saída do sistema real com a saída gerada por um modelo matemático do sistema a ser monitorado, seja esse construído a partir de princípios físicos ou

por aprendizagem ou treinamento. Pertencem ao terceiro grupo (Análise de Sinais) os métodos que analisam os sinais dos sensores verificando alguma característica específica dos mesmos, como, por exemplo, a análise espectral de sinais. Fazem parte do quarto grupo (Sistemas Baseados em Conhecimento) os sistemas especialistas, as redes Bayesianas e outros sistemas que sejam criados a partir de conhecimentos de especialistas na operação do sistema a ser supervisionado. Pertencem ao quinto grupo (Aprendizagem com Falhas) os métodos baseados na aprendizagem do comportamento do sistema que utilizam informações históricas dos valores das variáveis do sistema operando sem falhas e com falhas. Um exemplo bastante representativo desse grupo são os métodos baseados no treinamento de redes neurais artificiais como classificadores. No sexto grupo (Aprendizagem sem Falhas com Reaprendizagem *on-line*) estão os métodos de detecção de falhas que realizam aprendizagem a partir do sistema operando normalmente e continuam a realizar a aprendizagem durante a monitoração do sistema, com os dados coletados *on-line*. Finalmente no sétimo grupo (Aprendizagem sem Falhas com Verificação *on-line*) estão os métodos que realizam a aprendizagem a partir do sistema operando normalmente e realizam algum tipo de verificação, mas não uma aprendizagem durante o monitoramento do sistema.

Nas subseções seguintes cada um desses grupos será melhor detalhado e as limitações de sua aplicação serão listadas.

2.5.1 Redundância Física

Fazem parte desse grupo de métodos de detecção de falhas a redundância física propriamente dita e outros métodos que utilizem equipamento adicional, como, por exemplo, o uso de sensores de limiar (temperatura, vibração, aceleração, pressão).

Os primeiros métodos de detecção de falhas baseavam-se na redundância física. Nesses métodos são usados sensores ou até mesmo subsistemas redundantes. As saídas dos subsistemas redundantes, ou as medidas dos sensores redundantes, são comparadas para a detecção de falhas.

Caso os valores redundantes estejam todos próximos, o método infere que o sistema esteja operando normalmente. Por outro lado, casos tais valores diverjam entre si, um alarme de falha é acionado.

Quando mais de dois sensores ou subsistemas são utilizados na redundância física, e apenas uma falha ocorre no sistema, o sensor ou subsistema que apresenta a falha pode ser facilmente identificado, pois seu valor irá ficar distante de todos os outros. Para contornar a

falha, um esquema de votação simples pode ser utilizado e o sensor ou subsistema que apresenta a falha pode ser simplesmente ignorado.

Fica claro que uma das limitações desse tipo de abordagem é que ela é capaz apenas de detectar falhas nos sensores ou subsistemas redundantes. Se a falha ocorrer, por exemplo, no processo em si, que não tem redundância, todos os sensores ou subsistemas apresentariam valores próximos e a falha não seria detectada. O mesmo aconteceria se, por exemplo, a falha acontecesse em um atuador do sistema ou no controlador, que normalmente não são redundantes.

Além disso, há que se considerar o acréscimo de custo, necessidade de espaço e complexidade associados à incorporação de equipamento físico redundante (ZHANG; YAN, 2001). Portanto, o uso dessa abordagem encarece substancialmente o projeto de sistemas onde as limitações de espaço e peso são críticas, como, por exemplo, na área aeroespacial (aeronaves, espaçonaves, satélites, foguetes).

Uma vantagem da redundância física é que o sensor ou subsistema redundante que apresenta a falha pode ser simplesmente ignorado e, devido aos outros sensores ou subsistemas redundantes, o sistema continuaria a operar normalmente sem a necessidade de interrupção de sua operação ou intervenção humana imediata. Em um momento mais adequado o sensor ou subsistema que apresentou a falha pode ser substituído.

2.5.2 Redundância Analítica

A partir da década de 70, com os avanços tecnológicos, foi introduzido o paradigma da redundância analítica, onde um modelo matemático do sistema é utilizado para gerar sinais redundantes que são comparados aos medidos pelos sensores físicos (PERSIN et. al., 2002). Um esquema geral para detecção de falhas com o uso de redundância analítica é apresentado na figura 2.3.

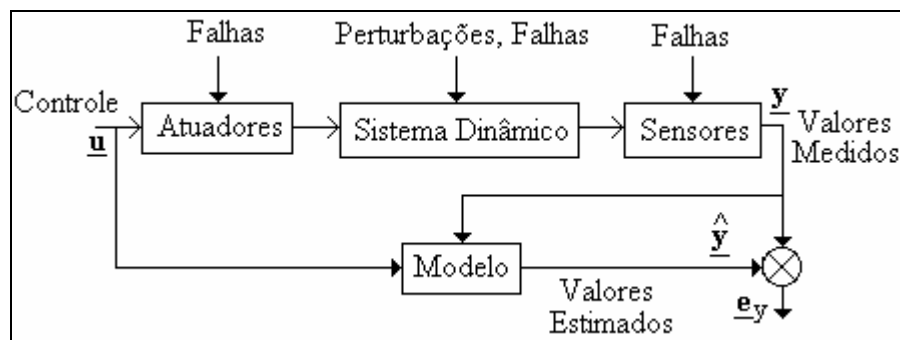


FIGURA 2.3 – Esquema geral para detecção de falhas com o uso de redundância analítica

Várias abordagens para detecção de falhas são baseadas na redundância analítica (CAPRIGLIONE; LIGUORI; PIETROSANTO, 2004); (PERSIN et al., 2002); (SIMANI; FANTUZZI; BEGHELLI, 2000); (DING et al., 2005) e o modelo analítico do sistema muitas vezes é um observador de Luenberger (PATTON; FRANK; CLARK, 1989). A diferença entre as saídas medidas e as calculadas pelo observador são comparadas e caso a diferença, comumente chamada de resíduo, seja superior a um certo limiar um alarme de falha é acionado.

Contudo, o modelo utilizado não necessariamente precisa ser um observador de estado. Qualquer forma de mapeamento entrada-saída pode ser utilizada na geração de uma estimativa do sinal de saída e conseqüentemente na geração do sinal de resíduo. Tal modelo pode, por exemplo, ser uma rede neural artificial treinada a partir de dados de entrada-saída do sistema operando normalmente.

Em vários casos o observador e a avaliação do resíduo podem ser implementados junto com o algoritmo de controle, não necessitando, portanto de espaço adicional como no caso da redundância analítica.

Quando aplicada a sistemas com baixo nível de ruído e com poucas incertezas de modelagem a redundância analítica se mostra bastante eficiente na detecção de falhas, mas em sistemas onde o modelo utilizado para a geração do resíduo e o sistema real se distanciam por erros de modelagem, não-linearidades ou ruído, seu desempenho deteriora muito.

A grande dificuldade com relação à utilização de abordagens que utilizam redundância analítica, ou que dependem de um modelo matemático do sistema, em sistemas reais é a obtenção de um modelo matemático suficientemente acurado do sistema físico. Incertezas de modelagem inevitáveis, advindas, por exemplo, de erros de modelagem, ruído e distúrbios, obscurecem os efeitos das falhas, tornando essas abordagens de uso bastante limitado em alguns casos (POLYCARPOU; HELMICKI, 1995).

2.5.3 Análise de Sinais

Técnicas de análise de sinais podem ser utilizadas tanto na análise de resíduos provenientes da redundância analítica quanto diretamente no sinal de saída do sistema. Em alguns casos, verificações simples de valores máximos e mínimos, de taxas de variação, de valor médio ou mesmo de potência do sinal podem ser suficientes para a indicação de ocorrência de uma falha no sistema.

Trabalhos mais recentes na área de detecção e diagnóstico de falhas propõem o uso da transformada wavelet e wavelet adaptativa (PAIVA, 2003); (SOUZA; GALVÃO; YONEYAMA, 2000) como ilustrado na figura 2.4; onde G é a função de transferência incorporando o atuador, a planta e o sensor, o Emulador representa o modelo do sistema na faixa de frequências considerada e DWT representa a transformada wavelet discreta, implementada através de um banco de filtros. $D[f]$ indica os coeficientes de f , obtidos através do banco de filtros, no nível de resolução selecionado para análise (PAIVA, 2003). Esse é um exemplo da análise de sinais sendo utilizada em conjunto com a redundância analítica.




FIGURA 2.4 – Esquema de detecção de falhas baseado em wavelets.

A utilização de wavelets na detecção de falhas (e de outros métodos de análise de sinais), assim como a redundância analítica, não implica em necessidade de equipamento adicional. Adicionalmente, se a análise for limitada apenas aos sinais de saída (e não ao resíduo) esses métodos também não necessitam de um modelo matemático acurado do sistema.

As grandes limitações no uso das wavelets na detecção de falhas são a baixa resolução espectral em alta frequência e a latência para se obter informações relevantes em baixa frequência, características essas inerentes às wavelets. Além disso, os métodos baseados em wavelets usam a informação relativa a apenas um par de variáveis (normalmente sinal de controle e saída) na detecção das falhas. Para sistemas simples a informação de relações de apenas duas variáveis pode ser suficiente para a detecção de falhas, mas para sistemas reais, com várias variáveis e dinâmica complexa, essa abordagem pode levar a resultados bem limitados.

Outras técnicas de análise de sinais, como o processamento estatístico de sinais ou a análise espectral, também estão limitadas ao monitoramento de apenas um sinal de saída, o que nem sempre é suficiente para detectar uma falha. Por esse motivo, normalmente as técnicas de análise de sinais são utilizadas em conjunto com a redundância analítica, na análise de resíduos.

2.5.4 Sistemas Baseados em Conhecimento

Sistemas especialistas e redes Bayesianas construídas a partir de conhecimentos de especialistas também não necessitam de equipamento adicional nem de um modelo matemático acurado do sistema para serem utilizados na detecção de falhas em sistemas dinâmicos.

A partir de entrevistas com especialistas na operação do sistema a ser monitorado, podem ser extraídas as regras necessárias para a construção de um sistema especialista ou mesmo o conhecimento probabilístico a respeito das variáveis do sistema necessário para a construção de uma rede Bayesiana. Em alguns casos um misto de conhecimento de especialistas e aprendizagem pode ser utilizado.

Entre os métodos de detecção de falhas que utilizam redes Bayesianas construídas manualmente estão os trabalhos de Lerner et al. (2000) e Mehranbod (2002).

Todavia, para a construção manual de redes Bayesianas para detecção de falhas (ou de sistemas especialistas) é necessário um profundo conhecimento sobre o sistema, principalmente sobre a probabilidade de ocorrência de falhas e sobre seus efeitos sobre o funcionamento do sistema. Esse conhecimento pode ser mais difícil de se obter do que um modelo acurado do sistema, especialmente em sistemas novos e/ou de complexidade elevada, onde nenhum especialista detém conhecimento suficiente para a construção de um sistema especialista ou de uma rede Bayesiana.

A figura 2.5 apresenta um exemplo de rede Bayesiana construída manualmente para a detecção de falhas em um reator de polimerização (MEHRANBOD, 2002). As variáveis X , R e B representam o valor real, o valor medido e o erro de medida de cada grandeza respectivamente. F , T , E e C indicam a vazão da água de refrigeração, a temperatura do reator, a temperatura do revestimento e a concentração do monômero na saída do reator.




FIGURA 2.5 – Rede Bayesiana para detecção de falhas em um reator de polimerização.

2.5.5 Aprendizagem com Falhas

Nos últimos anos novos métodos e técnicas que não necessitam de um modelo matemático do sistema, mas de alguma forma aprendem como o sistema se comporta na ausência e na presença de falhas vêm sendo propostos e estudados, como por exemplo, o uso de redes neurais artificiais (GULEZ; KARLIK; VAKKAS, 1996); (HUSH et al., 1997); (FORTUNA et. al., 1999); (JAKUBEK; STRASSER, 2002); (SORSA; KOIVO; KOIVISTO, 1991), (BACCARINI; MENEZES; CAMINHAS, 2003); (FURTADO et. al., 2005), e de redes *Neurofuzzy* (CAMINHAS; TAVARES; GOMIDE, 1996); (CAMINHAS et al., 1997); (CAMINHAS; TAKAHASHI, 2001) que são treinadas a partir de medidas do sistema funcionando em condições normais e com falhas. Vários trabalhos utilizam também redes Bayesianas aprendidas de dados do sistema operando normalmente e com falhas (CHIEN; CHEN; LIN, 2002); (SANTOSO et al., 1999); (RIASCOS; SIMÕES; MIYAGI, 2005).

A vantagem do uso de métodos de aprendizagem é a dispensa de equipamento adicional, modelo matemático do sistema, e conhecimento de especialistas.




FIGURA 2.6 – Rede neural artificial para detecção de falhas em motor de indução.

A topologia de uma rede neural proposta para a detecção de falhas em motores de indução (GULEZ; KARLIK; VAKKAS, 1996) é apresentada na figura 2.6. A variável I representa a corrente no rolamento, w a velocidade do rotor, N a condição de isolamento e B a condição de desgaste do rolamento. Os valores das variáveis de interesse (I , w , N , B) foram medidos ou determinados para várias condições de operação do motor de indução. Uma rede neural artificial que tem como entradas os valores de corrente no rolamento e velocidade do

motor, além de funções dessas duas variáveis; e como saídas a condição de isolamento e a condição de desgaste do rolamento foi então treinada para associar a cada conjunto de entradas um conjunto de condições.

A limitação do uso de aprendizagem com falhas está na necessidade de uma grande quantidade de dados do sistema operando com falhas para o treinamento das redes neurais ou para a aprendizagem das redes Bayesianas. A grande maioria, se não a totalidade, dos sistemas críticos, como aeronaves, usinas nucleares, processos químicos de alto custo, não tem uma grande quantidade de dados de operação com falha. Alguns deles não têm nem ao menos os dados referentes a uma única falha.

Sistemas novos também não dispõem dos dados de operação com falha, necessários à aprendizagem. Em alguns casos esses dados podem ser gerados forçando-se algumas falhas no sistema, mas nem todos os sistemas podem operar seguramente com falhas mesmo que intencionais. Além disso, não é possível cobrir toda a gama de falhas às quais um sistema está sujeito.

No caso de motores de indução, onde existe um conjunto de falhas conhecidas que normalmente afetam o sistema, inclusive com dados de operação com falhas, uma rede neural pode ser bastante útil na detecção de falhas, mas esse não é o caso geral.

Simulações do sistema dinâmico operando com falhas poderiam ser usadas para providenciar os dados necessários para a aprendizagem, sem colocar o sistema real em risco. Contudo essa abordagem necessitaria novamente de um modelo matemático acurado do sistema, como no caso da redundância analítica. Se o modelo usado nas simulações não for acurado o suficiente, a rede neural resultante não seria muito útil no monitoramento do sistema real.

Desse modo em sistemas críticos onde pouca ou nenhuma informação a respeito de falhas passadas está disponível, novamente como na área aeroespacial, esses métodos seriam de uso bastante restrito.

O mesmo raciocínio pode ser estendido para outros métodos de detecção de falhas que se baseiam na aprendizagem ou no conhecimento do sistema operando com falhas.

Em compensação, quando dados de operação do sistema com falha estão disponíveis ou podem ser gerados de alguma forma, os métodos baseados em aprendizagem com falhas, além de detectar as falhas, podem ainda ser utilizados no isolamento e na identificação das mesmas. Em alguns casos, dependendo do nível de informação disponível sobre as falhas e suas conseqüências, esses métodos podem até auxiliar na decisão de qual o melhor procedimento a ser tomado para minimizar os efeitos da falha.

2.5.6 Aprendizagem sem Falhas com Reaprendizagem *on-line*

Existem algumas propostas de detecção de falhas com o uso de redes neurais artificiais onde o treinamento das mesmas é realizado apenas com dados de operação normal do sistema (CAMINHAS; TAVARES; GOMIDE, 2001); (MOK; CHAN, 2005); (FREITAS; CERQUEIRA; FERREIRA, 2005). Esses métodos não têm, portanto a limitação da necessidade de uma extensa base de dados de operação com falhas.

Caminhas, Tavares e Gomide (2001) e Mok e Chan (2005) propõem o uso de redes *neurofuzzy*, treinadas a partir de medidas do sistema operando apenas em condições normais. Essas redes identificariam o comportamento normal do sistema. Uma nova rede *neurofuzzy* é então aprendida *on-line*, ou seja, a partir de medidas do sistema funcionando e sendo monitorado. Caminhas, Tavares e Gomide (2001) comparam os pesos da rede treinada anteriormente com os pesos da rede treinada *on-line*, acusando a presença de uma falha caso esses valores se distanciem além de um certo valor de limiar. Mok e Chan (2005) extraem regras *fuzzy* a partir de rede treinada anteriormente e a partir da rede treinada *on-line*, acusando a presença de uma falha caso as regras predominantes sejam diferentes.

Os dois trabalhos (CAMINHAS; TAVARES; GOMIDE, 2001); (MOK; CHAN, 2005) apresentam excelentes resultados quando o método neles proposto é aplicado a um sistema de exemplo. Porém, nenhum deles efetua uma comparação com qualquer outro método de detecção de falhas, o que faz com que não fique claro se as falhas foram detectadas devido à eficiência dos métodos ou à natureza das falhas simuladas.

Outros métodos de identificação de sistemas, como a identificação em subespaços ou a identificação paramétrica, também poderiam ser usados de maneira similar. Um modelo, ou parâmetros do modelo, são identificados com o sistema operando normalmente e novamente durante a supervisão. Caso os modelos ou os parâmetros identificados *on-line* se distanciem dos identificados previamente um alarme de falha é acionado.

Uma possível limitação da Reaprendizagem *on-line* é o tempo necessário para que os efeitos da falha sejam refletidos nos parâmetros aprendidos. Em alguns casos o esforço computacional necessário para a realização da reaprendizagem *on-line* pode ser substancial, fazendo com que o tempo necessário para a detecção de falhas também o seja. Mesmo nos casos em que o esforço computacional da reaprendizagem seja pequeno, dependendo da magnitude e dos efeitos da falha, vários conjuntos de medidas do sistema sendo supervisionado podem ser necessários para a detecção da mesma. No caso de falhas muito

acentuadas essa quantidade de medidas pode ser menor, ou até mesmo uma única amostra pode ser suficiente para a detecção da falha.

2.5.7 Aprendizagem sem Falhas com Verificação *on-line*

Técnicas de aprendizagem tanto de redes Bayesianas quanto de redes neurais artificiais podem ser usadas para a aprendizagem do comportamento normal do sistema, sem, porém que seja necessária uma reaprendizagem *on-line*. Ao invés da reaprendizagem, os dados do sistema sendo supervisionado podem ser simplesmente verificados através da aplicação de alguma métrica que indique a proximidade desses dados do comportamento considerado como normal.

Freitas, Cerqueira e Ferreira (2005) fazem o treinamento de um mapa de Kohonen que representa o sistema operando em condições normais. Esse mapa é utilizado então no monitoramento do sistema. É feita uma verificação da similaridade das medidas do sistema sendo monitorado com os pesos da rede treinada em operação normal. Caso os dados apresentados fiquem muito distantes dos pesos aprendidos pela rede é acusada a presença de uma falha no sistema.

O trabalho (FREITAS; CERQUEIRA; FERREIRA, 2005) apresenta excelentes resultados quando o método nele proposto é aplicado a um sistema de exemplo, porém não foi feita uma comparação com outros métodos de detecção de falhas, o que faz com que não fique claro se as falhas foram detectadas devido à eficiência do método ou à natureza das falhas simuladas.

Uma abordagem parecida com a de Freitas, Cerqueira e Ferreira (2005) foi utilizada como base de comparação para o método proposto nesse trabalho.

Hood e Ji (1997) propuseram o uso de redes Bayesianas, aprendidas apenas a partir de dados de operação normal do sistema, para detecção de falhas em redes de computadores.

Embora a idéia central desse método seja a mesma do método proposto nesse trabalho, ou seja, aprender o relacionamento probabilístico das variáveis do sistema em condições normais de operação e usar esse conhecimento para monitorar o próprio sistema, Hood e Ji (1997) utilizaram uma estrutura pré-definida para a rede Bayesiana e conhecimento de especialistas sobre os possíveis efeitos de falhas para definir parte das probabilidades condicionais, aprendendo apenas uma parcela das probabilidades condicionais a partir de dados de operação normal do sistema. Esses dados de operação normal ainda foram

previamente segmentados e tratados antes de serem utilizados na aprendizagem parcial das probabilidades condicionais.

Desse modo, até onde foi possível verificar-se, ainda não foi reportado na literatura nenhum método de detecção de falhas em sistemas dinâmicos que se baseasse na aprendizagem de redes Bayesianas a partir de dados somente da operação normal do sistema, sem nenhuma suposição sobre os relacionamentos probabilísticos das variáveis e sem qualquer conhecimento de especialistas sobre possíveis falhas e efeitos.

Mais detalhes sobre os esforços e os métodos propostos para detecção e diagnóstico de falhas em sistemas dinâmicos podem ser obtidos nos trabalhos de Angeli e Chatzinikolau (2004), Fenton, McGinnity e Maguire (2001) e Venkatasubramanian et al. (2003a; 2003b; 2003c).

3 Método Proposto

3.1 Introdução

Resumidamente, o método de detecção de falhas proposto consiste na utilização de uma rede Bayesiana no monitoramento do sistema dinâmico. Essa rede Bayesiana é aprendida a partir de dados medidos diretamente do sistema e de valores estimados com o auxílio de um observador de estados.

A idéia central do método é que as relações probabilísticas das variáveis monitoradas com o sistema funcionando em condições normais, isto é, sem a ocorrência de falhas, sejam aprendidas através do algoritmo de aprendizagem de rede Bayesiana e que a rede Bayesiana resultante armazene informações suficientes para caracterizar esse funcionamento tido como normal. A rede então é usada no monitoramento do sistema, através da rede, verifica-se se os valores das variáveis monitoradas respeitam as relações probabilísticas aprendidas anteriormente. Um desvio dessas relações probabilísticas é considerado como uma indicação de ocorrência de falha no sistema. Convém ressaltar que os dados necessários para a aprendizagem são coletados em tempo discreto e que o monitoramento do sistema também é feito em tempo discreto.

Pode-se fazer uma analogia do método proposto com a supervisão humana. A aprendizagem da rede Bayesiana, a partir de dados do sistema funcionando normalmente, seria como um supervisor que estivesse olhando para vários medidores e aprendendo como eles se comportam tanto individualmente quanto em conjunto durante a operação normal do sistema. Após observar os medidores por bastante tempo o supervisor humano seria capaz de notar desvios do comportamento normal dos mesmos. Do mesmo modo a rede Bayesiana aprendida é usada no monitoramento do sistema, detectando desvios do comportamento aprendido como normal.

3.2 O Método de Detecção de Falhas

O método proposto pode ser dividido em sete etapas:

1. Obtenção de um modelo matemático para o sistema;
2. Projeto de um observador de estados para o sistema;
3. Coleta de dados do sistema funcionando em condições normais;
4. Discretização dos dados obtidos;

5. Aprendizagem da rede Bayesiana;
6. Utilização da rede no monitoramento do sistema e coleta de novos dados;
7. Atualização da rede Bayesiana.

Sendo que, no caso particular da necessidade da identificação de um modelo a partir de medidas do próprio sistema, a etapa de coleta de dados (etapa 3) deve ser realizada logo no início para que um modelo do sistema possa ser obtido. Um observador de estados no domínio discreto do tempo pode ser projetado com base nesse modelo identificado e os mesmos dados utilizados na obtenção do modelo podem ser usados em conjunto com tal observador para a estimação dos estados correspondentes aos dados coletados, formando assim o conjunto de dados necessários para a aprendizagem da rede Bayesiana.

Na primeira etapa um modelo matemático ou analítico do sistema deve ser obtido. Como comprovado pelos resultados obtidos, apresentados nos Capítulos 4 e 5, esse modelo não precisa ser muito preciso para que o método apresente bons resultados. Mas como seria de se esperar, um modelo mais preciso pode elevar ainda mais o desempenho geral do método proposto. A escolha de um método para obtenção do modelo ou mesmo a proposta de um novo método para obtenção de um modelo matemático não fazem, porém parte do escopo deste trabalho.

A partir do modelo obtido na primeira etapa, é projetado um observador de estados para o sistema a ser monitorado. Esse observador fornecerá informações sobre o estado estimado do sistema, que com os valores medidos diretamente do sistema comporão o conjunto de variáveis de interesse para o monitoramento.

Na etapa de coleta de dados o observador projetado é usado para estimar o estado do sistema funcionando em condições normais. O estado estimado e os valores medidos diretamente são então amostrados e armazenados para que a rede Bayesiana possa ser aprendida. Essa etapa é uma mera coleta de dados, mas é preciso garantir que durante essa coleta o sistema não apresente nenhuma falha, caso contrário, o algoritmo de aprendizagem da rede Bayesiana poderá aprender um comportamento com falha como sendo normal, a rede resultante ficaria assim incapaz de detectar a ocorrência de falhas similares.

Os dados obtidos são então discretizados para que tanto o processo de aprendizagem quanto a posterior inferência Bayesiana sejam mais simples e rápidos (MATSUURA, 2003). Idealmente, valores contínuos poderiam ser usados, mas a aprendizagem de uma rede Bayesiana contínua ou híbrida e o processo de inferência com variáveis contínuas iriam requerer um esforço computacional consideravelmente maior, sem uma garantia de melhoria no desempenho da rede Bayesiana. Testes comparativos realizadas por Liu et al. (2002)

mostram que em média o uso de variáveis discretizadas reduz o tempo de aprendizagem das redes Bayesianas pela metade.

Comparações entre o uso de variáveis contínuas e discretizadas na aprendizagem de redes Bayesianas podem ser encontradas em Dougherty, Kohavi e Sahami (1995), Kohavi e Sahami (1996), Liu et al. (2002), Ludl e Widmer (2000); Ventura e Martinez (1995) e Yang (2003), nenhuma delas mostrando diferenças consideráveis no desempenho das redes Bayesianas resultantes, tanto na comparação entre o uso de variáveis contínuas e de variáveis discretizadas quanto na comparação entre o uso de diferentes métodos de discretização, sendo que em diversos casos os métodos de discretização mais simples apresentaram os melhores resultados.

Como a escolha de um método de discretização não faz parte do escopo desta tese, um dos métodos mais simples, a Discretização em Intervalos Iguais (*Equal Width Discretization - EWD*) (CEQUIDES; MANTARAS, 1997); (DOUGHERTY; KOHAVI; SAHAMI, 1995); (LUDL; WIDMER, 2000); (VENTURA; MARTINEZ, 1995); (YANG, 2003), foi escolhido para ser usado. A utilização de métodos de discretização mais elaborados e principalmente mais adequados à aprendizagem de redes Bayesianas, como a Discretização via Tabela de Probabilidades, proposta em Matsuura (2003), podem potencialmente melhorar o desempenho do método proposto, mas sua utilização fica como sugestão de trabalhos futuros.

Os dados discretizados são então utilizados na aprendizagem de uma rede Bayesiana que representará o sistema funcionando em condições normais. Para a aprendizagem da rede foi escolhido o algoritmo de aprendizagem Bayesiana K2 (COOPER; HERSKOVITZ, 1992), que é um algoritmo bastante representativo e popular devido aos resultados obtidos quando aplicado ao conjunto de dados da rede ALARM, um “*benchmark*” amplamente aceito para os algoritmos de aprendizagem de redes Bayesianas (KOEHLER; NASSAR, 2002).

Uma das limitações do K2 é que ele não é capaz de determinar a melhor ordem das variáveis para a aprendizagem da rede, estando restrito a utilizar uma ordem pré-definida. Apesar da escolha dessa ordem influenciar na aprendizagem e conseqüentemente no desempenho final da rede aprendida, os estudos realizados nesse trabalho não apontaram para uma diferença de desempenho muito grande. Desse modo, optou-se pelo uso de uma escolha canônica para a ordem das variáveis ao invés de lançar mão de um método mais complexo que aprendesse a melhor ordem das variáveis (FRIEDMAN; KOLLER, 2001); (LARRAÑAGA et al., 1996); (PENG; DING, 2003). Os resultados obtidos com o uso dessa escolha canônica se mostraram bastante adequados, embora, em casos específicos, a

determinação da melhor ordem das variáveis possa, talvez, melhorar ainda mais o desempenho do método proposto.

A rede Bayesiana aprendida é então utilizada em conjunto com o observador de estados projetado na segunda etapa no monitoramento do sistema. O estado estimado e os valores medidos diretamente do sistema são amostrados e a rede Bayesiana é usada para verificar se o conjunto de dados amostrado respeita as relações probabilísticas aprendidas, que representam o comportamento normal do sistema. A verificação da adequação, ou não, do conjunto de dados amostrado às relações aprendidas pela rede Bayesiana é detalhada na próxima seção.

Se o conjunto de dados respeita as relações aprendidas, o método considera que o sistema está operando normalmente, mas se o conjunto de dados não respeita essas relações, o método infere que essa divergência foi causada por uma falha no sistema.

Os dados coletados durante o monitoramento do sistema também são armazenados e podem ser usados na aprendizagem de uma nova rede, desde que nenhuma falha tenha ocorrido durante o monitoramento. Dessa forma a rede Bayesiana poderá ser constantemente atualizada, aprendendo inclusive novas relações probabilísticas, causadas por desvios naturais do sistema, como mudança de ponto de operação, mudança de temperatura ambiente devido às estações do ano, desgaste natural de componentes, ou simplesmente pela maior quantidade de dados disponível.

O esquema para detecção de falhas segundo o método proposto é apresentado na figura 3.1.

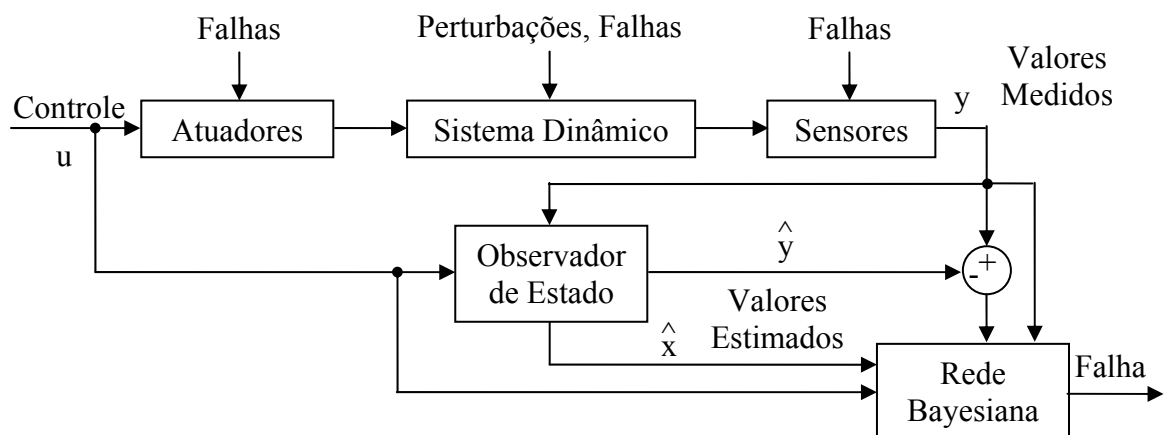


FIGURA 3.1 – Esquema de detecção de falhas do método proposto.

3.3 Verificação do Conjunto de Dados

Conforme citado na seção anterior, a sexta etapa do método proposto consiste no monitoramento propriamente dito do sistema, onde o estado estimado e os valores medidos diretamente do sistema são amostrados e a rede Bayesiana é usada para verificar se os mesmos respeitam as relações probabilísticas aprendidas. Nessa verificação é usado o conceito de probabilidade de um conjunto de valores.

Seja $D(t_k)$ o conjunto de valores estimados e medidos num dado instante de amostragem t_k . Para um sistema com n variáveis de interesse (estimadas ou medidas), $E_1 .. E_n$, temos $D(t_k) = \{e_i(t_k)\}, i=1 .. n$, onde $e_i(t_k)$ é o valor da variável E_i no instante t_k .

A probabilidade de ocorrência de um conjunto de valores é definida como a menor das probabilidades de ocorrência de cada valor, dados os outros valores do conjunto, conforme a equação 3.1.

$$P(D(t_k)) \equiv \min \{P(E_i = e_i(t_k) | \{E_j = e_j(t_k)\})\}, i = 1..n, j = 1..n, i \neq j \quad (3.1)$$

Durante o monitoramento do sistema, a cada instante de amostragem, os valores das variáveis de interesse são estimados e medidos e a rede Bayesiana é utilizada para calcular a probabilidade de ocorrência desse conjunto de valores. Para que a decisão de presença ou ausência de falha seja tomada, o valor da probabilidade de ocorrência de cada conjunto de valores é comparado com um valor de probabilidade limiar.

Caso a probabilidade de ocorrência do conjunto de valores seja menor que o valor da probabilidade limiar, o sistema acusa a presença de uma falha.

Uma escolha para o valor de probabilidade limiar seria zero, mas outros valores podem ser adotados. Alternativamente, como descrito abaixo, o limiar pode ser calculado automaticamente com base nos dados utilizados na aprendizagem da rede ou coletados do sistema funcionando normalmente após o processo de aprendizagem da rede. Esse valor de probabilidade limiar pode também ser reajustado constantemente.

O valor da probabilidade limiar pode ser calculado como sendo o menor valor de probabilidade dos conjuntos de valores obtidos do sistema funcionando na ausência de falhas, como indicado pela equação 3.2.

$$P_l = \min \{P(D(t_k))\}, k = 1..m, \text{ ou} \quad (3.2)$$

$$P_l = \min \{P(E_i = e_i(t_k) | \{E_j = e_j(t_k)\})\}, i = 1..n, j = 1..n, i \neq j, k = 1..m$$

em que m é a quantidade disponível de conjuntos de valores.

Para minimizar os efeitos do ruído de medida, pode-se, ao invés de considerar a probabilidade de apenas um conjunto de valores, tomar-se a maior probabilidade de q conjuntos de valores obtidos consecutivamente, conforme a equação 3.3.

$$P(D_q(t_k)) \equiv \max \{P(D(t_k)), P(D(t_{k-1})), \dots, P(D(t_{k-q+1}))\}, q > 1 \quad (3.3)$$

A probabilidade limiar para q conjuntos de valores pode ser calculada pela equação 3.4:

$$P_{lq} = \min \{ \max \{ P(D(t_{k-i})) \} \}, k = q \dots m, i = 0 \dots q - 1 \quad (3.4)$$

Nesse caso uma falha só seria detectada se q conjuntos de valores consecutivos tivessem uma probabilidade de ocorrência menor que a probabilidade limiar.

A utilização de mais de um conjunto de valores poderá, porém atrasar a detecção das falhas, pois será necessário que q conjuntos de valores sejam analisados para que ocorra uma detecção. A utilização de apenas um conjunto de valores ou de q conjuntos dependerá da relação sinal-ruído e dos requisitos do sistema de detecção de falhas. Se uma taxa de falsos alarmes alta é tolerada enquanto que uma rápida detecção se faz necessária, a utilização de apenas um conjunto de valores é recomendada. Por outro lado, se o tempo necessário para a detecção de uma falha não for tão crítico e falsos alarmes não forem tolerados, é preferível que vários conjuntos de valores sejam considerados.

É possível também que diferentes quantidades de conjuntos de valores sejam consideradas ao mesmo tempo na detecção de falhas. A inferência Bayesiana, ou seja, o cálculo da probabilidade de ocorrência de cada conjunto de valores é a etapa que demanda mais esforço computacional durante a supervisão. Uma vez calculadas as probabilidades de ocorrência de cada conjunto de valores, a utilização de mais de um valor de probabilidade limiar e a consideração de vários valores de probabilidade consecutivos demandam pouco esforço computacional adicional, podendo resumir-se a uma memória, um teste de limiar e um teste de contador para cada quantidade de conjuntos a ser considerada.

3.4 Exemplo de Aplicação

Para que o método proposto possa ser entendido mais facilmente, ele será aplicado a um servomecanismo de velocidade. Como se trata de um exemplo ilustrativo, a efetividade do

método proposto na detecção de falhas não será avaliada. Comparações quantitativas são apresentadas nos capítulos 4 e 5.

A função de transferência entre o sinal de entrada u (tensão em volts) e a saída y (velocidade angular em rad/s) do servomecanismo estudado, dada pela equação 3.5, é a mesma utilizada por Paiva (2003) e Souza, Galvão e Yoneyama (2000), que pode ser obtida através da modelagem matemática dos componentes do servomecanismo.

$$G(s) = \frac{Y(s)}{U(s)} = \frac{A}{(R_c + sL_c)(L_a I s^2 + R_a I s + K_m^2)} \quad (3.5)$$

Na equação 3.5, I é o momento de inércia da carga conectada ao eixo do servo (o momento de inércia do rotor do servo é suposto muito menor que I). R_c é a resistência de campo do gerador, L_c é a indutância de campo do gerador, L_a é a soma das indutâncias das armaduras do gerador e do motor, R_a é a soma das resistências das armaduras do gerador e do motor, K_m é a constante do gerador e A é o ganho que pode ser ajustado manualmente para que o ganho DC do sistema seja unitário.

O circuito equivalente do servomecanismo de velocidade é apresentado na figura 3.2.

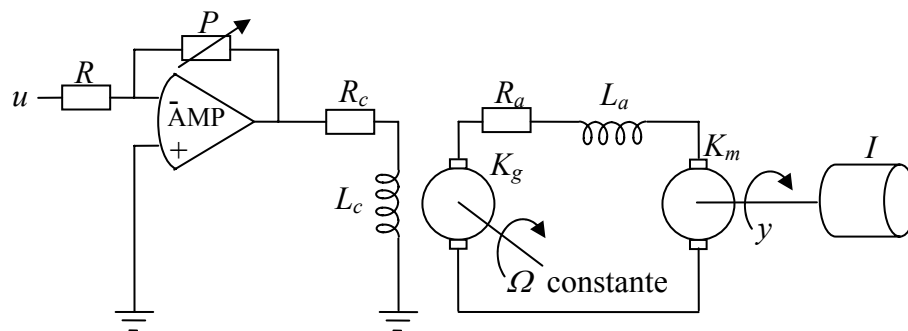


FIGURA 3.2 – Circuito equivalente do servomecanismo de velocidade.

O Amplificador é suposto ideal, o que resulta na equação 3.6 para o circuito de campo do gerador.

$$L_c \frac{dI_c}{dt} + I_c R_c = -u \frac{P}{R} \quad (3.6)$$

Para o circuito da armadura do gerador e do motor tem-se o conjunto de equações 3.7.

$$I_c K_g = R_a I_a + L_a \frac{dI_a}{dt} + K_m y \quad (3.7)$$

$$K_m I_a = I \frac{dy}{dt}$$

De 3.6 e 3.7, e incorporando as constantes isoladas no ganho ajustável A, temos a equação 3.5, utilizada por Paiva (2003) e Souza, Galvão e Yoneyama (2000).

Os valores dos parâmetros foram estimados em laboratório e são apresentados na tabela 3.1.

TABELA 3.1 – Parâmetros do Servomecanismo de Velocidade.

Parâmetro	Descrição	Valor
R_c	Resistência de campo do gerador	9,7 Ω
L_c	Indutância de campo do gerador	0,48 H
L_a	Soma das indutâncias de armadura do gerador e do motor	0,105 H
R_a	Soma das resistências de armadura do gerador e do motor	5,9 Ω
K_m	Constante do Gerador	0,116 Vs/rad
I	Momento de inércia da carga conectada ao eixo do servomecanismo	5,0x10 ⁻⁴ kg.m ²

Substituindo os parâmetros medidos em laboratório da tabela 3.1 na equação 3.5, obtemos o modelo matemático do servomecanismo, apresentado na equação 3.8, e assim concluímos a primeira etapa do método proposto: “1. Obtenção de um modelo matemático para o sistema”.

$$G(s) = \frac{Y(s)}{U(s)} = \frac{5179}{s^3 + 76,4s^2 + 1392s + 5179} \quad (3.8)$$

O modelo matemático poderia ser obtido por outros métodos, como, por exemplo, pela resposta em frequência do servomecanismo, identificação paramétrica ou métodos numéricos de obtenção de modelos lineares.

Para que um observador de estados possa ser projetado, primeiro é necessário que o sistema seja representado no espaço de estados. Uma possível realização da função de transferência dada pela equação 3.8 no espaço de estados é apresentada na equação 3.9.

Como os pólos do servomecanismo estão em -5,0; -20,2 e -51,2, foi projetado um observador de estados com pólos em -52; -53 e -54, um pouco mais rápidos que a dinâmica do sistema. Estudos realizados por Paiva (2003) e Souza, Galvão e Yoneyama (2000), mostram que para detecção de falhas um observador com pólos muito mais rápidos não seria efetivo.

$$\begin{aligned}
\dot{x}_1 &= 10x_2 \\
\dot{x}_2 &= 100x_3 \\
\dot{x}_3 &= -76,4x_3 - 13,92x_2 - 5,179x_1 + 5,179u \\
y &= x_1
\end{aligned} \tag{3.9}$$

A matriz de observação L é dada pela equação 3.10.

$$L = \begin{bmatrix} 82,6 \\ 72,3 \\ -26,6 \end{bmatrix} \tag{3.10}$$

A segunda etapa do método proposto, “2. Projeto de um observador de estados para o sistema”, está então concluída com a obtenção da matriz L.

Na terceira etapa as variáveis do sistema, que são o sinal de entrada u e a velocidade angular da carga y , bem como a estimativa do estado do sistema e o resíduo (diferença entre a saída real e a saída estimada) são amostrados e armazenados. Como o tempo de subida (10-90%) do sistema é de 0,47 s, uma frequência de amostragem de 50 Hz é suficiente para recuperar a dinâmica do sistema de modo adequado.

Não foram realizados estudos sobre qual a quantidade necessária de amostras para que a rede possa aprender os relacionamentos probabilísticos do sistema, mas é de se esperar que essa quantidade dependa da complexidade do sistema, como, por exemplo, do número de variáveis medidas e da dimensão do vetor de estado.

Pode-se, porém, fazer uma avaliação qualitativa da rede aprendida pela quantidade de arcos presente na mesma. A presença de poucos arcos indica que poucos relacionamentos foram aprendidos. Isso pode ser consequência de uma quantidade insuficiente de dados para a aprendizagem ou da não existência de relações probabilísticas entre as variáveis. Seja qual for o motivo, uma rede Bayesiana com poucos arcos dificilmente apresentará bons resultados na detecção de falhas. Nesse caso o processo de coleta de dados deve ser repetido para que uma quantidade de amostras suficiente seja usada na aprendizagem da rede.

Supondo que a quantidade de dados armazenada seja suficiente para a aprendizagem da rede Bayesiana, a terceira etapa do método, “3. Coleta de dados do sistema funcionando em condições normais”, foi finalizada.

Os valores de cada variável são então discretizados. Como citado anteriormente nessa seção, foi utilizada a Discretização em Intervalos Iguais. A quantidade de intervalos adotada

foi de cinco intervalos para todas as variáveis. Os resultados obtidos com a utilização de diferentes quantidades de intervalos são apresentados no capítulo 4.

Finalizada a quarta etapa do método proposto, “4. Discretização dos dados obtidos”, passa-se para a quinta etapa, “5. Aprendizagem da rede Bayesiana”.

O algoritmo de aprendizagem Bayesiana K2 é aplicado aos dados discretizados obtidos na etapa anterior, produzindo uma rede Bayesiana. A figura 3.3 mostra a estrutura da rede Bayesiana obtida com a aprendizagem para a ordem canônica dos nós adotada nesse trabalho: sinal de entrada, estados estimados, sinal de saída e resíduo.




FIGURA 3.3 – Estrutura da rede Bayesiana aprendida para o servomecanismo.

O sistema passa então a ser monitorado pela rede Bayesiana aprendida na etapa cinco, com o auxílio do observador de estados projetado na etapa dois. A cada instante de amostragem, nesse caso, a cada 0,02 segundos, os valores de entrada e de saída do sistema bem como os valores do estado do sistema são amostrados e discretizados. O conjunto de dados obtido dessa forma é então submetido à rede Bayesiana, que é usada para calcular a probabilidade de ocorrência de cada conjunto de valores.

Se a probabilidade de ocorrência for menor que um determinado valor de probabilidade limiar, uma indicação de falha é acionada. A etapa seis, “6. Utilização da rede no monitoramento do sistema e coleta de novos dados”, prossegue indefinidamente, ou até que o sistema seja desligado.

Caso não ocorra nenhuma falha no sistema, os conjuntos de valores obtidos durante a supervisão podem ser utilizados na etapa sete, “7. Atualização da rede Bayesiana” e a nova rede aprendida com os conjuntos de valores adicionais pode ser utilizada na supervisão no lugar da original. A etapa sete pode ser repetida inúmeras vezes para manter a rede Bayesiana sempre atualizada.

3.5 Similaridade com Supervisão Humana

No final da seção 3.1 foi afirmado que o método proposto tem similaridades com a atuação de um supervisor humano que aprende como as variáveis monitoradas de um sistema devem se comportar para depois supervisioná-lo.

Nessa seção essa similaridade será explicada em mais detalhes e exemplificada.

Para um supervisor humano, as sete etapas do método proposto podem ser agrupadas em apenas duas etapas:

- Aprendizagem do comportamento do sistema funcionando normalmente;
- Monitoramento do sistema comparando as observações com o comportamento aprendido anteriormente e refinamento do comportamento aprendido.

As etapas de um a cinco do método proposto, correspondem à etapa um do supervisor humano. O supervisor humano não precisa de um modelo matemático do sistema, nem de um observador de estados ou de discretizar os dados explicitamente. Ele pode montar ou aprender um modelo e fazer uma discretização mental dos dados, como, por exemplo, considerar que os valores indicados possam ser pequenos, médios, altos ou muito altos. Ao mesmo tempo em que ele observa os valores das variáveis do sistema ele aprende como esses valores variam e como devem se relacionar uns com os outros. Desse modo o supervisor humano realiza a coleta de dados e a aprendizagem ao mesmo tempo, podendo ou não criar um modelo mentalmente para a dinâmica do sistema ou discretizar as variáveis mentalmente se julgar mais conveniente.

A figura 3.4 apresenta a entrada e a saída de um sistema dinâmico de terceira ordem, que poderia ser, por exemplo, um servomecanismo de velocidade, operando em condições normais, ou seja, sem falhas.

Um supervisor humano, observando os valores dessas variáveis por muito tempo, pode aprender como elas devem se comportar e pode detectar desvios desse comportamento esperado.

As etapas seis e sete do método proposto equivalem à etapa dois do supervisor humano. O supervisor humano compara o comportamento aprendido como normal com o comportamento das variáveis de interesse e caso ocorra um desvio do mesmo, infere que ocorreu uma falha no sistema. Ao mesmo tempo em que monitora as variáveis buscando desvios do comportamento aprendido, o supervisor humano pode melhorar seu conhecimento do sistema, atualizando o comportamento esperado como normal em sua mente.




FIGURA 3.4 – Entrada u e saída y do sistema a ser monitorado operando em condições normais.

A figura 3.5 apresenta a entrada e a saída do mesmo sistema, mas agora com uma falha ocorrendo em $t = 5,44$ segundos. Após a falha o sistema responde mais rápido, o que pode ser notado observando-se que o sinal de saída y aproxima-se mais rapidamente do valor da entrada u após 5,44 segundos.




FIGURA 3.5 – Entrada u e saída y do sistema sendo monitorado com uma falha ocorrendo em $t = 5,44$ segundos.

Por comparação visual das figuras 3.4 e 3.5, ou pela forma da saída antes e depois da falha na figura 3.5, nota-se claramente que o comportamento das variáveis do sistema se

modificou. O mesmo princípio de aprendizagem de comportamento, no caso probabilístico, é utilizado no método proposto.

O sistema de supervisão proposto, assim como o supervisor humano, aprende como o sistema deve se comportar em condições normais (qual é o relacionamento probabilístico entre as variáveis do sistema) e interpreta desvios desse comportamento normal (baixa probabilidade de ocorrência de um conjunto de valores) como uma indicação de ocorrência de falha no sistema.

3.6 Vantagens Qualitativas

Devido à grande quantidade de métodos de detecção de falhas existente, de variações desses métodos e da constante proposição de novos métodos de detecção de falhas ou de variações dos métodos existentes, torna-se praticamente inviável uma comparação em larga escala com os mesmos. Contudo é possível comparar qualitativamente o método proposto aos demais métodos, apontando para as limitações de utilização destes em alguns casos.

A primeira grande vantagem do método proposto é sua similaridade com a supervisão humana e sua facilidade de entendimento em alto nível. Essas duas características podem facilitar muito a aceitação do método proposto por parte dos profissionais responsáveis pelo correto funcionamento dos sistemas dinâmicos a serem supervisionados.

Os seres humanos normalmente aceitam mais facilmente tecnologias que eles podem, ou pelo menos acham que podem, compreender. Um método de detecção de falhas que se assemelhe à atuação de um ser humano poderá então encontrar uma menor resistência à sua implementação do que métodos que utilizam, por exemplo, as transformadas wavelet.

Como já exposto, para explicar o método em alto nível, pode-se comparar a obtenção de um modelo matemático do sistema e a aprendizagem da rede Bayesiana com a familiarização do ser humano ao comportamento das variáveis do sistema. A estrutura resultante da rede Bayesiana pode inclusive ser validada por um especialista na área, que verificaria se as dependências probabilísticas aprendidas realmente fazem algum sentido. Uma possível melhoria do método proposto poderia inclusive ser o refinamento da rede Bayesiana aprendida através da adição, subtração ou troca de relacionamentos aprendidos, de acordo com a opinião de especialistas na área.

A utilização da rede Bayesiana na supervisão também pode ser facilmente explicada comparando a inferência Bayesiana da rede ao raciocínio probabilístico de uma pessoa. A rede calcula a probabilidade do valor de cada variável ser o valor medido, dados os valores

medidos das outras variáveis como evidência. Um ser humano pode raciocinar de maneira bastante similar, inferindo a probabilidade da leitura de um sensor ser a que ele está vendo, dado que ele conhece as leituras de todos os outros sensores.

Assim como a redundância analítica, a análise de sinais, os métodos baseados em conhecimento e os outros métodos que utilizam aprendizagem, o método proposto também não precisa de equipamento redundante, podendo em alguns casos ser implementado junto com o algoritmo de controle.

Mas diferentemente da redundância analítica e dos métodos que usam análise de sinais na análise de resíduos, o método proposto não depende de um modelo matemático acurado do sistema, podendo ser utilizado em sistemas com níveis de ruído consideráveis e com modelos pouco acurados sem apresentar a mesma perda de desempenho da redundância analítica. Tal característica pode ser vista nos resultados obtidos apresentados no capítulo 4.

Os resultados adicionais do capítulo 5 mostram ainda que o método proposto é capaz de detectar falhas mesmo usando um modelo linear para um sistema não linear, o que comprova que modelos acurados não são tão críticos quanto no caso da redundância analítica.

Diferentemente dos métodos de aprendizagem com falhas e de métodos baseados em conhecimento, o método proposto não necessita de uma base de dados do sistema operando com falhas, nem de conhecimento de especialistas, podendo ser aplicado a sistemas críticos que nunca apresentaram falhas e que não podem se sujeitar a ensaios de falhas. Esse é o caso da maioria dos sistemas críticos, como aeronaves, reatores nucleares, foguetes, satélites, processos químicos de alto custo e transporte coletivo no geral.

Resumindo, o método proposto é fácil de ser entendido em alto nível, tem grande semelhança com a supervisão humana, não necessita de equipamento adicional, não necessita de um modelo acurado do sistema e não precisa de informação nenhuma sobre falhas anteriores no sistema; podendo ser aplicado a sistemas onde os outros métodos dificilmente apresentariam resultados satisfatórios.

Uma comparação quantitativa do método proposto com a análise de resíduos de um observador de estados, uma técnica de redundância analítica bastante conhecida e usada como base de comparação em diversos trabalhos, é apresentada no capítulo 4.

3.7 Alternativas à Aprendizagem de Redes Bayesianas

Outros métodos de aprendizagem, que não a de redes Bayesianas poderiam ser utilizados na detecção de falhas, mantendo-se as vantagens qualitativas do método proposto:

similaridade com a supervisão humana, não necessidade de equipamento adicional, não necessidade de um modelo acurado do sistema e não necessidade de nenhuma informação sobre falhas anteriores.

Duas dessas alternativas à aprendizagem de redes Bayesianas foram testadas. Sua utilização será apresentada a seguir e resultados comparativos são apresentados no capítulo 4.

As duas alternativas se referem ao agrupamento não-supervisionado de padrões. A primeira delas utiliza um método de agrupamento bastante conhecido, o *k-Means* (DUDA; HART; STORK, 2001) e a segunda utiliza redes de Kohonen, também chamadas de mapas auto-organizáveis ou mapas de Kohonen (DUDA; HART; STORK, 2001); (NASCIMENTO JR.; YONEYAMA, 2000).

Os vetores a serem agrupados são os conjuntos de medidas e estados estimados que correspondem aos nós da rede Bayesiana aprendida pelo método proposto.

Os dados de operação normal do sistema são utilizados na definição dos centros dos agrupamentos no caso do *k-Means* e no treinamento da rede neural no caso da rede de Kohonen.

No caso do *k-Means*, os agrupamentos representam regiões do espaço de dimensão do vetor de medidas, vetores esses associados à operação normal do sistema. Vetores apresentados durante o processo de supervisão que estejam contidos ou próximos a essas regiões corresponderiam ao funcionamento normal do sistema, enquanto que vetores distantes dessas regiões corresponderiam a uma situação anormal, que pode ser a ocorrência de uma falha.

Para avaliar se os vetores apresentados durante a supervisão estão ou não contidos nessas regiões faz-se necessária a utilização de um limiar de proximidade, assim como no caso do limiar para o resíduo na redundância analítica e a probabilidade limiar no caso do método proposto.

Os vetores que estiverem próximos a um dos centros dos grupos aprendidos, ou seja, vetores cujas distâncias ao centro do agrupamento mais próximo forem menores que o limiar de proximidade serão considerados como indicadores de operação normal, ao passo que vetores cujas distâncias ao centro do agrupamento mais próximo forem maiores que o limiar de proximidade serão considerados como indicadores de ocorrência de falha no sistema.

Para um melhor entendimento desse método de detecção de falhas com o uso de agrupamento via *k-Means*, um exemplo artificial de duas dimensões será utilizado. Esse exemplo artificial também facilitará o entendimento da detecção de falhas com redes de Kohonen.

As duas variáveis do sistema de exemplo são x e y . A figura 3.6 ilustra a utilização de agrupamento via *k-Means* na detecção de falhas. Nesse exemplo foram utilizados dez agrupamentos.

A figura 3.6a apresenta os vetores de operação normal do sistema, utilizados para o agrupamento via *k-Means*. A figura 3.6b apresenta também os centros dos agrupamentos aprendidos pelo algoritmo.

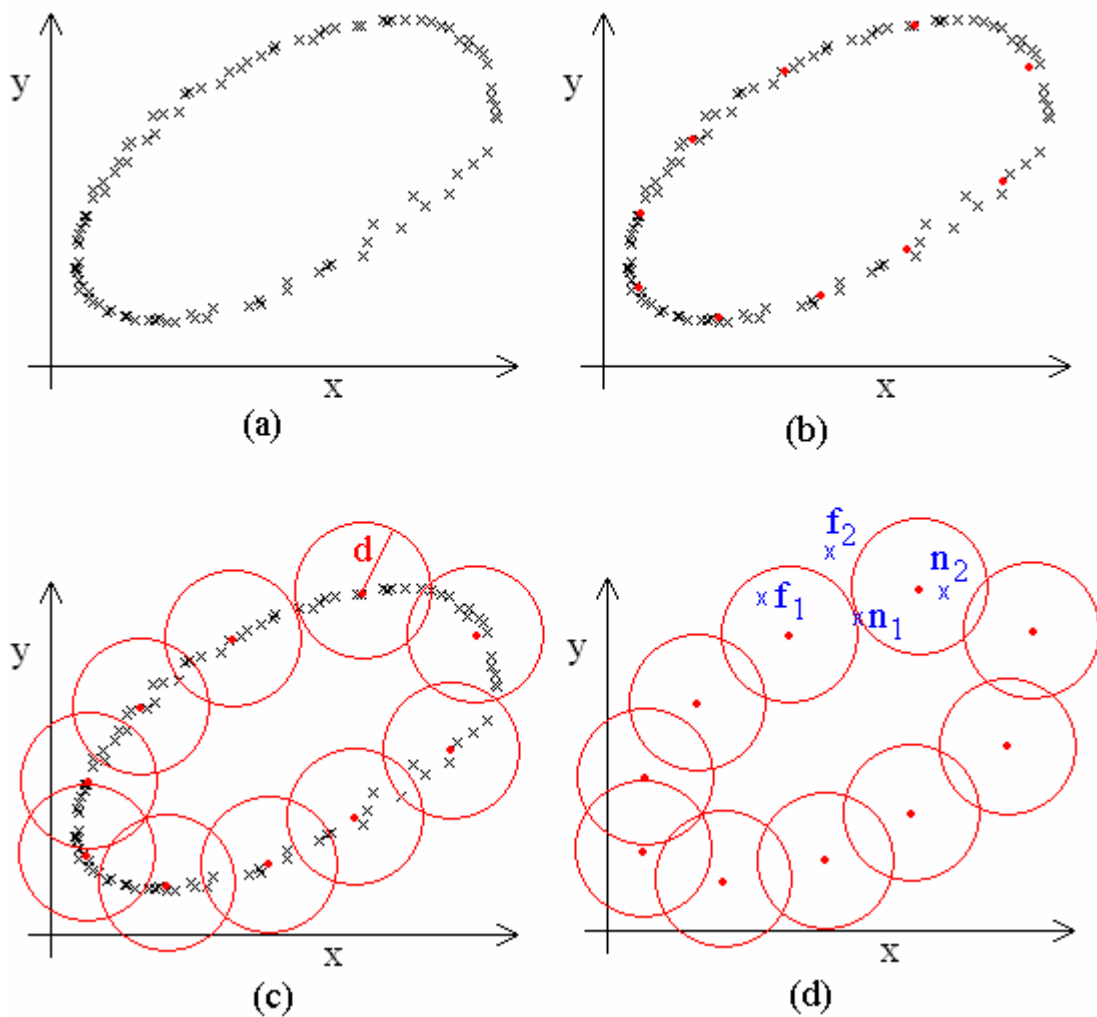


FIGURA 3.6 – Exemplo de detecção de falhas com agrupamento via *k-Means*. (a) Vetores de operação normal do sistema. (b) Centros dos agrupamentos obtidos via *k-Means*. (c) Regiões correspondentes à operação normal do sistema para um limiar de proximidade d . (d) Exemplo de detecção de falha para dois vetores de operação normal, n_1 e n_2 e para dois vetores de operação na presença de uma falha, f_1 e f_2 .

A figura 3.6c apresenta ainda as regiões que corresponderiam à operação normal do sistema para um limiar de proximidade d .

Finalmente a figura 3.6d apresenta as regiões correspondentes à operação normal do sistema e quatro pontos que teriam sido medidos durante a supervisão do mesmo. Nesse caso,

o ponto f_1 que teria sido medido com o sistema apresentando uma falha seria erroneamente considerado como normal, enquanto que o ponto f_2 , que também teria sido medido com o sistema apresentando falha, seria corretamente considerado como indicativo de falha.

Ainda na figura 3.6d o ponto n_1 seria erroneamente considerado como indicativo de falha, gerando um falso alarme, enquanto que o ponto n_2 seria corretamente considerado como de operação normal.

Da figura 3.6 verifica-se claramente que valores menores do limiar de proximidade d fariam com que a falha referente ao ponto f_1 fosse corretamente detectada, mas aumentariam o número de falsos alarmes; por outro lado, valores maiores de d reduziriam os falsos alarmes, mas também a sensibilidade a falhas. Fica claro também que um número maior de agrupamentos possibilitaria o uso de limiares de proximidade menores sem o aumento do número de falsos alarmes. Um número excessivo de agrupamentos e limiares de proximidade menores, porém, poderiam levar a um aumento do número de falsos alarmes. A escolha da quantidade de agrupamentos a serem utilizados e do limiar de proximidade não é, portanto algo trivial.

Para sistemas com n variáveis (medidas ou estimadas) as regiões de operação normal ao invés de circunferências seriam hiper-esferas, mas o mesmo raciocínio se aplica. Valores pequenos de limiar de proximidade tornam a detecção de falhas mais sensível aumentando também o número de falsos alarmes, enquanto limiares de proximidade maiores diminuem os falsos alarmes tornando a detecção de falhas menos sensível.

O uso de redes de Kohonen na detecção de falhas é bem parecido com a detecção de falhas com o uso de *k-Means* e já foi utilizado em Freitas, Cerqueira e Ferreira (2005).

Uma rede de Kohonen é treinada a partir dos dados do sistema operando sem falhas. A rede, assim com o algoritmo *k-Means*, também cria agrupamentos para os dados apresentados, mas ao invés de centros de agrupamentos, temos pesos de neurônios.

Uma grande diferença entre o agrupamento via *k-Means* e via rede de Kohonen é que, na rede de Kohonen treinada, alguns neurônios podem não representar um agrupamento. Isto é, alguns neurônios podem nunca ter sido vencedores para todo o conjunto de treinamento e, portanto, não corresponderiam a uma situação de operação normal do sistema. Já no agrupamento via *k-Means*, todos os agrupamentos contém pelo menos um elemento do conjunto de treinamento.

Para que vetores de medidas próximos aos pesos dos neurônios que não representam operação normal não sejam considerados como indicadores de operação normal, é preciso

rotulá-los como não sendo de operação normal, ou seja, esses neurônios são rotulados como representantes de um agrupamento que representa falhas no sistema.

Desse modo, antes de ser verificada a proximidade de um conjunto de medidas ao neurônio vencedor, verifica-se se esse neurônio representa um agrupamento normal ou um agrupamento de falha. Se o neurônio representar um agrupamento de falha, um alarme é acionado, senão verifica-se se a distância entre o vetor de medidas e o vetor representado pelos pesos do neurônio é maior ou menor que o limiar de proximidade. Essa verificação de distância é idêntica ao caso anterior, onde os agrupamentos foram gerados via *k-Means*.

A figura 3.7 ilustra a utilização de uma rede de Kohonen de 5x5 neurônios na detecção de falhas.

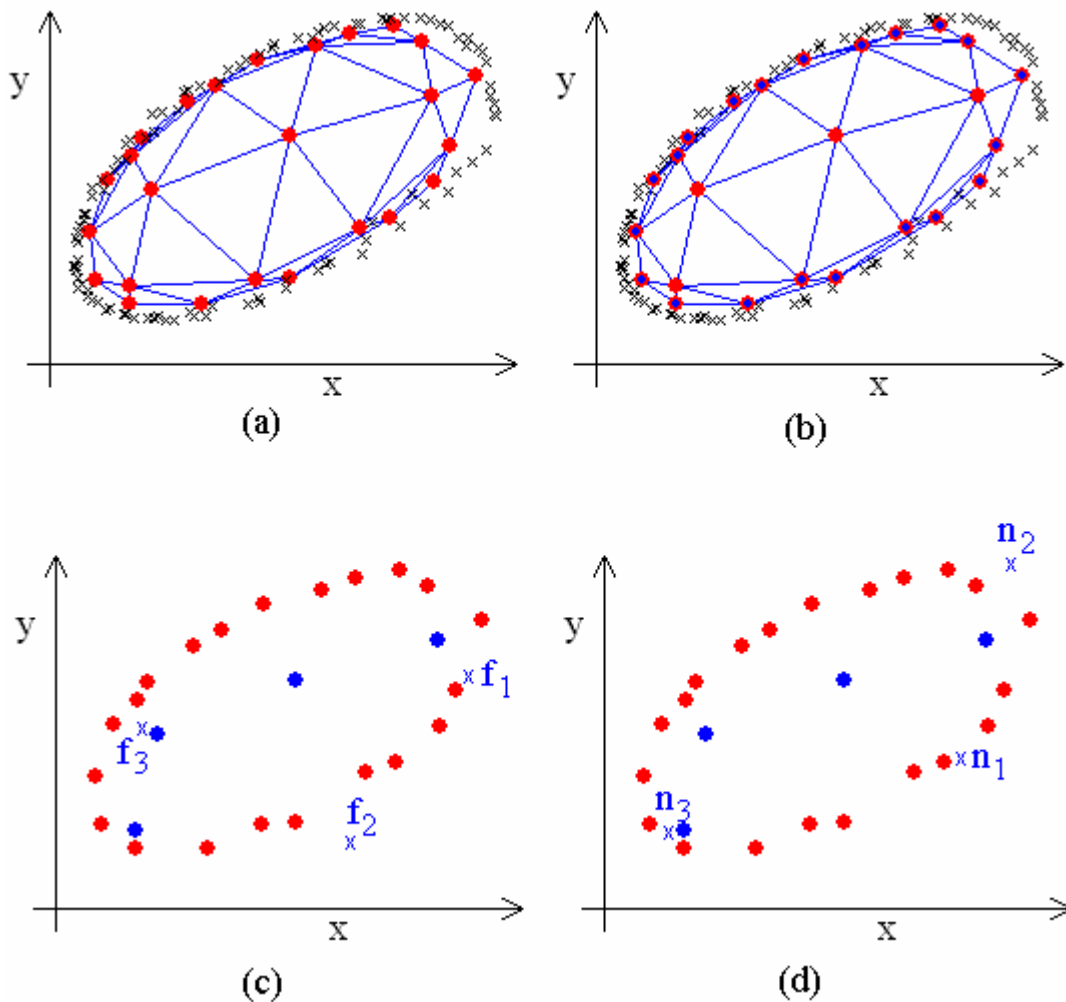


FIGURA 3.7 – Exemplo de detecção de falhas com agrupamento via mapa de Kohonen. (a) Vetores de treinamento e rede de Kohonen obtida. (b) Neurônios rotulados como válidos. (c) Exemplo de vetores de operação com falha, f_1 , f_2 e f_3 . (d) Exemplos de vetores de operação normal n_1 , n_2 e n_3 .

A figura 3.7a apresenta a rede de Kohonen após o treinamento com os mesmos dados utilizados no agrupamento via *k-Means*. A figura 3.7b apresenta em destaque os neurônios rotulados como válidos. Os segmentos de reta representam as relações de vizinhança entre os neurônios da rede de Kohonen.

A figura 3.7c apresenta três pontos que teriam sido medidos do sistema operando com falhas. As ligações entre os neurônios no mapa de Kohonen e as circunferências de raio igual ao limiar de proximidade foram omitidas por conveniência de visualização. Nesse caso o ponto f_1 seria erroneamente considerado como de operação normal, por ter estar próximo a um neurônio rotulado como normal. Já o ponto f_2 seria considerado como indicativo de falha por estar mais distante que o limiar de proximidade do neurônio vencedor. Finalmente o ponto f_3 seria considerado como indicativo de falha por estar mais próximo de um neurônio que não foi rotulado como normal.

A figura 3.7d apresenta três pontos que teriam sido medidos em condições normais de operação. O ponto n_1 seria corretamente considerado como normal por estar próximo a um neurônio rotulado como normal; já os pontos n_2 e n_3 iriam causar falsos alarmes, pois n_2 estaria mais distante do que o limiar de proximidade do neurônio mais próximo e n_3 seria associado a um neurônio não rotulado como válido.

O conceito básico por trás dessas duas abordagens é o mesmo do método proposto nesse trabalho: a aprendizagem do comportamento esperado como normal e a verificação de que esse comportamento reconhecido como normal está sendo mantido pelo sistema. Os métodos utilizam apenas maneiras diferentes de aprender esse comportamento e de verificar se ele está sendo mantido. No próximo capítulo, após a comparação do método proposto com a análise de resíduos de um observador de estados, são apresentadas também comparações entre o método proposto e a utilização de agrupamento via *k-Means* e com redes de Kohonen.

4 Detecção de Falhas em um Servomecanismo

No intuito de enriquecer os resultados comparativos, uma variedade de situações foi utilizada no estudo da detecção de falhas em um servomecanismo de velocidade.

Com relação ao servomecanismo propriamente dito, foram exploradas as seguintes situações:

- Três diferentes níveis de ruído no sensor.
- Três diferentes falhas, duas falhas mecânicas internas ao servomecanismo e uma falha de sensor.

Essas situações ilustram a sensibilidade dos métodos de detecção de falhas com relação ao nível de ruído e sua efetividade na detecção de diferentes falhas.

Com relação ao projeto dos observadores de estado, utilizados tanto na redundância analítica quanto no método proposto e nas alternativas que utilizam aprendizagem, foram exploradas as seguintes situações:

- Incertezas no modelo, com o uso de três conjuntos de parâmetros diferentes no projeto do observador de estado.
- Três diferentes velocidades para o observador.

Essas situações ilustram a sensibilidade dos métodos de detecção de falhas com relação à exatidão do modelo disponível do sistema e servem para verificar qual velocidade de observador de estado é a mais adequada à detecção de falhas.

Finalmente, com relação às redes Bayesianas, foram ainda exploradas as seguintes situações:

- Três diferentes níveis de discretização para as variáveis de interesse.
- Três diferentes ordens para os nós da rede Bayesiana.
- Três quantidades diferentes de dados para a aprendizagem das redes.

Posteriormente foram ainda utilizadas outras três quantidades diferentes de dados.

Essas situações ilustram as diferentes possibilidades na aprendizagem das redes Bayesianas, apontando para as escolhas mais favoráveis ou indicando em que casos as escolhas não teriam grande influência sobre os resultados obtidos.

Cada uma dessas situações é detalhada no decorrer do capítulo.

4.1 Sistema Simulado

Para ilustrar o uso do método de detecção de falhas proposto e para comparar seu desempenho ao de um esquema baseado em redundância analítica, bem como ao de métodos alternativos de aprendizagem, utilizou-se o servomecanismo de velocidade adotado em Souza, Galvão e Yoneyama (2000) e em Paiva (2003), já apresentado no capítulo 3 e cuja função de transferência entre o sinal de entrada u e velocidade do eixo do servo y é dada pela equação 3.5.

Para efeitos de simulação de falhas, a carga consiste de dois corpos rígidos iguais interconectados, cada um com momento de inércia de $0,5I$.

Mas, em contraste com os trabalhos de Souza, Galvão e Yoneyama (2000) e de Paiva (2003), que utilizam os mesmos parâmetros para o modelo do servomecanismo no projeto do observador de estados e nas simulações de falhas, nesse trabalho são utilizados três conjuntos de parâmetros para o servomecanismo, resultando em uma função de transferência nominal e duas funções de transferência chamadas de laboratoriais. As três funções de transferência, que utilizam parâmetros estimados em medidas realizadas em um mesmo servomecanismo real, são utilizadas para ilustrar os efeitos de erros de modelagem no desempenho dos métodos de detecção de falhas.

O modelo nominal é utilizado em todas as simulações e no projeto de um conjunto de observadores de estados, enquanto que os modelos laboratoriais são utilizados no projeto de outros dois conjuntos de observadores de estado.

A tabela 4.1 apresenta os valores dos três conjuntos de parâmetros estimados de um mesmo servomecanismo em laboratório. O primeiro conjunto de parâmetros foi escolhido como sendo o conjunto de parâmetros nominais do servomecanismo e é o mesmo que utilizado no capítulo 3. Os outros conjuntos representam os modelos laboratoriais. Como os diferentes conjuntos de valores foram estimados no mesmo servomecanismo, a incerteza associada a esses modelos está bem próxima às incertezas que podem ser encontradas em situações reais.

TABELA 4.1 – Parâmetros estimados de um servomecanismo real.

Parâmetro	Conjunto 1	Conjunto 2	Conjunto 3
R_c (Ω)	9,7	10,0	10,2
L_c (H)	0,48	0,48	0,45
L_a (H)	0.105	0.110	0.103
R_a (Ω)	5,9	5,0	5,5
K_m (mVs/rad)	116	119	116
I (kg.m ²)	$5,0 \times 10^{-4}$	$5,0 \times 10^{-4}$	$5,0 \times 10^{-4}$

Substituindo os valores da tabela 4.1 na equação 3.5 e ajustando-se o valor de A para que o ganho DC seja unitário, obtêm-se as funções de transferência do servomecanismo nominal e dos servomecanismos laboratoriais. A função de transferência do servomecanismo nominal foi apresentada na equação 3.8.

Foram consideradas três falhas possíveis, a saber:

- Falha 1: Ruptura da conexão entre os dois corpos que fazem parte da carga, e que é modelada por uma redução abrupta de 50% na inércia da carga, resultando em uma resposta mais rápida do servomecanismo. Esta falha foi considerada anteriormente em Matsuura e Yoneyama (2004a), Paiva (2003) e Souza, Galvão e Yoneyama (2000).
- Falha 2: Ruptura interna da carga, que faz com que a massa da mesma se concentre em sua periferia, resultando em um incremento de 50% do momento de inércia e em uma resposta mais lenta do servomecanismo. Pode ser interpretada como o oposto da falha 1.
- Falha 3: Travamento do sensor em um dado valor. O sensor passa, a partir do instante de ocorrência da falha, a não mais modificar seu valor.

A função de transferência do servomecanismo operando em condições normais pode ser realizada no espaço de estados utilizando-se a representação do conjunto de equações 3.9.

Quando a falha 1 ocorre, a expressão de \dot{x}_3 é modificada para a equação 4.1, enquanto as outras expressões em 3.9 mantêm-se inalteradas. Do mesmo modo a falha 2 também altera apenas a expressão de \dot{x}_3 para a equação 4.2.

$$\dot{x}_3 = -76,4x_3 - 16,48x_2 - 10,36x_1 + 10,36u_2 \quad (4.1)$$

$$\dot{x}_3 = -76,4x_3 - 12,64x_2 - 2,59x_1 + 2,59u_2 \quad (4.2)$$

Ambas as falhas modificam as posições dos pólos do sistema, preservando o ganho DC.

Já a falha 3 faz com que a saída y permaneça constante e igual ao valor do estado x_1 no instante de ocorrência da falha.

O sinal de entrada é uma onda quadrada, de nível baixo 0 volts, nível alto 1 volt e período de 2 segundos.

A saída do servomecanismo apresenta um ruído aditivo branco Gaussiano de média nula. Foram considerados três níveis de ruído: ruído baixo com desvio padrão de 0,005 volts, ruído médio com desvio padrão de 0,01 volts e ruído alto com desvio padrão de 0,02 volts.

As figuras 4.1 a 4.3 apresentam a entrada e a saída do sistema para os três níveis de ruído e para as seguintes situações:

- Sistema operando normalmente.
- Falhas 1 ocorrendo em $t = 3,4$ segundos.
- Falhas 2 ocorrendo em $t = 3,4$ segundos.
- Falhas 3 ocorrendo em $t = 3,4$ segundos.

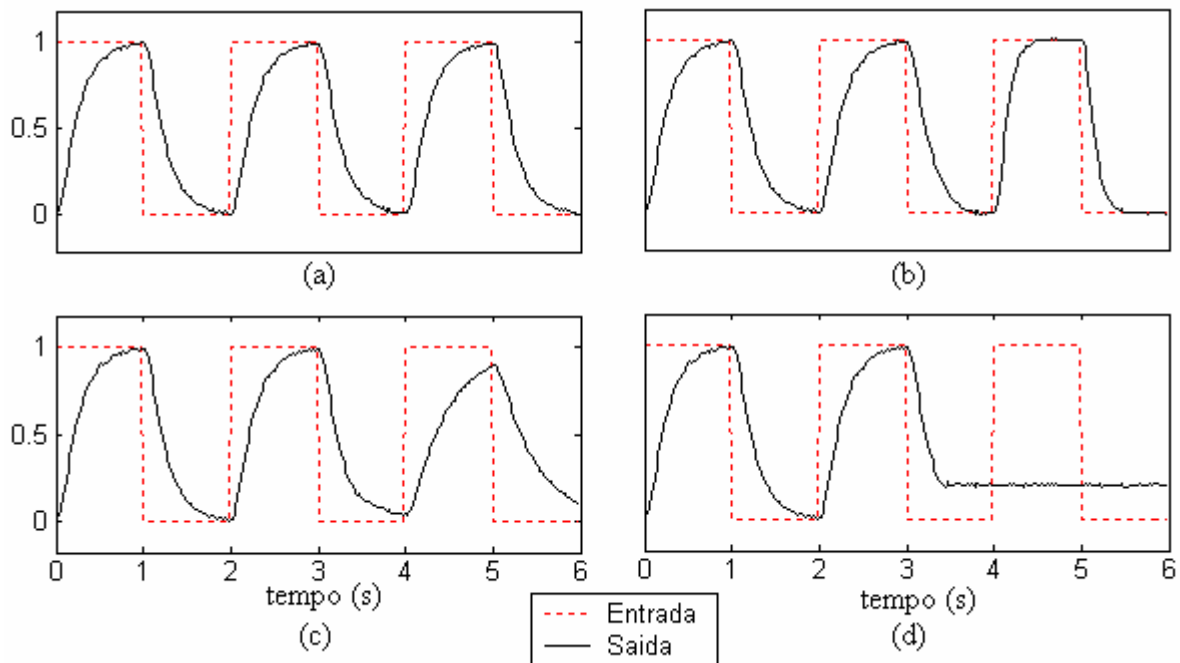


FIGURA 4.1 – Entrada e saída do servomecanismo com ruído baixo. (a) Operação normal. (b) Falha 1 ocorrendo em $t = 3,4$ segundos. (c) Falha 2 ocorrendo em $t = 3,4$ segundos. (d) Falha 3 ocorrendo em $t = 3,4$ segundos.

Nota-se mais facilmente a diferença do nível do ruído após a ocorrência da falha 3, comparando-se as figuras 4.1d, 4.2d e 4.3d.

Nas figuras 4.1b, 4.2b e 4.3b nota-se que após a falha 1 a saída do sistema aproxima-se mais rapidamente do valor de referência. Como já explicado, a falha 1 torna o sistema mais rápido. Em contrapartida, nas figuras 4.1c, 4.2c e 4.2c fica clara a resposta mais lenta do sistema após a ocorrência da falha 2.

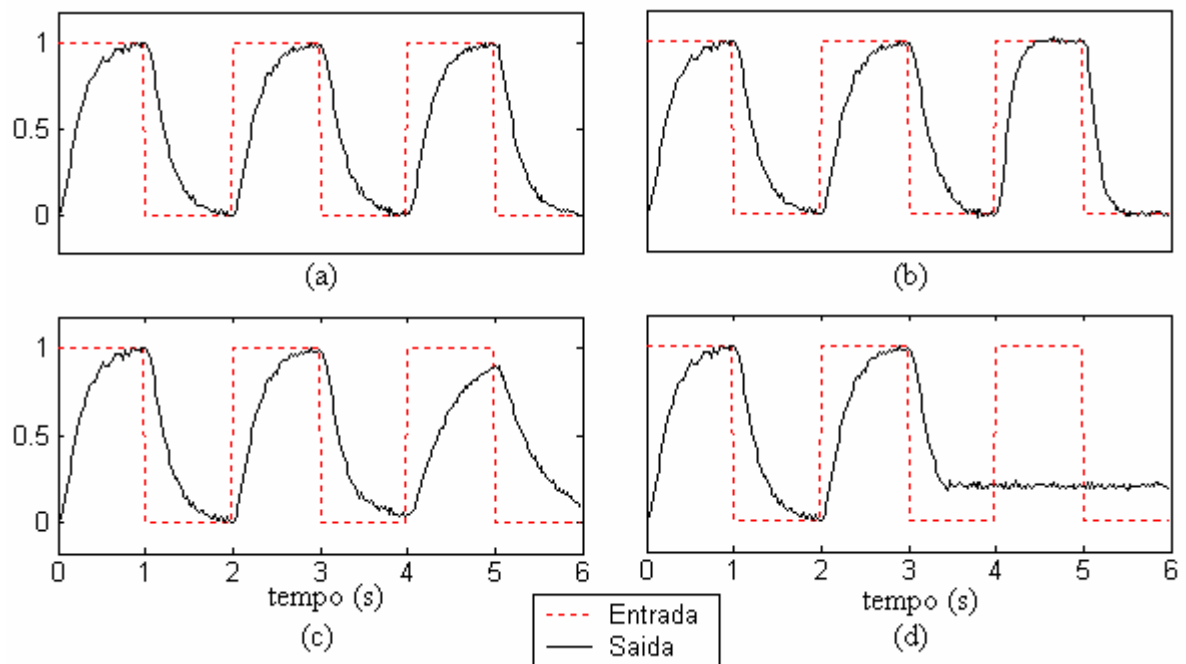


FIGURA 4.2 – Entrada e saída do servomecanismo com ruído médio. (a) Operação normal. (b) Falha 1 ocorrendo em $t = 3,4$ segundos. (c) Falha 2 ocorrendo em $t = 3,4$ segundos. (d) Falha 3 ocorrendo em $t = 3,4$ segundos.

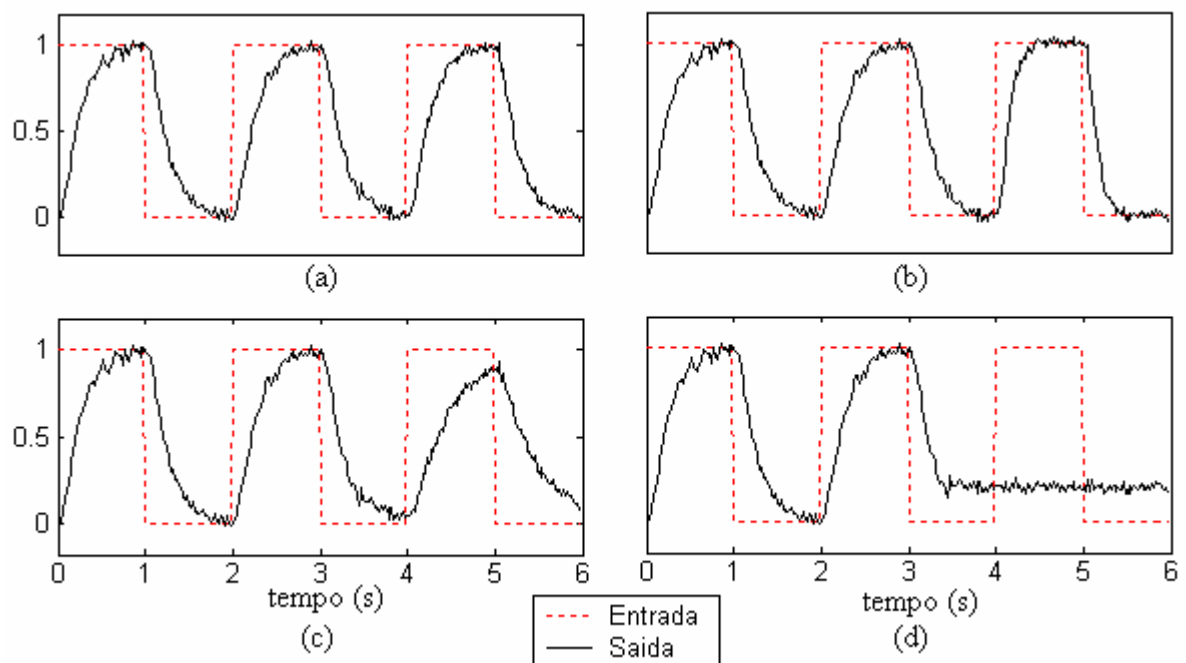


FIGURA 4.3 – Entrada e saída do servomecanismo com ruído alto. (a) Operação normal. (b) Falha 1 ocorrendo em $t = 3,4$ segundos. (c) Falha 2 ocorrendo em $t = 3,4$ segundos. (d) Falha 3 ocorrendo em $t = 3,4$ segundos.

4.2 Procedimentos

Inicialmente, tomando-se cada modelo do servomecanismo (modelo nominal e dois modelos laboratoriais), foram projetados três observadores de estados. O primeiro, com pólos ligeiramente mais rápidos que o pólo mais rápido do servomecanismo, mais precisamente 1,1 vez mais rápido, doravante denominado de observador lento. O segundo com pólos três vezes mais rápidos que o pólo mais rápido do servomecanismo, denominado de observador médio. E o terceiro com pólos cinco vezes mais rápidos que o pólo mais rápido do servomecanismo, como se o mesmo fosse ser utilizado para realimentação de estados. Esse terceiro observador é denominado observador rápido.

O diagrama utilizado na simulação do sistema dinâmico é apresentado na figura 4.4 e o diagrama para simulação do sistema com observador de estados é apresentado na figura 4.5.

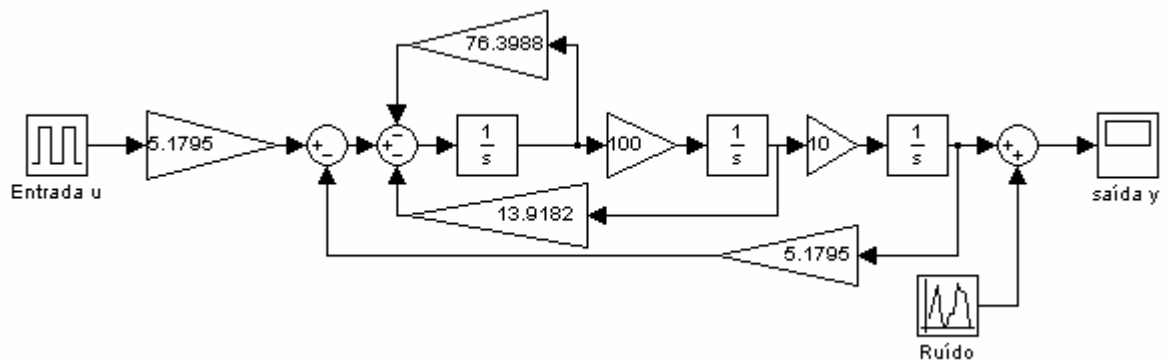


FIGURA 4.4 - Diagrama de Simulação do Servomecanismo.

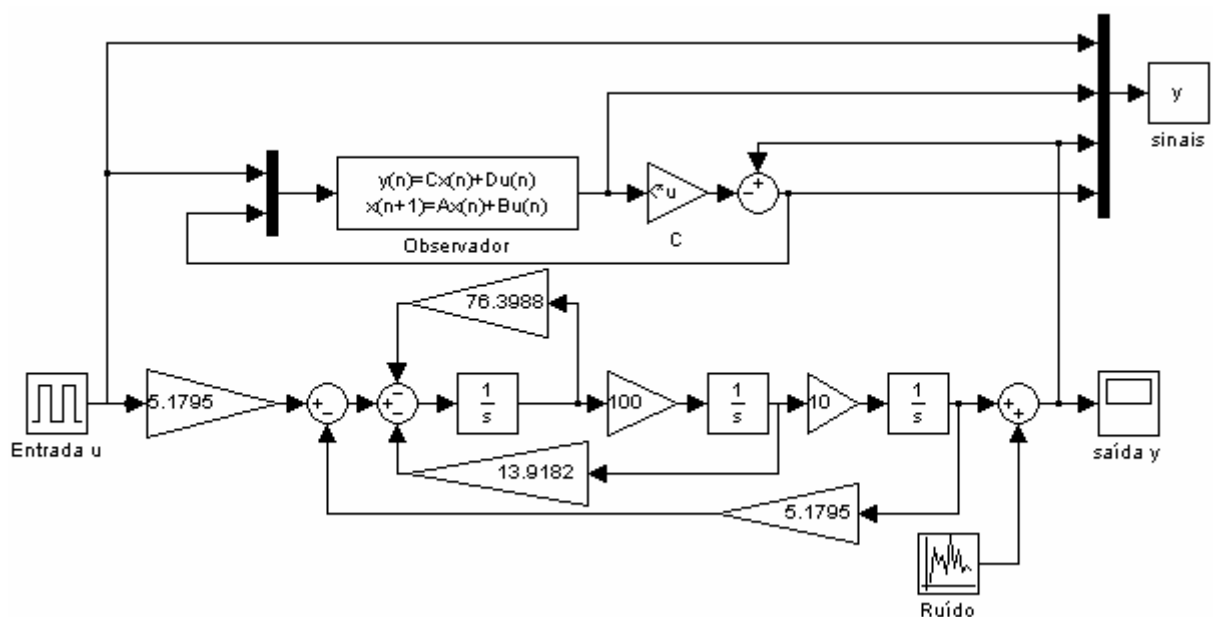


FIGURA 4.5 - Diagrama de Simulação do Servomecanismo com Observador.

A utilização de diferentes níveis de ruído testa a sensibilidade dos métodos a esse tipo de incerteza, enquanto que a utilização de modelos de simulação diferentes do modelo nominal testa a sensibilidade dos métodos a incertezas de modelagem.

O período de amostragem adotado nas simulações foi de 0,02 segundos.

Considerando-se os três modelos do servomecanismo, os três níveis de ruído e os três observadores de estado projetados para cada modelo de servomecanismo, temos um total de 27 modelos de simulação. Como para cada modelo de simulação são simuladas três falhas distintas, temos um total de 81 modelos de falhas. O diagrama utilizado na simulação das falhas do servomecanismo é apresentado na figura 4.6.

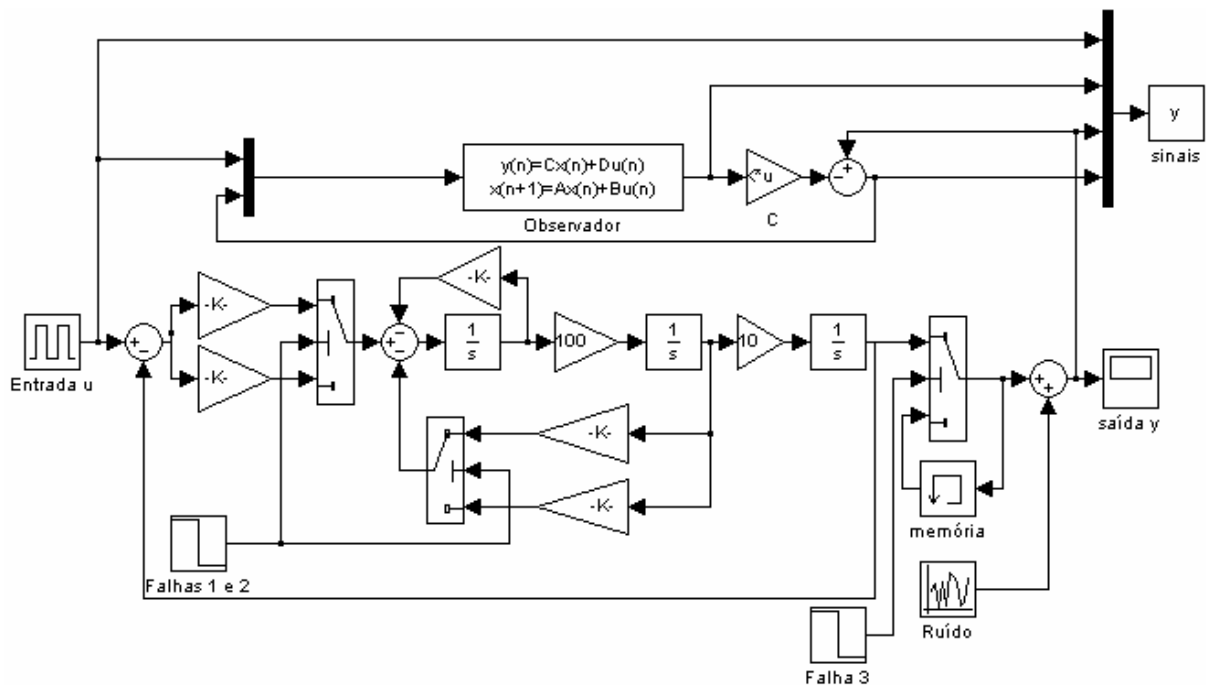


FIGURA 4.6 - Diagrama de Simulação das Falhas do Servomecanismo.

Para cada modelo de simulação (modelo de servomecanismo, nível de ruído e velocidade do observador) uma rede Bayesiana precisa ser aprendida para monitorar o sistema correspondente. Optou-se, no entanto, para enriquecimento dos resultados obtidos, pelo uso de diferentes redes Bayesianas. Para cada modelo de simulação foram aprendidas nove redes Bayesianas com características distintas.

Foram utilizados três níveis de discretização diferentes: discretização baixa em três intervalos, discretização média em cinco intervalos e discretização alta em oito intervalos. Foram usadas também três quantidades diferentes de dados para a aprendizagem das redes, 2.500 ciclos de operação, 2.000 ciclos de operação e 1.500 ciclos de operação. Onde cada

ciclo de operação equivale a um período completo do sinal de entrada, ou seja, 2 segundos. Desse modo os dados usados na aprendizagem das redes equivalem a 3 horas, 2 horas e 1 hora de operação do sistema. Posteriormente foram utilizados 1.000, 500 e 200 ciclos de operação na aprendizagem.

Finalmente, foram utilizadas três possíveis ordens para os nós:

- Ordem canônica: entrada, estados estimados, saída e resíduo.
- Ordem inversa: resíduo, saída, estados estimados em ordem inversa e entrada.
- Ordem mista: entrada, primeiro estado, saída, segundo estado, resíduo, terceiro estado. Ordem esta obtida aleatoriamente.

As ordens das variáveis de interesse para um sistema de ordem 3 são mostradas na figura 4.7. A figura 4.7a apresenta os nós em ordem canônica, a figura 4.7b em ordem inversa e a figura 4.7c na ordem mista.

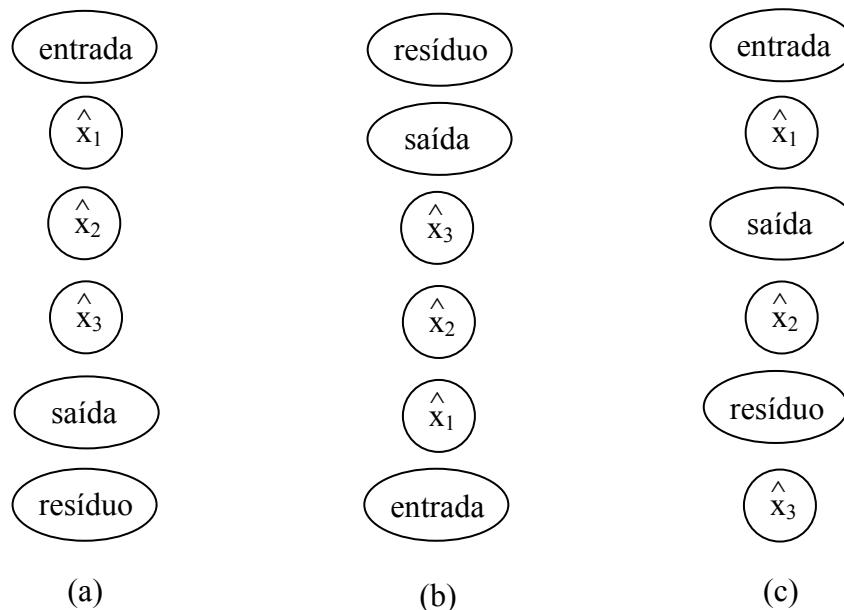


FIGURA 4.7 – Ordens das variáveis da rede Bayesiana. (a) Canônica. (b) Inversa. (c) Mista.

Cada um dos 27 modelos de simulação foi simulado por 2.500 ciclos de operação. Os sinais de interesse foram então armazenados e discretizados usando-se a Discretização em Intervalos Iguais para três, cinco e oito intervalos, gerando-se assim 81 conjuntos de dados para a aprendizagem das redes Bayesianas.

Para cada um dos conjuntos de variáveis discretizadas foram então aprendidas nove redes Bayesianas, três delas com a totalidade dos dados, três com 50% dos dados

armazenados e três com 20% dos dados armazenados. Para a mesma quantidade de dados, cada rede foi aprendida para uma ordem diferente dos nós: canônica, inversa e mista.

No total foram então aprendidas 729 redes Bayesianas. Cada uma dessas redes foi usada então no monitoramento dos três respectivos modelos de falhas.

A estrutura de uma dessas 729 redes Bayesianas aprendidas é mostrada na figura 4.8.

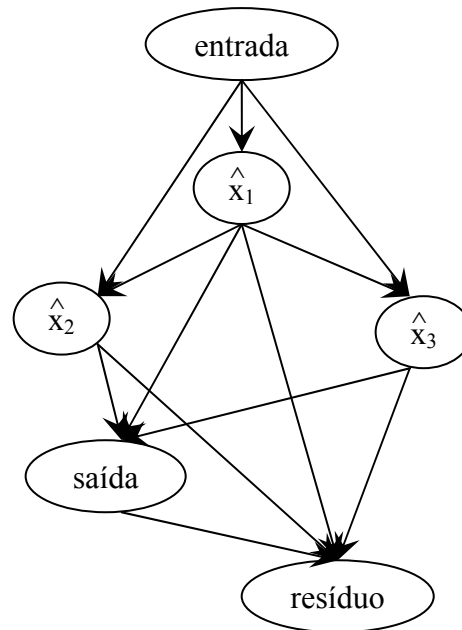


FIGURA 4.8 – Estrutura da rede Bayesiana aprendida.

Cada um dos 81 modelos de falhas foi então simulado 100 vezes, com a falha correspondente ocorrendo em diferentes instantes de tempo em cada simulação. As redes Bayesianas correspondentes foram então usadas na detecção de falhas. Para a comparação também foi realizada a análise do resíduo gerado pelo observador para cada uma das falhas.

A detecção foi restrita a um período de operação antes e um período de operação após a ocorrência da falha. Desse modo, para cada modelo de falha, 100 períodos de operação normal e 100 períodos de operação com falha foram considerados.

Apesar da aprendizagem das redes ter sido realizada com a BNT - *Bayes Net Toolbox* (MURPHY, 2001), para a detecção de falhas optou-se pelo uso da biblioteca do software MSBNx, *Microsoft Belief Networks* (KADIE; HOVEL; HORVITZ, 2001). Tal decisão foi tomada pelo fato da inferência Bayesiana ser um processo que consome uma quantidade razoável de recursos e o código compilado do software MSBNx é muito mais eficiente em termos de tempo de execução que o código interpretado da BNT.

A figura 4.9 ilustra a operação do sistema com a ocorrência de uma falha em 3,35 segundos.




FIGURA 4.9 – Saída do servomecanismo para uma falha em $t=3,35s$.

Após a análise dos resultados obtidos com a utilização da redundância analítica e do método proposto, foram também realizadas a detecção de falhas com agrupamento via *k-Means* e redes de Kohonen para algumas situações específicas.

Os dados de aprendizagem dessas situações específicas foram utilizados na definição dos centros de agrupamentos para o *k-Means* e no treinamento das redes de Kohonen.

Foram realizados testes para várias quantidades de agrupamentos diferentes e para diferentes dimensões da rede de Kohonen. Esses testes mostraram que o *k-Means* obtém seus melhores resultados para 200 agrupamentos e que a rede de Kohonen obtém seus melhores resultados com um mapa de 20 x 20 neurônios.

Apenas os resultados obtidos nessas situações (200 agrupamentos para *k-Means* e redes de Kohonen de 20 x 20 neurônios) são apresentados. Um estudo mais aprofundado sobre esses métodos e sobre a escolha da quantidade de agrupamentos e das dimensões da rede de Kohonen fica como proposta de trabalhos futuros.

Simulações adicionais com pequenas variações também foram realizadas para algumas situações específicas.

4.3 Resultados

Os resultados obtidos são comparados através de curvas ROC, que apresentam a relação entre a taxa de correta detecção e a taxa de falsos alarmes. Além da análise das curvas ROC também é usada a AUC, que representa um valor médio de taxa de detecção para todos os valores de falso alarme.

Outro fator considerado na comparação dos resultados é o tempo médio necessário para a detecção das falhas após sua ocorrência.

4.3.1 Resultados da Redundância Analítica

Inicialmente são apresentadas nas figuras 4.10 a 4.12 as curvas ROC para a redundância analítica, implementada pela análise de resíduo do observador de estados.

Em todos os casos, para a geração da curva ROC, o valor de limiar de detecção de falhas foi variado desde a taxa de falso alarme zero até a detecção de todas as falhas.

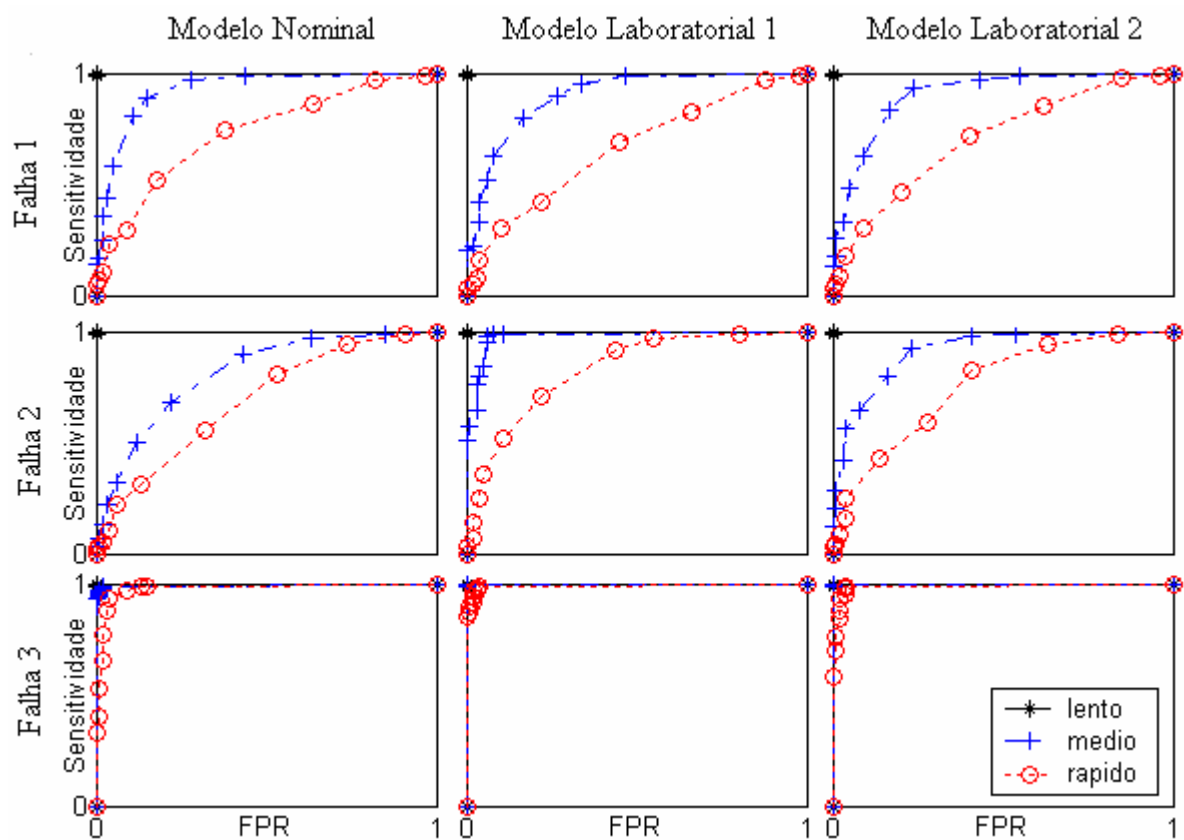


FIGURA 4.10 – Curvas ROC do observador de estados para nível de ruído baixo e observadores lento, médio e rápido.

A figura 4.10 apresenta as curvas ROC da redundância analítica com o uso dos três observadores de estado: lento, médio e rápido, para as três falhas e os três modelos. Na vertical, de cima para baixo: falha 1, falha 2 e falha 3. Na horizontal, da esquerda para a direita: modelo nominal, modelo laboratorial 1 e modelo laboratorial 2.

A figuras 4.11 e 4.12 apresentam as mesmas curvas para níveis de ruído médio e alto respectivamente.

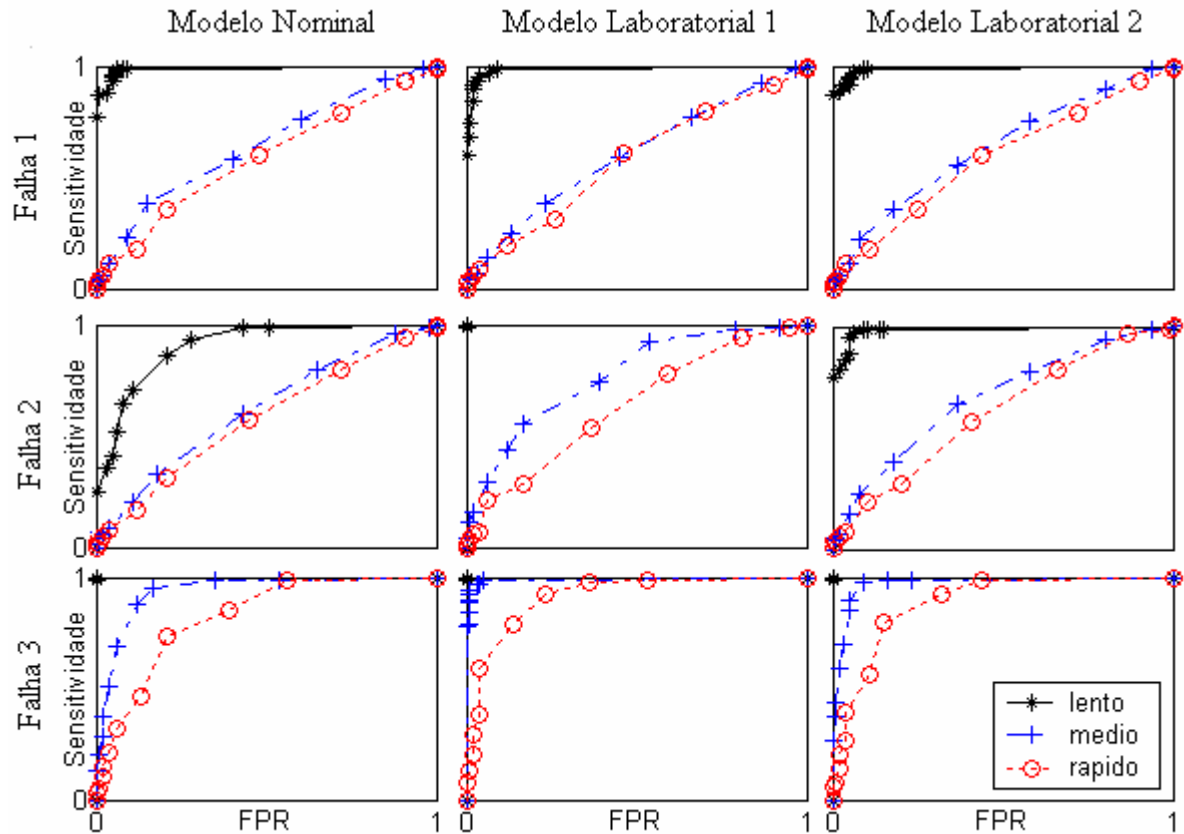


FIGURA 4.11 – Curvas ROC do observador de estados para nível de ruído médio e observadores lento, médio e rápido.

Nota-se claramente em cada uma das figuras de 4.10 a 4.12 que, como já reportado em Matsuura e Yoneyama (2004a), Paiva (2003) e Souza, Galvão e Yoneyama (2000), observadores com dinâmica muito mais rápida que a dinâmica do sistema não são adequados para a geração de resíduos para a detecção de falhas. Em todas as 27 simulações de falhas, a AUC do observador lento foi maior que a do observador médio que por sua vez foi maior que a do observador rápido. Na maioria dos casos ainda essa diferença foi visivelmente significativa.

Para facilitar a análise dos resultados obtidos com a redundância analítica a figura 4.13 apresenta as 27 Curvas ROC do observador lento juntas. A disposição vertical e horizontal das curvas é a mesma das figuras de 4.10 a 4.12.

Analisando as curvas da figura 4.13 nota-se que para nível de ruído baixo, os três modelos foram adequados para a detecção de falhas. Além disso, nota-se que a detecção da falha 3 é satisfatória para qualquer nível de ruído. Tais observações são bem coerentes, uma vez que um nível de ruído mais alto faz com que o valor absoluto dos resíduos seja alto mesmo em condições normais de operação, dificultando a correta detecção de falhas. Já para

nível de ruído baixo, a estimação da saída do sistema antes da falha é praticamente perfeita, deteriorando-se após a ocorrência da mesma.

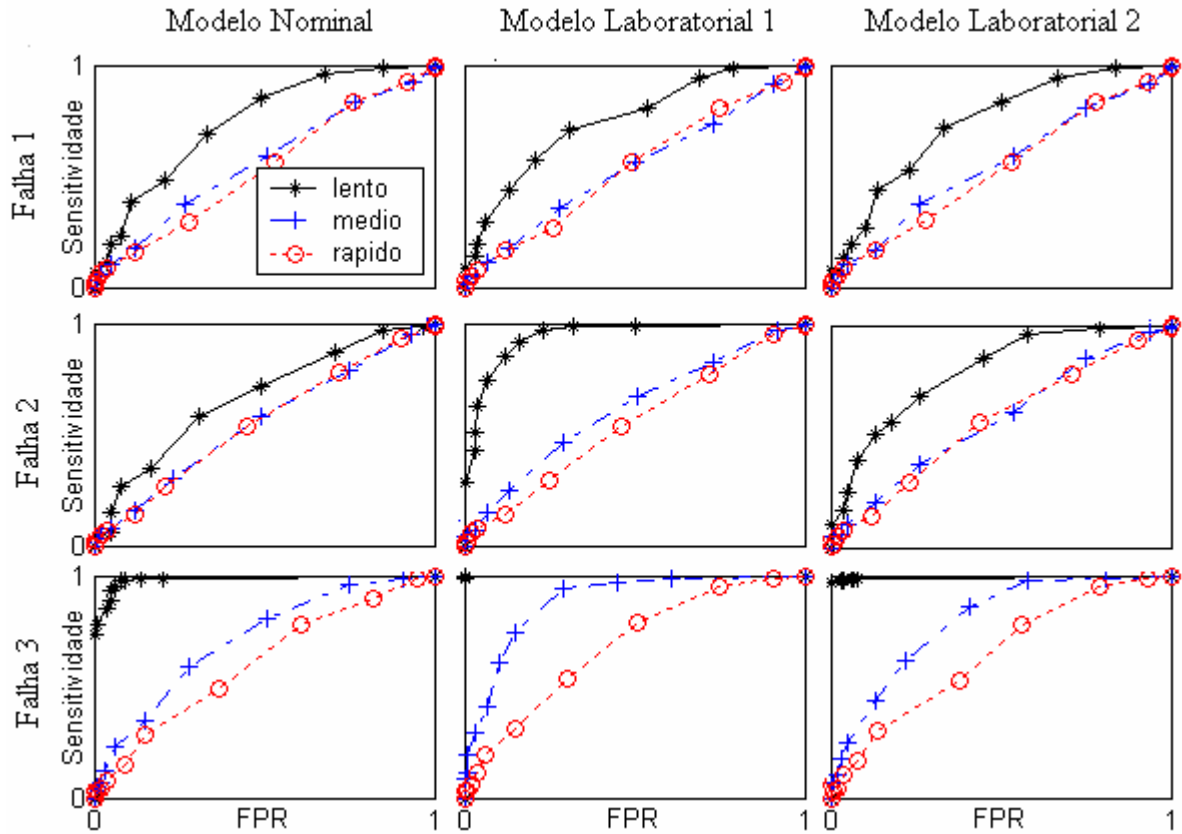


FIGURA 4.12 – Curvas ROC do observador de estados para nível de ruído alto e observadores lento, médio e rápido.

A falha 3 por ser um travamento do sensor é detectada mais facilmente porque o valor estimado para a saída continua variando enquanto a saída lida permanece constante, o que provoca um maior aumento do valor absoluto do resíduo após essa falha.

Para nível de ruído médio apenas uma das curvas ROC da figura 4.13, falha 2 e modelo nominal, não apresenta uma área próxima da unidade. Já para nível de ruído alto, com exceção da falha 3, as áreas das curvas ROC se distanciam consideravelmente da unidade.

Os valores das AUCs para as situações da figura 4.13 são apresentados na tabela 4.2.

TABELA 4.2 – AUCs para o observador lento.

Modelo	Nominal			Laboratorial 1			Laboratorial 2			Média
Falha	1	2	3	1	2	3	1	2	3	
Ruído baixo	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
Ruído médio	0,99	0,91	1,00	0,99	1,00	1,00	0,99	0,99	1,00	0,99
Ruído alto	0,74	0,67	0,98	0,75	0,94	1,00	0,74	0,79	0,99	0,84

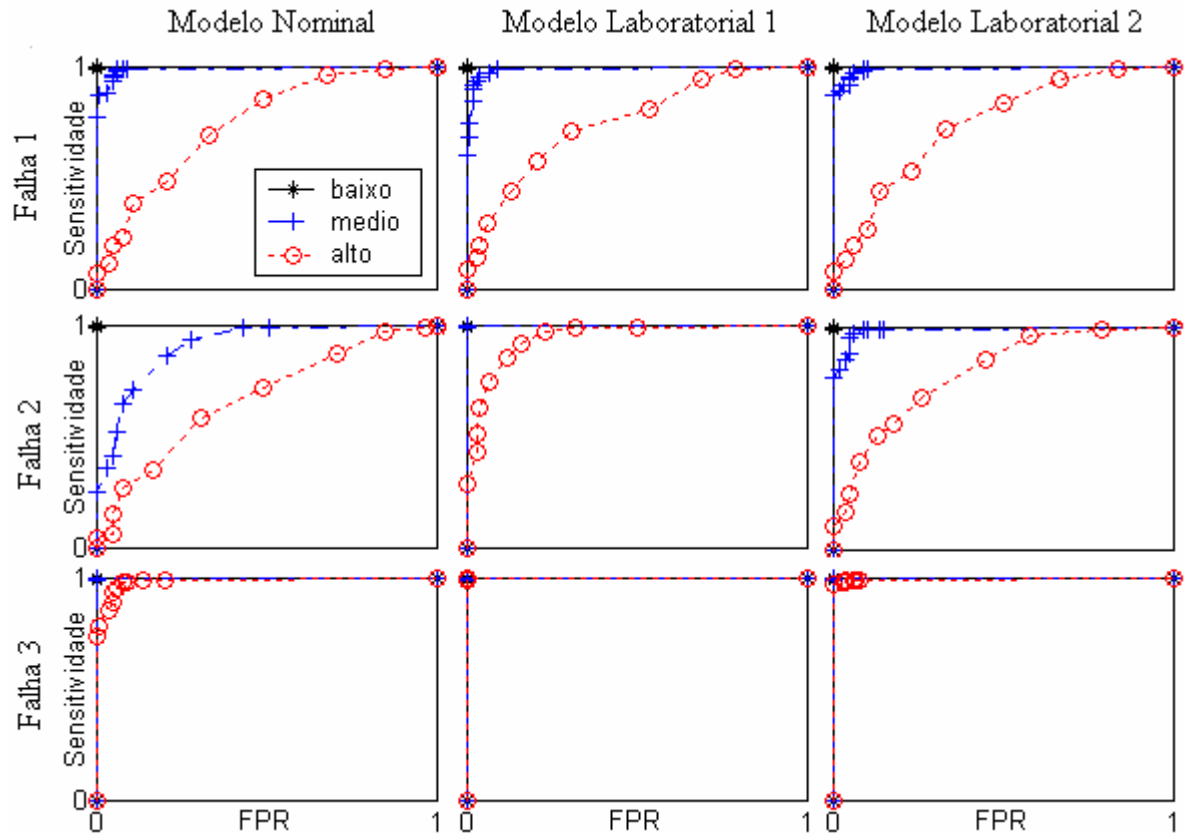


FIGURA 4.13 – Curvas ROC do observador de estados para observador lento e diferentes níveis de ruído.

A tabela 4.3 apresenta os tempos médios de detecção, considerando-se as detecções bem sucedidas para todos os valores de limiar utilizados no levantamento da curva ROC. O tempo de detecção para cada falha é o tempo decorrido entre a ocorrência da falha e sua correta detecção.

TABELA 4.3 – Tempo médio de detecção para o observador lento.

Modelo	Nominal			Laboratorial 1			Laboratorial 2			Média
Falha	1	2	3	1	2	3	1	2	3	
Ruído baixo	0,50	0,54	0,32	0,58	0,52	0,34	0,50	0,52	0,32	0,46
Ruído médio	0,76	0,76	0,42	0,80	0,56	0,38	0,72	0,64	0,38	0,60
Ruído alto	0,84	0,82	0,64	0,90	0,72	0,42	0,84	0,84	0,52	0,72

Os valores da tabela 4.3, assim como os da tabela 4.2 indicam uma maior facilidade de detecção da falha 3, que teve um tempo médio de detecção sempre inferior às demais falhas. Nota-se claramente também da tabela 4.3 que níveis de ruído mais elevados fazem com que o tempo necessário para a correta detecção das falhas aumente.

4.3.2 Resultados do Método Proposto

A análise de resíduos do observador de estados gerou 81 curvas ROC, devido aos três modelos, três níveis de ruído, três observadores e três tipos de falha. Como para cada uma dessas 81 situações foram usadas 27 redes Bayesianas na detecção de falhas, a detecção de falhas com redes Bayesianas gerou um total de 2187 curvas ROC.

Faz necessária então, antes da visualização das curvas ROC geradas pela detecção de falhas com redes Bayesianas que apenas as curvas mais significativas sejam selecionadas.

Na discretização dos dados foram utilizados três níveis de discretização diferentes, sendo que na discretização baixa foram usados apenas três intervalos. Discretizar os dados em apenas três intervalos talvez não seja o suficiente para detectar adequadamente falhas cujo efeito seja justamente alterar os valores desses dados. Caso tal alteração não seja suficiente para que o valor de uma variável discretizada passe de um intervalo discreto para outro, a falha nunca será detectada. Cinco intervalos dependendo da magnitude dos efeitos da falha talvez já sejam o suficiente, mas espera-se que resultados melhores sejam obtidos com oito intervalos de discretização.

Para cada nível de discretização diferente foram geradas 729 curvas ROC. A tabela 4.4 apresenta algumas estatísticas descritivas sobre a AUC dessas curvas ROC.

TABELA 4.4 – Estatísticas das AUCs para diferentes níveis de discretização.

Número de intervalos	3	5	8
AUC máxima	1,0	1,0	1,0
AUC mínima	0,2071	0,7482	0,8955
AUC média	0,9232	0,9766	0,9870
Desvio padrão	0,1412	0,0452	0,0203

Verifica-se pelos resultados apresentados na tabela 4.4 que a utilização de apenas três níveis de discretização realmente não é adequada para a detecção de falhas com redes Bayesianas. Embora o método tenha sido capaz de detectar todas as falhas sem um único falso alarme em pelo menos uma situação como indica a AUC Máxima (288 das 729 situações para ser mais exato) e de ter uma AUC Média maior que 0,9, a AUC mínima está muito abaixo de 0,5, o que representaria um falso alarme para cada detecção correta.

Para ser mais preciso, em 18 dos 729 casos a AUC para três intervalos ficou abaixo de 0,33. O desvio padrão de 0,1412 corrobora essa grande variação da AUC para essa quantidade de intervalos.

Os valores obtidos para cinco e oito intervalos de detecção estão de acordo com o esperado. A discretização com cinco intervalos já se mostra razoavelmente adequada enquanto que a discretização com oito intervalos se mostra ainda melhor.

A tabela 4.5 apresenta algumas estatísticas sobre o tempo de detecção médio, ou seja, o tempo decorrido entre a ocorrência da falha e a detecção por parte da rede Bayesiana. Os tempos máximo e mínimo são o tempo médio máximo e o tempo médio mínimo para as situações consideradas e todos os limiares utilizados no levantamento da curva ROC e não o tempo máximo e mínimo para uma única detecção.

TABELA 4.5 – Estatísticas dos tempos de detecção para diferentes níveis de discretização.

Número de intervalos	3	5	8
Tempo máximo (s)	1,18	1,20	1,24
Tempo mínimo (s)	0,40	0,30	0,18
Tempo médio (s)	0,85	0,65	0,49
Desvio padrão (s)	0,21	0,19	0,21

Pelo tempo médio de detecção, bem como pelo tempo mínimo, é possível verificar que a utilização de um número menor de intervalos implica em um tempo maior para a detecção, o que é bastante razoável e até intuitivo, uma vez que com um número menor de intervalos de discretização, os sinais têm uma região maior de excursão dentro de cada intervalo, demorando, portanto mais tempo para passar de um intervalo discreto para outro.

O tempo mínimo e o tempo médio de detecção para oito intervalos se mostram consideravelmente menores do que para cinco intervalos, mantendo praticamente os mesmos tempo máximo e o mesmo desvio padrão.

Há, porém uma contrapartida para o uso de mais níveis de discretização, que é uma maior necessidade de processamento na inferência Bayesiana. A tabela 4.6 apresenta o tempo médio necessário para o processamento de cada conjunto de medidas para os diferentes níveis de discretização utilizados. Esses tempos médios de processamento foram obtidos em um microcomputador Pentium 4 de 3.0 GHz e 512 MB de RAM não compartilhada, com sistema operacional Microsoft Windows XP Professional, versão 2002 e Service Pack 2.

TABELA 4.6 – Tempo médio de processamento de um conjunto de valores.

Número de intervalos	3	5	8
Tempo (ms)	3	12	50

Lembrando que o período de amostragem para esse exemplo é de 20 ms, a inferência Bayesiana com oito intervalos de discretização demoraria mais que um período de

amostragem. Tal carga computacional inviabilizaria o uso da rede, a menos que uma otimização no código da inferência Bayesiana fosse realizada, ou que três ou mais microcomputadores fossem utilizados na detecção de falhas.

Vale ressaltar que a ferramenta utilizada na inferência Bayesiana, o MSBN_x, é de 2001. Softwares mais eficientes com algoritmos de inferência Bayesiana mais rápidos já podem estar disponíveis. Além disso, não foi realizada nenhuma otimização no código que utiliza a biblioteca do MSB_x, como, por exemplo, verificar se o valor de uma variável mudou de intervalo de um conjunto de medições para o seguinte, antes de substituir esse valor na rede, obrigando a atualizar as probabilidades de todos os nós.

O estudo de softwares, bem como de algoritmos de inferência Bayesiana mais eficientes e a otimização da utilização de bibliotecas que realizem inferência Bayesiana ficam como sugestão de trabalhos futuros.

Descartadas as 729 curvas ROC referentes à discretização em três intervalos, restam ainda 1458 curvas a serem analisadas.

As tabelas 4.7 e 4.8 apresentam as estatísticas referentes ao uso de diferentes observadores. Foram analisadas 486 curvas para cada observador de estados.

Nota-se novamente, como no caso da análise de resíduo, que o observador lento é mais adequado à detecção de falhas.

TABELA 4.7 – Estatísticas das AUCs para diferentes observadores.

Observador	Lento	Médio	Rápido
AUC máxima	1,0	1,0	1,0
AUC mínima	0,8964	0,8834	0,7482
AUC média	0,9919	0,9819	0,9716
Desvio padrão	0,0176	0,0288	0,0491

TABELA 4.8 – Estatísticas dos tempos de detecção para diferentes observadores.

Observador	Lento	Médio	Rápido
Tempo máximo (s)	1,20	1,16	1,24
Tempo mínimo (s)	0,18	0,18	0,20
Tempo médio (s)	0,52	0,57	0,62
Desvio padrão (s)	0,21	0,20	0,22

As AUCs mínimas e médias são maiores para os observadores mais lentos. E os tempos de detecção mínimo e médio são menores para os observadores mais lentos.

Das 486 situações em análise, em 437 situações, ou seja em 90% das situações a AUC do observador lento foi maior que a do observador médio, sendo que a diferença máxima em favor do observador lento chegou a 0,1127. Nas 49 vezes em que o observador médio

apresentou AUC maior que o observador lento, a diferença máxima em favor do observador médio foi de 0,0346, sendo que na média, nessas 49 vezes a AUC do observador médio foi apenas 0,0113 maior que a AUC do observador lento.

Comparando-se o observador médio com o observador rápido, verifica-se que a AUC do observador médio foi maior que a do observador rápido em 78% das situações. A diferença máxima em favor do observador médio chegou a 0,1677, enquanto que a diferença máxima em favor do observador rápido foi de 0,0378. Na média, considerando-se apenas os casos em que a AUC do observador rápido foi maior, a diferença em favor do observador rápido foi de apenas 0,0089.

Vale notar que, apesar de observadores mais rápidos serem menos adequados à detecção de falhas, o método proposto não é tão afetado pelo uso de observadores mais rápidos quanto a detecção de falhas pela análise de resíduos. A tabela 4.9 apresenta as mesmas informações que a tabela 4.7, mas para a análise de resíduos.

TABELA 4.9 – Estatísticas das AUCs para a análise de resíduos com diferentes observadores.

Observador	Lento	Médio	Rápido
AUC máxima	1,0	1,0	0,9924
AUC mínima	0,6700	0,5359	0,5283
AUC média	0,9435	0,7798	0,6930
Desvio padrão	0,1024	0,1714	0,1508

A diferença de desempenho para a análise de resíduos é muito maior que no caso das redes Bayesianas. É possível verificar-se ainda, comparando-se as tabelas 4.7 e 4.9, que o desempenho das redes Bayesianas com observador rápido é superior ao desempenho da análise de resíduos com o observador lento.

As 972 curvas ROCs referentes aos observadores médio e rápido foram então descartadas, restando as 486 curvas referentes ao observador lento.

As tabelas 4.10 e 4.11 apresentam as estatísticas referentes a essas 486 curvas, divididas pela ordem dos nós utilizada na aprendizagem.

Nota-se que não há variações significantes nos resultados com o uso de diferentes ordens nos nós. A diferença máxima de AUC entre o uso de duas ordens diferentes foi de 0,011, sendo que a diferença média de AUC ficou em 0,001. A diferença máxima de tempo médio de detecção foi de 0,14 segundos, enquanto que a média das diferenças ficou em 0,01 segundos. Conclui-se então que a ordem dos nós influencia pouco no desempenho do método proposto, sendo consideradas então apenas os resultados obtidos com a ordem canônica, ou seja, 162 curvas ROC.

TABELA 4.10 – Estatísticas das AUCs para diferentes ordens dos nós.

Ordem	Canônica	Inversa	Mista
AUC máxima	1,0	1,0	1,0
AUC mínima	0,8964	0,9043	0,9043
AUC média	0,9920	0,9921	0,9916
Desvio padrão	0,0176	0,0178	0,0176

TABELA 4.11 – Estatísticas dos tempos de detecção para diferentes ordens dos nós.

Ordem	Canônica	Inversa	Mista
Tempo máximo (s)	1,20	1,20	1,20
Tempo mínimo (s)	0,18	0,18	0,18
Tempo médio (s)	0,52	0,52	0,52
Desvio padrão (s)	0,21	0,22	0,22

As tabelas 4.12 e 4.13 apresentam as estatísticas referentes a essas 162 curvas, divididas pela quantidade de dados utilizada na aprendizagem.

TABELA 4.12 – Estatísticas das AUCs para diferentes quantidades de dados.

Ciclos de Operação	2.500	2.000	1.500
AUC máxima	1,0	1,0	1,0
AUC mínima	0,8964	0,9208	0,9355
AUC média	0,9927	0,9939	0,9896
Desvio padrão	0,0206	0,0164	0,0153

TABELA 4.13 – Estatísticas dos tempos de detecção para diferentes quantidades de dados.

Ciclos de Operação	2.500	2.000	1.000
Tempo máximo (s)	0,96	1,00	1,20
Tempo mínimo (s)	0,19	0,18	0,18
Tempo médio (s)	0,53	0,53	0,52
Desvio padrão (s)	0,21	0,21	0,22

As variações são um pouco maiores que para o uso de diferentes ordens nos nós, principalmente na AUC mínima, mas a AUC média e o tempo médio de detecção não variaram consideravelmente. A diferença máxima de AUC foi de 0,0403, sendo que a diferença média de AUC ficou em 0,0051. A diferença máxima de tempo médio de detecção foi de 0,33 segundos, enquanto que a média das diferenças ficou em 0,04 segundos. Mesmo essas variações sendo maiores que no caso de diferentes ordens dos nós, elas não são tão significativas, o que indica que para o caso de estudo, 1.500 ciclos de operação já são o suficiente para uma aprendizagem adequada. Outra indicação de que essa quantidade de dados é suficiente para uma aprendizagem adequada é que em metade das 18 diferentes situações (três modelos diferentes, três níveis de ruído diferentes e dois níveis de discretização diferentes), as estruturas das redes Bayesianas aprendidas com as diferentes quantidades de

dados foi exatamente a mesma. E nas outras nove situações a diferença entre as estruturas aprendidas foi de apenas um relacionamento.

Desse modo apenas as 54 curvas ROC referentes à aprendizagem com 1.500 ciclos de operação foram comparadas com os resultados obtidos pela redundância analítica.

4.3.3 Comparações entre o Método Proposto e a Redundância Analítica

A figura 4.14 apresenta as curvas ROC para o observador de estados e para as redes Bayesianas com cinco e oito intervalos de discretização e nível de ruído baixo. Na vertical de cima para baixo: falha 1, falha 2 e falha 3. Na horizontal da esquerda para a direita: modelo nominal, modelo laboratorial 1 e modelo laboratorial 2.

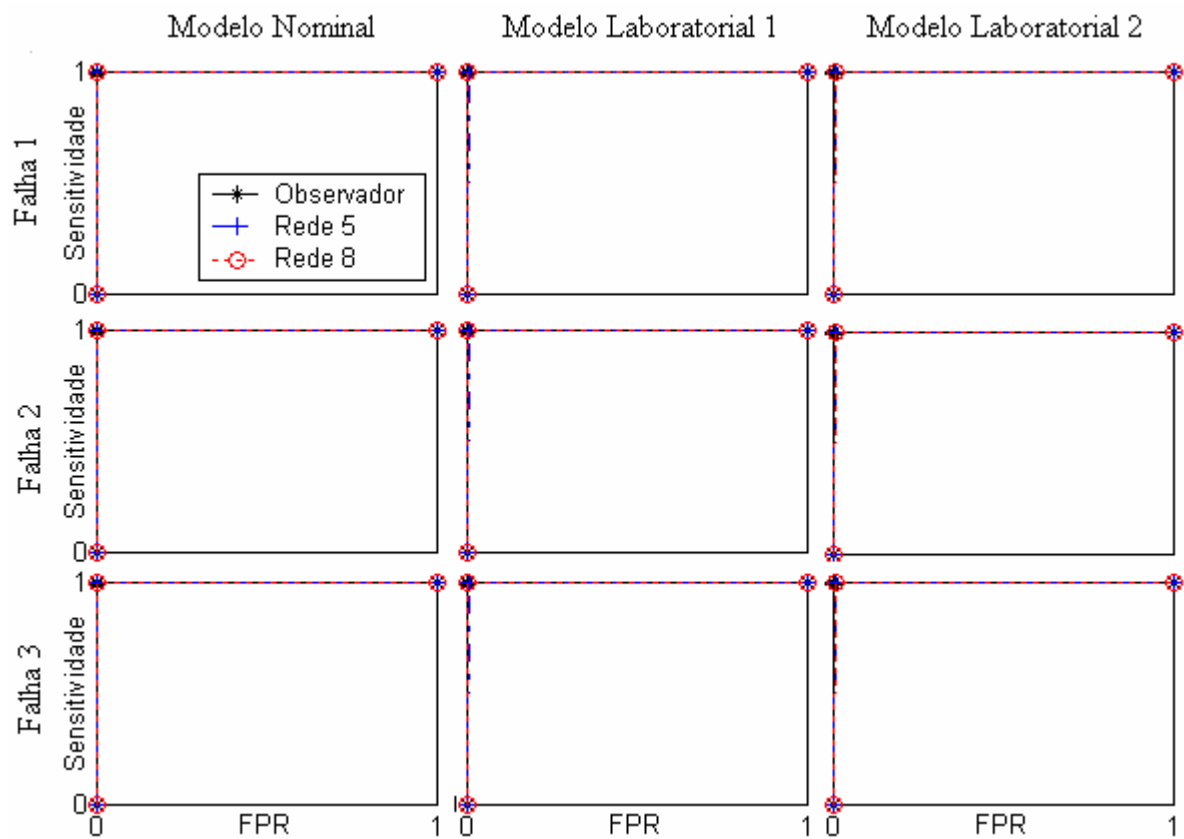


FIGURA 4.14 – Curvas ROC do observador de estados e das redes Bayesianas para nível de ruído baixo.

A figura 4.15 apresenta as mesmas curvas da figura 4.14 para nível de ruído médio.

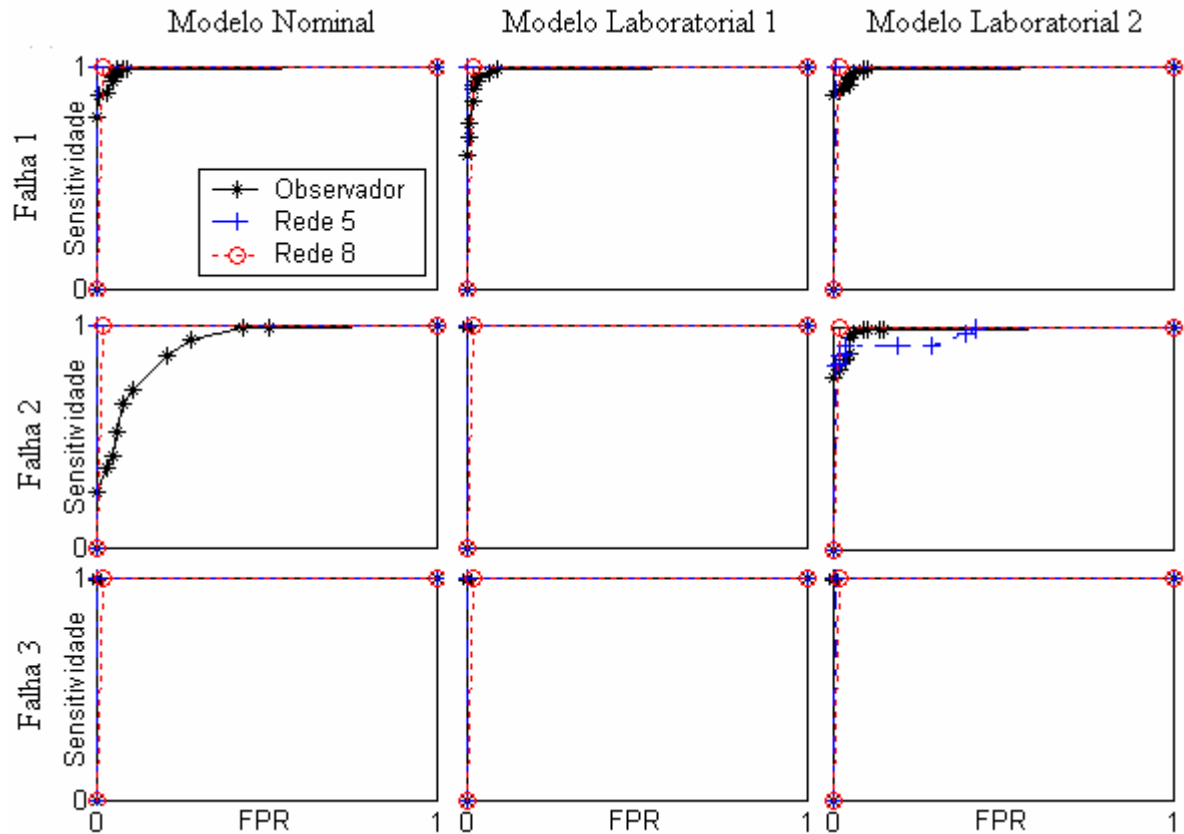


FIGURA 4.15 – Curvas ROC do observador de estados e das redes Bayesianas para nível de ruído médio.

Com exceção de duas situações: ruído médio, falha 2, modelo nominal e ruído médio falha 2, modelo laboratorial 2, verifica-se claramente que as AUCs para o observador de estados e para as redes Bayesianas estão bastante próximas da unidade. Desse modo as comparações entre esses métodos tornam-se interessantes apenas para nível de ruído alto. As curvas ROC para nível de ruído alto são apresentadas na figura 4.16. A ordem de apresentação das curvas é a mesma das figuras 4.14 e 4.15.

Como já notado anteriormente, os resultados de detecção da falha 3 são bem superiores aos resultados de detecção das falhas 1 e 2, com uma AUC bem próxima da unidade para os dois métodos utilizados. Desse modo a análise comparativa entre a redundância analítica via análise de resíduos de observador de estados e o método proposto se concentra nos resultados obtidos na detecção das falhas 1 e 2.

As tabelas 4.14 e 4.15 apresentam informações relativas às AUCs e ao tempo médio de detecção para os três modelos de servomecanismo, nível de ruído alto, observador lento e falhas 1 e 2, obtidas com o uso da análise de resíduos e com redes Bayesianas aprendidas com 5 e 8 intervalos de discretização, 1.500 ciclos de operação e ordem canônica dos nós. Essas tabelas apresentam também os valores médios considerando-se somente essas situações.




FIGURA 4.16 – Curvas ROC do observador de estados e das redes Bayesianas para nível de ruído alto.

TABELA 4.14 – AUCs para o observador de estados e para as redes Bayesianas.

Modelo	Nominal		Laboratorial 1		Laboratorial 2		Média
Falha	1	2	1	2	1	2	
Observador	0,7439	0,6700	0,7513	0,9416	0,7424	0,7926	0,7736
Rede Bayesiana 5	0,9751	0,9355	0,9999	0,9377	0,9938	0,9366	0,9631
Rede Bayesiana 8	0,9750	0,9750	0,9900	0,9900	0,9850	0,9850	0,9833

TABELA 4.15 – Tempo médio de detecção para o observador de estados e para as redes Bayesianas.

Modelo	Nominal		Laboratorial 1		Laboratorial 2		Média
Falha	1	2	1	2	1	2	
Observador	0,84	0,82	0,90	0,72	0,84	0,84	0,82
Rede Bayesiana 5	0,58	0,92	0,76	0,92	0,82	1,20	0,86
Rede Bayesiana 8	0,60	0,62	0,48	0,74	0,48	0,66	0,60

Os valores de AUCs e tempos médios de detecção das tabelas 4.12 e 4.13 são também apresentados nas figuras 4.17 e 4.18. Em ambos os casos os valores são apresentados em ordem crescente de AUC ou tempo de detecção para o observador de estados.

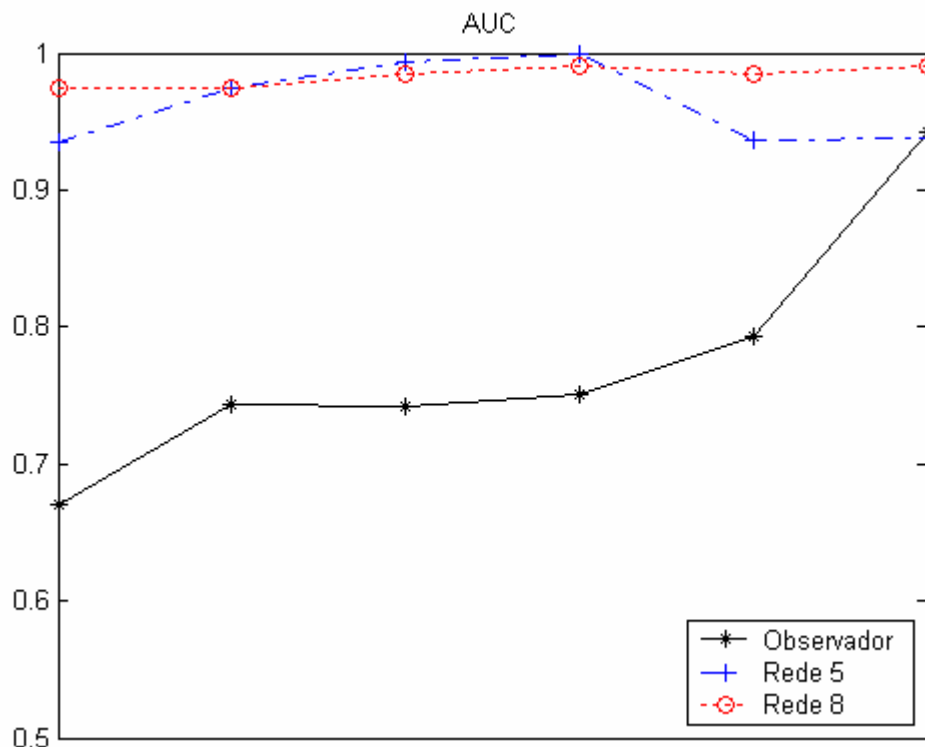


FIGURA 4.17 – Valores de AUCs

Nota-se claramente das figuras 4.16 e 4.17 e da tabela 4.14 que as AUCs da rede Bayesiana discretizada em oito intervalos estão sempre muito próximas da unidade.

Já as AUCs do observador de estados, com exceção de apenas uma situação estão todas abaixo de 0,8, enquanto que as AUCs da rede Bayesiana que utiliza cinco intervalos de discretização estão sempre acima de 0,93.

A média da AUC do observador também fica bem abaixo das médias das AUCs das redes Bayesianas.

Com relação ao tempo de detecção, verifica-se a partir da tabela 4.15 e da figura 4.18 que o tempo de detecção para a rede Bayesiana discretizada em oito intervalos é consistentemente menor que para o da rede discretizada em cinco intervalos e que para o observador de estados. Já o tempo de detecção para a rede Bayesiana discretizada em cinco intervalos é às vezes maior e às vezes menor que para o observador.

Isso indica que embora cinco intervalos de discretização sejam suficientes para uma correta detecção de falhas, não são o suficiente para que essa detecção seja realizada mais rapidamente que pela análise de resíduos. Apenas a diferença de AUC, ou seja, a maior eficiência da rede Bayesiana em distinguir situações de falha de situações de operação normal, já seria, no entanto, argumento suficiente para a escolha da utilização de redes Bayesianas ao invés da análise de resíduos.




FIGURA 4.18 – Tempos médios de Detecção

Como citado anteriormente o tempo médio de processamento necessário para o cálculo da probabilidade de ocorrência de um conjunto de valores, quando utilizados oito intervalos de discretização, é maior que o período de amostragem. Desse modo, nesse exemplo específico, se nenhuma otimização de código fosse feita, seriam necessários pelos menos três computadores para os cálculos das probabilidades. Mas para sistemas com constantes de tempo maiores e com períodos de amostragem maiores, esses cálculos poderiam ser realizados dentro de um período de amostragem em um único processador. A grande limitação de uso do método proposto seria, portanto, apenas no monitoramento de sistemas muito rápidos (com constantes de tempo da ordem de milisegundos) quando não pudessem ser utilizados vários processadores no cálculo das probabilidades.

Vale ressaltar também que a AUC do observador de estados apresenta uma variação muito maior para diferentes situações do que as AUCs das redes Bayesianas, o que mostra que as redes Bayesianas são menos sensíveis a diferenças no modelo e mantém sua efetividade para diferentes tipos de falhas e diferentes níveis de ruído, enquanto que o desempenho da análise de resíduos varia bastante, se deteriorando muito com o aumento do nível de ruído.

Esse comportamento superior do método proposto se deve principalmente ao fato da aprendizagem da rede Bayesiana incorporar os efeitos do erro de modelagem e do ruído no modelo probabilístico aprendido. Na redundância analítica, considera-se que o modelo utilizado é fiel à dinâmica real do sistema e, além disso, os efeitos do ruído são considerados apenas no estabelecimento do limiar de detecção de falhas. Por utilizar um modelo probabilístico aprendido a partir das variáveis do sistema, inclusive da saída que está sujeita ao ruído, a aprendizagem da rede Bayesiana incorpora os efeitos do mesmo ao aprender os relacionamentos probabilísticos das variáveis. De forma análoga os efeitos dos erros de modelagem também são refletidos na rede resultante do processo de aprendizagem, o que torna o método proposto mais robusto a erros de modelagem e ao ruído.

4.3.4 Aprendizagem com Quantidade Menor de Dados

Como os resultados obtidos inicialmente com o uso de diferentes quantidades de dados para a aprendizagem das redes Bayesianas não apresentaram diferenças significativas, conforme já apresentado nas tabelas 4.10 e 4.11, novas redes Bayesianas foram aprendidas utilizando-se 1.000, 500 e 200 ciclos de operação.

As AUCs resultantes para essas novas quantidades de dados de aprendizagem bem como para 1.500 ciclos de operação, para os três modelos de servomecanismo, nível de ruído alto, observador lento, três tipos de falha, discretização em cinco intervalos e ordem canônica dos nós são apresentados na figura 4.19. Na vertical de cima para baixo: falha 1, falha 2 e falha 3. Na horizontal da esquerda para a direita: modelo nominal, modelo laboratorial 1 e modelo laboratorial 2.

Os resultados para discretização em cinco intervalos e ruído médio, para discretização em oito intervalos e ruído médio, e para discretização em oito intervalos e ruído alto são todos muito parecidos com as apresentados na figura 4.19 para a falha 3 e modelo nominal e por isso foram omitidos.

Nota-se, como seria esperado, que uma quantidade maior de dados para a aprendizagem melhora o desempenho da rede Bayesiana na detecção de falhas. Nota-se que mesmo para apenas 200 ciclos de operação para a aprendizagem, o resultado obtido pelas redes Bayesianas já é melhor que para a redundância analítica via análise de resíduos.




FIGURA 4.19 – Curvas ROC das redes Bayesianas para diferentes quantidade de dados de aprendizagem.

4.3.5 Comparações com Métodos Alternativos de Aprendizagem

Para a comparação do método proposto com a utilização de agrupamento via *k-Means* e redes de Kohonen, foram utilizados os dados de 500 ciclos de operação normal para a aprendizagem das redes Bayesianas, para a definição dos centros de agrupamentos via *k-Means* e para o treinamento das redes de Kohonen. Os dados utilizados foram exatamente os mesmos para os três métodos, ou seja, os vetores para o agrupamento via *k-Means* e para as redes de Kohonen eram compostos pelo sinal de entrada, pelos estados estimados, pelo sinal de saída e pelo valor do resíduo, nessa ordem. Cada ciclo de operação é composto de 100 amostras, portanto a quantidade de elementos para o agrupamento é de 50.000 elementos. Antes da realização do agrupamento via *k-Means* e do treinamento das redes de Kohonen todos os dados foram normalizados no intervalo de -1 a 1 para que as variáveis com maior variação não tivessem um peso maior na definição dos agrupamentos.

Para o agrupamento via *k-Means* foram testadas várias quantidades de agrupamentos, sendo os melhores resultados obtidos com 200 agrupamentos.

Para as redes de Kohonen foram testados vários tamanhos de mapas bidimensionais, e depois diferentes quantidades de épocas de treinamento, sendo que os melhores resultados foram obtidos com mapas de 20 x 20 neurônios e o uso de mais de uma época não melhorou o desempenho da rede de Kohonen consideravelmente.

Fica como sugestão de trabalhos futuros um estudo melhor desses dois métodos que também se mostraram promissores, com resultados superiores aos da redundância analítica via análise de resíduo de observador de estado. Nesse estudo pode ser considerada a escolha automática da melhor quantidade de agrupamentos para o *k-Means* e da melhor dimensão do mapa para a rede de Kohonen.

Os resultados obtidos com a utilização da redundância analítica, de agrupamento via *k-Means*, de redes de Kohonen e de redes Bayesianas com cinco e oito intervalos de discretização são apresentados nas tabelas 4.16 e 4.17 e na figura 4.20.

Foram utilizados os três modelos de servomecanismo, ruído alto, observador lento e as falhas 1 e 2.

TABELA 4.16 – AUCs para os diferentes métodos utilizados.

Modelo Falha	Nominal		Laboratorial 1		Laboratorial 2		Média
	1	2	1	2	1	2	
Observador	0,7439	0,6700	0,7513	0,9416	0,7424	0,7926	0,7736
Kohonen	0,8207	0,8530	0,9440	0,8958	0,8428	0,8186	0,8625
<i>K-Means</i>	0,9097	0,8336	0,9317	0,8639	0,9468	0,8890	0,8958
Rede Bayesiana 5	0,9145	0,9046	0,9600	0,9008	0,9550	0,9378	0,9288
Rede Bayesiana 8	0,9500	0,9500	0,9650	0,9650	0,9600	0,9600	0,9583

TABELA 4.17 – Tempo médio de detecção para os diferentes métodos utilizados.

Modelo Falha	Nominal		Laboratorial 1		Laboratorial 2		Média
	1	2	1	2	1	2	
Observador	0,84	0,82	0,90	0,72	0,84	0,84	0,82
Kohonen	0,82	0,56	0,70	0,56	0,82	0,52	0,66
<i>K-Means</i>	0,84	0,92	0,74	0,86	0,74	0,74	0,80
Rede Bayesiana 5	0,76	1,00	0,54	0,88	0,54	1,22	0,82
Rede Bayesiana 8	0,50	0,76	0,46	0,84	0,48	0,70	0,62

Observa-se da figura 4.20 e da tabela 4.17 que, com relação à correta detecção de falhas, na maioria das vezes, e na média, o desempenho das redes Bayesianas com oito intervalos é superior ao das redes Bayesianas com cinco intervalos, que por sua vez é superior ao do agrupamento via *k-Means*, que por sua vez é superior ao da rede de Kohonen, que, finalmente, é superior ao desempenho da análise de resíduos. Nota-se também que as variações de AUCs das redes Bayesianas são bem menores do que para outros métodos, tanto

com relação a diferentes falhas quanto em relação ao uso de diferentes modelos e portanto diferentes observadores de estado.

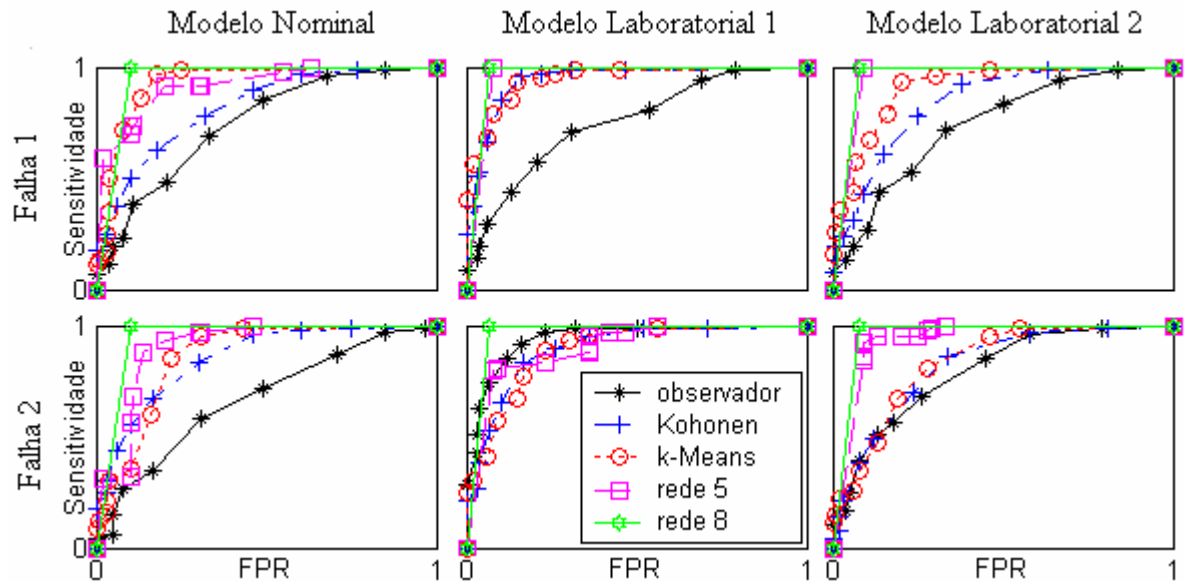


FIGURA 4.20 – Curvas ROC dos diferentes métodos utilizados.

Com relação ao tempo médio de detecção verifica-se uma menor variação para a análise de resíduos do observador de estados e uma detecção mais rápida para a rede de Kohonen e para a rede Bayesiana com oito intervalos de discretização.

Os resultados obtidos apontam para uma maior eficiência das redes Bayesianas na detecção de falhas, com um tempo de detecção menor se uma quantidade adequada de intervalos de discretização for utilizada.

Uma possível explicação para o melhor desempenho das redes Bayesianas quando comparadas ao agrupamento via *k-Means* e às redes de Kohonen é que na aprendizagem das redes Bayesianas são extraídas informações do relacionamento probabilístico entre as variáveis do sistema, ao passo que na aprendizagem utilizando-se *k-Means* e redes de Kohonen, são considerados apenas os vetores formados pelas variáveis do sistema e não o relacionamento entre as variáveis. Desse modo, a aprendizagem de redes Bayesianas consegue extrair dos mesmos dados uma quantidade maior de informações sobre o funcionamento normal do sistema que as outras duas técnicas de aprendizagem.

Testes mais extensos do método proposto, como, por exemplo, sua aplicação na detecção de falhas incipientes, ficam como sugestão de trabalhos futuros.

5 Resultados Adicionais de Detecção e Isolamento de Falhas

Além dos resultados apresentados no capítulo 4 onde o método proposto foi utilizado na detecção de falhas em um servomecanismo de velocidade em malha aberta, submetido a um sinal de controle periódico, o método proposto foi também utilizado na detecção de falhas no modelo longitudinal de uma aeronave, em malha fechada, controlada por um piloto automático, também apresentando bons resultados.

Adicionalmente o método proposto foi utilizado na detecção de falhas em um sistema não-linear controlado por um controlador também não linear, mas usando um modelo linear para estimativa dos estados do sistema.

Por fim, o método, inicialmente concebido apenas para a detecção de falhas, foi ainda testado no isolamento de falhas em um sistema de múltiplas entradas e múltiplas saídas.

Os resultados obtidos na detecção de falhas em um sistema não linear e no isolamento de falhas são bastante animadores, mostrando que ele poderá ser estendido para a detecção de falhas em sistemas não-lineares e para o isolamento de falhas. Os resultados obtidos nesses testes adicionais corroboram também os bons resultados obtidos na detecção de falhas em sistemas lineares.

5.1 Dinâmica Longitudinal de Aeronave

O método proposto foi utilizado no monitoramento da dinâmica longitudinal de uma aeronave 747 voando a 12.000 metros de altura, com uma velocidade de 235 m/s (BRYSON, 1993).

A equação dinâmica do sistema linearizado nas condições de operação é apresentada na equação 5.1, onde x é o vetor de estado de dimensão 6×1 , A é a matriz dinâmica de malha aberta, u é o vetor de entrada conhecido de dimensão 2×1 , com a matriz de distribuição de entrada correspondente B e o termo $B_n.w$ caracteriza um vetor de entrada desconhecido de dimensão 2×1 w (perturbação) com matriz de distribuição conhecida B_n .

$$\dot{x} = Ax + Bu + B_n.w \quad (5.1)$$

As matrizes e vetores do modelo linearizado do sistema são apresentados na equação 5.2.

$$\begin{aligned}
 A &= \begin{bmatrix} -0,003 & 0,039 & 0 & -0,322 & 0 & 1 \\ -0,065 & -0,319 & 7,74 & 0 & 0 & -0,04 \\ 0,0201 & -0,101 & -0,429 & 0 & 0 & 0,598 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & -1 & 0 & 7,74 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -0,25 \end{bmatrix}, B = \begin{bmatrix} 0,01 & 0 \\ -0,18 & 0 \\ -1,16 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0,25 \end{bmatrix}, \\
 B_n &= \begin{bmatrix} -0,003 & 0,039 \\ -0,65 & -0,319 \\ 0,0201 & -0,101 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix}, x = \begin{bmatrix} i \\ j \\ q \\ \theta \\ h \\ t \end{bmatrix}, u = \begin{bmatrix} e \\ tc \end{bmatrix}, w = \begin{bmatrix} wi \\ wj \end{bmatrix}
 \end{aligned} \tag{5.2}$$

As componentes do vetor de entradas u são o comando do profundor (leme de profundidade responsável pelo movimento de subir e descer da aeronave) (e) e o comando de injeção de combustível (tc). As componentes do vetor de perturbação w são rajadas de vento nas direções x (do nariz para a cauda da aeronave) (wi) e z (de cima para baixo) (wj). As componentes do vetor de estado são as velocidades da aeronave nas direções x (i) e z (j), a velocidade angular do eixo x (q) com relação à horizontal, o ângulo de Euler entre o eixo x e a horizontal (θ), a altitude da aeronave (h) e a injeção real de combustível (t). O ângulo de Euler e as direções mencionadas são mostrados na figura 5.1.




FIGURA 5.1 – Nomenclatura para o movimento longitudinal da aeronave.

A aeronave é controlada por realimentação de estado com um sistema de aumento de estabilidade para manter a altitude constante. Os ganhos de realimentação desse piloto automático são os determinados em Bryson (1993) e são apresentados na equação 5.3.

$$k = \begin{bmatrix} 0,1083 & 0,1938 & -0,5309 & -1,8814 & -0,0475 & -0,1534 \\ 0,4719 & -0,0121 & 0,0390 & 0,1007 & 0,0157 & 1,2230 \end{bmatrix} \tag{5.3}$$

Apesar da aeronave 747 possuir um sistema de navegação inercial e uma série de sensores redundantes que monitoram todas as variáveis de estado, que seriam utilizados para a aprendizagem da rede Bayesiana em uma situação real, para o estudo em questão considera-se que a única variável de estado medida pelos sensores é a altitude h .

Desse modo, a dinâmica a ser observada é a dinâmica total do movimento longitudinal da aeronave, caso contrário o observador de estados seria usado somente para estimar a altitude h a partir dos valores medidos de dois estados (j e θ).

O sensor de altitude está sujeito a um ruído branco Gaussiano aditivo de média zero e desvio padrão 0,1 m.

O observador foi então projetado considerando-se apenas o sensor de altitude como saída do sistema, desse modo o resíduo para a detecção de falhas com o observador é a diferença entre a leitura do sensor de altitude e a estimação da altitude feita pelo observador. O projeto do Observador foi realizado de modo que seus pólos fossem 10% mais rápidos que o pólo mais rápido do sistema em malha aberta.

A figura 5.2 mostra o esquema utilizado na simulação do movimento longitudinal da aeronave 747 e da falha do sensor.

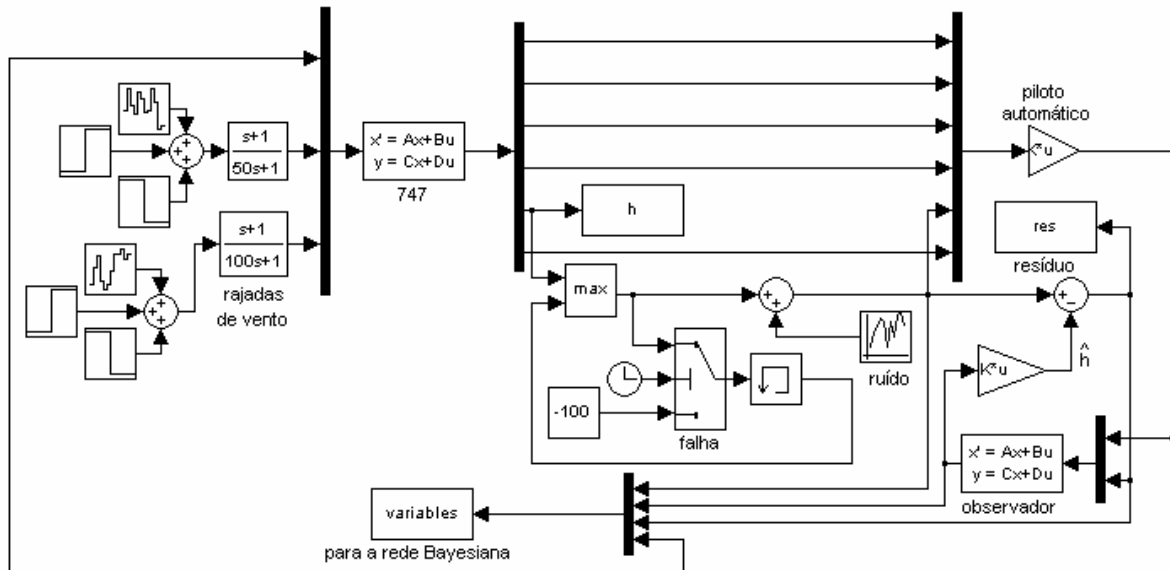


FIGURA 5.2 – Diagrama de simulação do movimento longitudinal da aeronave 747.

As rajadas de vento foram simuladas por duas funções degrau de diferentes amplitudes ocorrendo em instantes diferentes acrescidas de ruído. A soma desses sinais passa por um filtro passa baixa para que as variações não sejam bruscas demais. Tal implementação teve como objetivo reproduzir variações de rajadas de vento simuladas próximas às encontradas na prática.

As figuras 5.3 e 5.4 apresentam formas de onda típicas para as rajadas de vento utilizadas nas simulações. As rajadas de vento na direção x variam de -10 a +10 m/s, enquanto que as rajadas de vento na direção z variam de -5 a +5 m/s.




FIGURA 5.3 – Exemplo de rajada de vento na direção x.

Para a simulação da falha, a saída do sensor de altitude foi mantida constante após rajadas de vento que fazem a aeronave subir, o sensor trava em um valor positivo de variação de altitude, informando ao piloto automático que a aeronave está sempre a uma altitude maior que a desejada. Tal falha, se não detectada em tempo hábil, pode fazer com que o piloto automático desça a aeronave abaixo de limites seguros, podendo causar uma colisão.

As variações de altitude medidas pelo sensor para a aeronave voando em condições normais são apresentadas na figura 5.5. As variações de altitude medidas pelo sensor para um travamento de sensor ocorrendo em $t = 300$ segundos são apresentadas na figura 5.6. E as variações de altitude reais para um travamento de sensor ocorrendo em $t = 300$ segundos são apresentadas na figura 5.7.

Como pode ser observado da figura 5.7, se nenhuma atitude for tomada, a aeronave pode descer a altitudes perigosas em poucos minutos.




FIGURA 5.4 – Exemplo de rajada de vento na direção z.




FIGURA 5.5 – Variação de altitude medida pelo sensor em condições normais.




FIGURA 5.6 – Variação de altitude medida pelo sensor com falha em 300 s.




FIGURA 5.7 – Variação de altitude real com falha em 300 s.

Para a aprendizagem da rede Bayesiana o modelo da aeronave foi simulado por 100 horas (600 simulações de 10 minutos) sujeito a rajadas de vento típicas. O período de amostragem utilizado foi de um segundo. Os valores dos estados estimados das entradas e da

saída foram armazenados e o algoritmo K2 foi utilizado para a aprendizagem. A figura 5.8 apresenta a estrutura da rede Bayesiana aprendida. As variáveis representadas por retângulos são as estimativas do observador de estados e as variáveis representadas por elipses são os sinais medidos diretamente do sistema.




FIGURA 5.8 – Estrutura da rede Bayesiana aprendida.

A rede Bayesiana aprendida e um esquema de redundância analítica baseada no observador de Luenberger foram então utilizados no monitoramento do sistema.

O modelo foi simulado 100 vezes, cada simulação durando 600 segundos com uma falha ocorrendo em 300 segundos. Os resultados, na forma de curvas ROC são apresentados na figura 5.9. Mais uma vez, para a geração das curvas ROC os limiares de decisão dos dois métodos foram variados desde a taxa de falso alarme zero até a detecção de todas as falhas.

A partir das curvas apresentadas na figura 5.9 é possível observar um resultado quase perfeito para as redes Bayesianas e um resultado bastante pobre para o observador de estados. Um resultado melhor poderia ser esperado para a redundância analítica uma vez que não existem erros de modelagem e que o nível de ruído não é muito elevado, mas a realimentação de estado mascara os efeitos da falha, fazendo com que a saída do observador acompanhe o valor do sensor com falha como se esse fosse correto. Desse modo, os valores absolutos do resíduo, que define a decisão de presença ou não de falha para a redundância analítica, não se elevam consideravelmente após a falha, tornando essa abordagem praticamente inútil nesse

caso. Mas, mesmo com a realimentação de estado, a falha causa variações de magnitude suficiente nas relações entre as variáveis para que a rede Bayesiana seja capaz de detectá-la.




FIGURA 5.9 – Curvas ROC.

A figura 5.10 apresenta os sinais de controle para uma simulação sem falha e para uma simulação com falha em 300 segundos. É importante notar que o travamento do sensor não implica em uma variação muito grande dos sinais de controle, desse modo o observador continua sendo capaz de acompanhar o sinal de saída, mantendo o resíduo próximo de zero. Por outro lado a relação entre os sinais de controle e as estimativas de estado variam consideravelmente, proporcionando uma correta detecção da falha por parte da rede Bayesiana.

A tabela 5.1 apresenta os resultados obtidos com as redes Bayesianas e com o observador de estados. Além de uma AUC consideravelmente maior e próxima da unidade, a abordagem das redes Bayesianas também foi capaz de detectar as falhas muito mais rápido que o observador (nas poucas vezes em que este foi capaz de detectar corretamente a falha). Essa rápida detecção pode fazer a diferença entre uma recuperação segura da altitude da aeronave e uma colisão.

Como mostrado na tabela 5.1 e como pode ser observado da figura 5.7, 10 segundos após a falha, a altitude da aeronave ainda está próxima do valor desejado. De fato, devido aos efeitos de rajadas de vento, a altitude da aeronave é ainda maior que a desejada. Também da tabela 5.1 e da figura 5.7 observa-se que 129 segundos após uma falha (tempo médio

necessário para que o observador detecte a falha) a aeronave se encontra 347 metros abaixo da altitude desejada. Desse modo, mesmo que os dois métodos apresentassem uma AUC semelhante, o método proposto ainda seria preferível.




FIGURA 5.10 – Sinais de controle para operação normal e para falha em 300 segundos.

TABELA 5.1 – Resultados obtidos para o observador de estados e para as redes Bayesianas.

	AUC	Tempo de Detecção Médio	Varição de Altitude
Observador	0,49	129,1 s	- 347 m
Rede Bayesiana	0,98	10,1 s	10 m

O método proposto foi capaz de detectar 100% das falhas simuladas com cerca de 5% de falsos alarmes, com um tempo médio de detecção de 10 segundos. Desse modo, com o uso do método proposto, o piloto humano teria tempo mais que suficiente para desligar o piloto automático e assumir o controle da aeronave antes que essa descesse a altitudes perigosas.

Por outro lado, a análise de resíduos não foi capaz de distinguir entre operação normal e operação com falha, apresentando uma AUC próxima a 0,5. E mesmo quando o observador foi capaz de detectar uma falha, o tempo necessário para a detecção estava acima do aceitável.

5.2 Detecção de Falhas em Sistema Não-Linear

Foi estudada a aplicabilidade do novo método de detecção de falhas, inicialmente proposto para sistemas lineares, a sistemas não-lineares. Esse estudo foi efetuado através da aplicação do método no monitoramento de um manipulador robô com características não-lineares tanto na dinâmica do sistema quanto no controlador utilizado. Os resultados obtidos apontam para um grande potencial do método proposto.

O sistema a ser monitorado é o conjunto formado por um manipulador *pick and place* (NASCIMENTO JR.; YONEYAMA, 2000) e um controlador nebuloso. O sistema a ser controlado (braço mecânico) é não-linear e a utilização de um controlador nebuloso evidencia ainda mais as características não-lineares do conjunto a ser monitorado.

A operação do braço mecânico consiste em carregar peças, de massa m_2 , que passam por uma esteira rolante até a posição superior onde as mesmas serão descarregadas, conforme indica a Figura 5.11.




FIGURA 5.11 – Manipulador *Pick and Place*.

Para que as peças sobre a esteira possam ser acopladas ao braço mecânico, é necessário que o mesmo fique posicionado durante um segundo dentro de uma faixa de 6° centrada em -90° , isto é, entre -93° e -87° . Da mesma forma, para que a peça possa ser descarregada, é necessário que o braço fique posicionado durante um segundo dentro de uma faixa centrada em 0° , isto é, entre -3° e 3° .

A equação 5.4 descreve a dinâmica do braço mecânico e foi utilizada nas simulações do sistema.

As funções de pertinência do controlador nebuloso e as regras utilizadas são apresentadas nas Figuras 5.12, 5.13, 5.14 e 5.15. As entradas são o erro de posição angular e a

taxa de variação do erro (*rate*). A saída é o torque que deve ser aplicado ao eixo do braço mecânico.

$$\tau = \left(\frac{m1}{3} + m2 \right) \cdot d^2 \cdot \frac{d^2 q}{dt^2} + g \cdot \left(\frac{m1}{2} + m2 \right) \cdot d \cdot \cos(q) + b \cdot \frac{dq}{dt} \quad (5.4)$$

Onde,

τ = torque aplicado no braço (Nm); q = ângulo do braço com relação à horizontal (rad);

$m1$ = massa da barra do braço, 0,25 kg; g = aceleração da gravidade, 9,8 m/s²;

$m2$ = massa da carga do braço, 0,5 kg; b = coeficiente de atrito viscoso, 0,1 Nms.

D = comprimento do braço mecânico, 0,5 m;




FIGURA 5.12 – Função de pertinência para a entrada erro (graus).




FIGURA 5.13 – Função de pertinência para a entrada *rate* (graus/s).

A dinâmica completa do manipulador robô foi simulada com o controlador nebuloso. A variável de saída estava sujeita a um ruído aditivo branco Gaussiano de média zero e desvio padrão 0,5°.




FIGURA 5.14 – Função de pertinência para a saída torque (Nm).

1. If (erro is zero) then (torque is zero)
2. If (erro is pos) and (rate is pos) then (torque is pos)
3. If (erro is pos) and (rate is neg) then (torque is zero)
4. If (erro is neg) and (rate is neg) then (torque is neg)
5. If (erro is neg) and (rate is pos) then (torque is pos)

FIGURA 5.15 – Regras do controlador nebuloso.

Em condições normais de operação o manipulador apresentava um período de 3,5 segundos e o período de amostragem utilizado foi de 0,1 s.

As falhas simuladas para o manipulador robô foram erros aditivos (viés) no sensor de posição angular. Foram simuladas quatro diferentes falhas correspondentes a erros de +5° (falha 1), -5° (falha 2), +10° (falha 3) e -10° (falha 4).

As simulações foram efetuadas segundo as etapas determinadas para o método proposto. Primeiro foram feitas simulações para a determinação de um modelo linear do sistema, depois simulações para a aprendizagem da rede Bayesiana e finalmente foram realizadas as simulações de falhas para a verificação da efetividade do método proposto.

Para a determinação do modelo, o sistema foi simulado por 35 segundos, ou seja, 10 ciclos de operação. Foram armazenados os valores do sinal de referência (0° ou -90°) e os valores do sinal de saída.

Esses valores foram utilizados na determinação de quatro modelos lineares, de ordem dois, três, quatro e cinco. Para a determinação desses modelos foi utilizada a Identificação em Subespaços, mais precisamente um algoritmo N4SID (*Numerical Algorithms for Subspace State Space System Identification* – Algoritmos Numéricos para Identificação de Sistemas em Subespaços) (VAN OVERSCHEE; DE MOOR, 1994).

Outros métodos de Identificação em Subespaços poderiam ter sido utilizados, mas o N4SID apresentou bons resultados em um curto espaço de tempo. Modelos mais precisos do sistema provavelmente resultariam em um melhor desempenho na detecção de falhas.

Os quatro modelos foram simulados também por 35 segundos com os mesmos valores de sinal de referência como entrada e foi escolhido como modelo de referência o modelo de terceira ordem por apresentar o menor erro médio quadrático quando comparado ao sinal de saída do sistema completo.

A dinâmica do modelo linearizado obtido, em tempo discreto com período de amostragem de 0,1 segundos, é dada pela equação 5.5, onde x é o vetor de estado 3×1 , A é a matriz da dinâmica do sistema em malha aberta, u é a entrada escalar, B é o vetor de distribuição de entrada, y é a saída escalar, e C é o vetor de distribuição da saída.

$$\begin{aligned} x(k) &= A.x(k-1) + B.u(k) \\ y(k) &= C.x(k) \end{aligned} \quad (5.5)$$

A matriz e os vetores do modelo são apresentados na equação 5.6.

$$A = \begin{bmatrix} 0,8233 & 0,2398 & 0,0199 \\ -0,6576 & 0,2866 & 0,1971 \\ 0,0042 & -0,3199 & 0,0817 \end{bmatrix}, B = \begin{bmatrix} 0,0004 \\ 0,0014 \\ 0,0026 \end{bmatrix}, C = [340,2 \quad 27,25 \quad 6,419] \quad (5.6)$$

Com base no modelo de terceira ordem foi projetado um observador de Luenberger com os pólos 10% mais rápidos que o pólo mais rápido do modelo.

O sistema foi simulado por mais 350 segundos, 100 ciclos de operação, com o observador projetado. Os valores de referência, entrada do controlador nebuloso, sinal de controle, saída, resíduo e estados do observador foram utilizados na aprendizagem de uma rede Bayesiana. A figura 5.16 apresenta a estrutura da rede Bayesiana aprendida.

Para o monitoramento cada falha foi simulada 100 vezes, sendo que cada uma das 100 falhas ocorria em diferentes instantes dentro do período de operação.

Para a determinação de falsos alarmes e da correta detecção de falhas, foi considerado apenas um período de operação antes e um período de operação após a ocorrência da falha.

Foram utilizadas no monitoramento as análises do resíduo do observador de estados e a rede Bayesiana construída com o uso das variáveis do observador de estados.

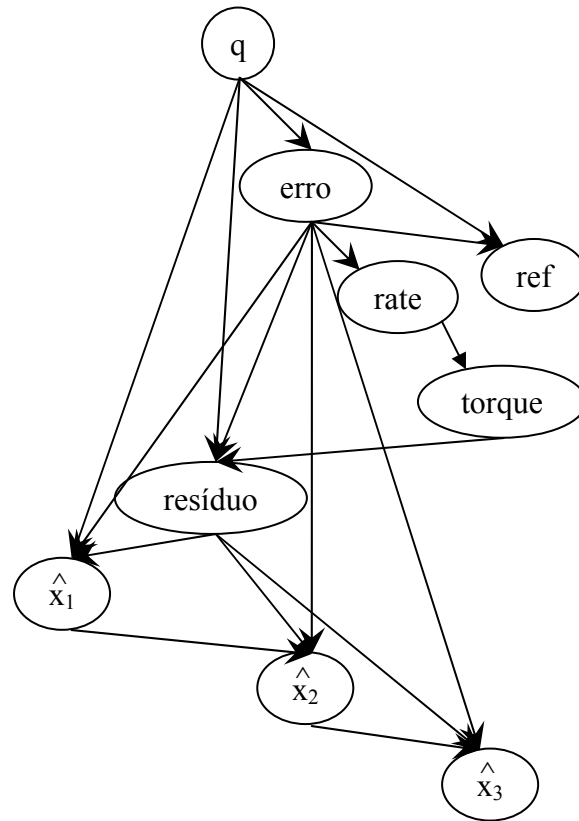


FIGURA 5.16 – Estrutura da rede Bayesiana aprendida.

As figuras 5.17, 5.18, 5.19 e 5.20 apresentam as curvas ROC para os dois métodos e a ocorrência das falhas 1, 2, 3 e 4 respectivamente.




FIGURA 5.17 – Curvas ROC para falha de +5° na saída.

Verifica-se facilmente a partir das figuras que o método proposto apresenta um desempenho consideravelmente superior à redundância analítica.

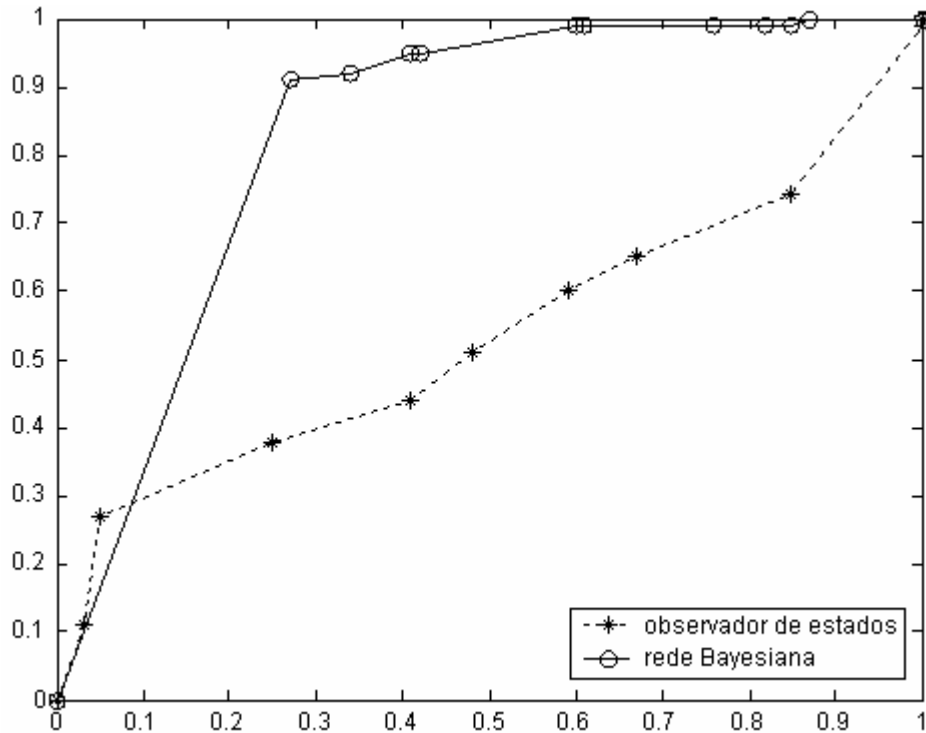


FIGURA 5.18 – Curvas ROC para falha de -5° na saída.




FIGURA 5.19 – Curvas ROC para falha de $+10^\circ$ na saída.

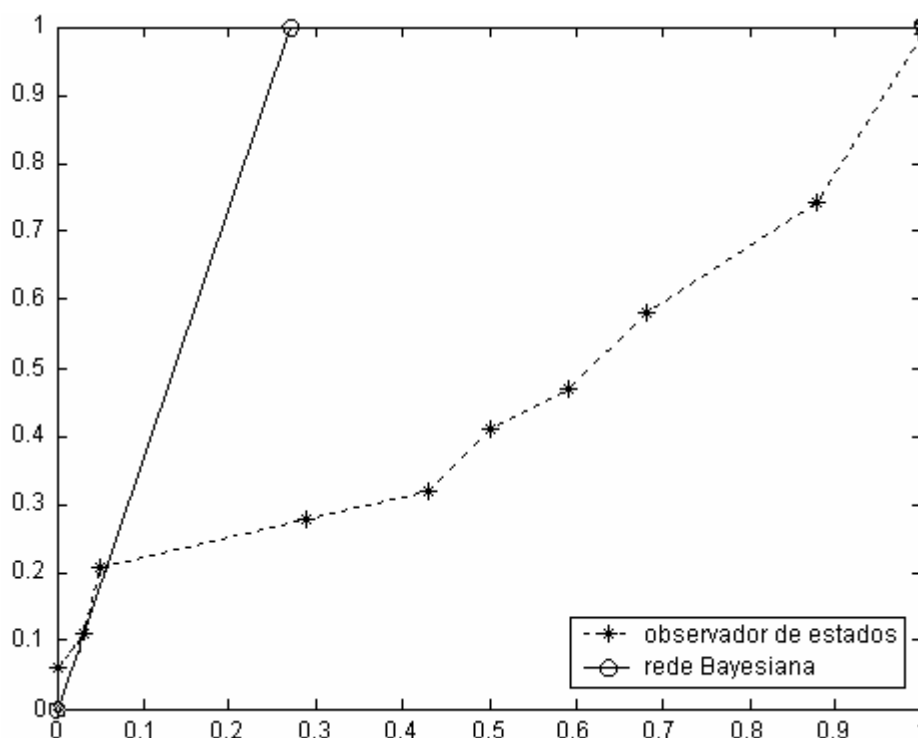


FIGURA 5.20 – Curvas ROC para falha de -10° na saída.

A tabela 5.2 apresenta os valores de AUC para os dois métodos e as quatro falhas simuladas.

TABELA 5.2 – AUCs para detecção de falhas do sistema não-linear.

Falha	1	2	3	4	Média
Observador	0,45	0,54	0,37	0,45	0,45
Rede Bayesiana	0,70	0,83	0,65	0,87	0,76

Apesar dos resultados obtidos com o método proposto não terem sido tão expressivos quanto nos exemplos anteriores, ele se mostra bastante superior à redundância analítica. Deve-se considerar também que o método está utilizando um modelo linear identificado por métodos numéricos para estimar os estados de um sistema não-linear. O uso de estimadores de estado não-lineares poderia melhorar muito o desempenho do método proposto, mas esses testes ficam como sugestão de trabalhos futuros.

5.3 Isolamento de Falhas

Apesar de que uma falha possa ocorrer nos sensores, nos atuadores, no processo ou no controlador, uma parcela considerável da pesquisa em detecção e isolamento de falhas é dirigida apenas aos sensores (CHEN et al.; 1994); (CAPRIGLINE; LIGUORI;

PIETROSANTO, 2004), (LEE, 1994), (LUNZE; SCHRÖDER, 2004), (SIMANI; FANTUZZI; BEGHELLI, 2000). De fato, na maioria de casos, os sensores são realmente a parte do sistema mais propensa a apresentar falhas.

O método proposto inicialmente apenas para detecção de falhas foi também testado no isolamento de falhas de sensores, com uma pequena alteração.

Uma vez que uma falha tenha sido detectada pelo método proposto, a mesma rede Bayesiana é usada para isolar o sensor que apresente a falha. O conjunto dos valores medidos das entradas e saídas do sistema e seu estado no momento do alarme são usados para isolar a falha.

A probabilidade de ocorrência de cada um dos valores medidos (ou estimados) do sistema é calculada novamente, mas dessa vez os valores medidos dos sensores são ignorados um a um. Por exemplo, se um sistema tem três sensores, A, B e C, a probabilidade de ocorrência de todos os valores, exceto o valor do sensor A será calculada, como se o valor do sensor A fosse desconhecido. O mesmo deve ser feito para o sensor B e para o sensor C. A média das probabilidades calculadas ignorando-se cada sensor é então considerada como sendo a probabilidade de que a falha detectada tenha ocorrido nesse sensor.

Se existir apenas um sensor com falha no sistema, então as probabilidades de ocorrência dos valores considerando o valor medido no sensor com falha como evidência deverão ser baixas, uma vez que o valor do mesmo não estará adequado às relações probabilísticas aprendidas anteriormente pela rede Bayesiana. Por outro lado, as probabilidades calculadas, ignorando-se o valor do sensor com falha, deverão estar próximas do valor médio para o sistema operando normalmente. O valor medido do sensor com falha diminui a média da probabilidade do conjunto todo de medidas.

Intuitivamente esse princípio é muito fácil de ser entendido. Como a falha ocorre somente em um sensor, e não na dinâmica do sistema, no controle ou no atuador, o sistema continua se comportando normalmente. Todas as variáveis medidas, exceto a do sensor com falha, também continuam se comportando normalmente. Se o valor do sensor com falha for ignorado, as relações probabilísticas entre os valores das outras variáveis serão mantidas, uma vez que elas não são afetadas pela falha. Quando o valor do sensor com falha é usado no cálculo das probabilidades, esse valor não segue as relações probabilísticas aprendidas como normais e, portanto deverá causar uma diminuição da probabilidade de ocorrência de cada um dos outros valores, o que é refletido na média.

Desse modo, o valor médio das probabilidades quando o sensor defeituoso é considerado se mantém alto. Por outro lado, diminuem os valores médios das probabilidades

quando o sensor defeituoso é considerado e cada um dos outros sensores é ignorado. Assim a maior média de probabilidade corresponderá às probabilidades calculadas ignorando-se o sensor com falha.

O método proposto foi utilizado na monitoração de um exemplo artificial, com quatro estados, duas entradas e três saídas. Para comparação, um Esquema de Observadores Dedicados (*Dedicated Observer Scheme - DOS*) (PATTON; FRANK; CLARK, 1989) foi implementado para monitorar o mesmo sistema.

No DOS utiliza-se um observador para cada saída do sistema. Cada observador é implementado considerando-se que apenas uma das saídas está disponível. As estimativas dos outros sinais de saída são então comparados com as saídas dos sensores, gerando os resíduos que são então multiplicados entre si para cada observador. Desse modo o produto de resíduos de maior módulo indicará o sensor com falha.

A figura 5.21 apresenta o diagrama de um DOS para um sistema com três saídas.

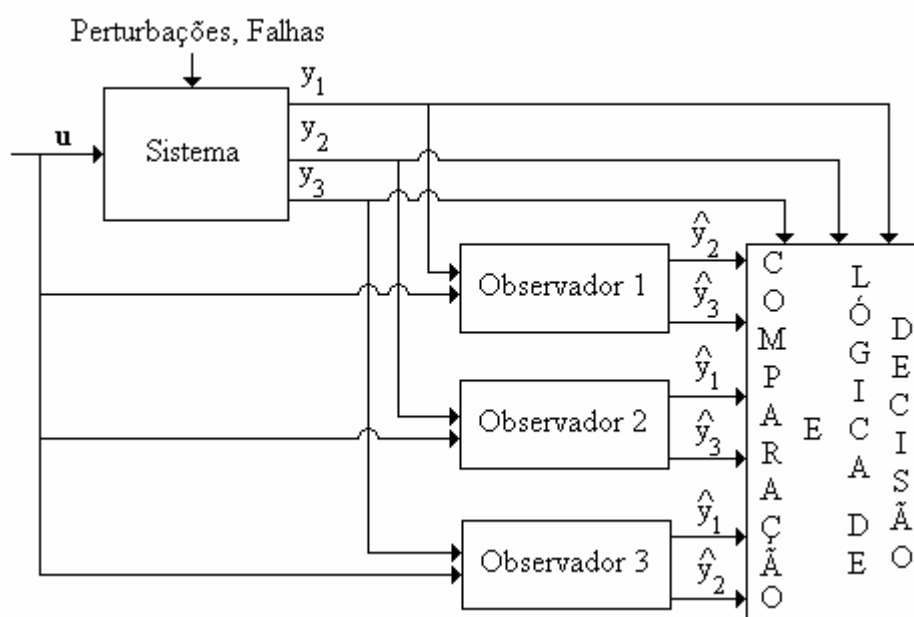


FIGURA 5.21 – Diagrama do DOS para um sistema com três saídas.

O Observador 1 utiliza apenas a saída y_1 , o Observador 2 apenas a saída y_2 e o Observador 3 apenas a saída y_3 para a estimação do estado. Quando uma falha ocorre, por exemplo, no sensor 2 os observadores 1 e 3 não são afetados pela falha. Porém para esses dois observadores o resíduo associado à saída y_2 irá aumentar. Já o observador 2 é afetado diretamente pela falha e ambos os resíduos (referentes a y_1 e y_3) irão aumentar. Por isso o

produto dos resíduos do Observador 2 sofre uma variação maior quando uma falha ocorre no sensor 2.

A dinâmica do sistema é dada pela equação 5.7, onde x é o vetor de estado 4×1 , A é a matriz da dinâmica do sistema em malha aberta, u é o vetor de entrada 2×1 , B é a matriz de distribuição de entrada, y é o vetor de saída 3×1 , e C é a matriz de distribuição da saída.

$$\begin{aligned} \dot{x} &= A.x + B.u \\ y &= C.x \end{aligned} \quad (5.7)$$

O observador para a rede Bayesiana e os observadores para o DOS foram projetados considerando-se um modelo nominal do sistema. Para caracterizar erros de modelagem, o sistema foi simulado com parâmetros com diferenças de até 20% do modelo nominal.

As matrizes de distribuição do sistema, B e C , são as mesmas para o modelo nominal e para o modelo simulado e são dadas pela equação 5.8. A matriz nominal de dinâmica do sistema An é dada pela equação 5.9 e a matriz de dinâmica do sistema simulado Ar é dada pela equação 5.10.

$$B = \begin{bmatrix} 0,8 & 0,2 \\ 0,2 & 0,8 \\ 0,5 & 0,5 \\ 0 & 1 \end{bmatrix}, C = \begin{bmatrix} 1 & 0 & 0 & 1 \\ 0 & 1 & 1 & 0 \\ 0 & 0 & 1 & 1 \end{bmatrix} \quad (5.8)$$

$$An = \begin{bmatrix} 0 & 0 & 0 & -24 \\ 1 & 0 & 0 & -50 \\ 0 & 1 & 0 & -35 \\ 0 & 0 & 1 & -10 \end{bmatrix} \quad (5.9)$$

$$Ar = \begin{bmatrix} 0 & 0 & 0 & -20 \\ 1 & 0 & 0 & -40 \\ 0 & 1 & 0 & -29 \\ 0 & 0 & 1 & -8 \end{bmatrix} \quad (5.10)$$

O modelo foi simulado com três diferentes níveis de ruído aditivo branco Gaussiano de média zero nos sensores. Os níveis de ruído baixo, médio e alto correspondiam a desvios-padrão de 0,014, 0,020 e 0,028 volts respectivamente. O ruído foi introduzido apenas nos

sensores porque a diferença de até 20% dos parâmetros nominais englobaria os efeitos de ruído de estado. O período de amostragem adotado foi de 0,1 segundo.

Falhas em cada um dos três sensores foram simuladas para cada um dos três níveis de ruído. As falhas consistem de um erro aditivo (viés) de 10% do valor de excursão de cada uma das saídas. Essas falhas simuladas são deliberadamente difíceis de serem detectadas para enfatizar a diferença de desempenho do método proposto e do DOS. Falhas de maior magnitude seriam facilmente detectadas e isoladas por ambos os métodos, o que não serviria de base para comparação.

Os sinais de entrada utilizados foram ondas quadradas de nível baixo 0 e nível alto 1 volt. A primeira entrada possuía um período de 5 segundos e a segunda entrada, um período de 10 segundos.

Para a aprendizagem da rede Bayesiana o sistema foi simulado por 500 períodos de operação. A figura 5.22 apresenta a estrutura da rede Bayesiana aprendida para o sistema simulado utilizando-se ordem canônica dos nós: entradas, estados estimados e saídas. O nós representados por círculos são medidas do sistema e os nós representados por quadrados são os estados estimados via observador de estado.




FIGURA 5.22 – Estrutura da rede Bayesiana aprendida.

O sistema foi simulado cem vezes para cada nível de ruído e para falha em cada sensor, totalizando novecentas simulações divididas em nove casos diferentes (cada caso corresponde a uma falha em um determinado sensor para um determinado nível de ruído).

As curvas ROC foram geradas considerando-se a decisão de detecção de falhas um período de operação antes (10 segundos) e um período de operação após a ocorrência da falha e com os limiares de detecção para a rede Bayesiana e para o DOS variando da taxa de falso alarme zero até a detecção de todas as falhas.

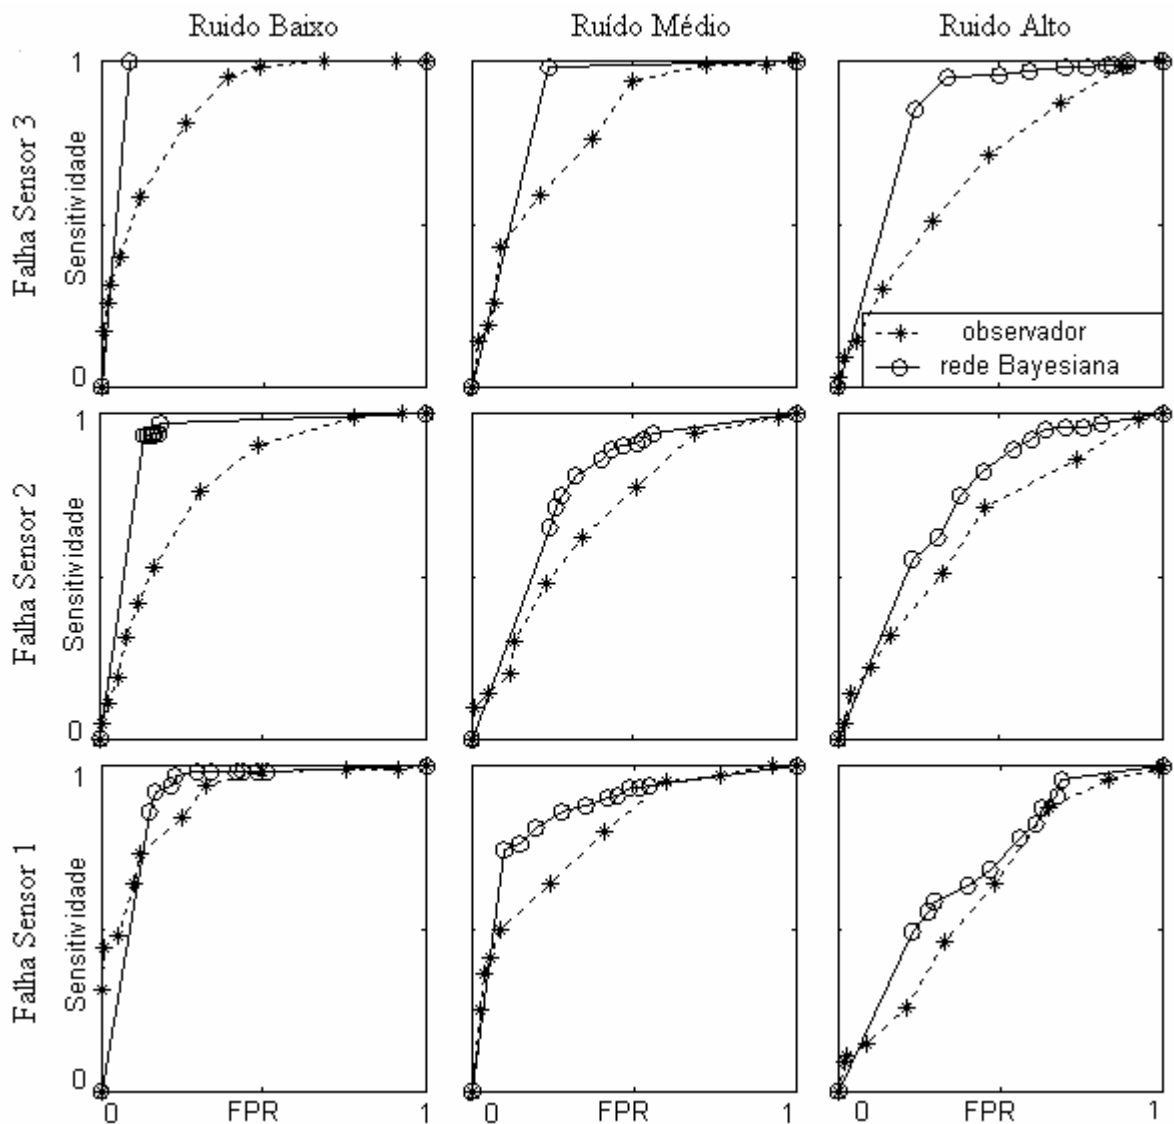


FIGURA 5.23 – Curvas ROC para o DOS e para a rede Bayesiana para os três níveis de ruído e para falhas em cada um dos três sensores.

A figura 5.23 apresenta as curvas ROC para os três níveis de ruído e para falhas em cada um dos três sensores do sistema. Na vertical, de cima para baixo: falha no sensor 1, falha

no sensor 2 e falha no sensor 3. Na horizontal, da esquerda para a direita: ruído baixo, ruído médio e ruído alto.

Nota-se que as curvas relativas à rede Bayesiana apresentam uma melhor sensibilidade para os mesmos valores de razão de falso alarme quando comparadas às curvas relativas ao DOS.

A figura 5.24 apresenta a AUC para os três níveis de ruído e para falhas em cada um dos três sensores. Os resultados estão em ordem crescente da AUC do DOS.




FIGURA 5.24 – AUC para os três níveis de ruído e falhas em cada um dos três sensores.

Exceto para um caso (nível de ruído baixo e falha no sensor 3), no qual a AUC é igual para os dois métodos, a AUC correspondente à rede Bayesiana foi sempre maior que a correspondente ao DOS, indicando que a rede Bayesiana pode apresentar resultados melhores que o DOS. A rede Bayesiana também foi capaz de detectar as falhas mais rápido que o DOS, como pode ser visto na figura 5.25.

Os valores médios obtidos com o método das redes Bayesianas e com o DOS são apresentados na tabela 5.3.

Para comparar o isolamento das falhas, apenas o melhor limiar para cada método e para cada caso foi considerado. Melhor limiar esse que corresponde ao ponto da curva ROC situado mais próximo do ponto de FPR 0 e Sensitividade 1. As razões de correta detecção, falso alarme e correto isolamento são apresentadas na tabela 5.4, onde a razão de correto isolamento indica a percentagem das falhas corretamente detectadas e identificadas considerando-se o número total de falhas. Desse modo, na média, para 100 falhas simuladas, a

abordagem usando redes Bayesianas foi capaz de detectar 59 falhas e 40 dessas 59 falhas foram isoladas corretamente.

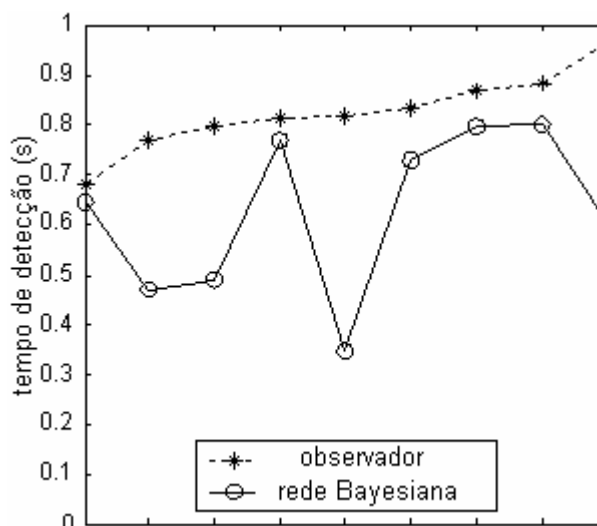


FIGURA 5.25 – Tempo de detecção médio para os três níveis de ruído e para falhas nos três sensores.

TABELA 5.3 – Valores médios de AUC e tempo de detecção para as redes Bayesianas e o DOS.

	AUC	Tempo de Detecção
DOS	0,75	0,57 s
Rede Bayesiana	0,84	0,84 s

TABELA 5.4 – Razões de detecção de falhas, falso alarme e isolamento.

	Detecção de Falhas	Falsos Alarmes	Correto Isolamento
DOS	38 %	27 %	21 %
Rede Bayesiana	59 %	21 %	40%

Com o uso de um limiar fixo para os dois métodos, ambos apresentaram uma razão de falso alarme similar, com uma razão levemente melhor para as redes Bayesianas. O DOS obteve uma razão de detecção de 40% e um correto isolamento de apenas 21%. A rede Bayesiana foi capaz de detectar cerca de 60% das falhas e o correto isolamento de 40% foi quase o dobro do apresentado pelo DOS. O correto isolamento da rede Bayesiana foi até superior à detecção do DOS.

Os resultados gerais para a detecção e isolamento de falhas, mesmo para a rede Bayesiana, não foram expressivos porque as falhas simuladas foram intencionalmente difíceis de serem detectadas. Mas, como intencionado, essas falhas de difícil detecção evidenciaram a diferença de desempenho entre os métodos utilizados. Simulações adicionais mostraram que

para falhas de maior magnitude ambos os métodos apresentam resultados gerais expressivos, mas a diferença de desempenho entre os dois métodos não pode ser observada claramente.

Mais uma vez a aprendizagem das relações probabilísticas se mostra mais eficiente que a redundância analítica, mas nesse caso específico uma possível explicação, além da incorporação dos efeitos dos erros de modelagem na rede Bayesiana aprendida, é que a inferência Bayesiana é não-linear, desse modo, as relações probabilísticas aprendidas e armazenadas na rede Bayesiana podem representar muito mais fielmente o processo em questão do que o observador de estados linear.

Uma possível melhoria no método proposto seria a utilização de uma rede Bayesiana na detecção das falhas e de redes Bayesianas específicas no isolamento das falhas detectadas. Além da rede Bayesiana aprendida para a detecção de falhas, seriam aprendidas outras redes Bayesianas, cada uma delas ignorando-se a existência de um dos sensores. Quando uma falha fosse detectada, as redes específicas seriam utilizadas no isolamento, usando o mesmo princípio proposto nesse trabalho. A rede específica que apresentasse o valor médio de probabilidade mais alto seria a rede onde o valor medido pelo sensor defeituoso foi desconsiderado. A implementação e o teste dessa proposta ficam como sugestão de trabalhos futuros.

6 Conclusão

6.1 Conclusões Gerais

Neste trabalho foi proposto um método de detecção de falhas baseado na aprendizagem de redes Bayesianas a partir de medidas do sistema operando normalmente.

Do ponto de vista qualitativo, o método proposto apresenta as seguintes vantagens:

1. É de fácil compreensão em alto nível, por realizar inferências de forma similar à análise de um especialista humano.
2. Não necessita de equipamento adicional para ser implementado.
3. Não requer um modelo acurado do sistema podendo assim ser utilizado em sistemas que sejam difíceis de serem modelados corretamente.
4. Não precisa de informações sobre as possíveis falhas do sistema ou sobre as falhas passadas do mesmo.

Para fins de validação foram considerados três estudos simulados de detecção de falhas, envolvendo um servomecanismo de velocidade, o movimento longitudinal de uma aeronave e um manipulador robótico. Os resultados do método proposto, analisados em termos de curvas ROC e tempos de detecção, mostraram-se sensivelmente melhores que os obtidos mediante análise de resíduo de um observador de Luenberger, que é uma técnica de redundância analítica bastante conhecida e usada como base de comparação em vários trabalhos.

Por fim, um estudo adicional revelou a viabilidade do uso de redes Bayesianas aprendidas a partir de medidas do funcionamento normal do sistema no isolamento de falhas.

Os resultados obtidos na detecção de falhas em sistemas lineares, já substancialmente melhores que a análise de resíduos, podem ainda ser melhorados com o uso, por exemplo, de técnicas de discretização de dados mais elaboradas, como a proposta por Matsuura (2003). É também possível que melhorias possam ser obtidas com o uso de técnicas de aprendizagem Bayesianas mais novas.

Os resultados na detecção de falhas em sistemas não-lineares podem ser melhorados com o uso de técnicas de identificação mais elaboradas e de modelos e estimadores não-lineares. O isolamento de falhas pode ser melhorado com o uso de redes Bayesianas específicas para cada sensor.

À medida que as redes Bayesianas são usadas no monitoramento dos sistemas, mais dados podem ser coletados e redes Bayesianas novas podem ser aprendidas com os dados

adicionais, melhorando ainda mais seu desempenho. Essas redes podem ser continuamente atualizadas, o que tornaria o modelo probabilístico aprendido cada vez mais rico em informações.

Se alguma informação sobre as relações de dependência das variáveis estiver disponível, esta pode ainda ser utilizada no auxílio à aprendizagem da rede Bayesiana. E se um modelo acurado do sistema estiver disponível para o projeto do observador ou do estimador de estado, o desempenho do método também será melhor.

A limitação da aplicação do método proposto é o esforço computacional necessário para o cálculo das probabilidades de ocorrência dos conjuntos de medidas, efetuado via inferência Bayesiana, durante a supervisão. Desse modo, para que o método possa ser aplicado a sistemas com constantes de tempo da ordem de centésimos ou milésimos de segundos, seria necessária uma otimização do código utilizado na inferência Bayesiana e possivelmente o uso de mais de um processador para essa tarefa.

Cabe ressaltar que estes são apenas os estudos iniciais do método proposto, implementado de maneira simples e que o mesmo pode ainda ser aprimorado e modificado de forma a melhorar os resultados.

6.2 Contribuições do trabalho

São contribuições originais deste trabalho:

- A proposição de um novo método para detecção de falhas em sistemas dinâmicos (Capítulo 3);
- Uma comparação qualitativa do método proposto com outros métodos de detecção de falhas (Capítulo 3);
- Proposição da utilização das curvas ROC e da AUC na comparação de métodos de detecção de falha que utilizem um valor de limiar para decidir sobre a presença ou não de falhas (Capítulo 4);
- Comparação entre os resultados obtidos pelo uso do método de detecção de falhas proposto e de um método de redundância analítica (Capítulo 4);
- Estudos adicionais da aplicação do método de detecção de falhas em sistemas não-lineares e no isolamento de falhas (Capítulo 5).

6.3 Trabalhos Futuros

Ficam como sugestões de trabalhos futuros as seguintes possibilidades:

- Uma comparação quantitativa mais extensa do método proposto com outros métodos de detecção de falhas em sistemas dinâmicos, como os métodos que utilizam a transformada wavelet, por exemplo;
- Teste de métodos de discretização mais elaborados como, por exemplo, a discretização via tabela de probabilidades proposta por Matsuura (2003) na discretização dos dados e estudo de seu efeito no desempenho da detecção de falhas das redes Bayesianas aprendidas;
- Testes de outros métodos de aprendizagem de redes Bayesianas e estudo de seu efeito no desempenho da detecção de falhas das redes aprendidas;
- Estudo mais aprofundado da detecção de falhas com agrupamento via *k-Means* e redes de Kohonen, incluindo a escolha da quantidade de agrupamentos e das dimensões da rede de Kohonen;
- Utilização de modelos e estimadores não-lineares para detecção de falhas em sistemas não-lineares;
- Utilização de redes Bayesianas específicas para o isolamento de falhas em sensores de sistemas com múltiplas saídas;
- Aplicação de softwares e de algoritmos de inferência Bayesiana mais eficientes;
- Otimização da utilização de bibliotecas que realizem a inferência Bayesiana;
- Aplicação do método proposto em um sistema real;

Tanto a área de detecção de falhas em sistemas dinâmicos quanto a área de aplicação de redes Bayesianas vem crescendo muito, principalmente com os avanços tecnológicos e as possibilidade de implementação de algoritmos mais complexos. As sugestões de trabalhos apresentadas são uma pequena fração das possíveis extensões desse trabalho e indicam apenas algumas direções que podem ser seguidas na obtenção de métodos de detecção de falhas cada vez melhores.

Referências Bibliográficas

ANGELI, C.; CHATZINIKOLAU, A. On-line fault detection techniques for technical systems: a survey. **International Journal of Computer Science & Applications**, v. 1, n. 1, p. 12-30, 2004.

ARAVENA, J. L.; CHOWDHURY, F. N. Fault detection of flight critical systems. In: DIGITAL AVIONICS SYSTEMS CONFERENCE, 20., 2004, Estados Unidos. **Proceedings...** Estados Unidos, 2001.

BACCARINI, L. M. R.; MENEZES, B. R.; CAMINHAS, W. M. . Utilização de redes neurais para diagnóstico de falhas mecânicas em motores de indução trifásicos. In: CONGRESSO BRASILEIRO DE REDES NEURAS, 6., 2003, São Paulo. **Anais...** São Paulo, 2003, v. 1, p. 151-156.

BASSEVILLE, M.; NIKIFOROV, I.V. **Detection of abrupt changes: theory and applications**. [S. l.]: Prentice-Hall, 1993.

BISWAS, G. et al. Diagnosis of complex systems: bridging the methodologies of the FDI and DX communities. **IEEE Trans. on Systems, Man and Cybernetics, Part B**, v. 34, n. 5, p. 2159-2162, out., 2004.

BRYSON JR., A. E. **Control of spacecraft and aircraft**. New Jersey: Princeton University Press, 1993.

CAMINHAS, W. M. et al. Detecção e identificação de falhas de instrumentação num sistema de tanques interativos usando rede neurofuzzy. In: CONGRESSO BRASILEIRO DE REDES NEURAS, 3., 1997. **Anais...** Florianópolis, 1997, p. 201-206.

CAMINHAS, W. M.; TAKAHASHI, R. H. C. Dynamic system failure detection and diagnosis employing sliding mode observers and fuzzy neural networks. In: JOINT IFSA WORLD CONGRESS, 9., AND NAFIPS INTERNATIONAL CONFERENCE, 20., 2001, Vancouver - Canada. **Proceedings...** Vancouver, 2001, v. 1, p. 304-309.

CAMINHAS, W. M.; TAVARES, H. M. F.; GOMIDE, F. A. C. A neurofuzzy approach for fault diagnosis in dynamic systems. In: IEEE INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, 1996, USA. **Proceedings...** USA: IEEE, 2006, v.1, p. 2032-2037.

CAMINHAS, W. M.; TAVARES, H. M. F.; GOMIDE, F. A. C. Detecção de falhas em sistemas dinâmicos: abordagem baseada em redes neurofuzzy com aprendizado on-line. In: CONGRESSO BRASILEIRO DE REDES NEURAS, 5., 2001, Rio de Janeiro. **Anais...** Rio de Janeiro, 2001, v. 1, p. 613-618.

CAPRIGLIONE, D.; LIGUORI, C.; PIETROSANTO, A. Analytical redundancy for sensor fault isolation and accommodation in public transportation vehicles. **IEEE Transactions on Instrumentation and Measurement**, v. 53, n. 4, p. 993-999, 2004.

CASTILLO, E.; GUTIERREZ, J. M.; HADI, A. S. **Expert systems and probabilistic network models**. New York: Springer Verlag, 1997.

CERQUIDES, J.; MANTARAS, R. L. Proposal and empirical comparison of a parallelizable distance-based discretization method. In: INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 3., 1997. **Proceedings...** [S.l.n.], 1997. p. 139-142.

CHAN, P. P. F. **An expert system for diagnosis of problems in reinforced concrete structures**. 2006. Dissertação (Master in Computer Science) - Royal Melbourne Institute of Technology, Melbourne.

CHEN, J.; PATTON, R. J. **Robust model-based fault diagnosis for dynamic systems**. Norwell, MA: Kluwer Academic Publishers, 1999.

CHEN, J.; PATTON, R. J.; LIU, G. P. Detecting incipient faults in flight control systems. In: IEEE CONFERENCE ON CONTROL APPLICATIONS, 3., 1994. **Proceedings...** IEEE, 1994, p. 871-876.

CHENG, J.; BELLI, D. A.; LIU, W. Learning belief networks from data: an information theory based approach. In: ACM INTERNATIONAL CONFERENCE ON INFORMATION AND KNOWLEDGE MANAGEMENT, 1997. **Proceedings...** [S.l.n.], 1997.

CHIEN, C. F.; CHEN, S. L.; LIN, Y. S. Using Bayesian network for fault location on distribution feeder. **IEEE Transactions on Power Delivery**, v. 17, n. 13, p. 785-793, 2002.

CHOUDREY, R. A. **Variational methods for Bayesian independent component analysis**. 2002. Tese (Doutorado of Department of Engineering Science) - University of Oxford, Oxford.

COELHO, A. S. G. **Abordagem Bayesiana na análise genética de populações utilizando dados de marcadores moleculares**. 2002. Tese (Doutorado em Agronomia) – USP. Escola Superior de Agricultura, Piracicaba.

COFRE, P.; CIPRIANO, A. Comparative analysis of statistical inference methods for fault detection and diagnosis using nonlinear models applied to the hydraulic benchmark system. In: SIMPOSIO ARGENTINO DE INTELIGENCIA ARTIFICIAL (ASAI), 5., 2003. **Anais...** [S.l.n.], 2003. CD-ROM.

COOPER, G. F.; HERSKOVITZ, E. A Bayesian method for the induction of probabilistic networks from data. **Machine Learning**, n. 9, p. 309-347, 1992.

DING, S. X. et al. Advanced model-based diagnosis of sensor faults in vehicle dynamics control systems. In: IFAC WORLD CONGRESS, 16., 2005, Prague. **Proceedings...** Prague, 2005, p. 1-8. CD-ROM.

DOSHI, P. J. **Effective methods for building probabilistic models from large noisy data sets**. 2001. Dissertação (Mestrado em Ciências da Computação) - Drexel University, Philadelphia.

DOUGHERTY, J.; KOHAVI, R.; SAHAMI, M. Supervised and unsupervised discretization of continuous features. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 12., 1995, San Mateo, CA. **Proceedings...** San Mateo, CA: Morgan Kaufmann, 1995, p.194-202.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**, New York: Wiley, 2001.

FARAGGI, D.; REISER, B. Estimation of the area under the ROC curve. **Statistics in Medicine**, n. 21, p. 3093-3106. 2002.

FENTON, W. G.; MCGINNITY, T. M.; MAGUIRE, L. P. Fault diagnosis of electronic systems using intelligent techniques: a review, **IEEE Transactions on Systems, Man and Cybernetics – Part C**, v. 31, n. 3, p. 269-281, 2001

FORTUNA, L. et al. An innovative intelligent system for fault detection in Tokamak machines. In: INTERNATIONAL CONFERENCE ON ACCELERATORS AND LARGE EXPERIMENTAL PHYSICS CONTROL SYSTEMS (ICALEPCS), 1999, Trieste, Itália. 1999. **Proceedings...** Trieste, 1999.

FREITAS, A. E. S.; CERQUEIRA, J. J. F.; FERREIRA, N. R. Detecção de falhas em motores de indução por meio de mapas de Kohonen. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI), 7., 2005, São Luis. **Anais...** São Luis, 2005, p. 1-8. CD-ROM.

FRIEDMAN, N.; KOLLER, D. Being Bayesian about network structure: a Bayesian approach to structure discovery in Bayesian networks. **Machine Learning**, v. 50, n. 1-2, p.95–125, 2003.

FRIEDMAN, N.; GOLDSZMIDT, M. Discretizing continuous attributes while learning Bayesian networks. In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING (ICML), 13., 1996. **Proceedings...** [S.l.n.], 1996, p. 157-165.

FRISK, E. **Model-based fault diagnosis applied to a SI-engine**. 1993. Dissertação (Mestrado em Vehicular Systems) – Linkoping University.

FURTADO, R. M. F. et al. Fault identification in rotor system using model based methods, experimental data and artificial neural network. In: CONGRESSO INTERNACIONAL DE ENGENHARIA MECÂNICA (COBEM), 2005, Ouro Preto. **Anais...** Ouro Preto, 2005, p. 1-8. CD-ROM.

GENTIL, S.; MONTMAIN, J.; COMBASTEL, C. Combining FDI and AI approaches within causal-model-based diagnosis. **IEEE Transaction on Systems, Man and Cybernetics - Part B**, v. 34, n. 5, p. 2207–2221, out. 2004.

GERTLER, J. J. **Fault detection and diagnosis in engineering systems**. New York: Marcel Dekker, 1998.

GULEZ, K.; KARLIK, B.; VAKKAS, S. Designing artificial neural networks for fault detection in induction motors with the TMS320C30 DSP. In: EUROPEAN DSP EDUCATION AND RESEARCH CONFERENCE (ESIEE), 1., 1996, Paris. **Proceedings...** Paris, 1996.

GUSTAFSSON, F.; HAGENBLAD, A.; KLEIN, I. A comparison of two methods for stochastic fault detection: the parity space approach and principal component analysis. In IFAC SYMPOSIUM ON SYSTEM IDENTIFICATION (SYSID), 13., 2003 Rotterdam, Holanda. **Proceedings...** Rotterdam, 2003.

HOOD, C. S.; CHUANYI J. I. Proactive network fault detection. In: ANNUAL JOINT CONFERENCE OF THE IEEE COMPUTER AND COMMUNICATIONS SOCIETIES (INFOCOM '97), 16., 1997. **Proceedings...** [S.l.n.], 1997, v. 3, p. 1147 – 1155.

HUSH, D. R. et al. Neural networks in fault detection: a case study. In: AMERICAN CONTROL CONFERENCE, 1997, Albuquerque, Estados Unidos. **Proceedings...** Albuquerque, 1997.

JAKUBEK, S.; STRASSER, T. Neural networks applied to automatic fault detection, In: IEEE MIDWEST SYMPOSIUM ON CIRCUITS AND SYSTEMS CONFERENCE (MWSCAS), 45., 2002, Tulsa, Oklahoma. **Proceedings...** Tulsa, 2002 p. I-639-I-642.

JIANGBO, W. J. Z.; LILING, M. A robust fault detection and isolation method via sliding mode observer, In: WORLD CONGRESS ON INTELLIGENT CONTROL AND AUTOMATION, 5., 2004. **Proceedings...** [S.l.n.], jun. 2004, v. 2, p. 1727-1730.

KADIE, C. M.; HOVEL, D.; HORVITZ, E. **MSBNx: a component-centric toolkit for modeling and inference with bayesian networks**. Redmond: Microsoft, 2001. (Microsoft Research Technical Report 2001-67).

KOEHLER, C.; NASSAR, S. M. Modelagem de redes Bayesianas a partir de bases de dados médicas. In: JORNADAS ARGENTINAS DE INFORMÁTICA E INVESTIGACIÓN OPERATIVA, 31., 2002. **Proceedings...** [S.l.n.], 2002, p.164-176.

KOHAVI, R.; SAHAMI, M. Error-based and entropy-based discretization of continuous features. In: INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING (KDD), 2., 1996, Portland. **Proceedings...** Portland: AAAI Press, 1996. p. 114-119.

KWEE, I. W. **Towards a Bayesian framework for optical tomography**. 1999. Tese (Doutorado of Department of Medical Physics and Bioengineering) - University College London, Londres.

LAMPERTU, G; ZANELLA, M. A bridged diagnostic method for the monitoring of polymorphic discrete-event systems. **IEEE Transactions on Systems, Man and Cybernetics, Part B**, v. 34, n. 5, p. 2222–2244, out. 2004.

LARRAÑAGA, P. et al. Learning Bayesian network structures by searching for the best ordering with genetic algorithms. **IEEE Transactions on Systems, Man, and Cybernetics – PART A: Systems and Humans**, v. 26, n.4, p. 487-493, jul., 1996.

LEE, S. C. Sensor value validation based on systematic exploration of the sensor redundancy for fault diagnosis KBS. **IEEE Transactions on Systems, Man and Cybernetics**, v. 24, n. 4, p. 594-605, 1994

LERNER, U. et al. Bayesian fault detection and diagnosis in dynamic systems. In. NATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENTE (AAAI), 17., 2000, Austin. **Proceedings...** Austin, 2000. p. 531-537.

LIU, H. et al. Discretization: an enabling technique. **Journal of Data Mining and Knowledge Discovery**, n. 6, p. 393-423, 2002.

LUDL, M.; WIDMER, G. Relative unsupervised discretization for regression problems. In: EUROPEAN CONFERENCE ON MACHINE LEARNING (ECML), 11., 2000, Barcelona. **Proceedings...** Barcelona: [s.n.], 2000.

LUNZE, J.; SCHRÖDER, J. Sensor and actuator fault diagnosis of systems with discrete inputs and outputs. **IEEE Transactions on Systems, Man and Cybernetics - Part B**, v. 34, p. 1096–1107, 2004.

MATSUURA, J. P. **Discretização para aprendizagem Bayesiana: aplicação no auxílio à validação de dados em proteção ao voo.** 2003. Dissertação (Mestrado em Engenharia Eletrônica e Computação) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

MATSUURA, J. P.; GALVÃO, R. K. H.; YONEYAMA, T. Sensor fault detection and isolation with a learning Bayesian network approach.. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI), 7., 2005, São Luis. **Anais...** São Luis, 2005a, p. 1-7. CD-ROM.

MATSUURA, J. P.; GALVÃO, R. K. H.; YONEYAMA, T. Detecção de falhas em manipuladores robôs com aprendizagem de redes Bayesianas. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI), 7., 2005, São Luis. **Anais...** São Luis, 2005b, p. 1-7. CD-ROM.

MATSUURA, J. P.; GALVÃO, R. K. H.; YONEYAMA, T. Learning Bayesian networks for fault detection: application to the 747 longitudinal motion. In: CONGRESSO INTERNACIONAL DE ENGENHARIA MECÂNICA (COBEM), 2005, Ouro Preto. **Anais...** Ouro Preto, 2005c, p. 1-6. CD-ROM.

MATSUURA, J. P.; YONEYAMA, T. Learning Bayesian networks for fault detection. In: IEEE WORKSHOP ON MACHINE LEARNING FOR SIGNAL PROCESSING, 2004, São Luís. **Proceedings...** São Luís: IEEE, 2004a. p. 133-142.

MATSUURA, J. P.; YONEYAMA, T. Redes Bayesianas e aprendizagem aplicadas à detecção de falhas em sistemas dinâmicos. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA (CBA) 2004, Gramado. **Anais...** Gramado, 2004b. p. 1-6, CD-ROM.

MEHRANBOD, N. **A probabilistic approach for sensor fault detection and identification.** 2002. Tese (Doutorado) – Drexel University.

MOK, H. T.; CHAN, C. W. Online fault diagnosis of nonlinear systems based on neurofuzzy networks. In: IFAC WORLD CONGRESS, 16., 2005, Prague. **Proceedings...** Prague, 2005. CD-ROM.

MURPHY, K. The Bayes net toolbox for Matlab. **Computing Science and Statistics**, v. 33, 2001.

NASCIMENTO JR., C. L.; YONEYAMA, T. **Inteligência artificial em controle e automação.** São Paulo: Edgard Blücher, 2000.

OLIVA, A. P. Sensor fault detection and analytical redundancy satellite launcher flight control system. **Controle & Automação**, v.9, n.3, p.156-164, 1998.

PAIVA, H. M. **Detecção de Falhas em Sistemas Dinâmicos Empregando Transformadas Wavelet Adaptativas**. 2003. Dissertação (Mestrado em Engenharia Eletrônica e Computação) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

PARK, S. H.; GOO, J. M.; JO, C. H. Receiver operating characteristic (ROC) curve: practical review for radiologists. **Korean Journal of Radiology**, n. 5, p. 11-18, 2004.

PATTON, R. J. Fault detection and diagnosis in aerospace systems using analytical redundancy. **IEE Computing and Control Engineering Journal**, v.2, n.3, p.127-136, 1991.

PATTON R. J.; CHEN, J. A robustness study of model-based fault detection for jet engine systems. In: IEEE CONFERENCE ON CONTROL APPLICATION, 1., 1992, Dayton, Ohio. **Proceedings...** Dayton, 1992. v. 2, p.871-876.

PATTON, R.; FRANK, P.; CLARK, R. N. (Eds.). **Fault diagnosis in dynamic systems – theory and application**. New York: Prentice Hall, 1989.

PATTON, R.; FRANK, P.; CLARK, R. N. **Issues in fault diagnosis for dynamic systems**. London: Springer, 2000.

PEARL, J. **Probabilistic reasoning in intelligent systems: networks of plausible inference**. San Mateo, CA: Morgan Kaufmann, 1988.

PENG, H.; DING, C. Structure search and stability enhancement of Bayesian networks. In: IEEE INTERNATIONAL CONFERENCE ON DATA MINING (ICDM'03), 3., 2003. **Proceedings...** IEEE Computer Society, 2003.

PERSIN, S. et al. Increasing process safety using analytical redundancy. **Electrotechnical Review**, v. 69, n. 3-4, p.240-246, 2002.

POLYCARPOU, M. M.; HELMICKI, A. J. Automated fault detection and accommodation: a learning systems approach. **IEEE Transactions on Systems, Man and Cybernetics**, v. 25, n. 11, p. 1447-1458, 1995.

REIS, L. A. **SANEP – sistema especialista probabilístico de apoio a nutrição enteral pediátrica**. 2001. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal de Santa Catarina, Florianópolis.

RIASCOS, L. A. M.; SIMÕES, M. G.; MIYAGI, P. E. Fault identification in fuel cells based on Bayesian network diagnosis. In: CONGRESSO INTERNACIONAL DE ENGENHARIA MECÂNICA (COBEM), 2005, Ouro Preto. **Anais...** Ouro Preto, 2005, p. 1-8. CD-ROM.

RINNER, B.; WEISS, U. Online monitoring by dynamically refining imprecise models. **IEEE Transactions on Systems, Man and Cybernetics - Part B**, v. 34, n. 5, p. 1811–1822, ago. 2004.

SAHAMI, M. et al. A Bayesian approach to filtering junk e-mail. In: WORKSHOP ON LEARNING FOR TEXT CATEGORIZATION, 1998, Madison. **Proceedings...** Madison: AIAA, 1998.

SANTOSO, N. I. et al. Nuclear plant fault diagnosis using probabilistic reasoning. In: IEEE POWER ENGINEERING SOCIETY SUMMER MEETING, 1999, Canada. **Proceedings...** Canada: IEEE, 1999. p. 714-719.

SHI, R.; MACGREGOR, J. F. A framework for subspace identification methods. In: AMERICAN CONTROL CONFERENCE, 2001, Arlington. **Proceedings...** Arlington, 2001. p. 2678-2683.

SILVESTRE, A. M. **Raciocínio probabilístico aplicado ao diagnóstico de insuficiência cardíaca congestiva (ICC)**. 2003. Dissertação (Mestrado em Ciência da Computação) - Universidade Federal do Rio Grande do Sul, Porto Alegre.

SIMANI, S.; FANTUZZI, C.; BEGHELLI, S. Diagnosis techniques for sensor faults of industrial processes. **IEEE Transactions on Control Systems Technology**, v. 8, n. 5, p. 848-855, 2000.

SORSA, T.; KOIVO, H. N.; KOIVISTO, H. Neural networks in process fault diagnosis. **IEEE Transactions on Systems, Man and Cybernetics**, v. 21, n. 4, p. 815-825, 1991.

SOUZA, J. A. M. F.; GALVÃO, R. K. H.; YONEYAMA, T. A novel Wavelet-based scheme for fault detection. In: UKACC CONTROL, 2000, Cambridge. **Proceedings...** Cambridge, 2000. CD-ROM.

SZÁSZI, I.; KULCSÁR, B. Robust control and fault detection filter design for aircraft pitch axis. **Periodica Polytechnica Transportation Engineering**, v.29, n. 1-2, p.83-100, 2001.

TILBURY, J. B. et al. Receiver operating characteristic analysis for intelligent medical systems – a new approach for finding confidence intervals. **IEEE Transactions on Biomedical Engineering**, v. 47, n. 7, p. 952-963, 2000.

VALLDEPERAS, E. M. **Sistema bayesiano para modelado del alumno**. 2000. Tese (Doutorado do Departamento de Lenguages y Ciencias de la Computación) - Universidad de Málaga, Málaga.

VAN OVERSCHEE, P.; DE MOOR, B. N4SID: subspace algorithms for the identification of combined deterministic-stochastic system. **Automatica**, v. 30, n. 1, p. 75-93, 1994.

VEGAS, F. J. D. **Sistema experto Bayesiano para ecocardiografía**. 1994. Tese (Doutorado em Ciências Físicas) - Facultad de Ciencias de la Universidad Nacional de Educacion a Distancia, Madrid.

VEMURI, A. T.; POLYCARPOU, M. M.; CIRIC, A. R. Fault diagnosis of differential-algebraic systems. **IEEE Transactions on Systems, Man and Cybernetics, Part A**, v. 31, n. 2, p. 143-152, 2001.

VENKATASUBRAMANIAN, V. et al. A review of process fault detection and diagnosis part I: quantitative model-based methods. **Computers and Chemical Engineering**, v. 27, p.293-311, 2003a

VENKATASUBRAMANIAN, V. et al. A review of process fault detection and diagnosis part II: quantitative models and search strategies. **Computers and Chemical Engineering**, v. 27, p.313-326, 2003.b

VENKATASUBRAMANIAN, V. et al. A review of process fault detection and diagnosis part III: process history based methods. **Computers and Chemical Engineering**, v. 27, p.327-346, 2003c.

VENTURA, D.; MARTINEZ T. R. An empirical comparison of discretization methods. In: INTERNATIONAL SYMPOSIUM ON COMPUTER AND INFORMATION SCIENCES, 1995. **Proceedings...** [S.l.n.], 1995. p. 443-450.

VIBERG, M. Subspace-based methods for the identification of linear time-invariant system. **Automatica**, v. 31, n. 12, p. 1835-1851, 1995.

WANG, H.; ZANIOLO, C. CMP: a fast decision tree classifier using multivariate predictions. In: INTERNATIONAL CONFERENCE ON DATA ENGINEERING (ICDE'2000), 16., 2000, San Diego. **Proceedings...** San Diego: ICDE, 2000. p.449-460.

WILSON, E.; LAGES, C.; MAH, R. Gyro-based maximum-likelihood thruster fault detection and identification. In: AMERICAN CONTROL CONFERENCE, 2002, Anchorage. **Proceedings...** Anchorage, 2002. p.4525-4530.

YAIRI, T.; KATO, Y.; HORI, K. Fault detection by mining association rules from house-keeping data. In: INTERNATIONAL SYMPOSIUM ON ARTIFICIAL INTELLIGENCE, ROBOTICS AND AUTOMATION IN SPACE, 2001, Montreal. **Proceedings...** Canadá, 2001.

YANG, Y. **Discretization for naïve-Bayes learning**. 2003. Tese (Doutorado em Ciências da Computação) - School of Computer Science and Software Engineering of Monash University, Melbourne.

ZHANG, X.; PARISINI, T.; POLYCARPOU, M. M. Adaptive fault-tolerant control of nonlinear uncertain systems: an information-based diagnostic approach. **IEEE Transactions on Automatic Control**, v. 49 , n. 8, p.1259 – 1274, ago., 2004.

ZHANG, H. Q.; YAN, Y. A Wavelet-based approach to abrupt fault detection and diagnosis of sensors. **IEEE Transactions on Instrumentation and Measurement**, v. 50, n. 5, p. 1389-1396, 2001.

ZHAO, Q.; XU, Z. Design of a novel knowledge-based fault detection and isolation scheme. **IEEE Transactions on Systems, Man and Cybernetics, Part B**, v. 34, n. 2, p. 1089–1095, abr., 2004.

FOLHA DE REGISTRO DO DOCUMENTO

1. CLASSIFICAÇÃO/TIPO TD	2. DATA 09 de Março de 2006	3. DOCUMENTO N° CTA/ITA-IEE/TD-001/2006	4. N° DE PÁGINAS 122
5. TÍTULO E SUBTÍTULO: Detecção de falhas em sistemas dinâmicos com redes Bayesianas aprendidas a partir de estimação de estados			
6. AUTOR(ES): Jackson Paul Matsuura			
7. INSTITUIÇÃO(ÕES)/ÓRGÃO(S) INTERNO(S)/DIVISÃO(ÕES): Instituto Tecnológico de Aeronáutica. Divisão de Engenharia Eletrônica – ITA/IEE			
8. PALAVRAS-CHAVE SUGERIDAS PELO AUTOR: Detecção de Falhas, Redes Bayesianas, Aprendizagem Bayesiana.			
9. PALAVRAS-CHAVE RESULTANTES DE INDEXAÇÃO: Diagnóstico de falhas; Sistemas dinâmicos; Teorema de Bayes; Estimação de sistemas; Matemática aplicada; Engenharia eletrônica.			
10. APRESENTAÇÃO: ITA, São José dos Campos, 2006 122 páginas.			
		X Nacional	Internacional
11. RESUMO: A pronta detecção da ocorrência de falhas em sistemas dinâmicos é essencial na prevenção de condições de operação perigosas e mesmo de avaria física do sistema, o que colocaria em risco recursos valiosos, equipamento vital e vidas humanas. Os métodos convencionais de detecção de falhas, porém, esbarram em limitações de espaço físico, existência de um modelo matemático acurado do sistema e existência de dados sobre o comportando do sistema operando com falhas, entre outros. Nesse trabalho é proposto e avaliado um novo método de Detecção de Falhas em Sistemas Dinâmicos que apresenta vantagens tanto qualitativas quanto quantitativas sobre os métodos já reportados na literatura. O método proposto é fácil de ser entendido em alto nível, tem grande semelhança com a supervisão humana, não necessita de equipamento adicional, não necessita de um modelo acurado do sistema e não precisa de informação nenhuma sobre falhas anteriores no sistema; podendo ser aplicado a sistemas onde os outros métodos dificilmente apresentariam resultados satisfatórios. Nele uma rede Bayesiana é aprendida a partir de medidas do sistema operando normalmente sem falhas e essa rede é então usada na detecção de falhas, inferindo que desvios do comportamento probabilístico aprendido como normal são causados por falhas no sistema. Os resultados obtidos com o novo método, extremamente animadores, são comparados aos obtidos com a utilização de um método baseado em redundância analítica, mostrando-se bastante superior ao mesmo. Resultados adicionais obtidos no isolamento de falhas e na detecção de falhas de um sistema não-linear corroboram os excelentes resultados obtidos, apontando para um grande potencial de uso do método proposto.			
12. GRAU DE SIGILO: (X) OSTENSIVO () RESERVADO () CONFIDENCIAL () SECRETO			