

Uma Nova Formulação *Fuzzy/Bayesiana* para Detecção
de Ponto de Mudança em Séries Temporais:
Aplicações na Detecção de Falhas Incipientes

Tese de Doutorado submetida à banca examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais, como parte dos requisitos exigidos para a obtenção do título de Doutor em Engenharia Elétrica.

por

Marcos Flávio Silveira Vasconcelos D'Angelo

Engenheiro Eletricista (PUC-MG)

Mestre em Engenharia Elétrica (PUC-MG)

Orientador: Prof. Dr. Reinaldo Martinez Palhares

Co-orientador: Prof. Dr. Ricardo Hiroshi Caldeira Takahashi

Fevereiro – 2010

Universidade Federal de Minas Gerais
Programa de Pós-Graduação em Engenharia Elétrica
Centro de Pesquisa e Desenvolvimento em Engenharia Elétrica

Uma Nova Formulação *Fuzzy/Bayesiana* para Detecção de Ponto de Mudança em Séries Temporais: Aplicações na Detecção de Falhas Incipientes

Autor: Marcos Flávio Silveira Vasconcelos D'Angelo

Orientador: Prof. Dr. Reinaldo Martinez Palhares

Co-orientador: Prof. Dr. Ricardo Hiroshi Caldeira Takahashi

Tese de Doutorado submetida à banca examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais, como parte dos requisitos exigidos para a obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: **Engenharia de Computação e Telecomunicações**.

Banca Examinadora

Reinaldo Martinez Palhares, Dr. - Orientador UFMG
Ricardo Hiroshi Caldeira Takahashi, Dr. - Co-orientador UFMG
Amit Bhaya, Dr. UFRJ
Roberto Kawakami Harrop Galvão, Dr. ITA
Rosângela Helena Loschi, Dra. UFMG
Walmir Matos Caminhas, Dr. UFMG

Belo Horizonte, MG

Fevereiro/2010

"Uma Nova Formulação Fuzzy/Bayesiana para Detecção de Ponto de Mudança em Séries Temporais: Aplicações na Detecção de Falhas Incipientes"

Marcos Flavio Silveira Vasconcelos D'Angelo

Tese de Doutorado submetida à banca examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais, como parte dos requisitos necessários à obtenção do grau de *Doutor em Engenharia Elétrica*.

Aprovada em 26 de Fevereiro de 2010.

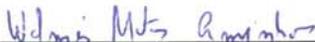
Por:



Reinaldo Martinez Palhares - Dr.
Prof. DELT/UFMG - Orientador



Ricardo Hiroshi C. Takahashi - Dr.
Prof. DMAT/UFMG - Co-Orientador



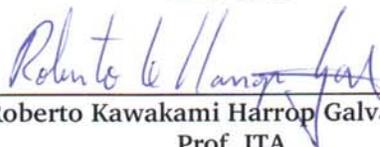
Walmir Matos Caminhas - Dr.
Prof. DEE/UFMG



Rosangela Helena Loschi - Dra.
Profa. EST/UFMG



Amit Bhaya - Dr.
Prof. UFRJ



Roberto Kawakami Harrop Galvão - Dr.
Prof. ITA

Resumo

Este trabalho apresenta uma nova abordagem para detecção de falhas incipientes em sistemas dinâmicos baseada em uma técnica *Fuzzy/Bayesiana* para detecção de ponto de mudança em séries temporais. A técnica de detecção de ponto de mudança proposta é baseada em uma formulação de duas etapas. Na primeira etapa, a teoria dos conjuntos *fuzzy* é aplicada na série temporal com o objetivo de aglomerar e transformar os dados iniciais, com distribuição arbitrária, em dados que podem ser aproximados por uma distribuição *beta*. A segunda etapa consiste em usar simulação de Monte Carlo via cadeias de Markov (o algoritmo de Metropolis-Hastings) para detectar ponto de mudança na série temporal transformada. No presente trabalho, falhas incipientes serão caracterizadas por mudanças gradativas na série temporal. Características especiais da metodologia proposta para detecção de falhas incipientes são a não necessidade de modelo matemático explícito e especificação de limiares. Com o objetivo de ilustrar a eficiência da metodologia proposta, serão apresentados alguns resultados de detecção de falhas incipientes em um atuador industrial usado como *benchmark* de FDI no european RTN DAMADICS e no enrolamento estatórico de máquinas de indução.

Palavras-chave: Detecção de falhas incipientes, conjuntos *fuzzy*, algoritmo Metropolis-Hastings.

Abstract

This work presents a novel approach for incipient fault detection in dynamical systems which is based on a Fuzzy/Bayesian technique for change point detection in time series. The proposed change point detection technique is based on a two step formulation. In the first step, a result from the fuzzy set theory is applied to the time series in order to cluster and transform the initial data, with arbitrary distribution, into new data that can be approximated with a beta distribution. The second step consists in using a Markov chain Monte Carlo (the Metropolis-Hastings algorithm) to the change point detection in the transformed time series. In this work, the incipient faults are characterized by small changes in the time series. As special features of the proposed methodology for incipient fault detection, it does not require any mathematical model of dynamic system, any threshold specification. To illustrate the efficiency of the proposed methodology, some results in the problem of detection of incipient faults in an industrial actuator of the FDI benchmark in the European RTN DAMADICS and in the stator winding of induction motors are presented.

Keywords: Incipient fault detection, fuzzy set, Metropolis-Hastings algorithm.

Agradecimentos

Agradeço à FAPEMIG e ao CNPq pelo apoio financeiro, aos Professores Reinaldo e Ricardo pela orientação, aos colegas do LABICOMP E GOPAC, aos Professores do CPDEE, em especial ao Walmir, Benjamin e Carlos Andrey e à Professora Rosangela do Departamento de Estatística.

Sumário

Lista de Figuras	vi
Lista de Tabelas	ix
Definições, Notações e Acrônimos	x
1 Introdução	1
1.1 Caracterização do Problema	1
1.2 Objetivos	5
1.2.1 Objetivos Gerais	5
1.2.2 Objetivos Específicos	5
1.3 Metodologia	6
1.4 Organização do Trabalho	7
1.5 Trabalhos Publicados e Submetidos pelo Autor	8
1.5.1 Trabalhos em Periódicos	8
1.5.2 Trabalhos em Anais de Congressos	8
2 Revisão de Literatura	9
2.1 Modelo do Sistema de Acionamento para o Motor C.C. Usado como Benchmark	10
2.1.1 Modelo do Benchmark do Motor C.C.	11
2.1.2 Modelo da Carga Mecânica	13
2.1.3 Modelo dos Conversores Estáticos	14
2.1.4 Modelagem das Falhas para o Sistema de Acionamento C.C.	14
2.1.5 Modelo Geral das Falhas no Sistema de Acionamento C.C.	17
2.1.6 Resultados de Simulações do Sistema de Acionamento C.C.	18
2.2 Metodologias para Detecção de Falhas	19
2.2.1 Observador de Luenberger	20
2.2.2 Filtro de Kalman	32
2.2.3 Redes Neurais Artificiais	36
2.2.4 Redes <i>Neuro-fuzzy</i>	38
2.2.5 Árvore de Falhas	39

2.2.6	Sistemas Especialistas Baseados em Lógica <i>Fuzzy</i>	41
2.2.7	Análise Qualitativa de Tendência (QTA)	43
3	Evolução Metodológica	51
3.1	Quantização da Série Temporal	52
3.2	Modelo de Identificação de Ponto de Mudança	55
4	Aplicação no DAMADICS	70
4.1	Resultados de Simulação para detecção de falhas incipientes no DAMADICS	73
5	Aplicação em Motores de Indução	80
5.1	Modelagem e Simulação do Motor de Indução com Curto-circuito entre Espiras no Enrolamento Estatórico	81
5.2	Implementação e Resultados da Metodologia Proposta	83
5.2.1	Resultados de Simulação	85
5.2.2	Resultados Práticos	86
6	Discussão Final	102
6.1	Trabalhos Futuros	103
A	Lista de Distribuições	105
A.1	Distribuição Uniforme	105
A.2	Distribuição Normal	106
A.3	Distribuição Gama	106
A.4	Distribuição Beta	106
A.5	Distribuição t de Student	107
	Referências bibliográficas	108

Lista de Figuras

2.1	Representação do sistema de acionamento C.C.	10
2.2	Diagrama de blocos do sistema de acionamento C.C.	11
2.3	Representação do sistema de acionamento C.C. para falhas nos atuadores.	15
2.4	Representação do sistema de acionamento C.C. para os diversos tipos de falhas.	19
2.5	Classificação de métodos de FDI de corrente de armadura, corrente de campo e velocidade para falha do tipo desconexão do conversor de campo.	3
1.3	Esquema geral para detecção de falhas através de modelos quantitativos.	20
2.6	Diagrama de blocos da metodologia proposta.	7
2.7	Esquema geral de um sistema de FDI utilizando observadores.	21
2.8	Resíduos gerados pelo observador de Luenberger.	23
2.9	Resíduos gerados pelo observador com rejeição de distúrbio na direção da corrente de campo e da velocidade para a falha de abertura da armadura.	24
2.10	Resíduos gerados pelo observador com rejeição de distúrbio na direção da corrente de armadura para a falha de abertura da armadura.	32
2.11	Esquema geral de um sistema de FDI utilizando filtro de Kalman.	33
2.12	Resíduos gerados pelo filtro de Kalman para a falha de abertura da armadura.	34
2.13	Esquema geral de um sistema de FDI utilizando Redes Neurais Artificiais.	36
2.14	Rede neural do tipo <i>feedforward</i> multicamadas.	37
2.15	Rede de Kohonen.	38
2.16	Resíduos gerados pela Rede Neural Artificial para a falha de abertura da armadura.	39
2.17	Esquema geral de um sistema de FDI utilizando <i>ANFIS</i>	40
2.18	Rede <i>Neuro-Fuzzy</i> do tipo <i>ANFIS</i>	41
2.19	Resíduos gerados pela Rede <i>Neuro-fuzzy</i> para a falha de abertura da armadura.	42
2.20	Etapas da análise da árvore de falhas.	43
2.21	Árvore de falhas (“Sim” corresponde ao ramo esquerdo e “Não” corresponde ao ramo direito).	44
2.22	Resultado obtido com a árvore de falha para a falha de abertura da armadura.	45
2.23	Resultado obtido com o sistema de inferência <i>fuzzy</i> para a falha de abertura da armadura.	45
2.24	Metodologia proposta para detecção de falhas em sistemas dinâmicos baseada em detecção de novidades	46
2.25	Resultado do detector para a simulação da falha de abertura da armadura	49

3.1	(a) Centros da série temporal para $y(t)$ dada em (3.1); (b) Funções de pertinência, $\mu_1(t)(-)$ e $\mu_2(t)(--)$ para $y(t)$ em (3.1); (c) Centros da série temporal para $y(t)$ dada em (3.2); (d) Funções de pertinência, $\mu_1(t)(-)$ e $\mu_2(t)(--)$ para $y(t)$ em (3.2).	55
3.2	Histograma do grau de pertinência <i>fuzzy</i> $\mu_1(t)$ para $t \leq 30$	56
3.3	Histograma do grau de pertinência <i>fuzzy</i> $\mu_1(t)$ para $t > 30$	57
3.4	Histograma do grau de pertinência <i>fuzzy</i> $\mu_1(t)$ para $t \leq 100$ e $e(t) \sim U(0, 1)$	58
3.5	Histograma do grau de pertinência <i>fuzzy</i> $\mu_1(t)$ para $t > 100$ e $e(t) \sim U(0, 1)$	59
3.6	Histograma do grau de pertinência <i>fuzzy</i> $\mu_1(t)$ para $t \leq 100$ e $e(t) \sim N(0, 1)$	60
3.7	Histograma do grau de pertinência <i>fuzzy</i> $\mu_1(t)$ para $t > 100$ e $e(t) \sim N(0, 1)$	61
3.8	Histograma do grau de pertinência <i>fuzzy</i> $\mu_1(t)$ para $t \leq 100$ e $e(t) \sim t(5)$	62
3.9	Histograma do grau de pertinência <i>fuzzy</i> $\mu_1(t)$ para $t > 100$ e $e(t) \sim t(5)$	63
3.10	Convergência do algoritmo para os parâmetros a, b, c, d e m	64
3.11	Resultado da metodologia proposta para $p_1 = 1, p_2 = 2, e(t) \sim U(0, 1)$, e $m = 30$	66
3.12	Resultado da metodologia para uma série temporal com mudança gradativa.	67
3.13	Esquema geral de um sistema de FDI associando observadores e o algoritmo proposto para detecção de pontos de mudança.	68
3.14	Resultado do detector para a simulação da falha de abertura da armadura.	69
4.1	European RTN DAMADICS.	71
4.2	Zonas do <i>benchmark</i>	74
4.3	(a) Sinal de vazão, F . (b) Posição da válvula, X . (c) Soma de F e X	77
4.4	Cada sub-figura ilustra a série temporal $X + F$ na parte superior com a janela de tempo considerada indicada pela linha grossa, e na parte inferior o resultado obtido.	78
4.5	(a) Variáveis de saída $X + F$. (b) Saída da Rede Neural. (c) Sinal de resíduo e o limiar igual a 0.2.	79
5.1	Representação dos enrolamentos	82
5.2	Corrente da fase a	84
5.3	Corrente da fase b	85
5.4	Corrente da fase c	86
5.5	Corrente da fase a (rms).	87
5.6	Corrente da fase b (rms).	88
5.7	Corrente da fase c (rms).	89
5.8	Diagrama de blocos da metodologia proposta.	90
5.9	Corrente da fase a (rms): i_{as} com 0.1% de espiras curto-circuitadas na fase a	91
5.10	Detecção de mudança na corrente i_{as}	91
5.11	Corrente da fase b (rms): i_{bs} com 0.1% de espiras curto-circuitadas na fase a	92
5.12	Detecção de mudança na corrente i_{bs}	92
5.13	Corrente da fase c (rms): i_{cs} com 0.1% de espiras curto-circuitadas na fase a	93
5.14	Detecção de mudança na corrente i_{cs}	93
5.15	Bancada experimental.	94

5.16	Diagrama de conexão do enrolamento estatórico.	94
5.17	Terminais do estator.	95
5.18	Corrente da fase a : i_{as} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b	95
5.19	Corrente da fase b : i_{bs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b	96
5.20	Corrente da fase c : i_{cs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b	96
5.21	Corrente da fase a (rms): i_{as} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b	97
5.22	Corrente da fase b (rms): i_{bs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b	97
5.23	Corrente da fase c (rms): i_{cs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b	98
5.24	a - i_{as} em operação normal; b - i_{as} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b ; c - Detecção de mudança na corrente i_{as} para operação normal; d - Detecção de mudança na corrente i_{as} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b	99
5.25	a - i_{bs} em operação normal; b - i_{bs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b ; c - Detecção de mudança na corrente i_{bs} para operação normal; d - Detecção de mudança na corrente i_{bs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b	100
5.26	a - i_{cs} em operação normal; b - i_{cs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b ; c - Detecção de mudança na corrente i_{cs} para operação normal; d - Detecção de mudança na corrente i_{cs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b	101
6.1	(a) Série temporal gerada sem nenhum ponto de mudança; (b) Resultado da metodologia proposta.	104

Lista de Tabelas

2.1	Resumo das Falhas no sistema de acionamento C.C.	18
3.1	Resultado da metodologia proposta.	65
4.1	Tipos de Falhas do <i>Benchmark</i> de FDI	72
4.2	Comportamento das Falhas (Δ_{t_3} : 15 minutos; Δ_{t_2} : 1 hora; Δ_{t_1} : 1 dia).	73
4.3	Detecção de falhas incipientes no DAMADICS usando o algoritmo proposto.	75

Definições, Notações e Acrônimos

Definições

Aqui serão colocadas algumas definições, no contexto de detecção de falhas, adotadas no decorrer deste trabalho (Isermann and Balle, 1997).

1. Estados e Sinais

- (a) **Falha:** desvio não permitido de pelo menos uma propriedade característica ou parâmetro do sistema a partir da condição aceitável/usual/padrão.
- (b) **Falta:** interrupção permanente de uma habilidade do sistema de executar uma função requerida sob condição de operação especificada.
- (c) **Mau funcionamento:** irregularidade intermitente do sistema em realizar a função desejada.
- (d) **Erro:** desvio entre um valor medido ou calculado (de uma variável de saída) e o valor verdadeiro/especificado/teoricamente correto.
- (e) **Distúrbio:** entrada desconhecida (e descontrolada) agindo no sistema.
- (f) **Perturbação:** entrada que age no sistema e resulta em uma modificação temporária do estado atual.
- (g) **Resíduo:** indicador de falhas, baseado no desvio entre medidas e modelo baseado em equações.
- (h) **Sintoma:** mudança de uma quantidade observável do comportamento normal.

2. Funções

- (a) **Detecção de falha:** determinação da presença de falhas em um sistema em um dado instante de tempo.

- (b) **Isolação de falha:** determinação do tipo, da localização e do tempo da detecção de uma falha. Feita após a detecção de falha.
- (c) **Identificação da falha:** determinação do tamanho e do comportamento no tempo de uma falha. Feita após a isolação de falha.
- (d) **Diagnóstico de falha:** determinação do tipo, do tamanho, da localização e do tempo de uma falha. Feita após a detecção de falha. Inclui a isolação e a identificação de falha.
- (e) **Monitoramento:** uma tarefa contínua em tempo real para determinar as condições de um sistema físico através da aquisição de dados que são utilizados para reconhecer e indicar falhas do comportamento do sistema.
- (f) **Supervisão:** monitoramento de um sistema físico para executar ações apropriadas com intuito de manter a sua operação mesmo na presença de falhas.
- (g) **Proteção:** extinção de um comportamento perigoso de um sistema físico.

3. Modelos

- (a) **Modelo Quantitativo:** Uso de relações estáticas e dinâmicas entre variáveis e parâmetros do sistema a fim de descrever o comportamento dos sistemas em termos matemáticos.
- (b) **Modelo Qualitativo:** Uso de relações estáticas e dinâmicas entre variáveis e parâmetros do sistema a fim de descrever o comportamento dos sistemas em termos qualitativos, tais como relações causa-efeito através de regras se-então, lógica *fuzzy*, etc..
- (c) **Modelo de Diagnóstico:** Um conjunto de relações estáticas ou dinâmicas que ligam variáveis específicas da entrada (sintomas) às variáveis específicas de saída (falhas).

4. Propriedades do Sistema

- (a) **Confiabilidade:** Habilidade de um sistema de executar uma função requerida sob condições indicadas, dentro de um dado espaço em um dado período de tempo.
- (b) **Segurança:** Habilidade de um sistema de não causar perigo para pessoas, equipamentos ou ambiente.

Notações

R	-	Conjunto dos números reais
R_+	-	Conjunto dos números reais positivos
R^n	-	Conjunto dos vetores reais de n componentes
$R^{n \times m}$	-	Conjunto das matrizes reais de dimensão $n \times m$
$diag\{\cdot\}$	-	denota uma matriz diagonal
$\min f(\cdot)$	-	minimize a função $f(\cdot)$
$\min(a, b)$	-	menor valor entre a e b
$\max(a, b)$	-	maior valor entre a e b

Acrônimos

FDI	-	Fault Detection and Isolation (Detecção e Isolação da Falha)
MCMC	-	Markov chain Monte Carlo (Monte Carlo via Cadeias de Markov)
CUSUM	-	Cumulative Sum (Soma Acumulada)
QTA	-	Qualitative Trend Analysis (Análise Qualitativa de Tendências)

Capítulo 1

Introdução

1.1 Caracterização do Problema

Atualmente há uma crescente demanda para uma detecção segura de falhas em sistemas dinâmicos representando processos reais, pois a detecção antecipada de falhas permite um alto grau de confiabilidade ao funcionamento dos mesmos, evitando uma eventual parada de produção, perda material, qualidade na produção e até mesmo acidentes envolvendo seres humanos. Esta demanda resultou na necessidade de sistemas de supervisão (Figura 1.1) que integram os sistemas FDI (Fault Detection and Isolation) baseados em modelos (baseados na física do processo, *fuzzy*, redes neurais, etc.) dos processos. Veja ainda que a detecção de falhas encontra forte apelo na engenharia de manutenção preventiva.

No contexto de sistemas dinâmicos, as falhas podem ser classificadas em dois grupos (Isermann and Balle, 1997):

- (a) *Falhas abruptas*: são as que resultam em grandes desvios nas condições normais de operação do processo, ou em variáveis do processo, e acontecem em um curto espaço de tempo;
- (b) *Falhas incipientes*: são as que afetam gradualmente o funcionamento normal do processo, e por isso podem levar um tempo maior para serem detectadas (foco principal deste trabalho de doutorado);

A classe de sistemas dinâmicos tratado neste trabalho é descrita por:

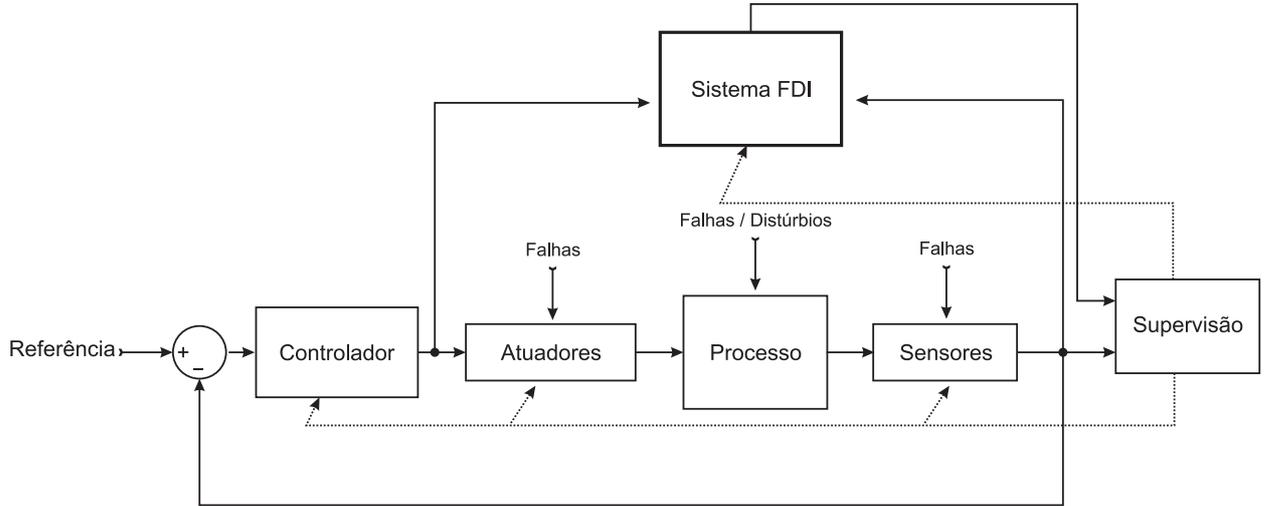


Figura 1.1: Supervisão de processos industriais com integração de sistema FDI

$$\dot{x}(t) = \xi(x(t), u(t)) + \beta(t - T)f(x(t), u(t)) \quad (1.1)$$

sendo $x \in \mathbb{R}^n$ o vetor de estados, $u \in \mathbb{R}^m$ o vetor de entradas, $\xi, f : \mathbb{R}^{n \times m} \rightarrow \mathbb{R}^n$, $T \geq 0$ o tempo de início da falha, e $\beta \in \mathbb{R}^{n \times n}$ o comportamento temporal da falha incipiente que pode ser modelado por:

$$\beta(t - T) = \text{diag}\{\beta_1(t - T), \beta_2(t - T), \dots, \beta_n(t - T)\}$$

sendo

$$\beta_i(\tau) = \begin{cases} 0, & \text{se } \tau < 0, \\ \rho_i \tau, & \text{se } 0 \leq \tau \leq T_{fi} \\ 1, & \text{se } \tau > T_{fi} \end{cases}$$

sendo T_{fi} o tempo onde a falha atinge seu valor máximo a partir do seu início e $\rho_i = \frac{1}{T_{fi}}$ uma constante que representa a taxa de desenvolvimento da falha no estado i . Para falhas incipientes este valor é bastante reduzido.

A literatura apresenta muitas classes de estratégias para tratar o problema de FDI (Chen and Patton, 1999). Estas estratégias podem ser, em geral, classificadas em abordagens baseadas em modelos quantitativos (Venkatasubramanian et al., 2003c) (Venkatasubramanian et al., 2003b) e em modelos qualitativos (Venkatasubramanian et al., 2003a) (Venkatasubramanian et al., 2003b). Esta classificação é ilustrada na Figura 1.2.

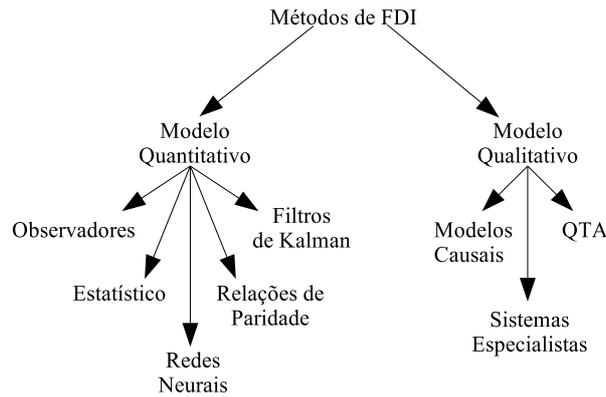


Figura 1.2: Classificação de métodos de FDI.

Durante as últimas décadas, uma importante linha metodológica para o problema de FDI é focada em aproximações analíticas, tais como observadores/filtros (Puig et al., 2006), (Douglas and Speyer, 1996), (Chen and Patton, 1999), (Hou and Patton, 1998), (Douglas and Speyer, 1996), (Takahashi et al., 1999), (Takahashi and Peres, 1999), (Jiang and Zhou, 2005) e (Dai et al., 2009), sendo que o contexto é gerar sinais que refletem a inconsistência entre a operação normal e a operação com falha no sistema, como indicado na Figura 1.3. Aplicações práticas destas técnicas podem ser encontradas em (Douglas and Speyer, 1996), (Chen and Patton, 1999), (Puig et al., 2006), e (Douglas and Speyer, 1999). Quando há necessidade de considerar a presença de retardo no tempo em problemas de detecção de falhas em sistemas dinâmicos, este pode ser aproximado por técnicas baseadas em observadores/filtros dedicados (Jiang and Zhou, 2005). Grande parte das abordagens na literatura, envolvendo estratégias baseadas em observadores, são construídas sob o contexto de observadores com entradas desconhecidas, visto que estas apresentam boas características frente a falhas abruptas e certas características de incertezas e não-linearidades que possam ser *agrupadas* na entrada desconhecida (Chen and Patton, 1999), (Takahashi and Peres, 1999), (Jiang and Zhou, 2005). No geral, *há grandes dificuldades* em se abordar o problema de detecção de falhas para sistemas que

apresentam incertezas paramétricas no modelo, tendo em vista que a geração do resíduo para a detecção de falhas não leva em conta o modelo incerto. Outras abordagens importantes no contexto de aproximações analíticas são as relações de paridade (Wilsky, 1976) (Ploix and Adrot, 2006) (onde a idéia principal é verificar a paridade (consistência) dos modelos da planta, as saídas dos sensores (medições) e as entradas conhecidas da planta (Wilsky, 1976), (Gertler, 1991), (Gertler and Singer, 1995) e (Gertler, 1997)) e técnicas de filtragem robusta baseadas em desigualdades matriciais lineares (LMI) que incluem critérios de desempenho do tipo H_∞/H_- (Casavola et al., 2008), sistemas incertos e retardo no tempo (Wang et al., 2008).

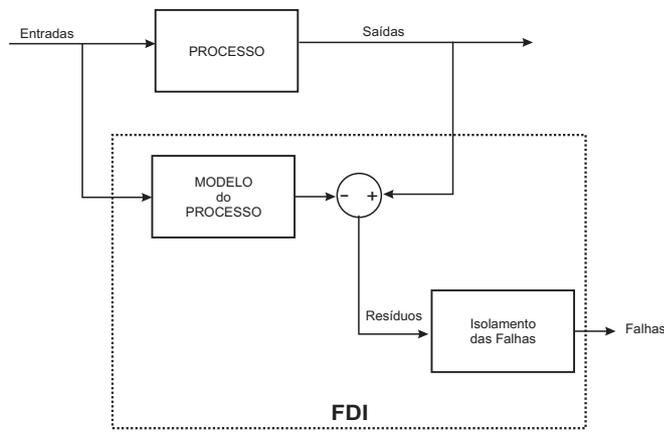


Figura 1.3: Esquema geral para detecção de falhas através de modelos quantitativos.

Aproximações relativamente novas para o problema de detecção (e diagnóstico) de falhas em sistemas dinâmicos são o uso de redes neurais e lógica *fuzzy*. Estas técnicas podem ser mais atrativas por não requererem modelos matemáticos explícitos. Nos casos onde se requerem modelos matemáticos e o sistema dinâmico é não-linear, a utilização de modelos *fuzzy Takagi-Sugeno* tem se mostrado um instrumento amigável (Calado et al., 2001). Ainda em (Calado et al., 2001) são descritos métodos para se alcançar uma boa detecção de falhas em sistemas dinâmicos, com entradas desconhecidas, através de técnicas de programação evolucionária, colocando-se ainda que técnicas baseadas em redes neurais "podem" fornecer informações sobre múltiplas falhas, possivelmente melhores que em outras técnicas. Aplicações práticas destas técnicas podem ser encontradas em (Lo et al., 2009), (D'Angelo and Costa, 2001), (Rigatos and Zhang, 2009), (Bartys et al., 2006), (Witczak et al., 2006) e (Bocaniala and da Costa, 2006). Tais técnicas podem ser usadas em modelos quantitativos (onde tais técnicas fazem o papel de um observador) ou qualitativos (onde tais técnicas fazem o papel de um classificador).

Por outro lado, alguns trabalhos têm focado no uso de estatística *Bayesiana* para tratar o problema de detecção (e diagnóstico) de falhas em vários tipos de problemas (Tang, 2000), (Berec, 1998), (Alag, 1996), (Castilloa et al., 1999), (Mast et al., 1999) e (O’Reilly, 1998). Particularmente, uma vertente importante nesta linha é o uso de redes *Bayesianas*, que são grafos orientados que codificam a dependência probabilística entre as várias variáveis como uma forma de modelar a incerteza associada com o modelo. Note que a lógica *fuzzy* (como introduzida em (Zadeh, 1965)), assim como a teoria *Bayesiana*, procuram levar em conta algum tipo de representação da incerteza – ambos, com seus fundamentos, trazem em si a sua compatibilidade com a intuição humana.

Porém, no geral, tais linhas de trabalhos lidam com falhas abruptas, mais simples de serem “capturadas” do que falhas incipientes, com evolução lenta no tempo. Considerando este problema, que ainda não parece ter um tratamento apropriado e sistemático no contexto de sistemas dinâmicos, este trabalho teve como principal contribuição a elaboração de uma abordagem que permite a detecção de falhas incipientes em sistema dinâmicos, sem a necessidade de modelo matemático, cálculo de limiares e resíduos, geração de padrões e com uma baixa taxa de alarmes falsos.

1.2 Objetivos

1.2.1 Objetivos Gerais

Um sistema FDI tem como objetivo principal o reconhecimento do comportamento anormal (falhas) dos componente de um processo, ou do próprio processo, através do monitoramento de suas variáveis. A primeira etapa de um sistema FDI é a detecção de falhas, que foi a principal motivação deste trabalho de doutorado.

O principal objetivo deste trabalho foi propor uma abordagem que considere o problema de detecção de falhas incipientes em sistemas dinâmicos. Em tais abordagens, foi investigado como a modelagem *Bayesiana* associadas à teoria dos conjuntos *fuzzy* podem ser utilizadas na detecção de falhas, esta (a detecção de falha) sendo tratada como um problema de detecção de ponto de mudança em séries temporais.

1.2.2 Objetivos Específicos

- (a) Propor a utilização de técnicas de agrupamentos *fuzzy* em séries temporais com o objetivo de obter um modelo fixo a ser usado no algoritmo Metropolis-Hastings para

detecção de ponto de mudança.

- (b) Propor a utilização de modelos *Bayesianos* para detecção de ponto de mudança em séries temporais (métodos MCMC (Markov chain Monte Carlo)) no problema de detecção de falhas incipientes. Tal técnica pode vir a ser um grande avanço no contexto de detecção de falhas, visto que não é necessário associá-la a algum tipo de modelo do sistema, que seja esse explícito ou implícito e especificação de limiares.

1.3 Metodologia

A metodologia utilizada para a detecção de falhas fará uso de uma abordagem baseada em uma formulação de duas etapas, sendo a primeira baseada na teoria dos conjuntos *fuzzy* e a segunda em uma abordagem *bayesiana* (métodos MCMC), para detecção de ponto de mudança em séries temporais, isto é, a detecção de ponto de mudança dará suporte a hipótese de ocorrência de falha.

O método proposto, diferentemente das outras técnicas, independe do modelo de série temporal que descreve originalmente o comportamento probabilístico dos dados para aplicação do método MCMC. Isto foi possível devido ao fato de que na primeira etapa da formulação, a teoria dos conjuntos *fuzzy* é aplicada na série temporal original (cuja distribuição de probabilidade não é conhecida *a priori*) a fim de agrupá-la e transformá-la em uma série temporal que pode ser aproximada por uma distribuição *beta*. Especificamente na primeira etapa, a rede de Kohonen é usada para encontrar os centros dos agrupamentos, e na sequência o grau de pertinência *fuzzy* é calculado para cada ponto da série temporal original, gerando uma série temporal com distribuição *beta*. Esta nova série temporal, gerada na primeira etapa, permite sistematizar a aplicação de métodos *MCMC* para obter a distribuição *a posteriori* do ponto de mudança, visto que sempre será usado o mesmo modelo, ou seja, séries temporais com distribuição *beta*. O algoritmo Metropolis-Hastings (Geman, 1997) foi usado para a detecção de ponto de mudança. A Figura 1.4 ilustra o diagrama de blocos da metodologia proposta nesta tese.

A associação da teoria dos conjuntos *fuzzy* com a abordagem *Bayesiana* permitiu utilizar um modelo fixo para construção das funções de probabilidades utilizadas no algoritmo Metropolis-Hastings. A obtenção de um modelo fixo a ser utilizado no algoritmo Metropolis-Hastings, através da teoria dos conjuntos *fuzzy*, sugere que uma vantagem da metodologia proposta é o fato desta não requerer nenhum conhecimento prévio sobre a estrutura dos dados, fazendo com que esta abordagem seja facilmente aplicada em situações práticas.

Além desse fato, pode-se notar que, devido o problema sempre ficar bem modelado, em situações onde ocorrem mudanças em pequenos níveis, a técnica tem um bom desempenho, fazendo que a mesma seja aplicável no problema de detecção de falhas incipientes, visto que estas afetam gradualmente o funcionamento normal do processo.

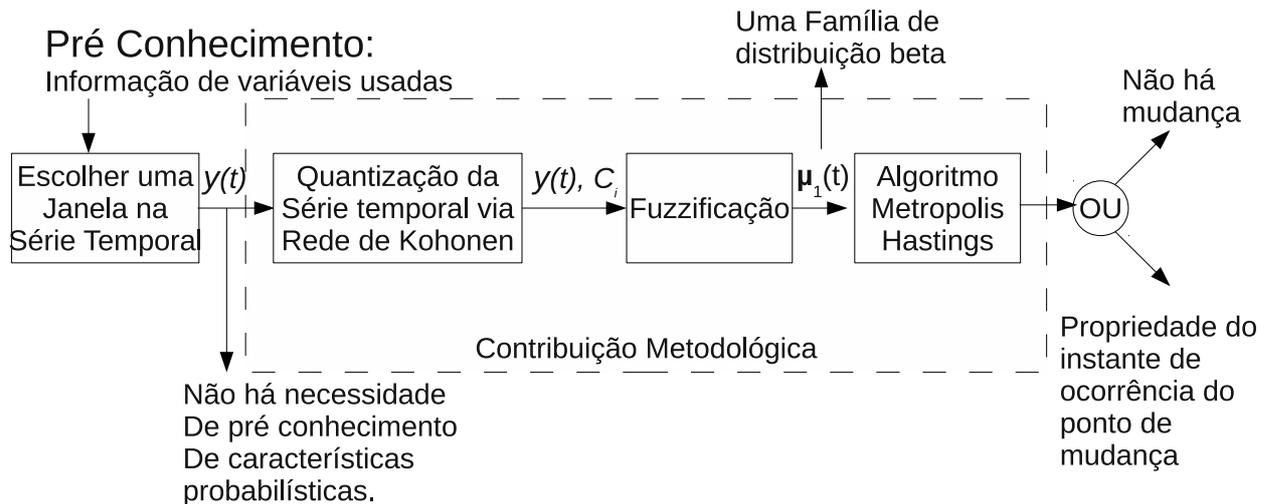


Figura 1.4: Diagrama de blocos da metodologia proposta.

1.4 Organização do Trabalho

A parte restante deste trabalho é composta por 5 capítulos. No capítulo 2 é apresentado, na opinião do autor desta tese, as principais técnicas de FDI e aplicadas a um *benchmark* proposto em (D'Angelo et al., 2009a). No Capítulo 3, o histórico evolutivo da metodologia proposta é apresentado, além de sua fundamentação teórica (D'Angelo et al., 2009c). No Capítulo 4, são apresentados resultados da metodologia proposta (D'Angelo et al., 2009b) aplicadas a um *benchmark* de FDI proposto em (Bartys et al., 2006) e no Capítulo 5, simulações e dados reais de uma máquina de indução (D'Angelo et al., 2009d), proposto em (Baccarini et al., 2004), foram utilizados para avaliar a eficiência da metodologia, e é válido ressaltar que a metodologia apresenta bons resultados frente as falhas incipientes. Finalmente, o último capítulo apresenta uma discussão geral do trabalho até o atual estágio de pesquisa e desafios futuros.

1.5 Trabalhos Publicados e Submetidos pelo Autor

1.5.1 Trabalhos em Periódicos

- (a) M.F.S.V. D'Angelo, R.M. Palhares, R.H.C. Takahashi, R.H. Loschi, L.M.R. Baccharini, W.M. Caminhas, *Incipient fault detection in induction machine stator-winding using a fuzzy-Bayesian change point detection approach*, Applied Soft Computing (2009), doi:10.1016/j.asoc.2009.11.008.
- (b) M.F.S.V. D'Angelo, R.M. Palhares, R.H.C. Takahashi, R.H. Loschi, *Fuzzy/Bayesian change point detection approach to incipient fault detection*, IET Control Theory & Applications, submetido (duas revisões já realizadas).
- (c) M.F.S.V. D'Angelo, R.M. Palhares, R.H.C. Takahashi, R.H. Loschi, *Uma abordagem fuzzy/bayesiana para o problema de detecção de ponto de mudança em séries temporais*, Pesquisa Operacional, submetido (uma revisão já realizada).

1.5.2 Trabalhos em Anais de Congressos

- (a) M.F.S.V. D'Angelo, R.M. Palhares, R.H.C. Takahashi, R.H. Loschi, *Uma Abordagem Fuzzy/Bayesiana para o Problema de Detecção de Falhas Incipientes*. In: Congresso Brasileiro de Automática, 2008, Juiz de Fora, p. 1-6.
- (b) M.F.S.V. D'Angelo, R.M. Palhares, R.H.C. Takahashi, R.H. Loschi, L.M.R. Baccharini, *Detecção de Falhas Incipientes no Estator de Máquinas de Indução através de uma Abordagem Fuzzy/Bayesiana*. In: Congresso Brasileiro de Automática, 2008, Juiz de Fora, p. 1-6.
- (c) M.F.S.V. D'Angelo, R.M. Palhares, R.H.C. Takahashi, R.H. Loschi, *Uma Abordagem Fuzzy/Bayesiana para o Problema de Detecção de Pontos de Mudança em Séries Temporais*. In: XXXIX Simpósio Brasileiro de Pesquisa Operacional, 2007, Fortaleza.
- (d) M.F.S.V. D'Angelo, R.M. Palhares, W.M. Caminhas, R.H.C. Takahashi, R. D. Maia, A. P. Lemos, M. J. Inácio, *Detecção de falhas: uma revisão com aplicações*, Tutorial a ser apresentado em minicurso no Congresso Brasileiro de Automática, 2010, Bonito, MS.

Capítulo 2

Revisão de Literatura

Este capítulo tem como finalidade revisar um amplo conjunto de métodos para detecção de falhas. Os métodos apresentados neste capítulo são:

- (a) Métodos Quantitativos:
 - i. Observador de Luenberger;
 - ii. Filtro de Kalman;
 - iii. Redes Neurais Artificiais;
 - iv. Redes *Neuro-fuzzy*.
- (b) Métodos Qualitativos
 - i. Árvore de Falha;
 - ii. Sistema Especialista baseado em Lógica *Fuzzy*;
 - iii. QTA (Análise Qualitativa de Tendências).

Com a finalidade de aplicação das técnicas que serão apresentadas neste capítulo, um modelo geral de falhas de um sistema de acionamento de um motor de corrente contínua (C.C.), proposto em (Caminhas, 1997) e disponibilizado em (Palhares, 2009) será utilizado como um *benchmark* neste capítulo. Este *benchmark* para detecção de falhas é amplo no sentido de considerar falhas em atuador, sensor e no processo. Todavia, não foi feita nenhuma análise comparativa entre as técnicas descritas, visto que a comparação não deveria levar em conta apenas a acurácia dos resultados, mas também fatores subjetivos, como, por exemplo, o tipo de falha, o comportamento temporal da falha, etc..

2.1 Modelo do Sistema de Acionamento para o Motor C.C. Usado como Benchmark

O sistema de acionamento C.C. é composto por duas fontes de alimentação, conversores estáticos controlados, uma máquina de corrente contínua e uma carga mecânica, como ilustrado na Figura 2.1. O diagrama de blocos do sistema completo, incluindo o controle, é ilustrado na Figura 2.2. O controlador de velocidade, tipo proporcional integral, fornece o valor da corrente de armadura de referência. O controle da corrente da armadura é feito através da variação da tensão de alimentação. Esta tensão é função do ângulo de disparo do conversor, fornecido pelo controlador de corrente. A malha de campo, além de proporcionar o controle da corrente, permite que o sistema de acionamento opere à velocidade acima da nominal com potência constante, via enfraquecimento de campo (Bose, 1986).

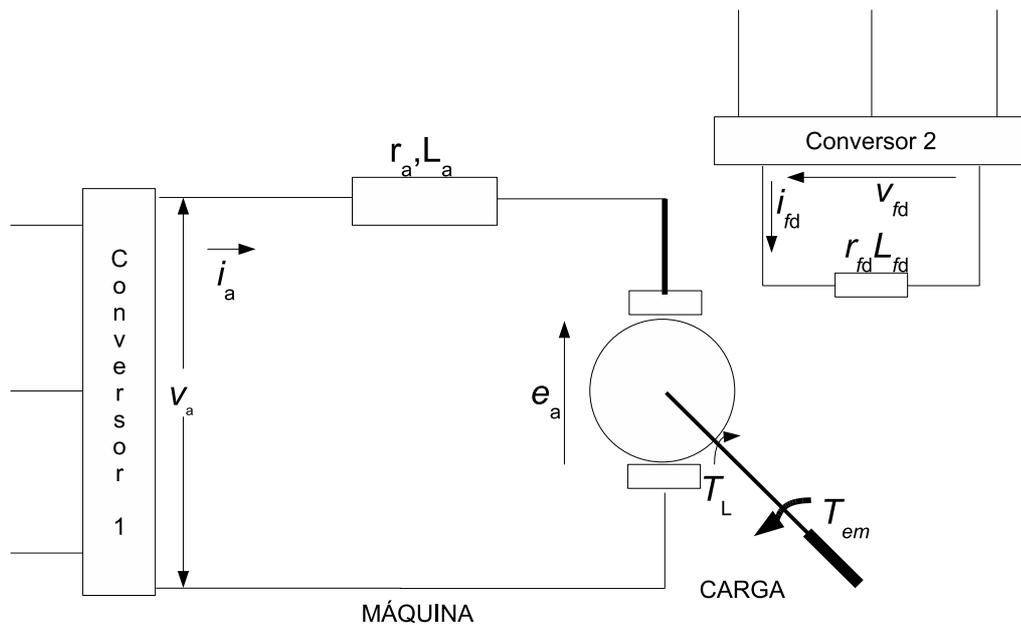


Figura 2.1: Representação do sistema de acionamento C.C.

Na Figura 2.1, v_a representa a tensão de alimentação do circuito da armadura, v_{fd} a tensão de alimentação do circuito de campo, i_a a corrente do circuito de armadura, i_{fd}

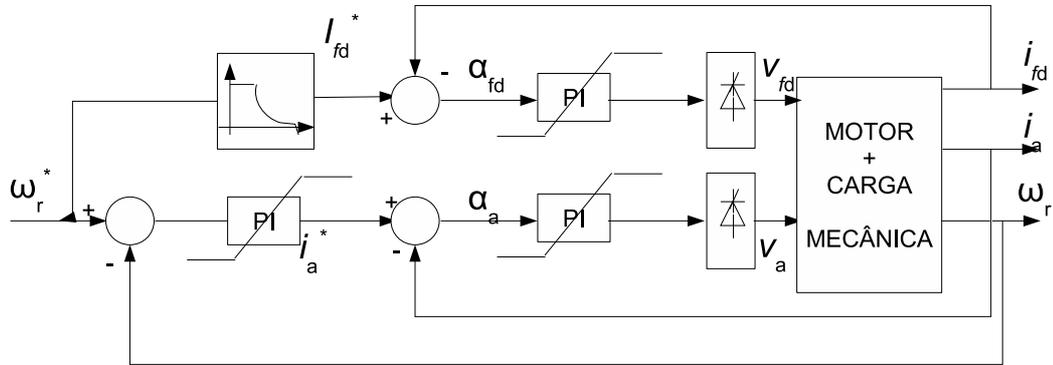


Figura 2.2: Diagrama de blocos do sistema de acionamento C.C.

a corrente do circuito de campo, e na Figura 2.2, ω_r a velocidade mecânica de rotação em rad/s , α_{fd} o ângulo de disparo do conversor do circuito de campo e α_a o ângulo de disparo do conversor do circuito de armadura. As variáveis indexadas por n são referentes a valores nominais da máquina.

A corrente de campo de referência é calculada da seguinte forma:

$$i_{fd}^* = \begin{cases} i_{fd}^n, & \text{para } \omega_r^* \leq \omega_r^n, \\ i_{fd}^n \frac{\omega_r^n}{\omega_r^*}, & \text{para } \omega_r^* > \omega_r^n \end{cases} \quad (2.1)$$

2.1.1 Modelo do Benchmark do Motor C.C.

A máquina de corrente contínua possui o campo (excitação) independente da armadura, como mostrado na Figura 2.1. Considerando as correntes i_a e i_{fd} e a velocidade ω_r como variáveis de estado, o modelo dinâmico para a máquina funcionando como motor é dado pela equação 2.2.

$$\begin{cases} \frac{di_a}{dt} = \frac{1}{L_a}(v_a - r_a i_a - e_a) \\ \frac{di_{fd}}{dt} = \frac{1}{L_{fd}}(v_{fd} - r_{fd} i_{fd}) \\ \frac{d\omega_r}{dt} = \frac{1}{J_m}(T_{em} - B_m \omega_r - T_L) \end{cases} \quad (2.2)$$

sendo r_a a resistência do circuito da armadura, r_{fd} a resistência do circuito de campo, L_a a indutância do circuito da armadura, L_{fd} a indutância do circuito de campo, $T_{em} = L_{afd}i_{fd}i_a$ é o conjugado eletromagnético, T_L o conjugado mecânico exigido pela carga, B_m o coeficiente de atrito viscoso, J_m o momento de inércia do sistema motor/carga, $e_a = L_{afd}i_{fd}\omega_r$ é a força-contratromotriz da armadura, e L_{afd} a indutância mútua armadura/campo.

Definem-se as variáveis de estado $x_1 = i_a$, $x_2 = i_{fd}$ e $x_3 = \omega_r$, sendo a representação em espaço de estados do sistemas não-linear dada em (2.3).

$$\dot{x} = Ax(t) + Bu(t) \quad (2.3)$$

$$y(t) = \mathbf{I}x(t), \quad y(t) \in \mathbb{R}^3$$

sendo:

$$A = \begin{bmatrix} -\frac{r_a}{L_a} & -\frac{L_{afd}}{L_a r_{fd}} x_3(t) & 0 \\ 0 & -\frac{r_{fd}}{L_{fd}} & 0 \\ \frac{L_{afd}}{J_m} x_2(t) & 0 & -\frac{B_m}{J_m} \end{bmatrix}$$

$$B = \begin{bmatrix} \frac{1}{L_a} & 0 & 0 \\ 0 & \frac{1}{L_{fd}} & 0 \\ 0 & 0 & -1 \end{bmatrix}$$

$$u = \begin{bmatrix} v_a(t) \\ v_{fd}(t) \\ T_L \end{bmatrix}$$

Um modelo discreto para o sistema (2.3) é dado em (2.4). Para obtê-lo foi usada a mesma metodologia adotada em (Silvino et al., 1993). Todas as variáveis de estado são medidas, isto é, $y(t) = \mathbf{I}x(t)$.

$$\begin{aligned}
 \begin{bmatrix} x_1(k+1) \\ x_2(k+1) \\ x_3(k+1) \end{bmatrix} &= \begin{bmatrix} a_1 & a_2(k) & 0 \\ 0 & a_3 & 0 \\ a_4(k) & 0 & a_5 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \end{bmatrix} \\
 &+ \begin{bmatrix} b_1 & 0 & 0 \\ 0 & b_2 & 0 \\ 0 & 0 & d_1 \end{bmatrix} \begin{bmatrix} v_a(k) \\ v_{fd}(k) \\ T_L(k) \end{bmatrix}
 \end{aligned} \tag{2.4}$$

$$y(k) = \mathbf{I}x(k), \quad y(k) \in \mathbb{R}^3$$

sendo:

$$a_1 = a_1(r_a, L_a) = e^{-\frac{r_a}{L_a}h};$$

$$a_3 = a_3(r_{fd}, L_{fd}) = e^{-\frac{r_{fd}}{L_{fd}}h};$$

$$a_2(k) = a_2(r_a, L_a, r_{fd}, L_{fd}, x_3(k)) = \frac{1}{r_{fd}L_a - r_aL_{fd}} [L_{afd}L_{fd}(a_3 - a_1)x_3(k) + (r_aL_{fd}a_1 - r_{fd}L_a a_3)];$$

$$a_5 = a_5(B_m, J_m) = e^{-\frac{B_m}{J_m}h};$$

$$a_4(k) = a_4(B_m, J_m, x_2(k)) = L_{afd} \frac{(1 - a_5)}{B_m} x_2(k);$$

$$b_1 = b_1(r_a, L_a) = \frac{1 - a_1}{r_a};$$

$$b_2 = b_2(r_{fd}, L_{fd}) = \frac{1 - a_3}{r_{fd}} d_1;$$

$$d_1 = d_1(B_m, J_m) = -\frac{1 - a_5}{B_m}.$$

2.1.2 Modelo da Carga Mecânica

O modelo da carga mecânica é estabelecido pela equação de conjugado. Considerou-se uma carga genérica, cujo conjugado é dado por:

$$T_L = C_0 + C_1\omega_r + C_2\omega_r^2 \tag{2.5}$$

2.1.3 Modelo dos Conversores Estáticos

Os dois conversores, do circuito de armadura e do circuito de campo, são do tipo Ponte de Graetz a Tiristor. Adota-se o modelo estático para computar a tensão de saída em função do ângulo de disparo (Bose, 1986) como descrito em (2.6):

$$v_a = 2.34V_{oa} \cos \alpha_a \quad \text{e} \quad v_{fd} = 2.34V_{ofd} \cos \alpha_{fd} \quad (2.6)$$

2.1.4 Modelagem das Falhas para o Sistema de Acionamento C.C.

Do ponto de vista de classificação de falhas, o sistema de acionamento C.C. pode ser dividido em três grandes grupos: atuadores (conversores da armadura e do campo); planta ou processo (máquina C.C.) e sensores (medidores de corrente e velocidade).

A seguir serão discutidas como as falhas relacionadas a estes três grupos são modeladas.

Falhas em Atuadores

Os tipos de falhas que podem ocorrer nos conversores estáticos são, por exemplo, a queima de componentes nos circuitos de potência e/ou comando, todavia, no contexto de máquina C.C., as duas falhas mais graves são curto-circuito e desconexão do conversor. Estas falhas podem ser modeladas pelas chaves ideais CH_{aa} , CH_{afd} , CH_{cca} e CH_{ccfd} , como apresentado na Figura 2.3.

Associam-se os seguintes parâmetros as suas respectivas falhas, a saber:

- Desconexão do conversor de armadura, $k_{aa} \in \{0, 1\}$, sendo que a desconexão é dada por $k_{aa} = 0$.
- Desconexão do conversor do campo, $k_{afd} \in \{0, 1\}$, sendo que a desconexão é dada por $k_{afd} = 0$.
- Curto-circuito do conversor de armadura, $k_{cca} \in \{0, 1\}$, sendo que o curto-circuito é indicado por $k_{cca} = 1$.
- Curto-circuito do conversor do campo, $k_{ccfd} \in \{0, 1\}$, sendo que o curto-circuito é indicado por $k_{ccfd} = 1$.

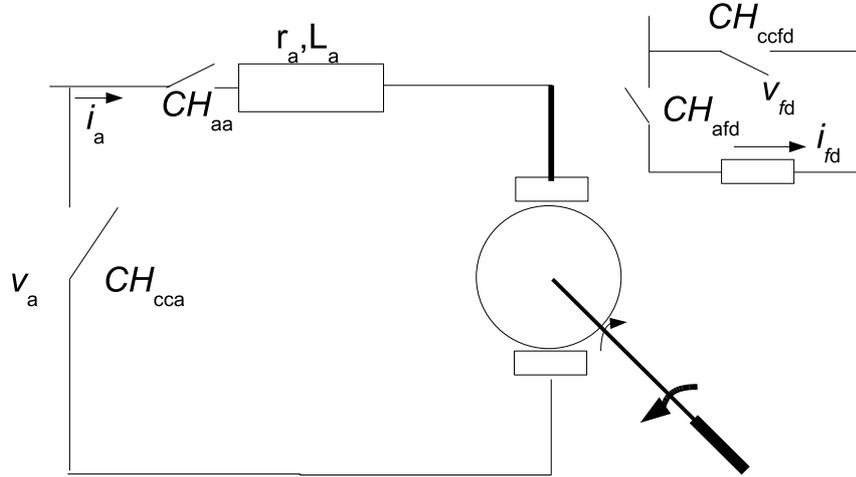


Figura 2.3: Representação do sistema de acionamento C.C. para falhas nos atuadores.

Os estados das chaves CH_i , para $i = aa, afd, cca, ccfd$, são indicados da seguinte forma: aberta se $k_i = 0$ e fechada se $k_i = 1$.

Considerando que uma falha de alimentação é caracterizada por uma corrente nula, e um curto-circuito por uma tensão nula, tem-se que o modelo para falhas no circuito de alimentação da máquina é dado em (2.7).

$$\begin{aligned}
 \begin{bmatrix} x_1(k+1) \\ x_2(k+1) \\ x_3(k+1) \end{bmatrix} &= \begin{bmatrix} k_{aa}a_1 & k_{aa}a_2(k) & 0 \\ 0 & k_{afd}a_3 & 0 \\ a_4(k) & 0 & a_5 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \end{bmatrix} \\
 &+ \begin{bmatrix} b_1 & 0 & 0 \\ 0 & b_2 & 0 \\ 0 & 0 & d_1 \end{bmatrix} \begin{bmatrix} k_{aa}\bar{k}_{cca}v_a(k) \\ K_{afd}\bar{k}_{ccfd}v_{fd}(k) \\ T_L(k) \end{bmatrix} \quad (2.7)
 \end{aligned}$$

$$\begin{bmatrix} y_1(k) \\ y_2(k) \\ y_3(k) \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \end{bmatrix}$$

sendo $\bar{k}_i = 1 - k_i$.

Falhas em Componentes da Planta

As falhas consideradas na máquina são:

- curto-circuito entre espiras no circuito de armadura;
- curto-circuito entre espiras no circuito de campo;
- falha no sistema de ventilação;
- falha de lubrificação.

As duas primeiras falhas podem ser representadas pelas variações nas resistências e indutâncias da armadura e do campo. E estas variações são modeladas pelos parâmetros a seguir:

- $k_{ca}^{r_a} \in [0, 1]$ indica a variação na resistência de armadura, r_a , quando ocorre curto-circuito entre espiras no enrolamento de armadura.
- $k_{ca}^{L_a} \in [0, 1]$ indica a variação na indutância de armadura L_a quando ocorre curto-circuito entre espiras no enrolamento de armadura.
- $k_{cf}^{r_{fd}} \in [0, 1]$ indica a variação na resistência do campo r_{fd} quando ocorre curto-circuito entre espiras no enrolamento do campo.
- $k_{cf}^{L_{fd}} \in [0, 1]$ indica a variação na indutância do campo L_{fd} quando ocorre curto-circuito entre espiras no enrolamento do campo.

A falha no sistema de ventilação se traduz em variações simultâneas da resistência de armadura e do campo, provocadas pela elevação de temperatura da máquina. Por outro lado, uma lubrificação deficiente dos mancais pode ser modelada por uma variação do coeficiente de atrito.

Os parâmetros que representam estas duas falhas são:

- Falha no sistema de ventilação é indicada por $k_{fv}^{r_a}$, variação na resistência r_a , e $k_{fv}^{r_{fd}}$, variação na resistência r_{fd} .
- Falha de lubrificação dos mancais é indicada por k_{fl} , que é variação no coeficiente de atrito B_m .

O modelo que incorpora somente as falhas em componentes da planta é apresentado em (2.4), onde no cálculo dos coeficientes a_1 , $a_2(k)$, a_3 , $a_4(k)$, b_1 , b_2 e d_1 , os parâmetros nominais são substituídos por (2.8).

$$\begin{cases} r_a^f = k_{ca}^{ra} k_{fv}^{ra} r_a \\ L_a^f = k_{ca}^{La} L_a \\ r_{fd}^f = k_{cfd}^{rfd} k_{fv}^{rfd} r_{fd} \\ L_{fd}^f = k_{cfd}^{Lfd} L_{fd} \\ B_m^f = k_{fl} B_m \end{cases} \quad (2.8)$$

Falhas de Sensores

Aqui serão consideradas falhas (desligamentos) dos sensores de corrente (armadura e campo) e de velocidade, modeladas pelos parâmetros:

- $k_{i_a}^f \in \{0, 1\}$, sendo que $\{0\}$ indica falha no sensor da corrente de armadura.
- $k_{i_{fd}}^f \in \{0, 1\}$, sendo que $\{0\}$ indica falha no sensor da corrente de campo.
- $k_{\omega_r}^f \in \{0, 1\}$, sendo que $\{0\}$ indica falha no sensor de velocidade da máquina.

Com relação ao modelo das falhas nos sensores, este difere do modelo representado pela equação 2.4 somente com relação a saída, isto é:

$$\begin{bmatrix} y_1(k) \\ y_2(k) \\ y_3(k) \end{bmatrix} = \begin{bmatrix} k_{i_a}^f & 0 & 0 \\ 0 & k_{i_{fd}}^f & 0 \\ 0 & 0 & k_{\omega_r}^f \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \end{bmatrix}$$

2.1.5 Modelo Geral das Falhas no Sistema de Acionamento C.C.

Considerando os três tipos de falhas abordados anteriormente (veja Tabela 2.1), o modelo completo é descrito em (2.9). Os coeficientes com sobrescrito f são computados substituindo os parâmetros nominais da máquina por seu respectivo valor de falha como apresentado em (2.8). O circuito representativo deste modelo é mostrado na Figura 2.4.

$$\begin{aligned} \begin{bmatrix} x_1(k+1) \\ x_2(k+1) \\ x_3(k+1) \end{bmatrix} &= \begin{bmatrix} k_{aa} a_1^f & k_{aa} a_2^f(k) & 0 \\ 0 & k_{afd} a_3^f & 0 \\ a_4^f(k) & 0 & a_5^f \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \end{bmatrix} \\ &+ \begin{bmatrix} b_1^f & 0 & 0 \\ 0 & b_2^f & 0 \\ 0 & 0 & d_1^f \end{bmatrix} \begin{bmatrix} k_{aa} k_{cca} v_a(k) \\ k_{afd} k_{ccfd} v_{fd}(k) \\ T_L(k) \end{bmatrix} \end{aligned} \quad (2.9)$$

$$\begin{bmatrix} y_1(k) \\ y_2(k) \\ y_3(k) \end{bmatrix} = \begin{bmatrix} k_{i_a}^f & 0 & 0 \\ 0 & k_{i_{fd}}^f & 0 \\ 0 & 0 & k_{\omega_r}^f \end{bmatrix} \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \end{bmatrix}$$

Tipo de Falha	Váriáveis Afetadas	Parâmetro(s) Indicador(es) da Falha	Definição do(s) Parâmetro(s)
abertura do enrolamento de armadura	$i_a = 0$	k_{aa}	$\{0, 1\}$
abertura do enrolamento de campo	$i_{fd} = 0$	k_{af}	$\{0, 1\}$
curto-circuito do conversor de armadura	$v_a = 0$	k_{cfa}	$\{0, 1\}$
curto-circuito do conversor de campo	$v_{fd} = 0$	k_{cfa}	$\{0, 1\}$
curto-circuito entre espiras no enrolamento de armadura	r_a e L_a	k_{ca}^{ra} e k_{ca}^{La}	$[0, 1]$
curto-circuito entre espiras no enrolamento de campo	r_{fd} e L_{fd}	k_{cf}^{rfd} e k_{cf}^{Lfd}	$[0, 1]$
falha no sistema de ventilação	r_a e r_{fd}	k_{fv}^{ra} e k_{fv}^{rfd}	$[1, \infty)$
falha de lubrificação nos mancais	B_m	k_{fl}	$[1, \infty)$
falha no sensor de corrente de armadura	i_a	$k_{i_a}^f$	$\{0, 1\}$
falha no sensor de corrente da fonte	i_{fd}	$k_{i_{fd}}^f$	$\{0, 1\}$
falha no sensor de velocidade	ω_r	$k_{\omega_r}^f$	$\{0, 1\}$

Tabela 2.1: Resumo das Falhas no sistema de acionamento C.C.

2.1.6 Resultados de Simulações do Sistema de Acionamento C.C.

As Figuras 2.5–2.6 mostram as curvas de correntes de campo e de armadura e a velocidade da máquina com ocorrência de falhas. As falhas simuladas foram, a título de ilustração: abertura da armadura (Figura 2.5) e abertura do campo (Figura 2.6) no instante $t = 5$ s (podendo ser estendidas para as outras falhas). Uma desconexão do conversor de armadura provoca a parada da máquina, pois, com a corrente de armadura nula, o conjugado eletromagnético também se anula. Já a corrente de campo não é afetada, porque o circuito de campo é independente. Por outro lado, a desconexão do conversor do campo provoca a parada da máquina e, com isto, um aumento da corrente de armadura, que

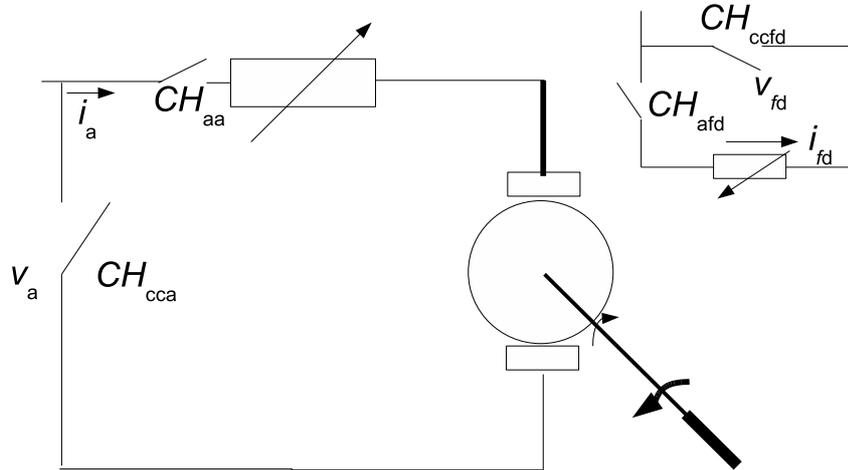


Figura 2.4: Representação do sistema de acionamento C.C. para os diversos tipos de falhas.

fica limitada somente pela resistência r_a , pois a força-contraeletromotriz se anula com a velocidade.

2.2 Metodologias para Detecção de Falhas

Nesta seção serão revisadas algumas das principais abordagens no contexto de detecção de falhas em sistemas dinâmicos, bem como será apresentada uma nova abordagem baseada na análise de séries temporais como discutidas em (Lemos, 2007) (D'Angelo et al., 2007) (D'Angelo et al., 2008a) (D'Angelo et al., 2008b). Como descrito no início deste capítulo, serão consideradas técnicas baseadas em modelos quantitativos (observador de Luenberger, filtro de Kalman, redes neurais artificiais, redes *neuro-fuzzy*) com o objetivo de gerar resíduos, como foi ilustrado na Figura 1.3, e em modelos qualitativos, onde é necessário a análise de sinais do sistema dinâmico. Esta classificação foi ilustrada na Figura 1.2.

A aplicação de todas estas abordagens será ilustrada através do *benchmark* proposto na seção anterior. Ressalta-se que esta seção, por se tratar de uma seção de revisão e

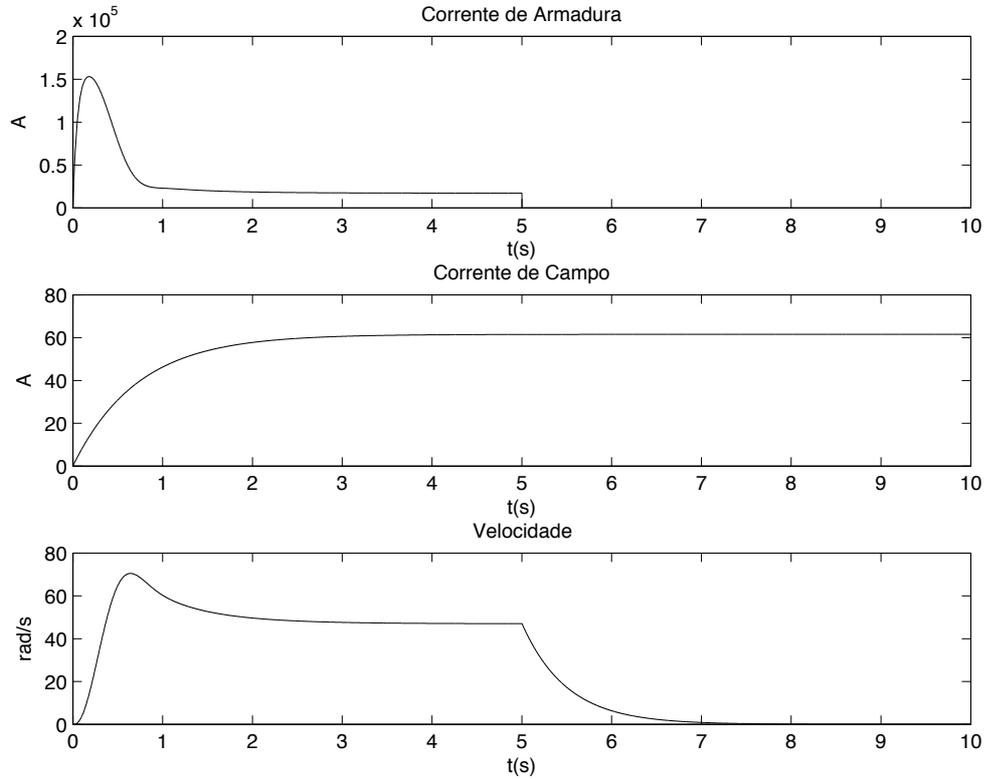


Figura 2.5: Corrente de armadura, corrente de campo e velocidade para falha do tipo desconexão do conversor de armadura.

aplicação, tem o seu foco em apresentar a aplicabilidade de todas estas abordagens, porém não no contexto comparativo.

2.2.1 Observador de Luenberger

Muitas abordagens para detecção de falhas em sistemas dinâmicos têm sido focadas no observador clássico de Luenberger, sendo que o papel principal do mesmo em sistemas de FDI é a geração de sinais de resíduos com o objetivo de detectar e identificar diferentes falhas.

Para ilustrar o projeto de um observador, considere o seguinte sistema descrito pelas equações em espaço de estado:

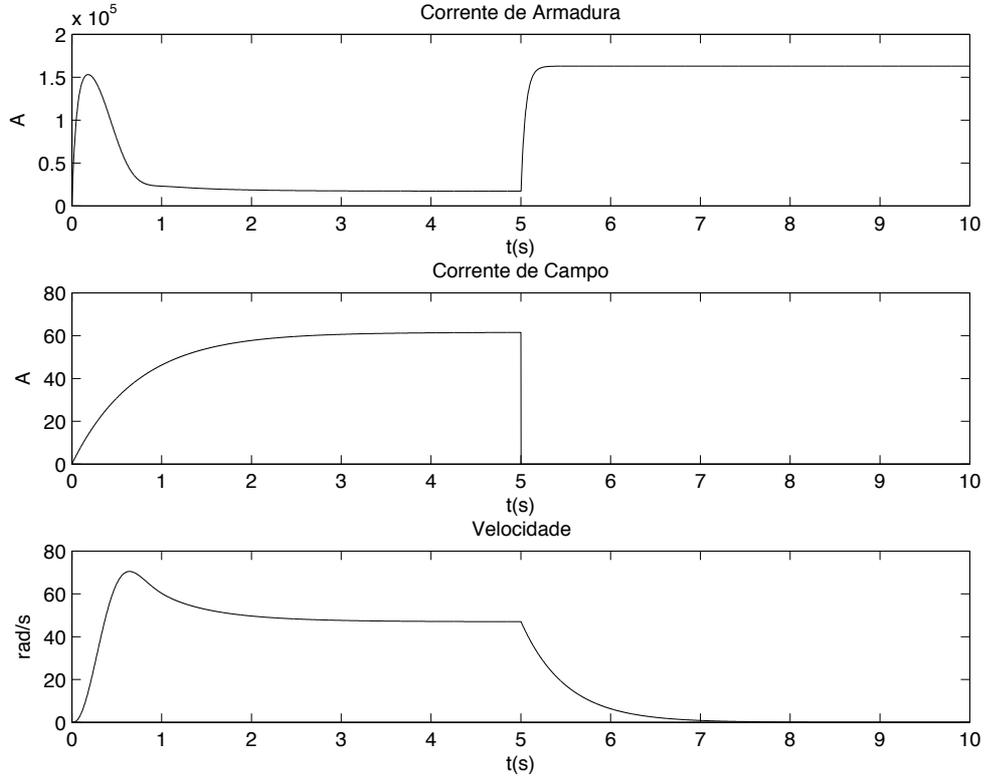


Figura 2.6: Corrente de armadura, corrente de campo e velocidade para falha do tipo desconexão do conversor de campo.

$$\dot{x}(t) = Ax(t) + Bu(t) \tag{2.10}$$

$$y(t) = Cx(t) \tag{2.11}$$

Assumindo que a estrutura e os parâmetros do modelo são conhecidos, o observador de estados é dado por:

$$\dot{\hat{x}}(t) = A\hat{x}(t) + Bu(t) + Le(t) \tag{2.12}$$

$$e(t) = y(t) - C\hat{x}(t) \tag{2.13}$$

sendo $e(t)$ o erro de saída, L é a matriz de ganho do observador e $\hat{x}(t)$ é o estado observado. Substituindo (2.13) em (2.12) tem-se:

$$\dot{\hat{x}}(t) = [A - LC]\hat{x}(t) + Bu(t) + Ly(t) \quad (2.14)$$

assumindo que o sistema seja observável.

O erro de estado entre o estado real do processo e o estado observado é dado por:

$$\dot{\tilde{x}}(t) = \dot{x}(t) - \dot{\hat{x}}(t) \quad (2.15)$$

pressupondo que os parâmetros do processo e do modelo são idênticos, e substituindo (2.10) e (2.14) em (2.15), tem-se:

$$\dot{\tilde{x}}(t) = [A - LC]\tilde{x}(t) \quad (2.16)$$

Por isso

$$\lim_{t \rightarrow \infty} \tilde{x}(t) = 0$$

para algum desvio inicial no estado, $[x(0) - \hat{x}(0)]$, se o observador é estável, isto através de um projeto apropriado da matriz de realimentação L do observador, por exemplo, através da alocação de pólos.

Considerando que o processo é agora influenciado por entradas (distúrbios) desconhecidas $v(t)$ e $n(t)$ e falhas aditivas $f_l(t)$ e $f_m(t)$, como segue:

$$\dot{x}(t) = Ax(t) + Bu(t) + Vv(t) + Tf_l(t) \quad (2.17)$$

$$y(t) = Cx(t) + Nn(t) + Mf_m(t) \quad (2.18)$$

T e M são matrizes de falha. Introduzindo estas novas equações do processo nas equações do observador, (2.16), leva ao seguinte erro de estado:

$$\dot{\tilde{x}}(t) = [A - LC]\tilde{x}(t) + Vv(t) + Tf_l(t) - HNn(t) - LMf_m(t) \quad (2.19)$$

e o erro de saída:

$$e(t) = y(t) - C\hat{x}(t) = C\tilde{x}(t) + Nn(t) + Mf_m(t) \quad (2.20)$$

Depois do desvio inicial do estado, $[x(0) - \hat{x}(0)]$, o erro do estado, $\tilde{x}(t)$, e o erro de saída, $e(t)$, dependem dos distúrbios $v(t)$ e $n(t)$ e das falhas $f_l(t)$ e $f_m(t)$. No geral, o erro de saída ($e(t) = r(t)$) é usado como resíduo, (Figura 2.7). O resíduo é zero, se não existem distúrbios e falhas.

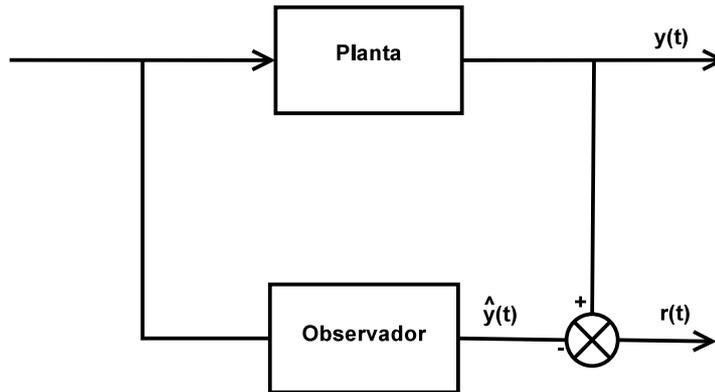


Figura 2.7: Esquema geral de um sistema de FDI utilizando observadores.

Considerando as matrizes A e C do sistema discreto em (2.4) para $A - LC$, e impondo alocação de pólos para o ganho L do observador, da forma:

$$A - LC = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix}$$

obtêm-se, por simples inspeção, que:

$$L = \begin{bmatrix} a_1 - \lambda_1 & a_2(k) & 0 \\ 0 & a_3 - \lambda_2 & 0 \\ a_4(k) & 0 & a_5 - \lambda_3 \end{bmatrix}$$

Nota: Como sistema é discreto, escolhe-se $|\lambda_i|$ dentro do círculo de raio unitário. Nota-se que o ganho L deve ser calculado a cada iteração, devido à não-linearidade do sistema (2.4).

A Figura 2.8 ilustra os resíduos gerados por esse observador, para a falha de abertura da armadura.

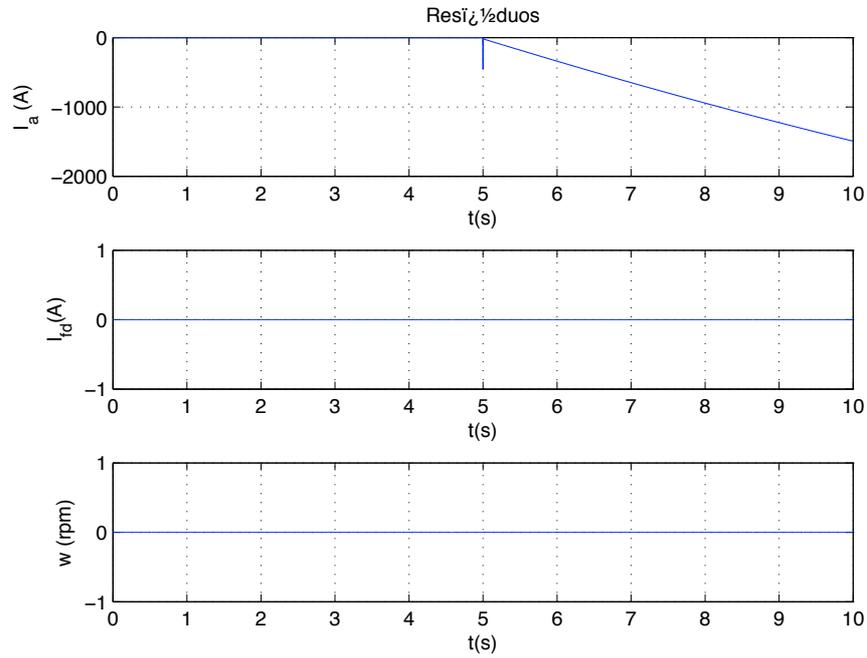


Figura 2.8: Resíduos gerados pelo observador de Luenberger.

Entretanto, para que as decisões de detecção de falha sejam corretas, é necessário que os resíduos tenham determinadas características, no sentido de que as decisões não sejam corrompidas por entradas desconhecidas (Caminhas and Takahashi, 2001). Portanto é necessária o projeto de um conjunto de observadores, sendo cada subconjunto seja sensível a falhas em certa direção e insensível às falhas restantes e às entradas desconhecidas. A idéia básica é que, no caso de não haver falha no processo, os observadores acompanham o processo fazendo com que os resíduos sejam pequenos (ou nulos). Se ocorrer uma falha, todos os observadores que não são sensíveis à essa falha geram resíduos pequenos ou nulos, refletindo apenas a entrada desconhecida. Por outro lado, os observadores, que são sensíveis à falha produzem resíduos de amplitude significativa. Conforme (Takahashi and Peres, 1999), será apresentado um observador que é fundamentado na teoria de modos deslizantes (*sliding modes*). Este observador é robusto quanto a perturbações paramétricas e entradas e/ou parâmetros desconhecidos.

Parte-se do seguinte sistema discreto não-linear:

$$\begin{aligned}
 x(k+1) &= F(x(k), u(k), k) + \Delta F(x(k), u(k), k) \\
 &\quad + Dv(k) \\
 y(k) &= Cx(k)
 \end{aligned} \tag{2.21}$$

sendo $x \in \mathbf{R}^n$, $u \in \mathbf{R}^p$, $y \in \mathbf{R}^m$, $v \in \mathbf{R}^q$, $k \in N$. Neste sistema, x representa o vetor de estados, que será estimado pelo observador, u representa o vetor de entradas de controle (suposto conhecido), v representa um vetor de entradas desconhecidas (distúrbios), e y representa um vetor de medições disponível. A dinâmica do sistema é composta por uma parte *nominal* F e por uma parte *perturbada* ΔF . Supõem-se conhecidas a função $F(., ., .)$ e a matriz C , e desconhecidas a matriz D e a função $\Delta F(., ., .)$, obedecendo porém a seguinte condição de *matching* das perturbações:

$$\begin{aligned}
 \Im(H) &= \Im(D) \cup \mathbf{F} \\
 \mathbf{F} &= \mathbf{Im}(\Delta F)
 \end{aligned} \tag{2.22}$$

sendo $\Im(.)$ o espaço imagem da matriz argumento, e $\mathbf{Im}(.)$ o espaço imagem da função argumento. A matriz H em (2.22) é suposta conhecida e indica as direções onde existem perturbações ou entradas desconhecidas. Além disso, a matriz H deve satisfazer conjuntamente com C :

$$\begin{aligned}
 \rho(C, H) &= \rho(H) = r \\
 \rho(C) &= m \geq r
 \end{aligned} \tag{2.23}$$

onde $\rho(.)$ representa o posto da matriz argumento e r é o número de direções onde aparecem perturbações que serão desacopladas. Como última suposição, a planta nominal (sistema (2.21), excluídas as entradas desconhecidas) deve ser estável e observável através da matriz C em toda a faixa de operação.

Com a condição (2.22), pode-se escrever:

$$\forall(x, k, u, v) \exists \omega : H\omega = \Delta F(x(k), u(k), k) + Dv(k) \tag{2.24}$$

Isto permite rescrever a equação (2.21) como:

$$x(k+1) = F(x(k), u(k), k) + H\omega(k) \tag{2.25}$$

O observador discreto em modos deslizantes é construído acrescentando-se a (2.25) um termo de cancelamento de perturbações $d(k)$:

$$\hat{x}(k+1) = F(\hat{x}(k), u(k), k) + H\omega(k) + Hd(k) \quad (2.26)$$

Considera-se a seguinte partição do vetor de saída:

$$y(k) = Cx(k) = \begin{bmatrix} y^1 \\ y^2 \end{bmatrix} = \begin{bmatrix} C^1 \\ C^2 \end{bmatrix} x(k) \quad (2.27)$$

onde a partição y^1 do vetor de saída contém as medidas usadas para viabilizar o desacoplamento das perturbações.

O termo $d(k)$ é deduzido a partir da restrição:

$$C^1\hat{x}(k+1) - y^1(k+1) = 0 \quad (2.28)$$

A restrição (2.28) equivale a uma redução de ordem do sistema, ou a impor que a evolução temporal do vetor de estados pertença a uma superfície do espaço de estados $C^1.e(k) = 0$, sendo $e(k) = \hat{x}(k) - x(k)$. Essa superfície é chamada "superfície de deslizamento", e o observador é dito estar em "modos deslizantes" nessa superfície, por analogia com os sistemas de controle em modos deslizantes.

Substituindo (2.28) em (2.26) conduz a:

$$\begin{aligned} \hat{x}(k+1) = & [I - H(C^1H)^{-L}C^1]F(\hat{x}(k), u(k), k) \\ & + H(C^1H)^{-L}y^1(k+1) \end{aligned} \quad (2.29)$$

onde $(.)^{-L}$ significa qualquer inversa à esquerda da matriz argumento. Finalmente, para aumentar a liberdade na seleção da dinâmica do erro, acrescenta-se à equação (2.29) um termo proporcional ao erro de saída, à semelhança do clássico observador de Luenberger:

$$\begin{aligned} \hat{x}(k+1) = & [I - H(C^1H)^{-L}C^1]F(\hat{x}(k), u(k), k) \\ & + H(C^1H)^{-L}y^1(k+1) + L[C^r\hat{x}(k) - y^r(k)] \end{aligned} \quad (2.30)$$

sendo y^r uma partição do vetor u que contém as saídas que serão realimentadas e C^r a correspondente partição da matriz C .

Omitindo os índices dos vetores correspondentes ao instante k e considerando:

$$\begin{aligned}\Phi_2 &= H(C^1H)^{-L} \\ \Phi_1 &= I - \Phi_2C^1\end{aligned}\tag{2.31}$$

tem-se a seguinte expressão para o observador:

$$\begin{aligned}\hat{x}(k+1) &= \Phi_1F(\hat{x}(k), u(k), k) + \Phi_2y^1(k+1) \\ &\quad + L[C^r\hat{x}(k) - y^r(k)]\end{aligned}\tag{2.32}$$

Esta equação corresponde a um observador capaz de rejeitar completamente perturbações conforme descritas em (2.24), com uma dinâmica de erro selecionável. A análise geral da convergência do erro não será apresentada aqui. No entanto, é fácil ver que, para o caso particular (suficiente para os propósitos deste trabalho) em que F é globalmente assintoticamente estável em relação a um ponto de equilíbrio e u é constante (ou constante por partes), pode-se sempre escolher os parâmetros de projeto de maneira a garantir a convergência global do observador. O projetista deve selecionar as matrizes H , L e $(C^1H)^{-L}$, procurando um compromisso adequado entre a dinâmica do erro e a rejeição de perturbações, como discutido em (Takahashi and Peres, 1999).

Para sistemas bilineares, como é o caso do sistema de acionamento C.C., tem-se que a função $F(x, u, k)$ pode ser escrita como:

$$F(x, u, k) = A(x)x + Bu\tag{2.33}$$

Escrevendo A no lugar de $A(x)$, para simplificar a notação, tem-se a seguinte equação do observador:

$$\hat{x}(k+1) = \Phi_F\hat{x}(k) + \Phi_1Bu(k) + \Phi_2y^1(k+1) - Ly^r(k)\tag{2.34}$$

sendo $\Phi_F = \Phi_1A + LC^r$ a matriz de transição em malha fechada.

O projeto deste observador, que é desenvolvido algebricamente, é simples, bastando seguir os passos:

- (a) construa a matriz H ;
- (b) escolha a partição da matriz C ;
- (c) calcule C^1H ;
- (d) encontre uma inversa à esquerda para C^1H ;
- (e) calcule Φ_2 e Φ_1 , expressão (2.31);
- (f) escolha a matriz de ganhos do observador;
- (g) estabeleça a equação final do observador.

Para fins de ilustração, será projetado, para o sistema (2.4), um observador para rejeição de perturbações na direção de x_1 .

• **Passo 1**

No caso do sistema (2.4), a matriz H é construída da seguinte forma:

$$H = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} \tag{2.35}$$

A matriz H é formada por "0" e "1", sendo que a presença do elemento de valor "1" indica a direção onde aparecem perturbações desconhecidas (variações paramétricas ou entradas desconhecidas), a qual deseja-se desacoplar. Como pode ser verificada, com esta matriz H , juntamente com a matriz C , a condição (2.23) é satisfeita.

• **Passo 2**

A partição da matriz C adotada para este observador foi:

$$\begin{aligned} \begin{bmatrix} y^1(k) \\ \dots \\ y^2(k) \end{bmatrix} &= \begin{bmatrix} y_1(k) \\ \dots \\ y_2(k) \\ y_3(k) \end{bmatrix} = \begin{bmatrix} C^1 \\ \dots \\ C^2 \end{bmatrix} x(k) \\ &= \begin{bmatrix} 1 & 0 & 0 \\ \dots & \dots & \dots \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} x_1(k) \\ x_2(k) \\ x_3(k) \end{bmatrix} \end{aligned} \tag{2.36}$$

portanto $C^1 = [1 \ 0 \ 0]$. Qualquer outra opção de partição de C implicaria numa matriz C^1H nula, inviabilizando o projeto do observador.

• **Passo 3**

$$C^1 H = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} = [1] \quad (2.37)$$

• **Passo 4**

Neste caso a inversa à esquerda é a própria inversa, já que $C^1 H$ é uma matriz quadrada, ou seja:

$$(C^1 H)^{-L} = [1] \quad (2.38)$$

• **Passo 5**

$$\phi_2 = H (C^1 H)^{-L} = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} [1] = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} \quad (2.39)$$

$$\phi_1 = I - \phi_2 C^1 = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (2.40)$$

• **Passo 6**

A dinâmica de erro do observador depende dos autovalores da matriz $\Phi_f = \Phi_1 A + LC^r$, que podem ser arbitrariamente alocados pela escolha de L . Tomando o caso mais geral, que é todas as saídas sendo realimentadas, tem-se:

$$L = \begin{bmatrix} L_{11}(k) & L_{12}(k) & L_{13}(k) \\ L_{21}(k) & L_{22}(k) & L_{23}(k) \\ L_{31}(k) & L_{32}(k) & L_{33}(k) \end{bmatrix} \quad (2.41)$$

$$C^r = C \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

logo:

$$\Phi_F = \begin{bmatrix} L_{11}(k) & L_{12}(k) & L_{13}(k) \\ L_{21}(k) & L_{22}(k) + a_3 & L_{23}(k) \\ L_{31}(k) + a_4(k) & L_{32}(k) & L_{33}(k) + a_5 \end{bmatrix} \quad (2.42)$$

Para casos particulares, onde uma ou duas saídas são realimentadas, basta desconsiderar as colunas de L que correspondem às saídas não realimentadas.

Os valores dos ganhos de L podem ser determinados a partir da expressão:

$$|\lambda I - \Phi_F| = 0 \quad (2.43)$$

Considerando que o sistema possui três autovalores, a partir de (2.43) é possível montar três equações envolvendo os nove ganhos. Para resolver esse sistema de equações é necessário arbitrar no mínimo seis ganhos para calcular os demais. Por exemplo, arbitrando os ganhos $L_{ij}(K) = 0$ para $i \neq j$ é possível determinar os demais facilmente a partir dos autovalores desejados:

$$[\lambda I - \Phi_f] = \begin{bmatrix} \lambda - L_{11}(k) & 0 & 0 \\ 0 & \lambda - L_{22}(k) + a_3 & 0 \\ -a_4(k) & 0 & \lambda - L_{33}(k) + a_5 \end{bmatrix} \quad (2.44)$$

Portanto, a alocação arbitrária de autovalores é facilmente realizada fazendo-se:

$$\begin{aligned} L_{11}(k) &= L_{11} = \lambda_1; \\ L_{22}(k) &= L_{22} = \lambda_2 - a_3; \\ L_{33}(k) &= L_{33} = \lambda_3 - a_5 \end{aligned} \quad (2.45)$$

sendo λ_1, λ_2 e λ_3 os autovalores desejados.

- **Passo 7**

Para estabelecer a equação resta calcular os termos:

$$\Phi_1 B = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} b_1 & 0 \\ 0 & b_2 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} 0 & 0 \\ 0 & b_2 \\ 0 & 0 \end{bmatrix} \quad (2.46)$$

$$\Phi_2 \cdot y^1(k+1)B = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} [y_1(k+1)] \quad (2.47)$$

Finalmente, a equação do observador é:

$$\begin{aligned} \begin{bmatrix} \hat{x}_1(k+1) \\ \hat{x}_2(k+1) \\ \hat{x}_3(k+1) \end{bmatrix} &= \begin{bmatrix} L_{11} & 0 & 0 \\ 0 & L_{22} + a_3 & 0 \\ a_4(k) & 0 & L_{33} + a_5 \end{bmatrix} \begin{bmatrix} \hat{x}_1(k) \\ \hat{x}_2(k) \\ \hat{x}_3(k) \end{bmatrix} \\ &+ \begin{bmatrix} 0 & 0 & 1 \\ 0 & b_2 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} v_a(k) \\ v_{fd}(k) \\ y_1(k+1) \end{bmatrix} \\ &- \begin{bmatrix} L_{11}y_1(k) \\ L_{22}y_2(k) \\ L_{33}y_3(k) \end{bmatrix} \end{aligned} \quad (2.48)$$

Observa-se que as equações são bastante simples, envolvendo apenas operações básicas, tornando o observador atraente em termos de implementação prática.

Para ilustrar a metodologia descrita, foi projetado, para o *benchmark* proposto na seção anterior, um observador com rejeição de distúrbios nas direções da velocidade (x_3) e da corrente de campo (x_2), para a falha de abertura da armadura. A Figura 2.9 ilustra os resíduos gerados por esse observador. É válido ressaltar que, para observadores robustos, é necessário projetar um banco de observadores, com cada observador rejeitando distúrbios em certa direção. Isso se justifica pelo fato de que, caso ocorra uma falha que modifique a variável à qual a rejeição do distúrbio está associada, o respectivo observador não vai acusar falha, como ilustrado na Figura 2.10, onde o observador foi projetado para rejeitar distúrbio na direção da corrente de armadura, para a mesma condição de falha descrita anteriormente.

Foi mostrada, resumidamente, a idéia básica do projeto de um observador. Uma discussão mais detalhada sobre observadores pode ser encontrada em (Frank, 1994), em (Wilsky, 1976) e (Johansson et al., 2006) são mostrados projetos de observadores robustos, e em (Policarpou and Trunov, 2000), (Zhang et al., 2002) projetos de observadores para sistemas não-lineares. Também é necessário ressaltar que observadores analíticos, como descritos aqui, sempre necessitam do modelo do processo.

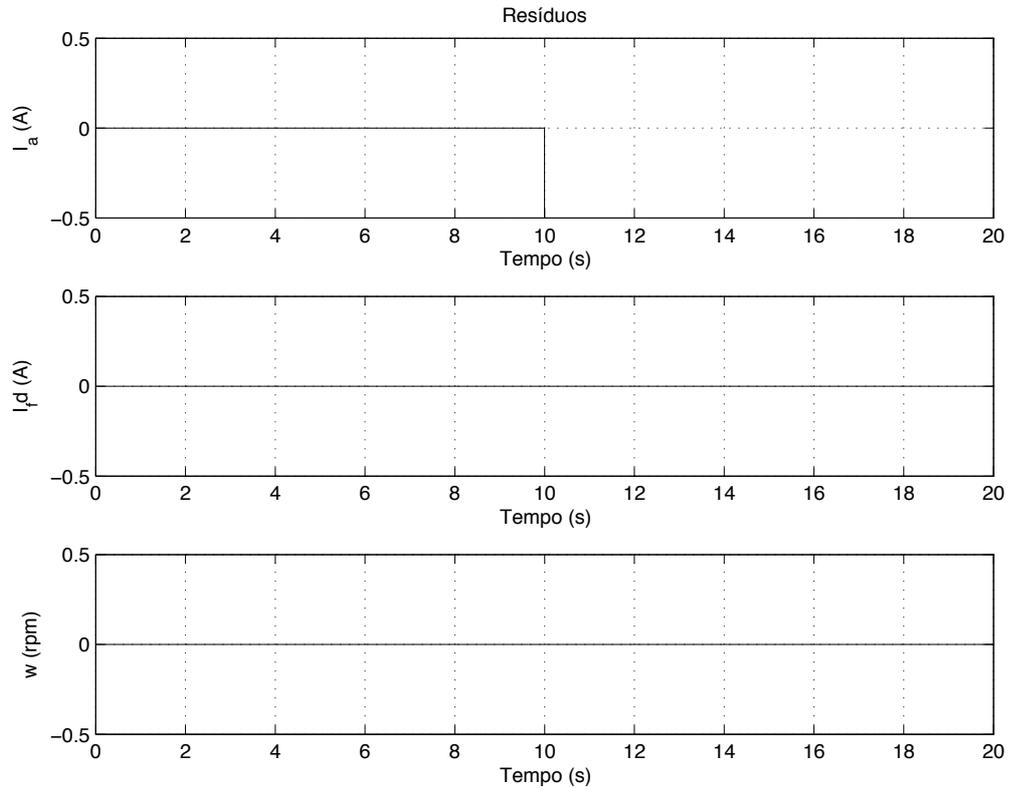


Figura 2.9: Resíduos gerados pelo observador com rejeição de distúrbio na direção da corrente de campo e da velocidade para a falha de abertura da armadura.

2.2.2 Filtro de Kalman

Nesta seção será descrito o filtro de Kalman em sua formulação original (Kalman, 1960), onde os distúrbios na planta são flutuações aleatórias e geralmente só os seus parâmetros estatísticos são conhecidos. Uma solução (Wilsky, 1976), (Basseville, 1988), para o problema de detecção de falhas em tais sistemas, implica em uma previsão de erros. O objetivo é projetar um estimador de estado com mínimo erro de estimativa. Ela envolve a utilização de um estimador de estado ótimo, por exemplo, o filtro de Kalman (Figura 2.11), que é projetado com base no modelo do sistema operando em condições normais. A teoria essencial sobre filtro de Kalman é mostrada a seguir, para mais detalhes ver (Aguirre, 2007).

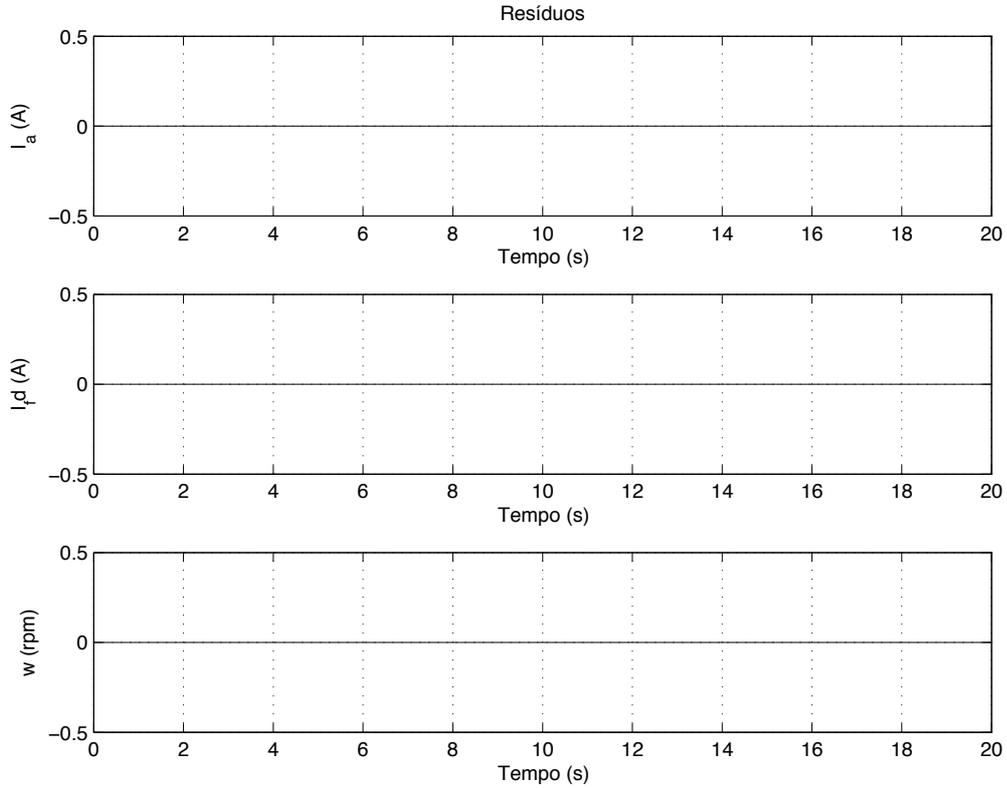


Figura 2.10: Resíduos gerados pelo observador com rejeição de distúrbio na direção da corrente de armadura para a falha de abertura da armadura.

Seja o sistema dinâmico estocástico descrito em variáveis de estado:

$$\begin{aligned} x(t+1) &= Ax(t) + Bu(t) + \omega(t) \\ y(t) &= Cx(t) + v(t), \quad t \geq 0 \end{aligned} \tag{2.49}$$

sendo $x(t)$ um vetor n -dimensional e A, B, C matrizes com dimensões apropriadas. As variáveis aleatórias $\omega(t)$ e $v(t)$ são, respectivamente, ruído de processo e medida. Estes ruídos são independentes com distribuição de probabilidade normal:

$$\omega(t) \sim N(0, Q) \tag{2.50}$$

$$v(t) \sim N(0, R) \tag{2.51}$$

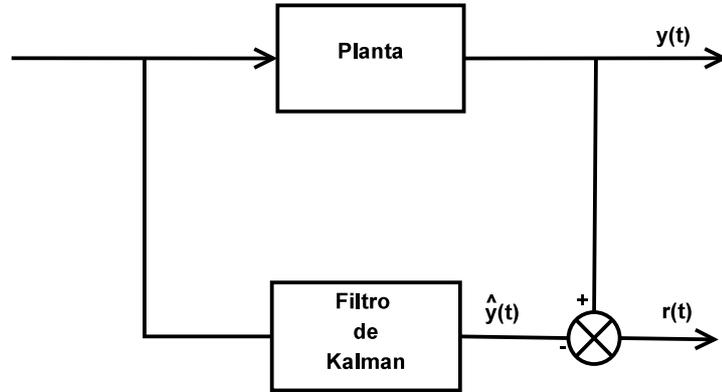


Figura 2.11: Esquema geral de um sistema de FDI utilizando filtro de Kalman.

Na prática, a covariância do ruído de processo Q e a covariância do ruído de medida R mudam a cada instante de tempo, todavia serão assumidas constantes.

Define-se $\tilde{x}(t)$ como a estimativa a priori do estado no instante t , dado o conhecimento do processo no instante $(t - 1)$, e $\hat{x}(t)$ como sendo a estimativa a posteriori no instante t , ou seja, após ser incorporado o conhecimento advindo do vetor de medições no instante t . Pode-se, então, definir os erros de estimação a priori e a posteriori como:

$$\begin{aligned}\bar{e}(t) &= x(t) - \tilde{x}(t) \\ e(t) &= x(t) - \hat{x}(t)\end{aligned}$$

A covariância do erro de estimação *a priori* é dada por:

$$\bar{P}(t) = E[\bar{e}(t)\bar{e}(t)^T] \quad (2.52)$$

A covariância do erro de estimação *a posteriori* é dada por:

$$P(t) = E[e(t)e(t)^T] \quad (2.53)$$

A estimativa *a posteriori*, $\hat{x}(t)$, é dada pela combinação linear da estimativa *a priori*, $\tilde{x}(t)$, e da inovação, que é a diferença entre os valores de medição e predição no instante t , tal como apresentado em (2.54).

$$\hat{x}(t) = \bar{\hat{x}}(t) + K(y(t) - C\bar{\hat{x}}(t)) \quad (2.54)$$

O ganho K do filtro, presente na equação 2.55, é calculado visando à minimização da covariância da estimativa do erro de predição *a posteriori*, determinado por (2.53).

$$K(t) = \bar{P}(t)C^T(C\bar{P}(t)C^T + R)^{-1} \frac{\bar{P}(t)C^T}{C\bar{P}(t)C^T + R} \quad (2.55)$$

Os passos do filtro de Kalman podem são resumidos a seguir. Primeiramente, calcula-se $\bar{\hat{x}}(t+1)$ e $\bar{P}(t+1)$, que constituem a etapa de predição, por:

$$\bar{\hat{x}}(t+1) = A\bar{\hat{x}}(t) + Bu(t) \quad (2.56)$$

$$\bar{P}(t+1) = AP(t)A^T + Q \quad (2.57)$$

Em seguida, calcula-se $K(t+1)$, $\hat{x}(t+1)$ e $P(t+1)$, que constituem a etapa de correção, por:

$$K(t+1) = \bar{P}(t+1)C^T(C\bar{P}(t+1)C^T + R)^{-1} \quad (2.58)$$

$$\hat{x}(t+1) = A\bar{\hat{x}}(t+1) + K(t+1)(y(k+1) - C\bar{\hat{x}}(t+1)) \quad (2.59)$$

$$P(t+1) = (I - K(t+1)C)\bar{P}(t+1) \quad (2.60)$$

Para ilustrar a metodologia descrita, foi projetado, para o *benchmark* proposto na seção anterior, um filtro de Kalman. A Figura 2.12 ilustra os resíduos gerados por esse filtro, para a falha de abertura da armadura. A metodologia, adotada para projetar o filtro de Kalman utilizado nessa aplicação, é a mesma descrita anteriormente, isto é, sem nenhum tipo de robustez. A robustez em filtros de Kalman, como o tratamento de entradas desconhecidas, pode ser visto em (Chen and Patton, 1996).

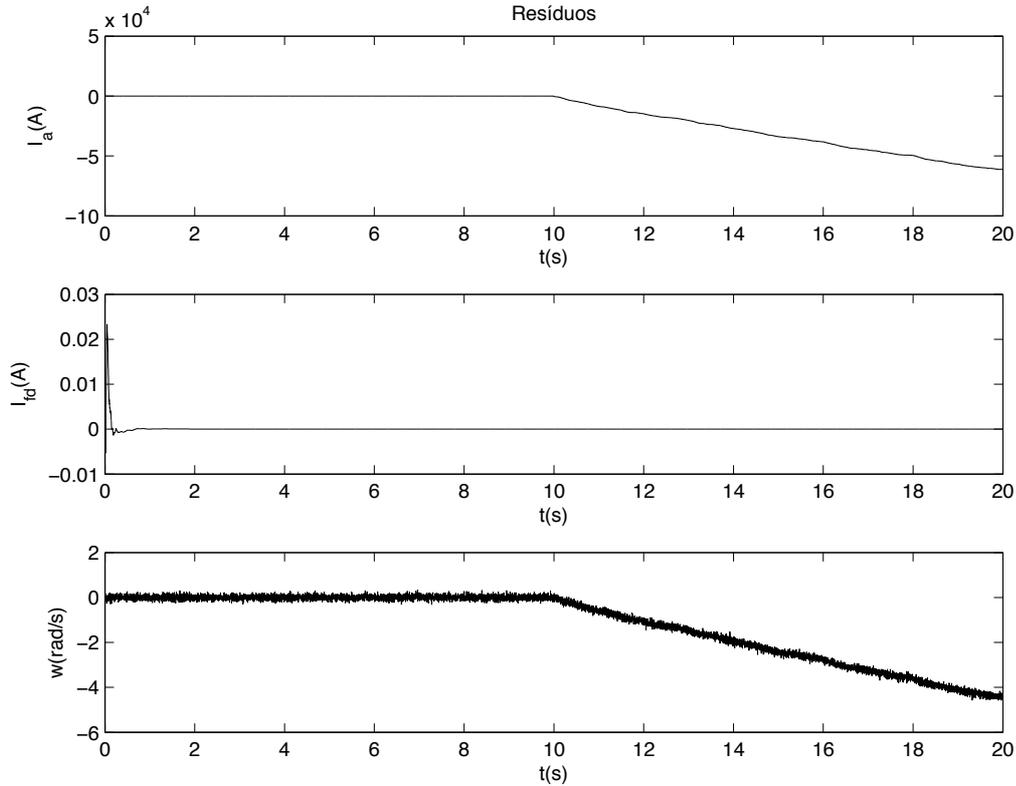


Figura 2.12: Resíduos gerados pelo filtro de Kalman para a falha de abertura da armadura.

2.2.3 Redes Neurais Artificiais

As redes neurais artificiais (RNAs) encontram um forte apelo em aplicações relacionadas com problemas que envolvam classificação de padrões e aproximação de funções. A detecção de falhas pode ser vista tanto como um problema de classificação de padrões como um problema de aproximação de funções. Uma possível vantagem das RNAs é a sua capacidade “reproduzir” a dinâmica de certos sistemas dinâmicos, sem no entanto necessitar necessitar “explicitamente” de um modelo matemático. Portanto, para processos/plantas cujos modelos matemáticos explícitos são de difícil obtenção, o uso de RNAs é uma escolha desejável. Em geral, os trabalhos que usam redes neurais para detecção de falhas tem focado seus esforços nas arquiteturas das redes neurais e na aprendizagem. Dentre eles pode-se relacionar os trabalhos de (D’Angelo and Costa, 2001), (Witczak et al., 2006).

Em estruturas onde a rede neural funciona como modelo do processo (Figura 2.13), a topologia de rede neural mais utilizada na detecção de falhas é do tipo *feedforward* multicamadas (Selmic et al., 2009) como ilustrado na Figura 2.14 e em casos onde as redes neurais funcionam como classificadores, pode-se usar topologias como a própria *feedforward* multicamadas (D’Angelo and Costa, 2001) ou topologias típicas para classificação, como, por exemplo, a rede neural de *Kohonen* (Chan et al., 2001) (Figura 2.15).

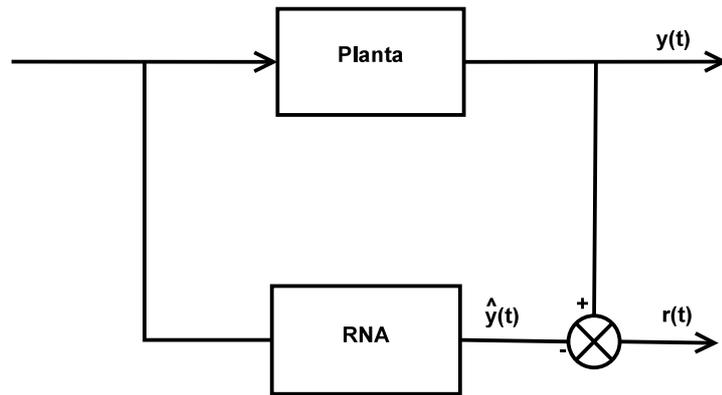


Figura 2.13: Esquema geral de um sistema de FDI utilizando Redes Neurais Artificiais.

Para ilustrar a metodologia descrita, foi projetada, para a falha de abertura da armadura no *benchmark* proposto na seção anterior, uma Rede Neural Artificial *feedforward* de três camadas, com cinco neurônios na camada de entrada: v_a , v_{fd} , I_a , I_{fd} e ω_r , atrasados de um passo, três neurônios na camada intermediária e três neurônios na camada de saída: I_a , I_{fd} e ω_r . A Figura 2.16 ilustra os resíduos gerados por essa rede neural, na mesma situação de falha descrita anteriormente. A rede foi treinada utilizando-se 2500 observações do modelo do motor, que representa 5 segundos de simulação. Utilizou-se o algoritmo de treinamento supervisionado *Levenberg-Marquardt* (Marquardt, 1963) durante 250 épocas com um erro objetivo de 10^{-6} . O *script* do MatLab para construção do observador neural é dado a seguir, sendo $[X, Y] = motor_cc$ a função que roda o benchmark do sistema de acionamento (disponibilizado em (Palhares, 2009)).

```

» [X, Y] = motor_cc;
» net.trainParam.epochs = 250;
» net.trainParam.goal = 1e - 6;

```

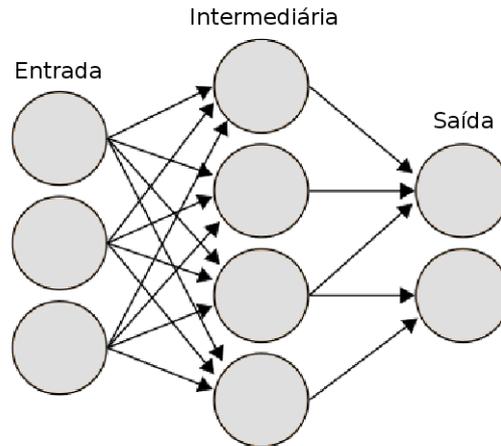


Figura 2.14: Rede neural do tipo *feedforward* multicamadas.

```

» net = newff([min(X)' max(X)'],
    [3 3], {'logsig','purelin'},'trainlm');
» net1 = train(net, X, Y);

```

2.2.4 Redes *Neuro-fuzzy*

As redes *neuro-fuzzy* (RNF) podem ser empregadas de maneira similar as redes neurais (Figura 2.17), isto é, em caso onde não existem modelos matemáticos explícitos do processo/planta (Uppal et al., 2006) (Caminhas et al., 1996) (Caminhas and Gomide, 2008). A topologia mais difundida no contexto de redes *neuro-fuzzy* é a *ANFIS* (*Adaptive-Neuro-Network-Based Fuzzy Inference System*) descrita em (Jang and Sun, 1997) e ilustrada na Figura 2.18.

Para ilustrar a metodologia descrita, foi projetada, para a falha de abertura da armadura no *benchmark* proposto na seção anterior, uma Rede *Neuro-Fuzzy* com cinco entradas: v_a , v_{fd} , I_a , I_{fd} e ω_r , atrasados de 1 passo, três funções de pertinência triangulares por entrada, três regras e três saídas: I_a , I_{fd} e ω_r . A Figura 2.19 ilustra os resíduos gerados por essa RNF, na mesma situação de falha descrita anteriormente. O *script* do MatLab para construção do observador *neuro-fuzzy* é dado a seguir, sendo $[X, Y] = motor_cc$ a função que roda o *benchmark* do sistema de acionamento (disponibilizado em (Palhares, 2009)).

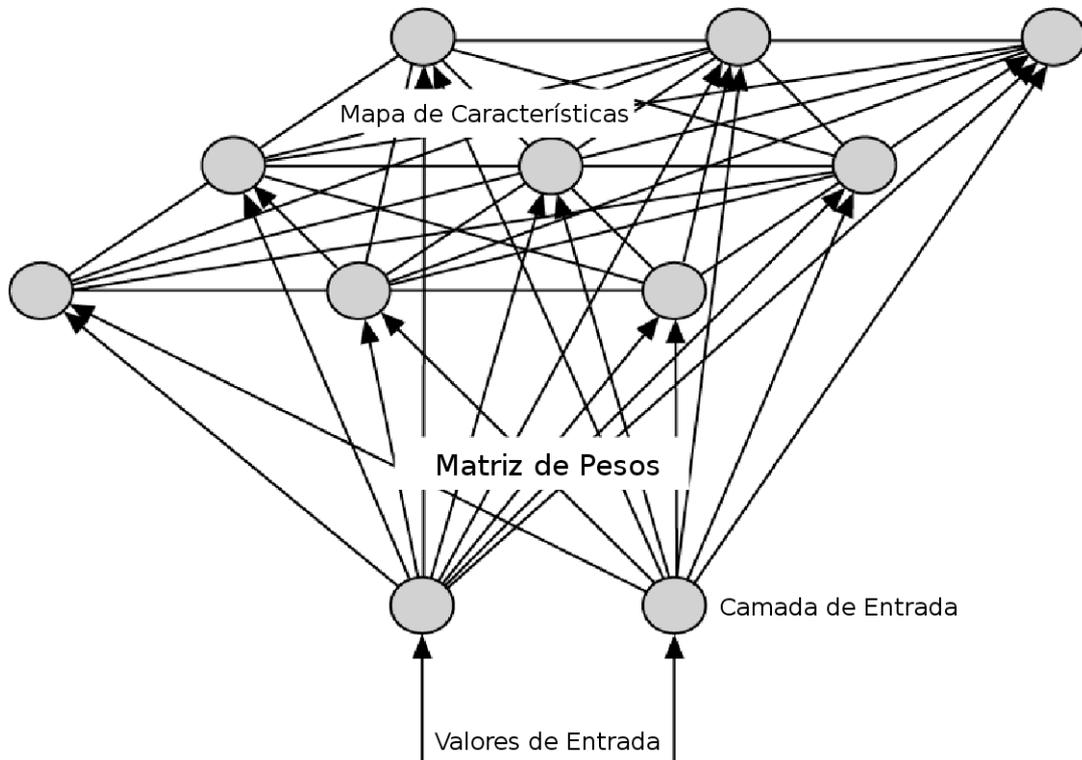


Figura 2.15: Rede de Kohonen.

- » $[X, Y] = motor_cc;$
- » $fis = genfis2(X, Y, 0.5);$
- » $epoch_n = 20;$
- » $out_fis = anfis([X Y], fis, epoch_n);$

2.2.5 Árvore de Falhas

A árvore de falhas – FT (do inglês, Fault Tree) consiste na construção de um diagrama lógico, através de um processo dedutivo que, partindo de um evento indesejado pré-definido, busca as possíveis causas de tal evento (Simões, 2006). O processo segue investigando as sucessivas combinações de falhas dos componentes até atingir as chamadas

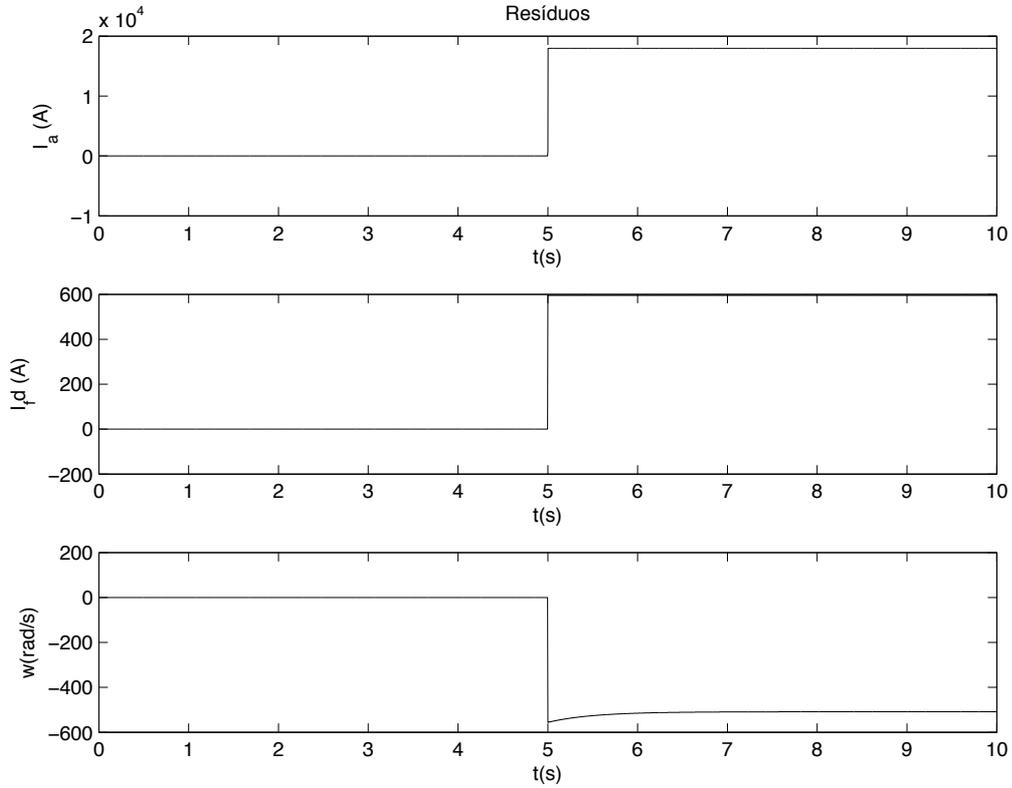


Figura 2.16: Resíduos gerados pela Rede Neural Artificial para a falha de abertura da armadura.

falhas básicas (ou eventos básicos da FT), as quais constituem o limite de resolução da análise. O evento indesejado é comumente chamado de *evento topo* da árvore.

O conceito fundamental da FT consiste na tradução de um sistema físico em um diagrama lógico estruturado (árvore de falhas), em que certas causas específicas conduzem a um *evento topo* de interesse (Nguyen and Lee, 2008) (Sheng and Rovnyak, 2004). O relacionamento entre as etapas de uma árvore de falha são ilustrado na Figura 2.20.

Para fins de ilustração da metodologia no contexto de detecção e isolamento de falhas, foi gerada uma árvore de falhas, Figura 2.21, para as falhas do tipo:

- (a) Falha 1: abertura do enrolamento de armadura;
- (b) Falha 2: abertura do enrolamento de campo;
- (c) Falha 3: curto-circuito no conversor da armadura;
- (d) Falha 4: curto-circuito entre espiras da bobina de armadura.

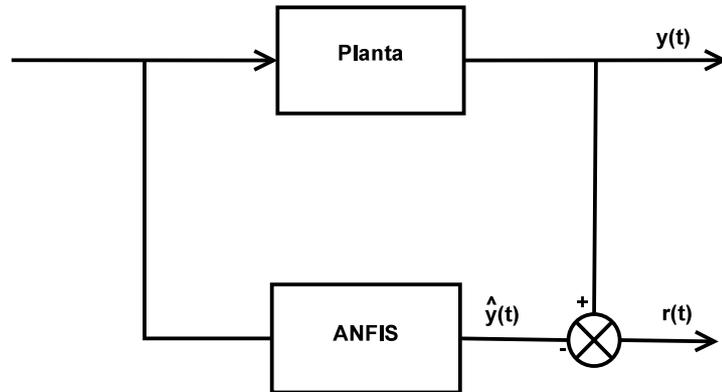


Figura 2.17: Esquema geral de um sistema de FDI utilizando *ANFIS*.

Nas entradas da árvore de falhas foram utilizados os resíduos gerados por um observador de Luenberger, sendo que, na Figura 2.21, r_1 é o resíduo da corrente de armadura, r_2 é o resíduo da corrente de campo e r_3 é o resíduo da velocidade. Na Figura 2.22 é mostrado o resultado para detecção da falha de abertura da armadura no *benchmark* proposto na seção anterior, com base na árvore de falha da Figura 2.21, sendo que o índice de falha representa o tipo de falha: índice igual a 1 representa a Falha 1, índice igual a 2 representa a Falha 2, índice igual a 3 representa a Falha 3 e índice igual a 4 representa a Falha 4.

2.2.6 Sistemas Especialistas Baseados em Lógica *Fuzzy*

Sistemas baseados em regras foram os primeiros sistemas especialistas para detecção de falhas. Estes representam a experiência de especialistas na forma de regras do tipo *SE sintoma(s) ENTÃO falha(s)*. Uma desvantagem nesse tipo de sistema é que ele pode conter um número muito grande de regras, além de não ter habilidade para lidar com falhas não previstas. Outra abordagem no contexto de sistemas especialistas é a lógica e os conjuntos *fuzzy* (Zadeh, 1965) (Zadeh, 2008). Esta fornece um meio alternativo de representar a imprecisão e a falta de informação associadas à descrição das características de um determinado elemento de um problema particular (Saravanan et al., 2009) (Bilski and Wojciechowski, 2007) (Bocaniala and da Costa, 2006).

O sistema especialista a ser considerado será baseado em lógica *fuzzy* e utilizará o sistema

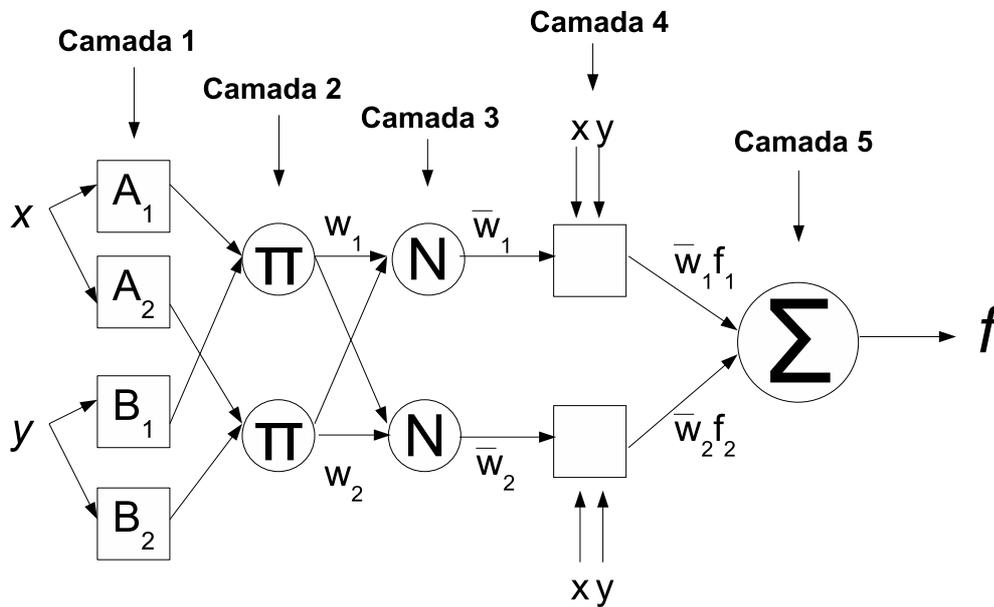


Figura 2.18: Rede *Neuro-Fuzzy* do tipo *ANFIS*.

de inferência de Mandani (Mamdani, 1974).

Para fins de ilustração da metodologia no contexto de detecção e isolamento de falhas, foi gerada um conjunto de regras *fuzzy* para as falhas do tipo:

- (a) Falha 1: abertura do enrolamento de armadura;
- (b) Falha 2: abertura do enrolamento de campo;
- (c) Falha 3: curto-circuito no conversor da armadura;
- (d) Falha 4: curto-circuito entre espiras da bobina de armadura.

Nas entradas do sistema de inferência de Mandani foram utilizados os resíduos gerados por um observador de Luenberger. Na Figura 2.23 é mostrado o resultado para detecção da falha de abertura da armadura no *benchmark* proposto na seção anterior, onde o índice de falha representa o tipo de falha: índice igual a 1 representa a Falha 1, índice igual a 2

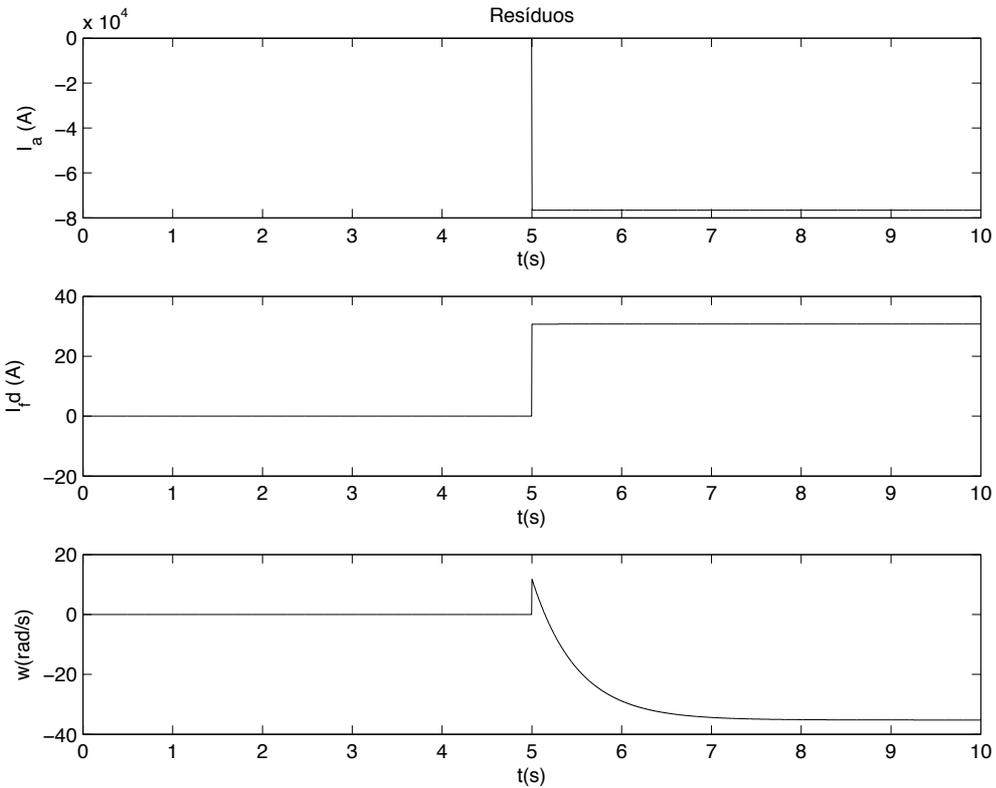


Figura 2.19: Resíduos gerados pela Rede *Neuro-fuzzy* para a falha de abertura da armadura.

representa a Falha 2, índice igual a 3 representa a Falha 3 e índice igual a 4 representa a Falha 4.

2.2.7 Análise Qualitativa de Tendência (QTA)

Pode-se utilizar QTA para representar as tendências qualitativas de sinais (tendências, grau de oscilação, alarmes, etc.). Uma dessas técnicas é a representação de sinais pelas médias das amostras. Neste caso, a dimensão das variáveis não é alterada, mas a complexidade do estado do sistema é reduzido, permitindo apenas um conjunto finito de descrições qualitativas. A vantagem desta representação é que ela permite a extração de informação útil. QTA tem sido utilizado com sucesso no monitoramento, detecção e diagnóstico de falhas em processos. Muitos trabalhos nesse contexto propõem o uso de transformada de

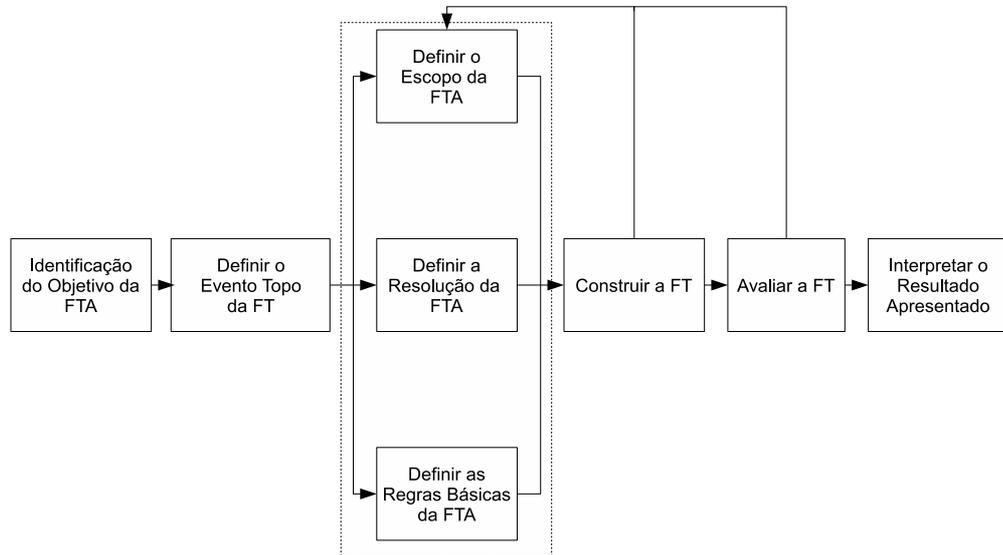


Figura 2.20: Etapas da análise da árvore de falhas.

Fourier (Baccarini et al., 2010) e transformada wavelet (Vedam and Venkatasubramanian, 1997), (Stephanopoulos et al., 1995), (Dash et al., 2003), (Maurya et al., 2007). Uma análise mais detalhada sobre QTA pode ser vista em (Maurya et al., 2007), onde é feita uma revisão das principais técnicas de QTA. Nesta seção será abordada uma metodologia de QTA, proposta em (Lemos, 2007), a qual é baseada em detecção de novidades.

Detecção de Falhas baseado em Detecção de Novidades

Esta seção descreve uma metodologia de detecção de falhas em sistemas dinâmicos baseada na detecção de novidades (Markou and Singh, 2003a) (Markou and Singh, 2003b), de forma que uma falha é caracterizada por uma novidade, ou seja, um desvio do comportamento assumido como normal do sistema.

A metodologia de detecção de novidades proposta realiza a detecção de falhas através

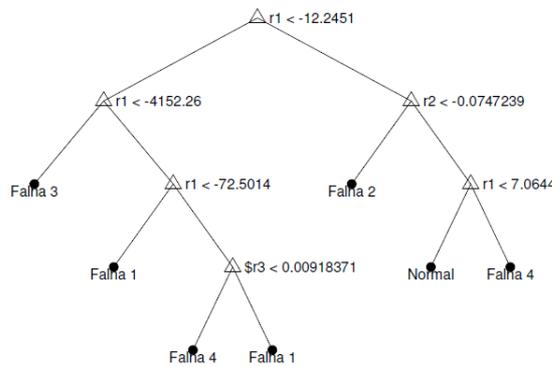


Figura 2.21: Árvore de falhas (“Sim” corresponde ao ramo esquerdo e “Não” corresponde ao ramo direito).

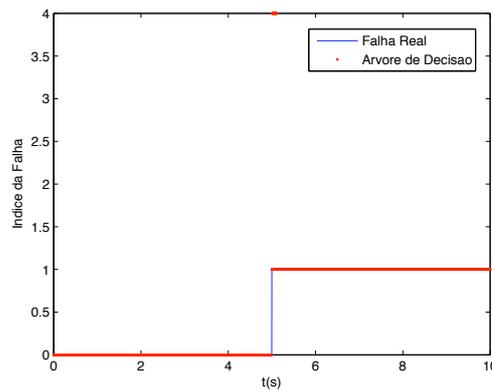


Figura 2.22: Resultado obtido com a árvore de falha para a falha de abertura da armadura.

do processamento da saída de cartas de controle estatístico construídas para o resíduo de um modelo do sistema dinâmico monitorado. Cartas de controle estatístico são ferramentas largamente utilizadas para o monitoramento de processos (Montgomery, 2001). Geralmente, essas cartas analisam observações obtidas do sistema individualmente (todas medidas em um mesmo instante de tempo) para detectar comportamentos anormais no processo, porém, em muitos casos práticos, o comportamento anormal a ser detectado não é caracterizado por apenas uma observação desviando dos limites de controle, mas sim por uma sequência temporal de observações, formando um padrão anormal (Zorrias-

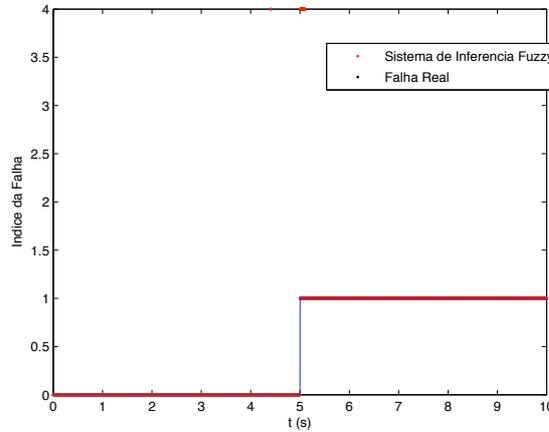


Figura 2.23: Resultado obtido com o sistema de inferência *fuzzy* para a falha de abertura da armadura.

satine et al., 2003). Assim, a metodologia de detecção de novidades proposta analisa as saídas de cartas de controle em janelas temporais para detectar padrões anômalos, que são então associados a possíveis falhas no sistema.

Dado um modelo capaz de realizar estimativas das saídas do sistema, constrem-se cartas de controle estatístico para o seu resíduo, calculado a partir de um conjunto de dados descrevendo o comportamento normal do sistema. Os limites da carta devem ser calculados de forma que seja possível estimar a probabilidade de que uma observação viole os limites de controle (LC), durante condição de operação normal. Em seguida, para cada observação do sistema a ser monitorado, uma variável binária é gerada, sendo que um valor verdadeiro corresponde a uma observação que viole os limites definidos. Finalmente, essa variável é analisada em conjunto pelo detector utilizando uma janela deslizante de tamanho w , de maneira que, a classificação final de cada observação é definida baseando-se na probabilidade de se observar k violações em uma janela de tamanho w .

Inicialmente, deve-se construir um modelo para o sistema. Uma vez contruído, utiliza-se um conjunto de dados de operação normal para construir uma carta de controle para o resíduo. Porém, ao invés de se utilizar regras tradicionais para definir os limites de controle das cartas, tais como 3σ (Montgomery, 2001), utiliza-se uma técnica não paramétrica que possibilita a estimação da probabilidade de violação dos limites de controle durante operação normal, sem que seja necessário definir a função de distribuição do resíduo.

Os limites são calculados através da técnica de intervalos robustos de confiança (Masters,

1995). Essa técnica calcula numericamente intervalos de confiança da distribuição do resíduo, sem que seja necessário definir a forma de sua distribuição de probabilidade. Para isso, utiliza-se a *função de distribuição amostral* do resíduo, $S_n(r)$. Dado um conjunto de n valores do resíduo ordenados, essa função retorna a fração dessa coleção menor ou igual a um dado valor (Masters, 1995):

$$S_n(r) = \begin{cases} 0, & r < r(1) \\ \frac{k}{n}, & r(k) \leq r \leq r(k+1) \\ 1, & r(n) \leq r \end{cases} \quad (2.61)$$

Caso o conjunto de pontos utilizados para calcular $S_n(r)$ represente os valores encontrados na prática e o tamanho desse conjunto seja suficientemente grande, $S_n(r)$ é assumido ser uma boa estimativa da verdadeira função de distribuição de probabilidade do resíduo $F(r)$ (Masters, 1995). Para se calcular os limites de controle do resíduo, define-se um nível de significância α , que corresponde à probabilidade de violação dos limites durante operação normal. Em seguida, para cartas de controle definidas por limites inferiores e superiores, tais como a \bar{x} de *Shewhart* (Montgomery, 2001), descartam-se $n \times \alpha/2$ valores de cada extremo do conjunto ordenado de observações do resíduo, e os limites de controle são definidos como os valores limítrofes do conjunto resultante. Já para cartas de controle definidas por apenas o limite superior, como a T^2 (Montgomery, 2001), descartam-se $n \times \alpha$ do extremo superior.

Uma vez definidas as cartas de controle e seus respectivos limites, para todas as observações do processo, calcula-se sua *ocorrência*:

$$O(t) = \begin{cases} 0, & \text{para } r(t) \in LC \\ 1, & \text{caso contrário} \end{cases} \quad (2.62)$$

Em condições de operação normal, a probabilidade de $O(t) = 1$ é conhecida, sendo assim, $O(t)$ pode ser descrita por uma distribuição de *Bernoulli* com uma probabilidade de sucesso α .

Um *evento* $E_w(t)$ é definido como uma sequência de valores de ocorrência:

$$E_w(t) = [O(t) \ O(t-1) \ \dots \ O(t-w+1)] \quad (2.63)$$

sendo w a duração do evento, definido como um parâmetro do algoritmo.

A partir dos valores de ocorrência e dado o tamanho do evento w , $n - w + 1$ eventos são gerados utilizando-se uma janela deslizante, sendo n o número total de pontos da série

a serem classificados. Sendo assim, o primeiro evento contém os valores de ocorrência relativos aos pontos no intervalo $[1, w]$, o segundo contém os valores relativos ao intervalo $[2, w + 1]$, assim por diante.

Para cada um dos eventos gerados, sua *norma-1*, $|E_w(t)|$, é definida como:

$$|E_w(t)| = \sum_{i=0}^{i=w-1} O(t+i) \quad (2.64)$$

Essa grandeza mede o número violações dos limites de controle em cada evento.

A função de probabilidade de $|E_w(t)|$ é representada como $p(|E_w(t)| = k)$ para $|E_w(t)|$ assumindo valores $k = 0 \dots w$. Para se definir a forma de $p(|E_w(t)| = k)$, assume-se que $E_w(t)$ é uma sequência de variáveis aleatórias independentes e identicamente distribuídas de *Bernoulli* com a mesma probabilidade de sucesso, α . Assim, a função de distribuição probabilidade discreta de $|E_w(t)|$ pode ser descrita como uma distribuição *Binomial*:

$$p(|E_w(t)| = k) = \begin{cases} \binom{w}{k} \alpha^k (1-\alpha)^{w-k}, & k = 0 \dots w \\ 0, & \text{c.c.} \end{cases} \quad (2.65)$$

A distribuição descrita em (2.65) calcula a probabilidade de se observar k violações dos limites de controle em uma janela de w observações, assumindo-se que o processo opere em condições normais. Uma alta probabilidade sugere que o processo esteja operando em condições normais, enquanto uma baixa probabilidade sugere condições anormais de operação, que são então associadas a falhas.

Dado o nível de significância α , um evento $E_w(t)$ é definido como um *evento de novidade* se o valor de $|E_w(t)|$ for maior que o limite do intervalo de confiança unilateral construído para $p(|E_w(t)| = k)$.

Dadas as ocorrências e o limiar do intervalo de confiança de $p(|E_w(t)| = k)$, os eventos são classificados como normais ou eventos de novidades. Caso o evento seja classificado como evento de novidade, o último ponto pertencente ao evento é classificado como novidade, ou seja, caso o evento $E_n(t)$ seja classificado como um evento de novidade, o ponto $x(t+w-1)$ é definido como novidade.

A figura 2.24 apresenta um diagrama ilustrativo da metodologia proposta.

A metodologia proposta possui os seguintes parâmetros:

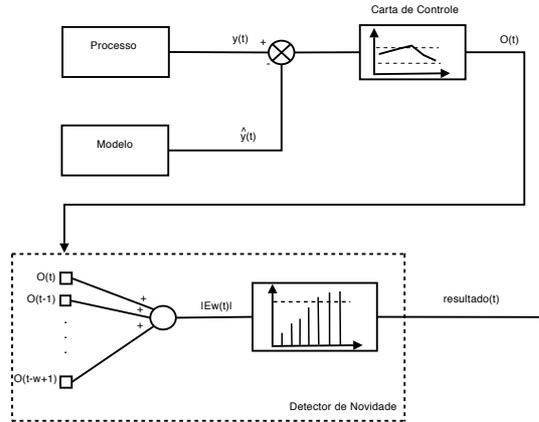


Figura 2.24: Metodologia proposta para detecção de falhas em sistemas dinâmicos baseada em detecção de novidades

- α , o nível de significância utilizado para calcular os limites de controle do resíduo e o intervalo unilateral de confiança de $p(|E_w(t)| = k)$.
- w , o tamanho do evento, ou seja, o tamanho da janela utilizada para processar as ocorrências em conjunto.

Para o problema em questão, utilizou-se como modelo um observador de Luenberger. Para esse experimento, o modelo do motor de corrente contínua foi modificado, um ruído gaussiano de medição com média nula e variância igual a 0.1% do valor nominal das variáveis de saída do modelo. O resíduo deste observador é formado por 3 componentes relacionadas às três saídas do modelo, sendo assim, utilizou-se uma carta de controle T^2 . Os parâmetros do algoritmo foram ajustados para: $\alpha = 0.05$ e $w = 50$. Para estimar o limite da carta de controle foram utilizadas 2500 observações do resíduo do modelo durante condições de operação normais. A figura 2.25 ilustra o resultado da detecção para a simulação da falha de abertura da bobina da armadura.

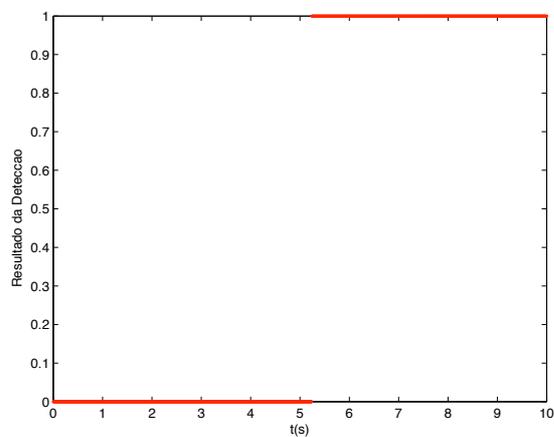


Figura 2.25: Resultado do detector para a simulação da falha de abertura da armadura

Capítulo 3

Evolução Metodológica

A detecção de pontos de mudança em uma seqüência de dados que represente com consistência o comportamento de um sistema dinâmico, será considerado, no decorrer do texto, como evidência de ocorrência de falha.

Vários são os trabalhos que abordam o problema de detecção de pontos de mudança, como em séries financeiras (Oh et al., 2005), séries ecológicas (Beckage et al., 2007), série de índice de criminalidade (Loschi et al., 2005), etc. As principais técnicas para detecção de pontos de mudança apresentadas na literatura são baseadas em testes estatísticos e abordagens *bayesianas*. O teste estatístico mais comum no problema de detecção de pontos de mudança é o CUSUM (Cumulative Sum) e no contexto de análise *bayesiana* são largamente utilizados os métodos MCMC. Existem também abordagens alternativas, como por exemplo, uma abordagem proposta em (Wu and Chen, 1999) que usa entropia *fuzzy* associada a uma variação do CUSUM.

O teste CUSUM proposto por (Hinkey, 1971) é largamente utilizado na detecção de pontos de mudança, e suas modificações e extensões podem ser vistas em (Hadjiliadis and Moustakides, 2006), (Lee et al., 2006a), e (Lee et al., 2006b), bem como suas aplicações.

No contexto de abordagens *bayesianas* temos como referência o trabalho de (Barry and Hartigan, 1993), que utiliza o modelo partição produto (mpp) para a identificação de pontos de mudança na média de dados com distribuição normal. Em (Loschi and Cruz, 2005b) a probabilidade *a posteriori* de um instante ser um ponto de mudança é usada como medida de evidência de que o comportamento de uma seqüência de dados mude em algum instante. Em (Loschi and Cruz, 2005a) é avaliada a eficiência da medida na identificação de mudanças, propostas em (Loschi and Cruz, 2005b), na taxa da distribuição

Poisson, em dados seqüencialmente observados, sendo feita a comparação com a medida proposta por (Hartigan, 1990).

Entretanto, todos esses trabalhos exigem algum conhecimento *a priori* do comportamento estatístico da série temporal, por exemplo, qual tipo de distribuição que melhor representa seu comportamento dinâmico. Neste trabalho é proposta uma abordagem onde não é preciso ter esse conhecimento *a priori* sobre a série temporal, pois será mostrado empiricamente que uma classe de séries temporais, após sofrer uma transformação definida por operações *fuzzy*, sempre conduz a séries que podem ser adequadamente aproximadas por séries com distribuição *beta*. A parametrização da distribuição *beta*, portanto, é utilizada para substituir o conhecimento *a priori* a respeito da série temporal.

3.1 Quantização da Série Temporal

A teoria dos conjuntos *fuzzy*, proposta por (Zadeh, 1965), tem recebido muita atenção recentemente, não somente no âmbito de desenvolvimentos teóricos, mas também em aplicações. Uma de suas principais aplicações ocorre em métodos de agrupamentos, visto que os métodos clássicos de agrupamentos separam os dados em k categorias, e em muitos casos, alguns elementos não podem pertencer a uma categoria específica, pois pertencem a duas ou mais categorias simultaneamente. Utilizar métodos de agrupamentos *fuzzy* é uma boa maneira de resolver tal problema, pois, diferente da abordagem clássica, um elemento pode pertencer a mais de uma categoria simultaneamente.

Nessa seção é proposta uma alternativa de quantização da série temporal, através de agrupamento *fuzzy*, para ser utilizada no algoritmo Metropolis-Hastings, como mostrado a seguir.

No decorrer desta seção serão utilizadas as seguintes séries temporais¹:

$$y(t) = \begin{cases} p_1 + 0.1 * \epsilon(t) - 0.1 * \epsilon(t - 1), & \text{se } t \leq m, \\ p_2 + 0.1 * \epsilon(t) - 0.1 * \epsilon(t - 1), & \text{se } t > m \end{cases} \quad (3.1)$$

¹Note que estas séries temporais foram introduzidas somente para ilustrar os passos da metodologia proposta, visto que a acurácia da abordagem para detecção de falhas incipientes será apresentada nas duas próximas seções.

$$y(t) = \begin{cases} p_1 + 0.1 * \epsilon(t) - 0.1 * \epsilon(t - 1), & \text{se } t \leq m_1, \\ (t - m_1) \frac{p_2 - p_1}{m_2 - m_1} + p_1 + 0.1 * \epsilon(t) - 0.1 * \epsilon(t - 1), & \text{se } t > m_1 \text{ e } t \leq m_2, \\ p_2 + 0.1 * \epsilon(t) - 0.1 * \epsilon(t - 1), & \text{se } t > m_2 \end{cases} \quad (3.2)$$

sendo p_1 o primeiro ponto de operação, p_2 o segundo ponto de operação, $\epsilon(t)$ é um ruído com distribuição $\pi(\cdot)$, m é o ponto de mudança para (3.1) e $[m_1, m_2]$ é o intervalo onde ocorre o ponto de mudança em (3.2).

Definição (Agrupamento fuzzy): *Seja $y(t)$ uma série temporal, e considere um inteiro positivo k . Defina o conjunto*

$$C = \{C_i \mid \min\{y(t)\} \leq C_i \leq \max\{y(t)\}, i = 1, 2, \dots, k\}$$

que resolve o problema de minimização:

$$\min \sum_{i=1}^k \sum_{\mu_i(t) \in C_i} \|\mu_i(t) - C_i\|^2 \quad (3.3)$$

então $C = \{C_i, i = 1, 2, \dots, k\}$, que minimiza (3.3), é o conjunto de centros da série temporal $y(t)$. Em (3.3),

$$\mu_i(t) \triangleq \left[\sum_{j=1}^k \frac{\|y(t) - C_i\|^2}{\|y(t) - C_j\|^2} \right]^{-1} \quad (3.4)$$

é o grau de pertinência fuzzy de $y(t)$ em relação a cada centro C_i . ■

Repare que, tendo em conta um conjunto C de centros, a tarefa de medir a distância de cada ponto na série temporal $y(t)$ à cada centro C_i é fácil, o problema é encontrar os centros que resolvam (3.3). Para resolver esse problema existem várias abordagens, por exemplo K-means (Kaufman and Rousseeuw, 1990), C-means (Bezdek, 1981), rede de Kohonen (Kohonen, 2001), etc.. Neste trabalho, uma abordagem via rede de Kohonen foi usada.

A seguir é descrito o procedimento de quantização da série temporal:

- (a) Apresente a série temporal $y(t)$ (dada em (3.1 ou 3.2 e ilustradas nas Figuras 3.1(a) e 3.1(b));
- (b) Encontre um conjunto k de centros (nesse caso dois centros), $C = \{C_i, \min\{y(t)\} \leq C_i \leq \max\{y(t)\}, i = 1, 2\}$, que minimize a distância *euclidiana* conforme (3.3) e ilustrados nas Figuras 3.1(a) e 3.1(b) considerando, por exemplo, as séries temporais (3.1) e (3.2).
- (c) Calcule o grau de pertinência *fuzzy* como dado em (3.4), para cada amostra da série temporal, $y(t)$, em relação a cada centro C_i (como ilustrado nas Figuras 3.1(c) e 3.1(d) considerando, por exemplo, as séries temporais (3.1) e (3.2)).

Repare que, uma vez que a ideia é encontrar apenas um ponto de mudança, apenas dois centros serão encontrados. A função $\mu_1(t)$ define a nova série temporal em que o ponto de mudança deverá ser detectado.

Tomando novamente a série temporal $y(t)$ em (3.1), a Figura 3.2 ilustra o histograma do grau de pertinência *fuzzy* $\mu_1(t)$ para $t \leq 30$ (antes do ponto de mudança), e a Figura 3.3 ilustra o histograma de $\mu_1(t)$ para $t > 30$ (depois do ponto de mudança).

Para ilustrar a técnica proposta, as Figuras 3.4-3.9 apresentam os histogramas de $\mu_1(t)$ para $t \leq 100$ e $t > 100$, with $p_1 = 1$, $p_2 = 1.5$, $m = 100$, 200 amostras e diferentes distribuições para $e(t)$ na série temporal (3.1), a saber $U(0, 1)$ (distribuição uniforme) nas Figuras 3.4 e 3.5, $N(0, 1)$ (distribuição normal(0,1)) na Figuras 3.6 e 3.7, e $t(5)$ (distribuição student's-t(5)) nas Figuras 3.8 e 3.9, respectivamente.

Além disso, é evidente que as distribuições de $\mu_1(t)$, de acordo com (3.4), estão confinados em $[0, 1]$, como mostrado a seguir:

- se $y(t) \rightarrow C_1$ então $\mu_1(t) \rightarrow 1^-$
- se $y(t) \rightarrow C_2$ então $\mu_1(t) \rightarrow 0^+$
- se $C_1 \rightarrow C_2$ então $\mu_1(t) \rightarrow \frac{1}{2}$
- se $y(t) \in [C_1, C_2]$ então $\mu_1(t) \in [0, 1]$

e usando a divergência de Kullback-Leibler (Kullback and Leibler, 1951) pode-se concluir que a distribuição de $\mu_1(t)$, como ilustrado nas Figuras 3.4-3.9, segue uma família de distribuições *beta* com diferentes parâmetros de entrada: para $\mu_1(t)$, $t \leq 100$, tem-se uma distribuição *beta*(a, b), ou uma distribuição *beta*(c, d), se $t > 100$.

Essa quantização da série temporal garante que $\mu_1(t)$ (a nova série temporal) pode ser sempre aproximada por uma função de distribuição *beta*, esse modelo fixo será usado na formulação *bayesiana* para detectar ponto de mudança. Neste trabalho, será utilizado o algoritmo Metropolis-Hastings, uma vez que se trata de uma estratégia simples e eficiente.

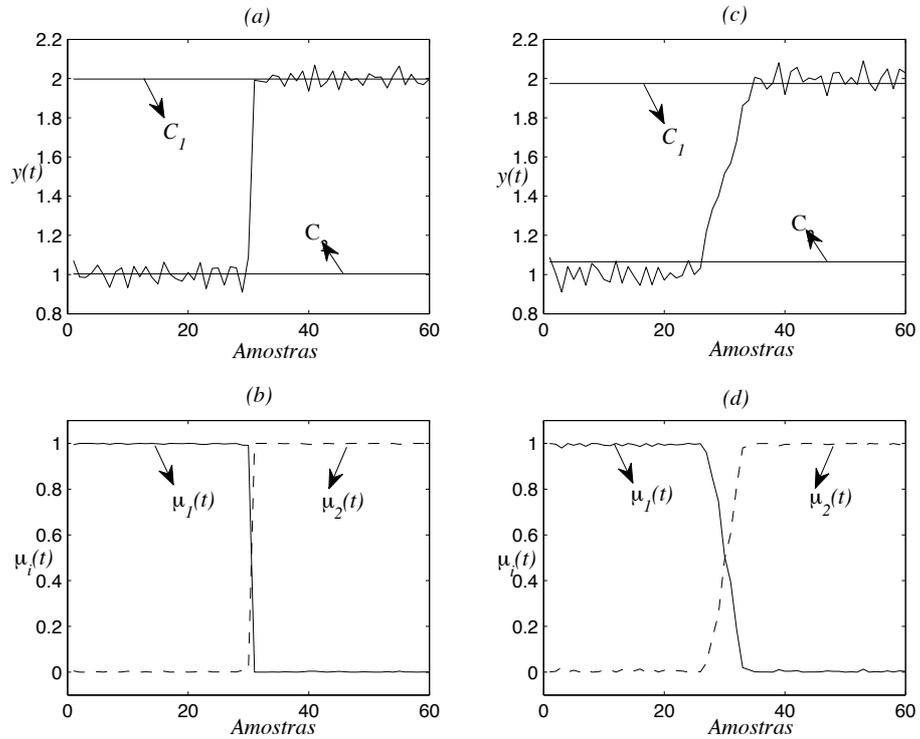


Figura 3.1: (a) Centros da série temporal para $y(t)$ dada em (3.1); (b) Funções de pertinência, $\mu_1(t)$ (—) e $\mu_2(t)$ (---) para $y(t)$ em (3.1); (c) Centros da série temporal para $y(t)$ dada em (3.2); (d) Funções de pertinência, $\mu_1(t)$ (—) e $\mu_2(t)$ (---) para $y(t)$ em (3.2).

3.2 Modelo de Identificação de Ponto de Mudança

O algoritmo Metropolis-Hastings (Gamerman, 1997) será usado para detectar ponto de mudança em séries temporais, sendo que seu objetivo é construir uma cadeia Markov que tem uma determinada distribuição equilíbrio π .

Defina uma cadeia de Markov como segue. Se $X_i = x_i$, então gere um valor candidato y a partir de uma distribuição com densidade $f_{Y|X}(y) = q(x_i, y)$. A função $q(\cdot)$ é conhecida como o núcleo de transição da cadeia de Markov. O valor candidato Y é aceito ou rejeitado com probabilidade de aceitação:

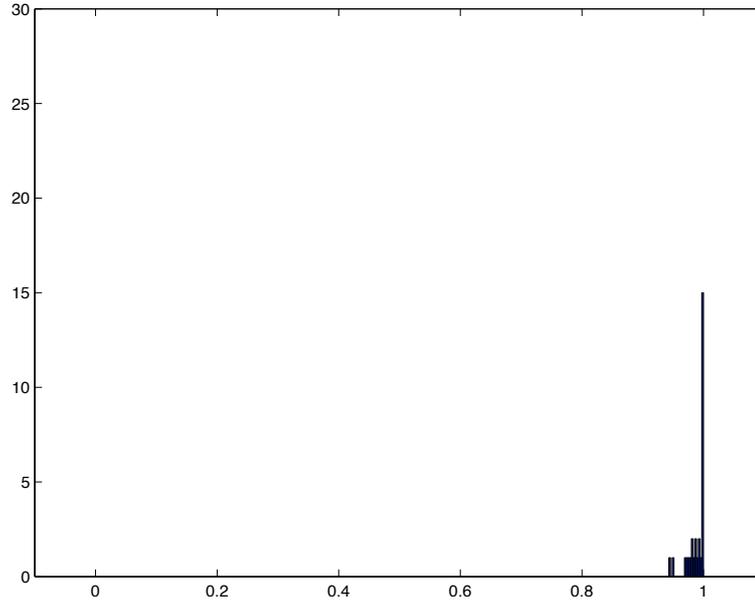


Figura 3.2: Histograma do grau de pertinência *fuzzy* $\mu_1(t)$ para $t \leq 30$.

$$\alpha(x, y) = \min \left(1, \frac{\pi(y) q(y, x_i)}{\pi(x_i) q(x_i, y)} \right) \quad (3.5)$$

Se a candidata for aceita, faça $X_{i+1} = Y$, caso contrário faça $X_{i+1} = X_i$. Assim, se a candidata for rejeitada, a cadeia de Markov repete a seqüência de estados. É possível mostrar que, em condições gerais a seqüência X_0, X_1, X_2, \dots é uma cadeia de Markov com distribuição de equilíbrio π .

Em termos práticos, o algoritmo Metropolis-Hastings pode ser especificado pelos seguintes passos:

- (a) Escolha um valor inicial x_0 , o número de iterações, R , e faça o contador de iterações $r = 0$;
- (b) Gere um valor candidato $y \sim q(x_i, \cdot)$;
- (c) Calcule a probabilidade de aceitação em (3.5) e gere $u \sim U(0, 1)$;
- (d) Calcule o novo valor do estado atual:

$$x_{i+1} = \begin{cases} y, & \text{se } \alpha(x, y) \geq u, \\ x_i, & \text{caso contrário} \end{cases}$$

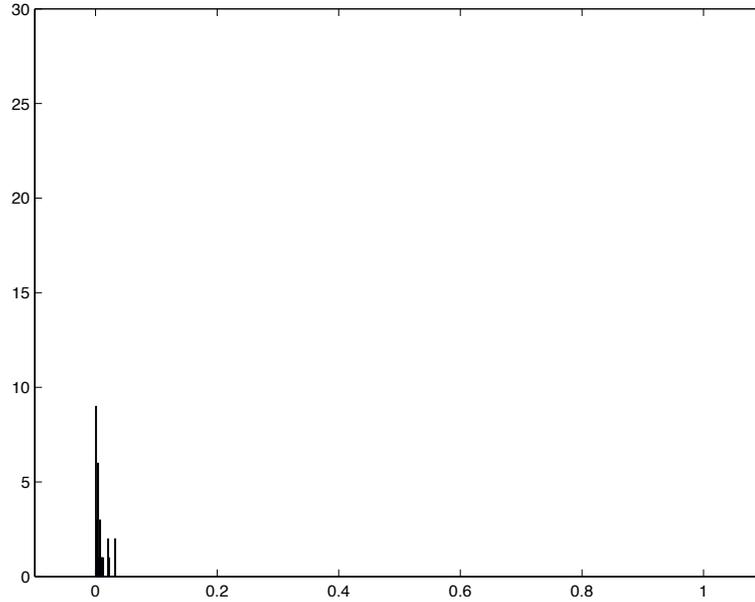


Figura 3.3: Histograma do grau de pertinência *fuzzy* $\mu_1(t)$ para $t > 30$.

(e) Se $r < R$, retorne ao passo 2. Caso contrário pare.

Note que, como discutido na seção anterior, a técnica de quantização gera uma série temporal transformada com a seguinte distribuição de probabilidade:

$$y(t) \sim \text{beta}(a, b), \text{ para } t = 1, \dots, m$$

$$y(t) \sim \text{beta}(c, d), \text{ para } t = m + 1, \dots, n$$

Os parâmetros a serem estimados pelo algoritmo Metropolis-Hastings são a , b , c , d e o ponto de mudança m . Nesse tipo de algoritmo, normalmente, a escolha de *prioris* pouco informativas são utilizadas, por exemplo:

$$a \sim \text{gamma}(0.1, 0.1)$$

$$b \sim \text{gamma}(0.1, 0.1)$$

$$c \sim \text{gamma}(0.1, 0.1)$$

$$d \sim \text{gamma}(0.1, 0.1)$$

$$m \sim U\{1, 2, \dots, n\}, \text{ with } p(m) = \frac{1}{n}$$

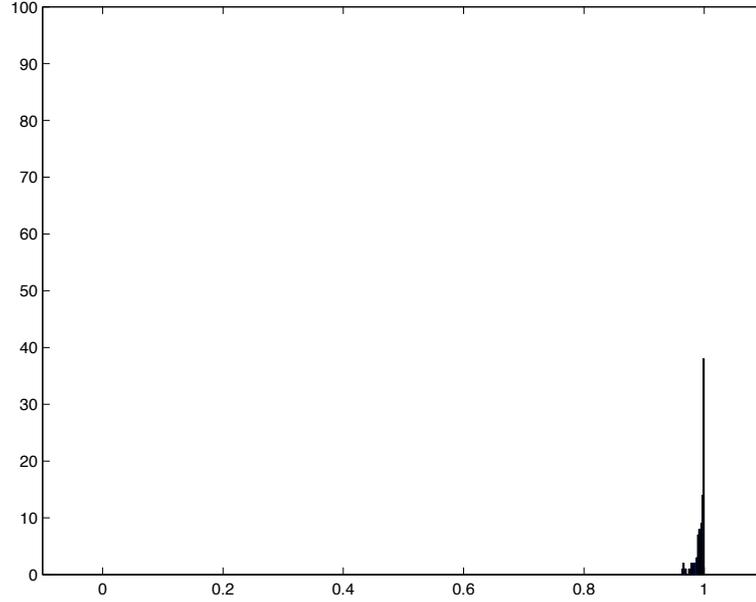


Figura 3.4: Histograma do grau de pertinência *fuzzy* $\mu_1(t)$ para $t \leq 100$ e $e(t) \sim U(0, 1)$.

Essas distribuições, com parâmetros iguais a 0.1, foram escolhidas pelo fato de serem pouco informativas com o objetivo de varrer todo o espaço paramétrico.

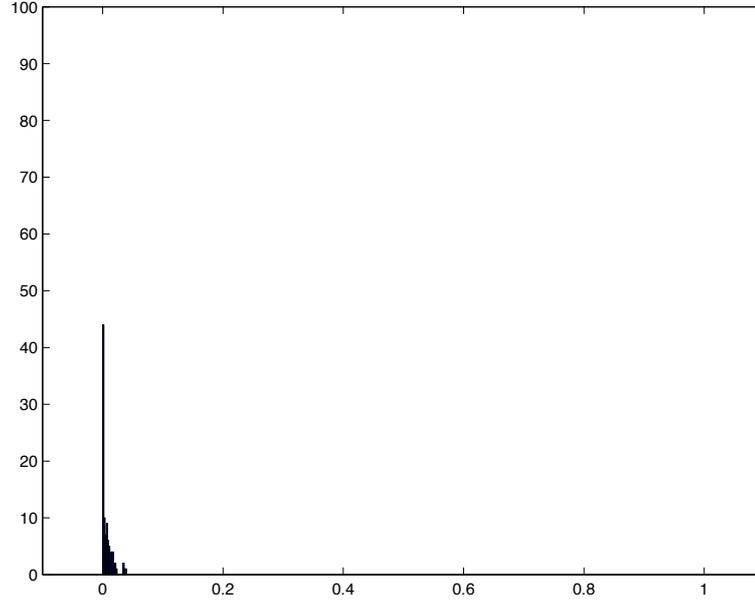
A função de verossimilhança será usada para o cálculo das distribuições de referência, e é dada por:

$$f(y \mid a, b, c, d, m) \sim \prod_{i=1}^m \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} y_i^{a-1} (1-y_i)^{b-1} \prod_{i=m+1}^n \frac{\Gamma(c+d)}{\Gamma(c)\Gamma(d)} y_i^{c-1} (1-y_i)^{d-1} \quad (3.6)$$

Os núcleos de transição das distribuições de referência são calculadas a partir das *prioris* dos parâmetros como a seguir:

- (a) O núcleo de transição distribuição de referência para o parâmetro a :

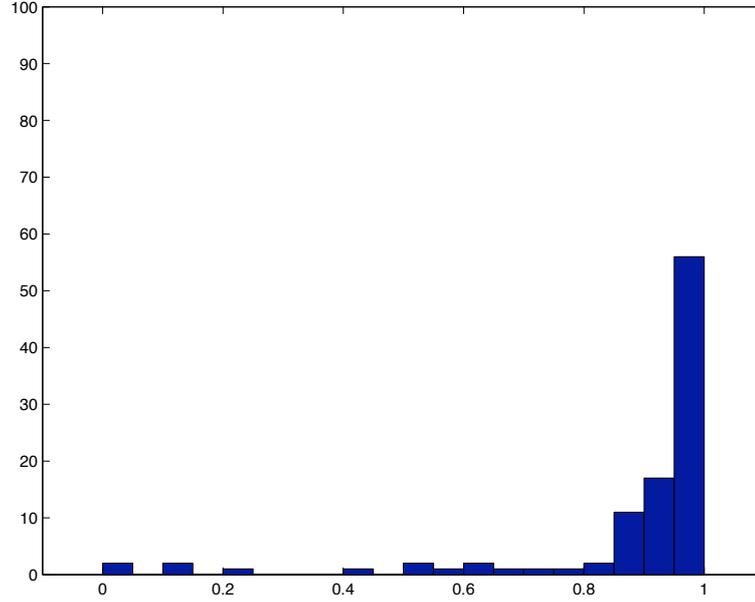
$$\begin{aligned} \frac{\pi(a^*)}{\pi(a_{i-1})} \frac{q(a^*, a_{i-1})}{q(a_{i-1}, a^*)} &= \\ &= \frac{\pi(a^*)}{\pi(a_{i-1})} \frac{f(y \mid a^*, b^{i-1}, c^{i-1}, d^{i-1}, m^{i-1}) \pi(a^*) \pi(b^{i-1}) \pi(c^{i-1}) \pi(d^{i-1}) \pi(m^{i-1})}{f(y \mid a^{i-1}, b^{i-1}, c^{i-1}, d^{i-1}, m^{i-1}) \pi(a^{i-1}) \pi(b^{i-1}) \pi(c^{i-1}) \pi(d^{i-1}) \pi(m^{i-1})} \\ &= \frac{\left[\frac{\Gamma(a^* + b^{i-1})}{\Gamma(a^*) \Gamma(b^{i-1})} \right]^{m^{i-1}} \left[\frac{\Gamma(c^{i-1} + d^{i-1})}{\Gamma(c^{i-1}) \Gamma(d^{i-1})} \right]^{n - m^{i-1}} \prod_{j=1}^{m^{i-1}} [y_j^{a^* - 1} (1 - y_j)^{b^{i-1} - 1}]}{\left[\frac{\Gamma(a^{i-1} + b^{i-1})}{\Gamma(a^{i-1}) \Gamma(b^{i-1})} \right]^{m^{i-1}} \left[\frac{\Gamma(c^{i-1} + d^{i-1})}{\Gamma(c^{i-1}) \Gamma(d^{i-1})} \right]^{n - m^{i-1}} \prod_{j=1}^{m^{i-1}} [y_j^{a^{i-1} - 1} (1 - y_j)^{b^{i-1} - 1}]} \end{aligned}$$


 Figura 3.5: Histograma do grau de pertinência *fuzzy* $\mu_1(t)$ para $t > 100$ e $e(t) \sim U(0, 1)$.

$$\begin{aligned}
 & \times \frac{\prod_{j=m^{i-1}+1}^n [y_j^{c^{i-1}-1} (1-y_j)^{d^{i-1}-1}]}{\prod_{j=m^{i-1}+1}^n [y_j^{c^{i-1}-1} (1-y_j)^{d^{i-1}-1}]} \frac{0.1^{0.1} [\Gamma(0.1)]^{-1} a^{*0.1-1} e^{-0.1a^*}}{0.1^{0.1} [\Gamma(0.1)]^{-1} a^{i-1} 0.1^{-1} e^{-0.1a^{i-1}}} \\
 & = \frac{\left[\frac{\Gamma(a^*+b^{i-1})}{\Gamma(a^*)\Gamma(b^{i-1})} \right]^{m^{i-1}} \prod_{j=1}^{m^{i-1}} y_j^{a^*-1} \left[\frac{a^{i-1}}{a^*} \right]^{0.9} e^{-0.1(a^*-a^{i-1})}^2}{\left[\frac{\Gamma(a^{i-1}+b^{i-1})}{\Gamma(a^{i-1})\Gamma(b^{i-1})} \right]^{m^{i-1}} \prod_{j=1}^{m^{i-1}} y_j^{a^{i-1}-1}}
 \end{aligned}$$

(b) O núcleo de transição distribuição de referência para o parâmetro b :

$$\begin{aligned}
 & \frac{\pi(b^*)}{\pi(b_{i-1})} \frac{q(b^*, b_{i-1})}{q(b_{i-1}, b^*)} = \\
 & = \frac{\pi(b^*)}{\pi(b_{i-1})} \frac{f(y|a^i, b^*, c^{i-1}, d^{i-1}, m^{i-1}) \pi(a^i) \pi(b^*) \pi(c^{i-1}) \pi(d^{i-1}) \pi(m^{i-1})}{f(y|a^i, b^{i-1}, c^{i-1}, d^{i-1}, m^{i-1}) \pi(a^i) \pi(b^{i-1}) \pi(c^{i-1}) \pi(d^{i-1}) \pi(m^{i-1})} \\
 & = \frac{\left[\frac{\Gamma(a^i+b^*)}{\Gamma(a^i)\Gamma(b^*)} \right]^{m^{i-1}} \left[\frac{\Gamma(c^{i-1}+d^{i-1})}{\Gamma(c^{i-1})\Gamma(d^{i-1})} \right]^{n-m^{i-1}} \prod_{j=1}^{m^{i-1}} [y_j^{a^i-1} (1-y_j)^{b^*-1}]}{\left[\frac{\Gamma(a^i+b^{i-1})}{\Gamma(a^i)\Gamma(b^{i-1})} \right]^{m^{i-1}} \left[\frac{\Gamma(c^{i-1}+d^{i-1})}{\Gamma(c^{i-1})\Gamma(d^{i-1})} \right]^{n-m^{i-1}} \prod_{j=1}^{m^{i-1}} [y_j^{a^{i-1}-1} (1-y_j)^{b^{i-1}-1}]} \\
 & \times \frac{\prod_{j=m^{i-1}+1}^n [y_j^{c^{i-1}-1} (1-y_j)^{d^{i-1}-1}]}{\prod_{j=m^{i-1}+1}^n [y_j^{c^{i-1}-1} (1-y_j)^{d^{i-1}-1}]} \frac{0.1^{0.1} [\Gamma(0.1)]^{-1} b^{*0.1-1} e^{-0.1b^*}}{0.1^{0.1} [\Gamma(0.1)]^{-1} b^{i-1} 0.1^{-1} e^{-0.1b^{i-1}}}
 \end{aligned}$$

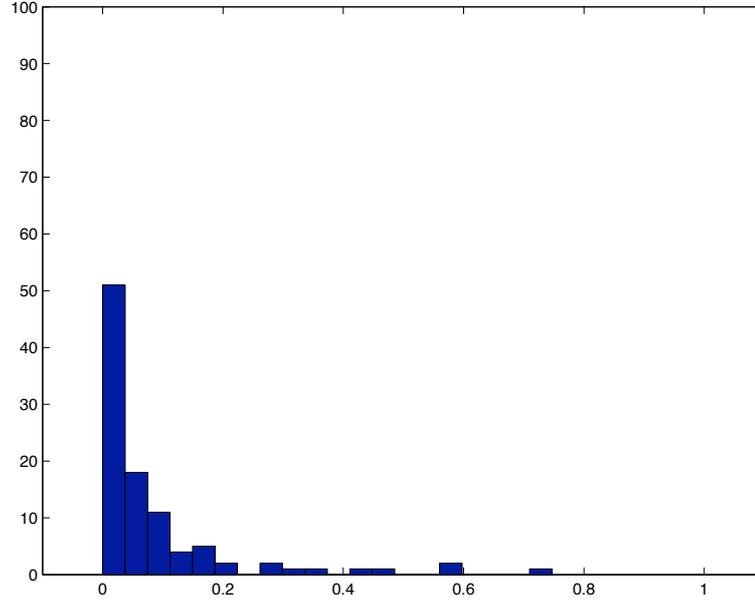

 Figura 3.6: Histograma do grau de pertinência *fuzzy* $\mu_1(t)$ para $t \leq 100$ e $e(t) \sim N(0, 1)$.

$$= \frac{\left[\frac{\Gamma(a^i + b^*)}{\Gamma(a^i)\Gamma(b^*)} \right]^{m^{i-1}} \prod_{j=1}^{m^{i-1}} y_j^{b^*-1} \left[\frac{b^{i-1}}{b^*} \right]^{0.9} e^{-0.1(b^* - b^{i-1})}^2}{\left[\frac{\Gamma(a^{i-1} + b^{i-1})}{\Gamma(a^{i-1})} \right]^{m^{i-1}} \prod_{j=1}^{m^{i-1}} y_j^{b^{i-1}-1}}$$

(c) O núcleo de transição distribuição de referência para o parâmetro c :

$$\begin{aligned} & \frac{\pi(c^*) q(c^*, c_{i-1})}{\pi(c_{i-1}) q(c_{i-1}, c^*)} = \\ & = \frac{\pi(c^*)}{\pi(c_{i-1})} \frac{f(y|a^i, b^i, c^*, d^{i-1}, m^{i-1}) \pi(a^i) \pi(b^i) \pi(c^i) \pi(d^{i-1}) \pi(m^{i-1})}{f(y|a^i, b^i, c^{i-1}, d^{i-1}, m^{i-1}) \pi(a^i) \pi(b^{i-1}) \pi(c^{i-1}) \pi(d^{i-1}) \pi(m^{i-1})} \\ & = \frac{\left[\frac{\Gamma(a^i + b^i)}{\Gamma(a^i)\Gamma(b^i)} \right]^{m^{i-1}} \left[\frac{\Gamma(c^* + d^{i-1})}{\Gamma(c^*)\Gamma(d^{i-1})} \right]^{n-m^{i-1}} \prod_{j=1}^{m^{i-1}} [y_j^{a^i-1} (1-y_j)^{b^i-1}]}{\left[\frac{\Gamma(a^i + b^{i-1})}{\Gamma(a^i)\Gamma(b^{i-1})} \right]^{m^{i-1}} \left[\frac{\Gamma(c^{i-1} + d^{i-1})}{\Gamma(c^{i-1})\Gamma(d^{i-1})} \right]^{n-m^{i-1}} \prod_{j=1}^{m^{i-1}} [y_j^{a^{i-1}-1} (1-y_j)^{b^{i-1}-1}]} \\ & \times \frac{\prod_{j=m^{i-1}+1}^n [y_j^{c^*-1} (1-y_j)^{d^{i-1}-1}]}{\prod_{j=m^{i-1}+1}^n [y_j^{c^{i-1}-1} (1-y_j)^{d^{i-1}-1}]} \frac{0.1^{0.1} [\Gamma(0.1)]^{-1} c^{*0.1-1} e^{-0.1c^*}}{0.1^{0.1} [\Gamma(0.1)]^{-1} c^{i-1,0.1-1} e^{-0.1c^{i-1}}} \\ & = \frac{\left[\frac{\Gamma(c^* + d^{i-1})}{\Gamma(c^*)\Gamma(d^{i-1})} \right]^{m^{i-1}} \prod_{j=1}^{m^{i-1}} y_j^{c^*-1} \left[\frac{c^{i-1}}{c^*} \right]^{0.9} e^{-0.1(c^* - c^{i-1})}^2}{\left[\frac{\Gamma(c^{i-1} + d^{i-1})}{\Gamma(c^{i-1})\Gamma(d^{i-1})} \right]^{m^{i-1}} \prod_{j=1}^{m^{i-1}} y_j^{c^{i-1}-1}} \end{aligned}$$

(d) O núcleo de transição distribuição de referência para o parâmetro d :


 Figura 3.7: Histograma do grau de pertinência *fuzzy* $\mu_1(t)$ para $t > 100$ e $e(t) \sim N(0, 1)$.

$$\begin{aligned}
 \frac{\pi(d^*)}{\pi(d_{i-1})} \frac{q(d^*, d_{i-1})}{q(d_{i-1}, d^*)} &= \\
 &= \frac{\pi(d^*)}{\pi(d_{i-1})} \frac{f(y|a^i, b^i, c^i, d^*, m^{i-1}) \pi(a^i) \pi(b^i) \pi(c^i) \pi(d^*) \pi(m^{i-1})}{f(y|a^i, b^i, c^i, d^{i-1}, m^{i-1}) \pi(a^i) \pi(b^{i-1}) \pi(c^{i-1}) \pi(d^{i-1}) \pi(m^{i-1})} \\
 &= \frac{\left[\frac{\Gamma(a^i + b^i)}{\Gamma(a^i) \Gamma(b^i)} \right]^{m^{i-1}} \left[\frac{\Gamma(c^i + d^*)}{\Gamma(c^i) \Gamma(d^*)} \right]^{n - m^{i-1}} \prod_{j=1}^{m^{i-1}} [y_j^{a^i - 1} (1 - y_j)^{b^i - 1}]}{\left[\frac{\Gamma(a^i + b^{i-1})}{\Gamma(a^i) \Gamma(b^{i-1})} \right]^{m^{i-1}} \left[\frac{\Gamma(c^i + d^{i-1})}{\Gamma(c^i) \Gamma(d^{i-1})} \right]^{n - m^{i-1}} \prod_{j=1}^{m^{i-1}} [y_j^{a^i - 1} (1 - y_j)^{b^i - 1}]} \\
 &\times \frac{\prod_{j=m^{i-1}+1}^n [y_j^{c^i - 1} (1 - y_j)^{d^* - 1}]}{\prod_{j=m^{i-1}+1}^n [y_j^{c^i - 1} (1 - y_j)^{d^{i-1} - 1}]} \frac{0.1^{0.1} [\Gamma(0.1)]^{-1} d^{*0.1-1} e^{-0.1 d^*}}{0.1^{0.1} [\Gamma(0.1)]^{-1} c^{i-1 0.1-1} e^{-0.1 c^{i-1}}} \\
 &= \frac{\left[\frac{\Gamma(c^i + d^*)}{\Gamma(c^i) \Gamma(d^*)} \right]^{m^{i-1}} \prod_{j=1}^{m^{i-1}} y_j^{d^* - 1} \left[\left[\frac{d^{i-1}}{d^*} \right]^{0.9} e^{-0.1(d^* - d^{i-1})} \right]^2}{\left[\frac{\Gamma(c^i + d^{i-1})}{\Gamma(c^i) \Gamma(d^{i-1})} \right]^{m^{i-1}} \prod_{j=1}^{m^{i-1}} y_j^{d^{i-1} - 1}}
 \end{aligned}$$

(e) O núcleo de transição distribuição de referência para o parâmetro m :

$$\begin{aligned}
 \frac{\pi(m^*)}{\pi(m_{i-1})} \frac{q(m^*, m_{i-1})}{q(m_{i-1}, m^*)} &= \\
 &= \frac{\pi(d^*)}{\pi(d_{i-1})} \frac{f(y|a^i, b^i, c^i, d^i, m^*) \pi(a^i) \pi(b^i) \pi(c^i) \pi(d^i) \pi(m^*)}{f(y|a^i, b^i, c^i, d^i, m^{i-1}) \pi(a^i) \pi(b^i) \pi(c^i) \pi(d^i) \pi(m^{i-1})}
 \end{aligned}$$

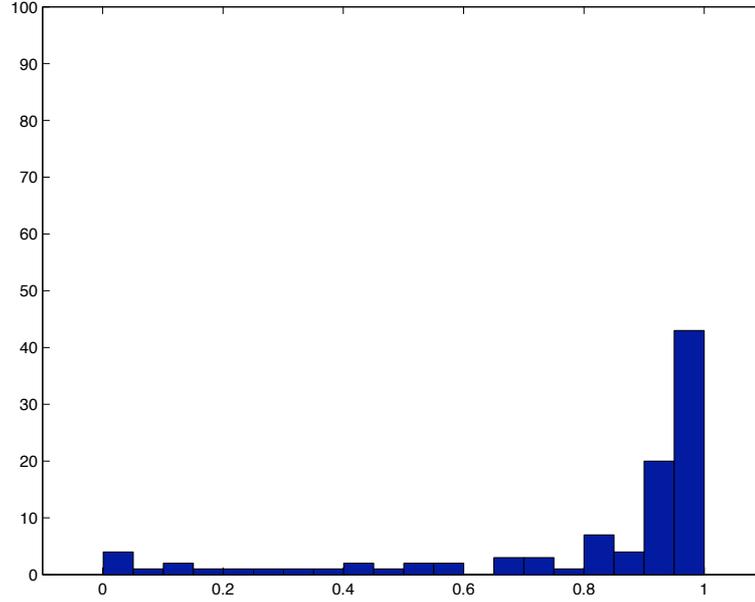


Figura 3.8: Histograma do grau de pertinência *fuzzy* $\mu_1(t)$ para $t \leq 100$ e $e(t) \sim t(5)$.

Sendo $\pi(m^{(\cdot)}) \sim U(0, 1)$, então:

$$\begin{aligned} \frac{\pi(m^*)}{\pi(m_{i-1})} \frac{q(m^*, m_{i-1})}{q(m_{i-1}, m^*)} &= \frac{f(y|a^i, b^i, c^i, d^i, m^*)}{f(y|a^i, b^i, c^i, d^i, m_{i-1})} \\ &= \frac{\left[\frac{\Gamma(a^i + b^i)}{\Gamma(a^i)\Gamma(b^i)} \right]^{m^*} \left[\frac{\Gamma(c^i + d^i)}{\Gamma(c^i)\Gamma(d^i)} \right]^{n-m^*} \prod_{j=1}^{m^*} [y_j^{a^i-1} (1-y_j)^{b^i-1}] \prod_{j=m^*+1}^n [y_j^{c^i-1} (1-y_j)^{d^i-1}]}{\left[\frac{\Gamma(a^i + b^i)}{\Gamma(a^i)\Gamma(b^i)} \right]^{m_{i-1}} \left[\frac{\Gamma(c^i + d^i)}{\Gamma(c^i)\Gamma(d^i)} \right]^{n-m_{i-1}} \prod_{j=1}^{m_{i-1}} [y_j^{a^i-1} (1-y_j)^{b^i-1}] \prod_{j=m_{i-1}+1}^n [y_j^{c^i-1} (1-y_j)^{d^i-1}]} \end{aligned}$$

Para ilustrar a eficiência da metodologia proposta para detecção de pontos de mudança, foi feito um conjunto de simulações considerando (3.1). A tabela 3.1 mostra resultados de 100 simulações para diferentes valores dos parâmetros p_2 , e $e(t)$. É evidente, a partir desta tabela, que a metodologia proposta apresentou 100% de acerto na detecção de pontos de mudança. Como ilustração, considerando somente uma simulação, a Figura 3.10 mostra a convergência dos parâmetros a , b , c , d e m e a Figura 3.11 mostra a probabilidade do ponto de mudança para 1000 simulações de Monte Carlo, sendo as 100 primeiras consideradas como período de aquecimento, para a série (3.1) com $p_1 = 1$, $p_2 = 2$, $e(t) \sim U(0, 1)$, e $m = 30$. Será considerado como regra para a detecção de ponto de mudança onde esta probabilidade de mudança tem um ponto de máximo e este seja um ponto de inflexão, isso descarta a possibilidade de indicação de bordas da série como ponto de mudança,

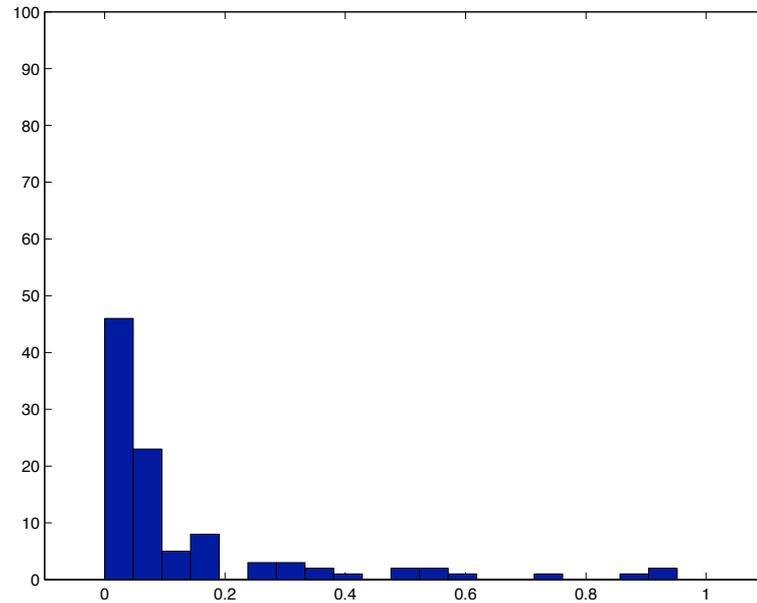


Figura 3.9: Histograma do grau de pertinência $fuzzy \mu_1(t)$ para $t > 100$ e $e(t) \sim t(5)$.

visto que quando não existe mudança aparece este efeito. No caso onde não existe ponto de mudança e o ruído inserido na série temporal em (3.1) segue uma distribuição $t(5)$ a metodologia indicou mudanças em 7 das 100 simulações.

Considerando a série temporal (3.2), onde ocorre mudança de forma gradativa, a Figura 3.12 ilustra o resultado da metodologia (na parte de baixo da Figura) para várias janelas de tempo da série, sendo que a linha grossa indica a janela que foi considerada.

Para fins de ilustração, um observador de Luenberger foi aplicado no *benchmark* proposto no Capítulo 2. A metodologia proposta foi aplicada, em seguida, aos resíduos gerados pelo observador, como ilustrado na Figura 3.13. A Figura 3.14 ilustra o resultado da detecção de mudança nos resíduos gerados pelo observador para as mesmas condições de ruído e tipo de falha apresentadas na Seção 2.2.7. Embora abordar modelos e informações *a priori* não é o enfoque desta tese, este teste serve para mostrar que a metodologia também funciona neste tipo de caso, isto é, informações, apesar de não serem necessárias, são “bem-vindas”. Os dois próximos capítulos desta tese ilustram a aplicação da metodologia em outros dois problemas sem a necessidade de geração de resíduo como necessário em tantas outras abordagens em detecção de falhas.

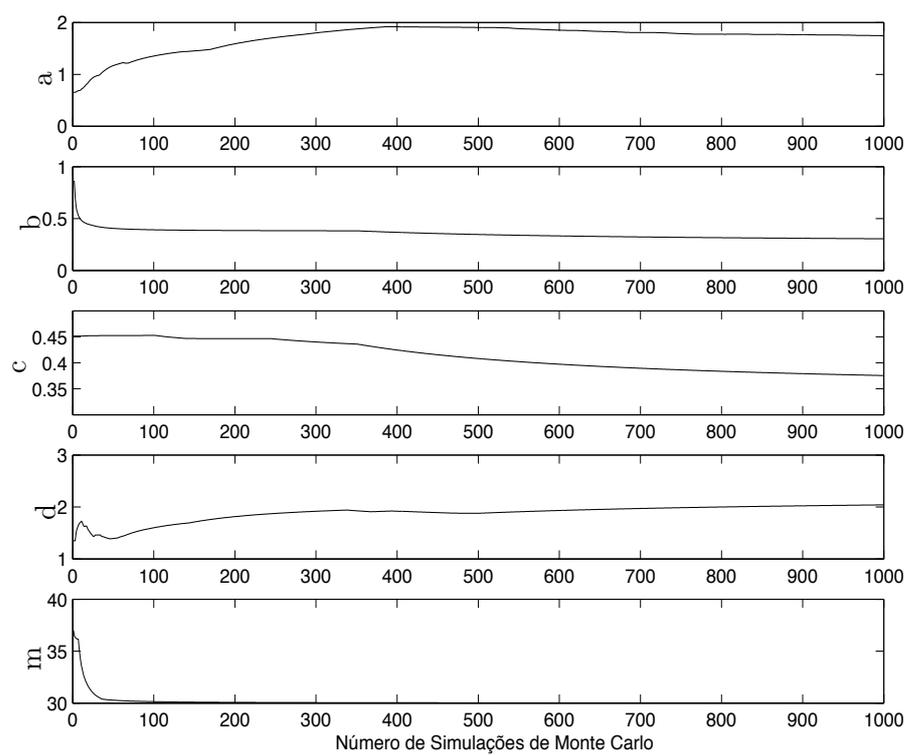


Figura 3.10: Convergência do algoritmo para os parâmetros a , b , c , d e m .

p_1	p_2	m	Amplitude do ruído	% de acerto para $e(t) \sim U(0, 1)$	% de acerto para $e(t) \sim N(0, 1)$	% de acerto para $e(t) \sim t(5)$
1	2	30	0.1	100	100	100
1	1.9	30	0.1	100	100	100
1	1.8	30	0.1	100	100	100
1	1.7	30	0.1	100	100	100
1	1.6	30	0.1	100	100	100
1	1.5	30	0.1	100	100	100
1	1.4	30	0.1	100	100	100
1	1.3	30	0.1	100	100	100
1	1.2	30	0.1	100	100	100
1	1.1	30	0.1	100	100	100
1	1	0	0.1	100	100	93

Tabela 3.1: Resultado da metodologia proposta.

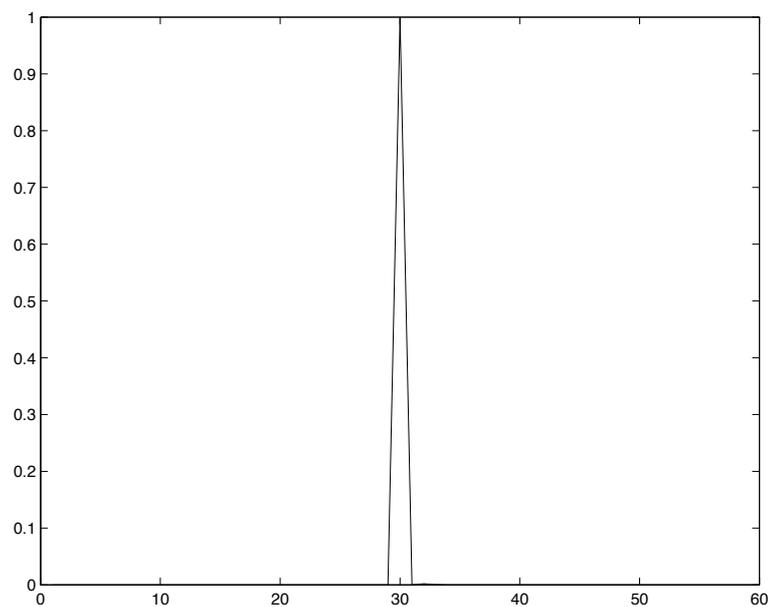


Figura 3.11: Resultado da metodologia proposta para $p_1 = 1$, $p_2 = 2$, $e(t) \sim U(0, 1)$, e $m = 30$.

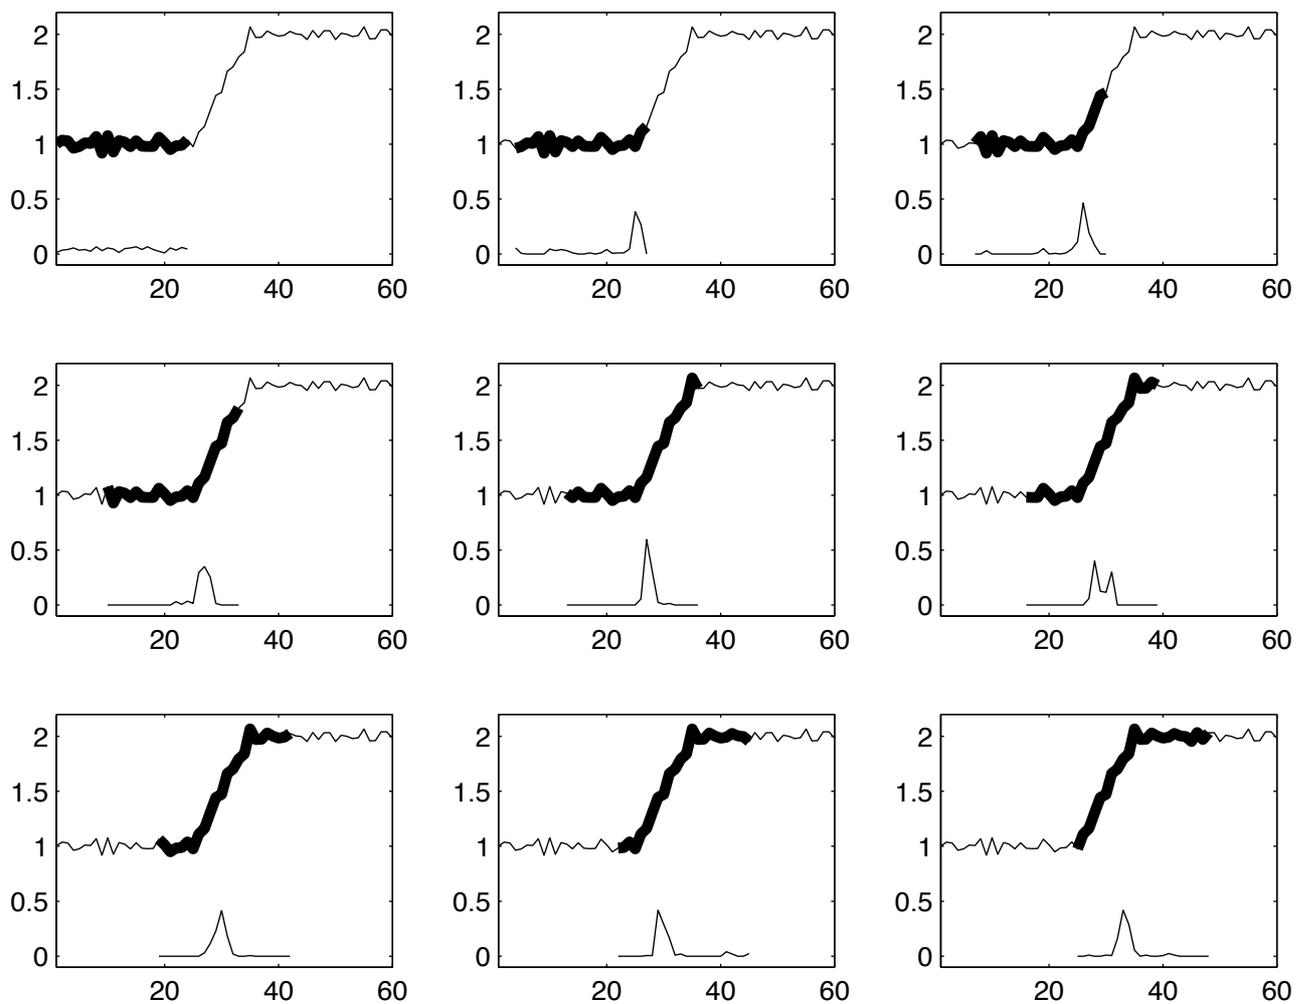


Figura 3.12: Resultado da metodologia para uma série temporal com mudança gradativa.

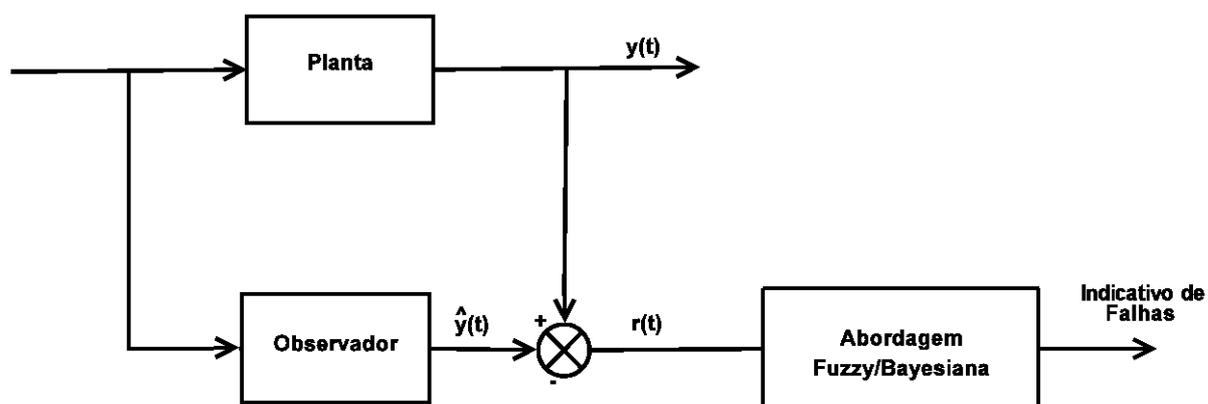


Figura 3.13: Esquema geral de um sistema de FDI associando observadores e o algoritmo proposto para detecção de pontos de mudança.

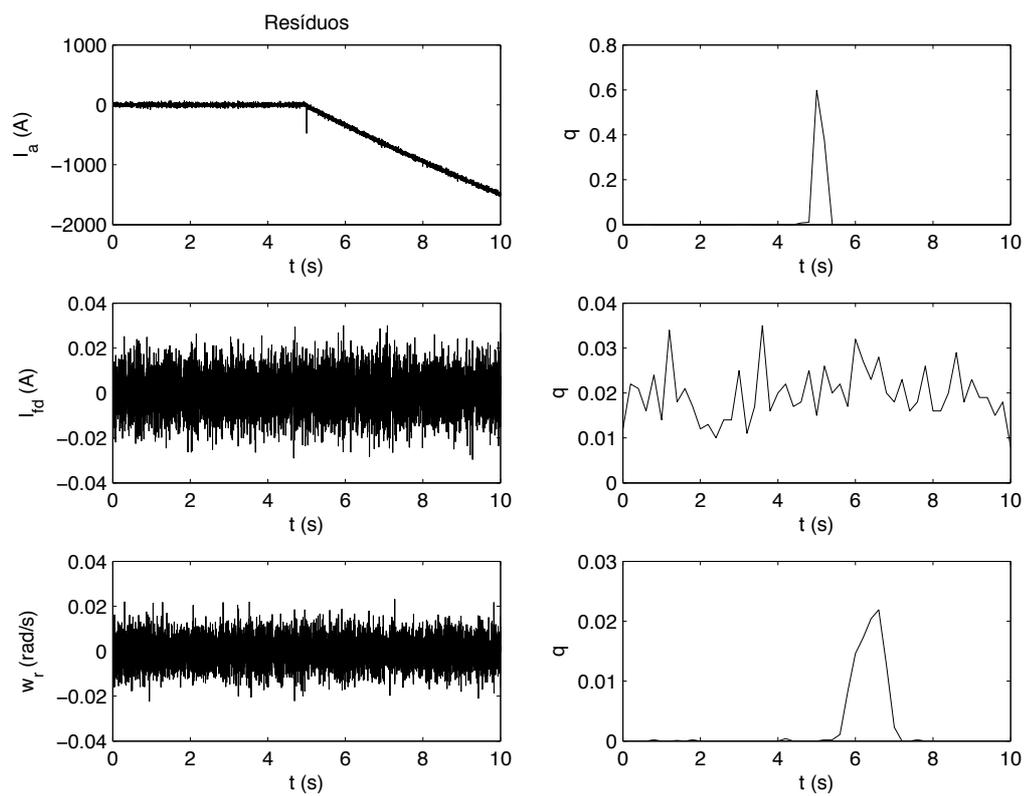


Figura 3.14: Resultado do detector para a simulação da falha de abertura da armadura.

Capítulo 4

Aplicação da Metodologia Proposta no DAMADICS Benchmark

O exemplo prático a ser trabalhado nessa seção é o atuador industrial usado como um *benchmark* de FDI no European RTN DAMADICS, introduzido por Bartys et al. (2006) e ilustrado na Figura 4.1. Este *benchmark* de FDI, DAMADICS, tem sido largamente estudado na literatura e é reconhecido como um problema realístico no contexto de um cenário industrial. Como pode ser visto na literatura, muitos dos artigos lidam com este *benchmark* considerando o problema de falhas abruptas, usando modelos matemáticos baseados em estruturas (Puig et al., 2006), (Previdi and Parisini, 2006), redes neurais (Witczak et al., 2006), classificadores *fuzzy* (Bocaniala and da Costa, 2006), redes *neuro-fuzzy* (Uppal et al., 2006), autômatos temporizados (Supavatanakul et al., 2006). Em todos esses trabalhos algum tipo de conhecimento *a priori* do sistema é usado, como por exemplo limites ou domínios de falhas. Alguns dos trabalhos mencionados afirmam que as abordagens propostas podem ser estendidas para o problema de falhas incipientes, mas sem apresentar algum tipo de simulação que confirme essa afirmação.

No *benchmark* DAMADICS, muitos tipos de falhas na válvula de controle de vazão podem ser analisadas (Bartys et al., 2006). A válvula de controle de vazão foi extensivamente modelada e um programa feito em MATLAB/SIMULINK (Syfert et al., 2002) foi desenvolvido para fins de simulação. A entrada para a simulação baseia-se em dados reais coletados da própria planta onde está inserida a válvula, operando em condição normal e em várias condições de falhas. Este programa prevê condições realísticas para simular o comportamento do sistema enquanto este opera sob condição de falha.

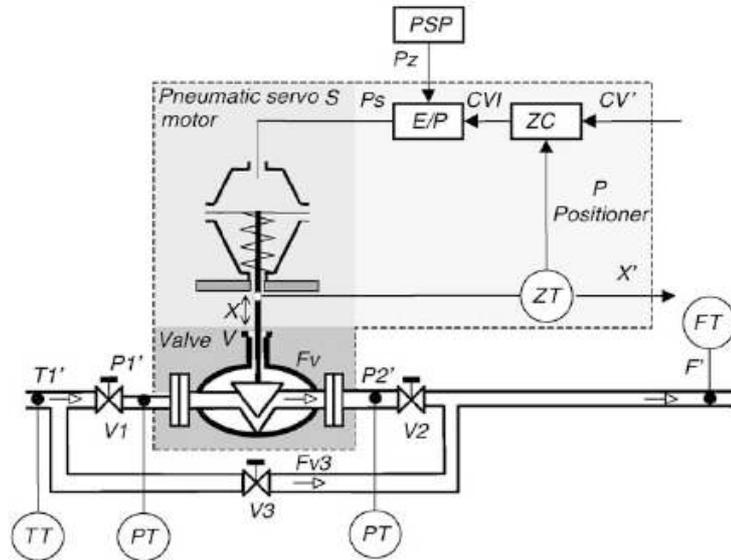


Figura 4.1: European RTN DAMADICS.

A válvula de controle de vazão pode ser afetada por um total de 19 falhas que podem ter comportamento de falhas abruptas e/ou incipientes. Essas falhas são descritas na tabela 4 e seu comportamento é mostrado na tabela 4.2.

Neste trabalho somente manifestações incipientes de falhas serão consideradas. Uma descrição mais detalhada das falhas e a forma de como elas afetam a válvula pode ser encontrada em (Syfert et al., 2002). Há vários sensores na planta com o objetivo de medir as variáveis que afetam a mesma, a saber: pressão de entrada e saída da água, a temperatura da água, a posição da haste e a vazão através da válvula.

Para todos os cenários duas zonas de tempo são definidas:

- Primeira zona, *Set-up zone*, é definida para evitar falsas decisões de FDI que podem ocorrer no início, por exemplo, alguns métodos de FDI precisam ser ajustados depois da partida do processo. Essa zona é limitada pelo tempo t_{on} (veja figura 4.2);
- A segunda zona é a *Benchmark zone*. Todos os resultados (figuras, índices de performance, etc.) são referidos a essa zona e essa é limitada por t_{hor} :

$$t_{hor} = t_{from} + t_{fd} + t_{ov}$$

Código	Localização	Descrição
f1	Válvula de Controle	Válvula entupida
f2	Válvula de Controle	Sedimentação na válvula ou em sua base
f3	Válvula de Controle	Corrosão na válvula ou em sua base
f4	Válvula de Controle	Aumento do atrito na válvula
f5	Válvula de Controle	Vazamento externo
f6	Válvula de Controle	Vazamento interno
f7	Válvula de Controle	Evaporação média ou fluxo crítico
f8	Servo motor	Servo motor com haste torcida
f9	Servo motor	Agarramento da haste do servo motor
f10	Servo motor	Perfuração do diafragma do servo motor
f11	Servo motor	Falha na mola do servo motor
f12	Posicionador	Falha no transdutor eletro-pneumático
f13	Posicionador	Falha no sensor de posição da haste
f14	Posicionador	Falha no sensor de pressão
f15	Posicionador	Falha na mola do posicionador
f16	Geral ou Externa	Queda no suprimento de pressão para o posicionador
f17	Geral ou Externa	Varição inesperada de pressão ao longo da válvula
f18	Geral ou Externa	Válvula de escape aberta totalmente ou parcialmente
f19	Geral ou Externa	Falha no sensor de medição de vazão

Tabela 4.1: Tipos de Falhas do *Benchmark* de FDI

sendo que t_{ov} é o período de tempo predefinido, a partir do momento em que a falha atinge o seu valor máximo.

Código	Abrupta			Incipiente
	Baixa	Média	Alta	
f1	x	x	x	-
f2	-	-	x	Δ_{t1}
f3	-	-	-	Δ_{t1}
f4	-	-	-	Δ_{t2}
f5	-	-	-	Δ_{t1}
f6	-	-	-	Δ_{t1}
f7	x	x	x	-
f8	x	x	x	-
f9	-	-	-	Δ_{t1}
f10	x	x	x	-
f11	-	-	x	Δ_{t1}
f12	x	x	x	-
f13	x	x	x	Δ_{t3}
f14	x	x	x	-
f15	-	-	x	-
f16	x	x	x	-
f17	-	-	x	Δ_{t2}
f18	x	x	x	Δ_{t1}
f19	x	x	x	-

Tabela 4.2: Comportamento das Falhas (Δ_{t3} : 15 minutos; Δ_{t2} : 1 hora; Δ_{t1} : 1 dia).

4.1 Resultados de Simulação para detecção de falhas incipientes no DAMADICS

Os dados usados nessa seção foram gerados pelo *software* de simulação feito na biblioteca Simulink para o projeto DAMADICS de acordo com o procedimento padronizado e de-

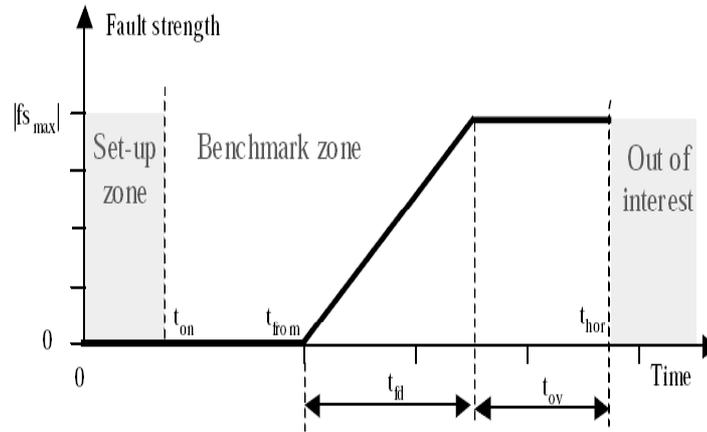


Figura 4.2: Zonas do *benchmark*

scrito em (Syfert et al., 2002). Como mencionado anteriormente, o objetivo desse trabalho é trabalhar com falhas cuja natureza primária é incipiente. Note que, no *benchmark*, somente seis faltas, com características incipientes, f_6 , f_9 , f_{11} , f_{13} , f_{17} , and f_{18} podem ser realmente detectadas, como reportado em Bartys et al. (2006).

As variáveis medidas no *benchmark* são:

- CV : valor de referência (*setpoint*) do processo;
- P_1 : a pressão da água na entrada da válvula;
- P_2 : a pressão da água na saída da válvula;
- X : a posição do tampão da válvula;
- F : a vazão da água;
- T : a temperatura média.

Os resultados de detecção de falhas incipientes usando a metodologia proposta, considerando esses seis tipos de falhas, são apresentados na Tabela 4.3 para 100 simulações de cada tipo de falha com o setpoint fixo. Note que a abordagem proposta detecta com sucesso todas as falhas nas 100 simulações. Além disso, a Tabela 4.3 apresenta a média da amplitude da falha, no momento que ocorreu a detecção, em porcentagem, considerando todas as simulações no DAMADICS operando em regime permanente. Para cada tipo de falha foram usados diferentes combinações de variáveis para a detecção de falhas.

Falha	Variável usada	Acertos (%)	Média da Amplitude da Falha
f_6	F	100	14
f_9	X ou F	100	32
f_{11}	X ou F	100	34
f_{13}	F	100	15
f_{17}	P_2	100	2
f_{18}	F	100	14

Tabela 4.3: Detecção de falhas incipientes no DAMADICS usando o algoritmo proposto.

Para ilustrar o comportamento da abordagem proposta, o seguinte teste foi realizado. Considere, por exemplo, a ocorrência da falha incipiente f_{13} no DAMADICS considerando o *set-point* variando segundo uma função senoidal (apesar de ser uma forma não realística de variação de *set-point*, esta foi feita com o objetivo de considerar o pior caso). Considerando o tempo de amostragem de 1s, $t_{from} = 900s$, $t_{fd} = 900s$ and $t_{hor} = 2100s$. A evolução no tempo da vazão, F , e da posição da válvula, X , com tempo de amostragem de 10s, com a manifestação da falha incipiente f_{13} são apresentadas na Figura 4.3a e na Figura 4.3b, respectivamente. Para este caso (*set-point* variando), a série temporal usada para detecção da falha é composta pela soma da vazão, F , com a posição da válvula, X , como ilustrada na Figura 4.3c, tal consideração (ou informação) foi introduzida com o objetivo de se corrigir a saturação da variável F . A Figura 4.4 mostra várias janelas de tempo varrendo a série temporal original $X + F$, linha grossa em cada sub-figura. Os resultados obtidos pela metodologia proposta para diferentes janelas de tempo de 950s são apresentados na parte inferior de cada sub-figura da Figura 4.4. A detecção do ponto de mudança ocorre após 100s do início da falha e com 11% do tamanho da falha.

Para avaliar o desempenho da metodologia proposta, foi utilizado um observador, para a soma das variáveis X e F , baseado em uma rede neural com 4 entradas (vazão, posição da válvula, pressão de entrada e saída da válvula). A rede neural é uma MLP de três camadas (treinada pelo algoritmo *backpropagation*). A camada intermediária tem cinco neurônios e a camada de saída tem um neurônio (soma das variáveis X e F). A Figura 4.5(a) mostra a variável de saída $X + F$. A Figura 4.5(b) apresenta a saída da rede neural, treinada

somente para o caso de operação normal. Note que a falha incipiente se manifesta em $t_{from} = 900s$. A fim de detectar a falha, é necessário estabelecer um limiar do sinal de resíduo como ilustrado na Figura 4.5(c), i.e. o sinal de resíduo deve ser maior que um determinado limiar. Por exemplo, se um escolher um limiar com metade da variabilidade do sinal $X + F$, aproximadamente 0,2, então a detecção da falha ocorre próximo de 1200s com $\sim 33\%$ do tamanho da falha. Observe que o método proposto detecta a falha perto de 1000s e $\sim 11\%$ do tamanho da falha.

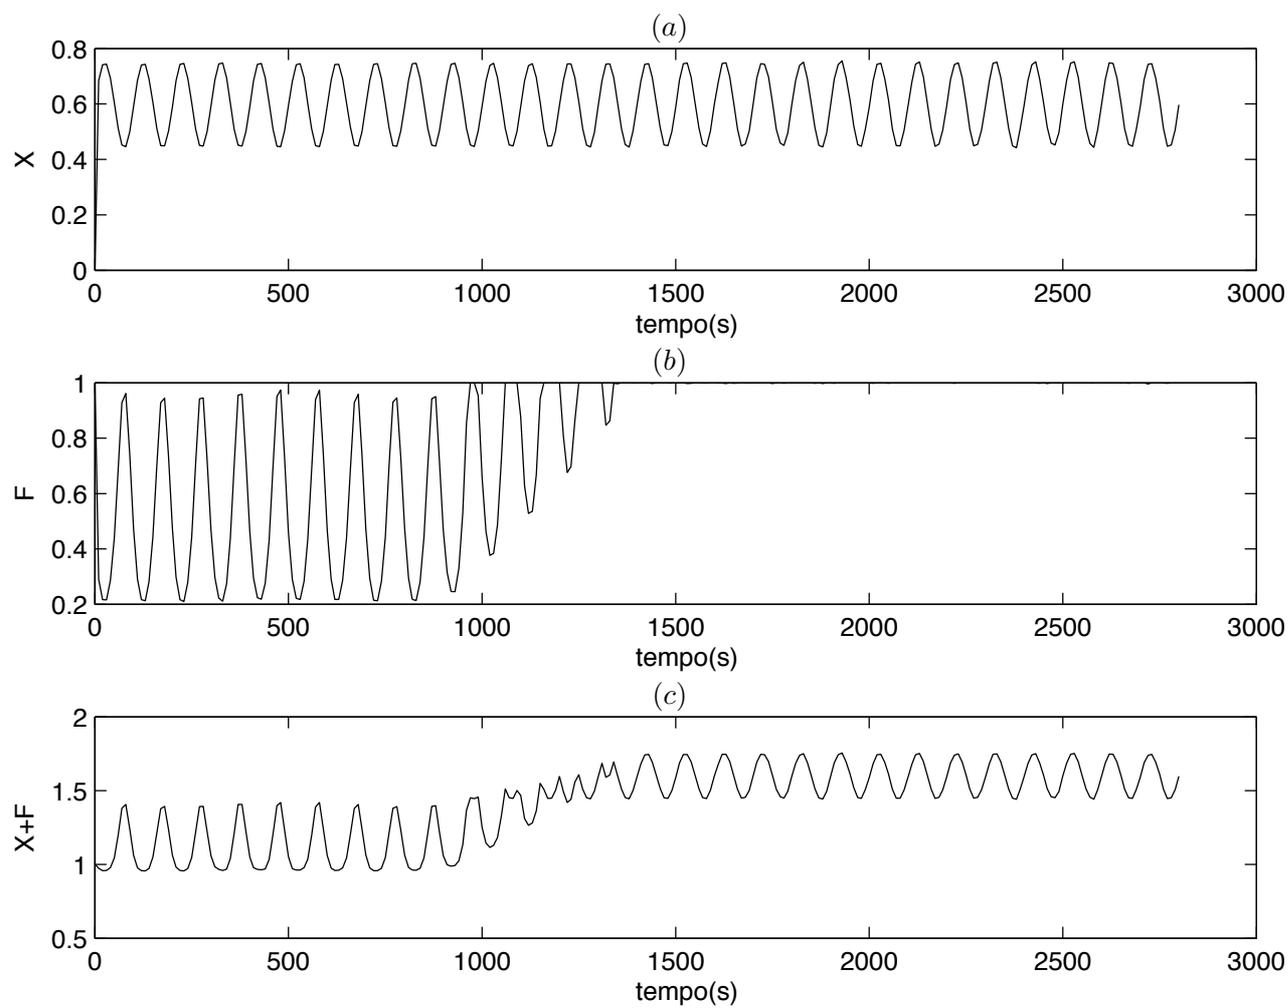


Figura 4.3: (a) Sinal de vazão, F . (b) Posição da válvula, X . (c) Soma de F e X .

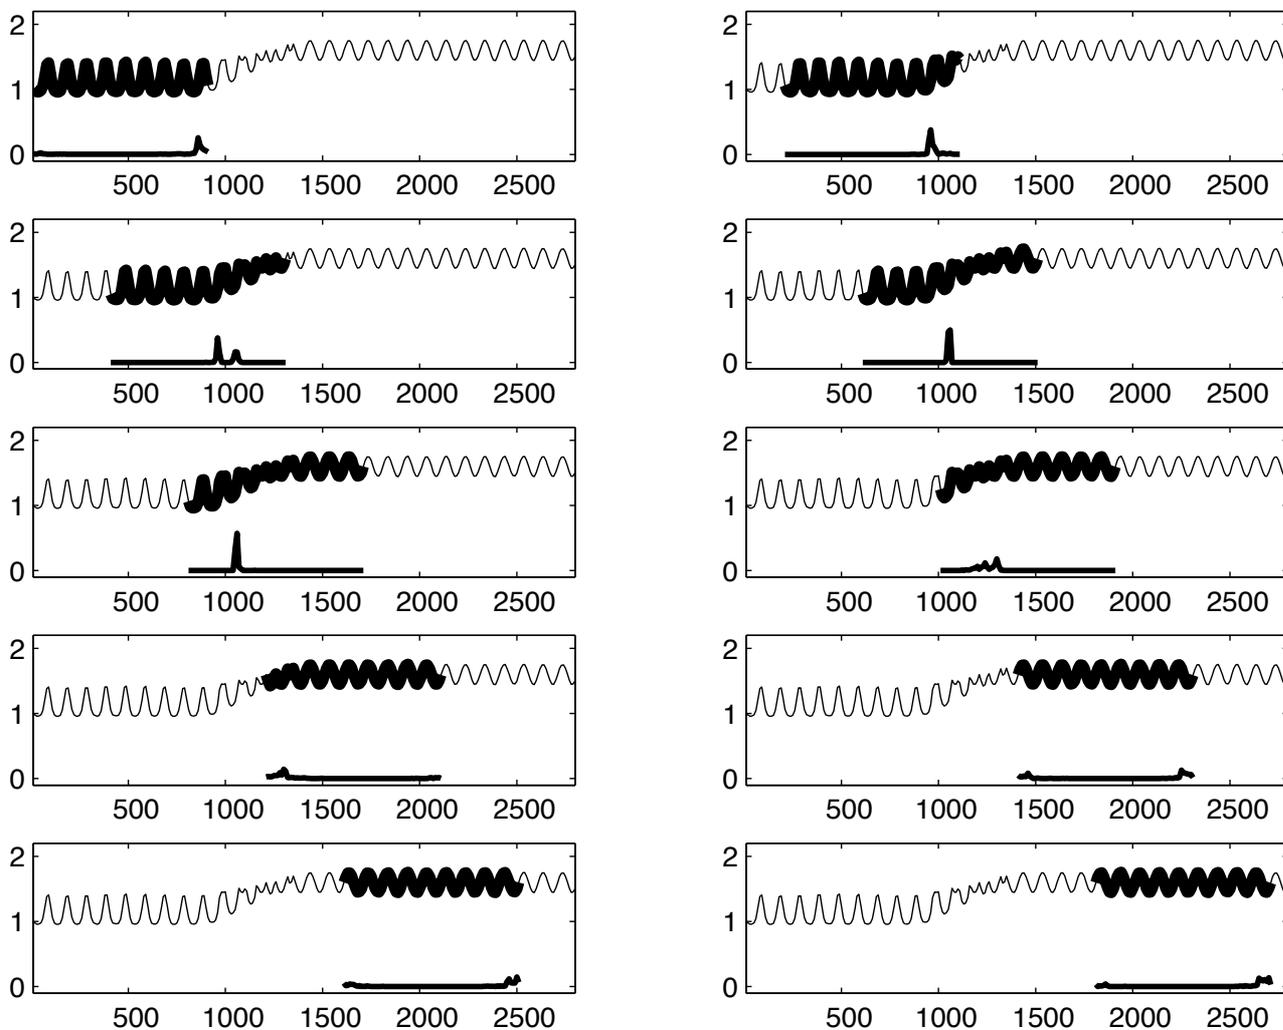


Figura 4.4: Cada sub-figura ilustra a série temporal $X + F$ na parte superior com a janela de tempo considerada indicada pela linha grossa, e na parte inferior o resultado obtido.

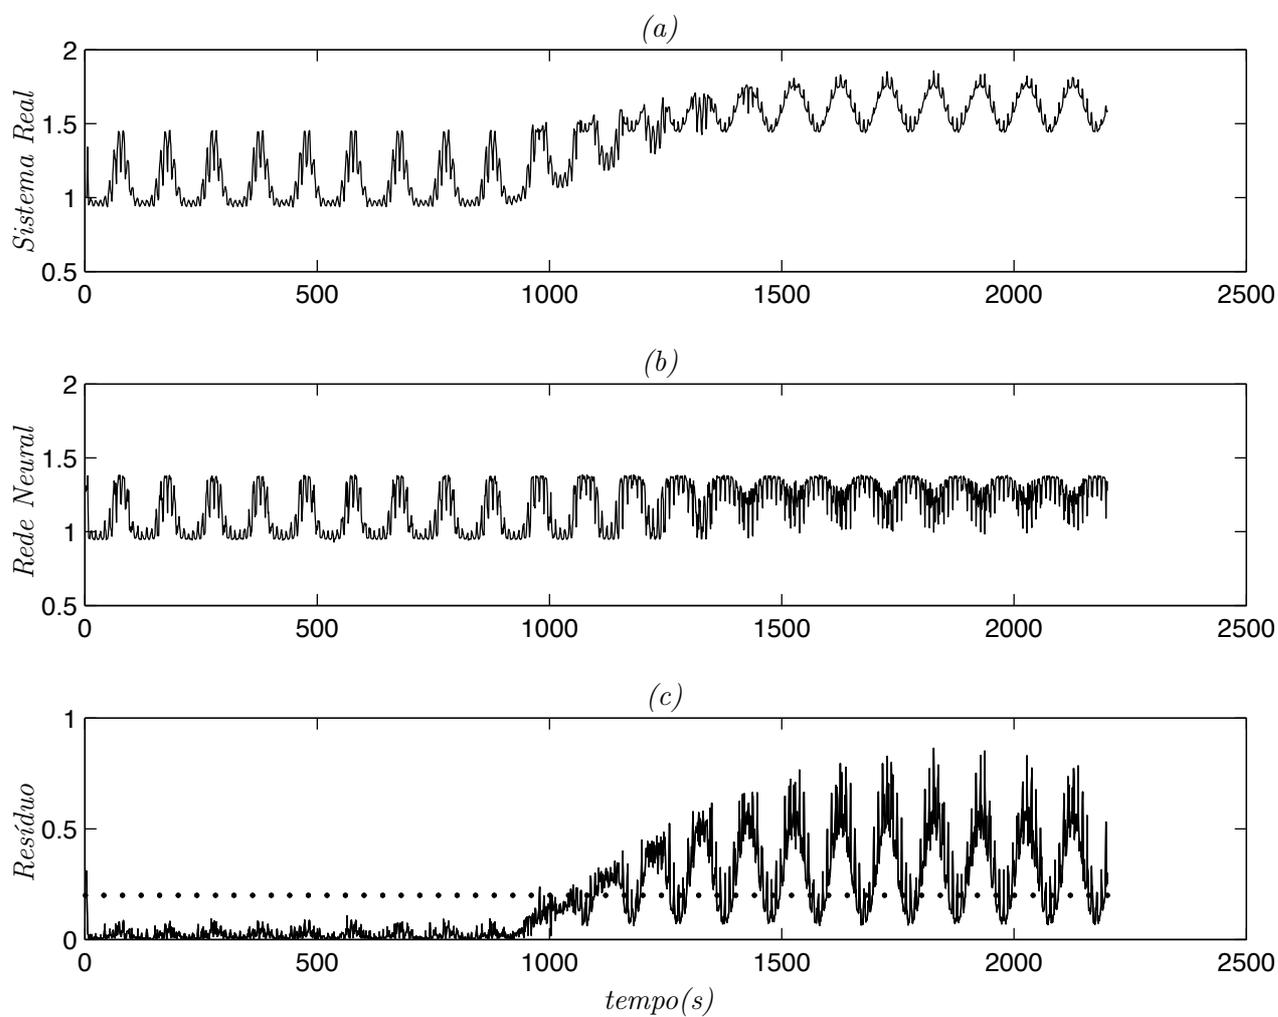


Figura 4.5: (a) Variáveis de saída $X + F$. (b) Saída da Rede Neural. (c) Sinal de resíduo e o limiar igual a 0.2.

Capítulo 5

Aplicação da Metodologia Proposta na detecção de Curtos-circuitos incipientes no Estator de Motores de Indução

Os motores de indução são as máquinas elétricas mais importantes em aplicações industriais. Falhas nos enrolamentos do estator de motores de indução trifásicos representam uma parte significativa das falhas que surgem durante a vida útil do motor. Quando estes motores são alimentados através de um inversor, a situação tende a se tornar ainda pior devido a mudança de tensões impostas pelo inversor (Cruz and Cardoso, 2004). Muitos estudos mostraram que uma grande parte das falhas em máquinas de indução estão relacionadas com o enrolamento estatórico (O'Donnell, 1985), (Albrecht et al., 1987), (Bonnett and Soukup, 1992), (Thorsen and Dalva, 1999). O estator de uma máquina de indução está sujeito *stresses* devido a vários fatores, que incluem sobrecarga térmica, vibrações mecânicas, e picos de tensão causados por variadores de velocidade. A deterioração do isolamento normalmente começa como uma falha de curto-circuito do enrolamento do estator.

Embora não haja dados experimentais que indicam o intervalo de tempo entre o início do curto-circuito no enrolamento até sua queima total, acredita-se que a transição entre os dois estados não é instantânea. Portanto, a detecção antecipada do curto-circuito durante o funcionamento do motor pode ser de grande importância, uma vez que eliminaria os danos subsequentes para as bobinas adjacentes e o núcleo do estator, reduzindo o custo e

o tempo de reparação do enrolamento (W.T.Thomson and Fenger, 2001) (Boqiang et al., 2003).

5.1 Modelagem e Simulação do Motor de Indução com Curto-circuito entre Espiras no Enrolamento Estatórico

Nesta seção será usado um modelo genérico do motor de indução (Baccarini et al. (2004)), válido para qualquer velocidade dos eixos dq . Representando as correntes, tensões e fluxos pelas letras i , v e λ , as resistências, indutâncias de dispersão e mútuas por r , L_l e L_m , as fases a , b e c pelos subíndices a , b e c , os enrolamentos do estator e do rotor pelos subíndices s e r , tem-se as equações de tensão para o estator e o rotor:

$$[v_s] = [r_s][i_s] + \frac{d[\lambda_s]}{dt} \quad (5.1)$$

$$[v_r] = [r_r][i_r] + \frac{d[\lambda_r]}{dt} \quad (5.2)$$

Sendo

$$[v_s] = [v_{as1} \ v_{as2} \ v_{bs} \ v_{cs}]^T$$

$$[v_r] = [v_{ar} \ v_{br} \ v_{cr}]^T$$

$$[i_s] = [i_{as} \ i_{as} - i_f \ i_{bs} \ i_{cs}]^T$$

$$[i_r] = [i_{ar} \ i_{br} \ i_{cr}]^T$$

$$[\lambda_s] = [\lambda_{as1} \ \lambda_{as2} \ \lambda_{bs} \ \lambda_{cs}]^T$$

$$[\lambda_r] = [\lambda_{ar} \ \lambda_{br} \ \lambda_{cr}]^T$$

A Figura 5.1 representa os enrolamentos do estator do motor de indução, sendo as_2 o número de espiras da fase a que estão curto-circuitadas.

No modelo proposto por Baccarini et al. (2004) as tensões dos enrolamentos do estator são dadas por:

$$V_{ds} + \frac{2}{3}\mu r_s i_f \cos\theta = r_s i_{ds} + \frac{d\lambda_{ds}}{dt} + \omega \lambda_{qs} \quad (5.3)$$

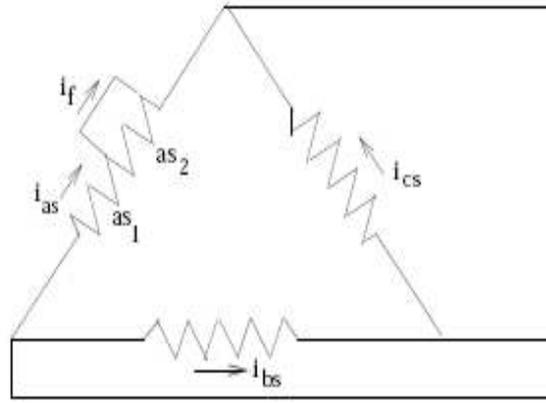


Figura 5.1: Representação dos enrolamentos

$$V_{qs} + \frac{2}{3}\mu r_s i_f \sin\theta = r_s i_{qs} + \frac{d\lambda_{qs}}{dt} + \omega \lambda_{ds} \quad (5.4)$$

$$V_{0s} + \frac{1}{3}\mu r_s i_f = r_s i_{0s} + \frac{d\lambda_{0s}}{dt} \quad (5.5)$$

As equações do circuito do rotor são iguais às do modelo tradicional simétrico. Os fluxos de estator e de rotor nos eixos dq , são dados por:

$$\lambda_{ds} = L_s i_{ds} + L_m i_{dr} - \frac{2}{3}\mu L_s i_f \cos\theta \quad (5.6)$$

$$\lambda_{qs} = L_s i_{qs} + L_m i_{qr} - \frac{2}{3}\mu L_s i_f \sin\theta \quad (5.7)$$

$$\lambda_{0s} = L_{l_s} i_{0s} + \frac{\mu}{3} L_{l_s} i_f \sin\theta \quad (5.8)$$

$$\lambda_{dr} = L_r i_{dr} + L_m i_{ds} - \frac{2}{3}\mu L_m i_f \cos\theta \quad (5.9)$$

$$\lambda_{qr} = L_r i_{qr} + L_m i_{qs} - \frac{2}{3}\mu L_m i_f \sin\theta \quad (5.10)$$

A tensão e o fluxo induzidos nas espiras curtocircuitadas são dadas por:

$$v_{as2} = \mu r_s (i_{ds} \cos \theta + i_{qs} \sin \theta - i_f) + \frac{d\lambda_{as2}}{dt} \quad (5.11)$$

$$\begin{aligned} \lambda_{as2} = & \mu L_{ls} (i_{qs} \sin \theta + i_{ds} \cos \theta - i_f) + \mu L_m (i_{qs} \sin \theta + \\ & + i_{ds} \cos \theta + i_{qr} \sin \theta + i_{dr} \cos \theta - \frac{2}{3} \mu i_f) \end{aligned} \quad (5.12)$$

O conjugado é dado por:

$$T = \frac{3p}{2} L_m (i_{qs} i_{dr} - i_{ds} i_{qr}) - \frac{p}{2} \mu L_m i_f i_{qr} \quad (5.13)$$

Os resultados de simulação das correntes do estator máquina de indução com 5% de espiras da fase a em curto-circuito, inseridos após 0.72s de simulação, são ilustrados nas Figuras 5.2–5.4. Os valores rms das correntes são ilustrados nas Figuras 5.2–5.4. Observe que quando ocorre um curto-circuito na fase de a , o aumento da corrente de fase a é maior que as correntes das fases b e c .

5.2 Implementação e Resultados da Metodologia Proposta

Nesta seção, serão descritos os detalhes de implementação e apresentados resultados de simulação e resultados experimentais na detecção de curto-circuitos incipientes no enrolamento estático de motores de indução. Um diagrama de blocos do sistema é apresentado na Figura 5.8. O sistema monitora os valores instantâneos das correntes do estator i_{as} , i_{bs} , i_{cs} . Primeiramente, as medidas analógicas são convertidas em dados digitais através de um conversor A/D e depois o valor (rms) de cada corrente de fase é calculado.

Considerando que \bar{i} denota o valor rms associado a corrente instantânea i . No caso da máquina de indução com conexão delta, e considerando a Figura 5.1, a detecção de falha é dada pelo seguinte conjunto de regras:

SE $m(\bar{i}_{as}) \cong m(\bar{i}_{bs}) > m(\bar{i}_{cs})$ **ENTÃO** falha na fase b ;

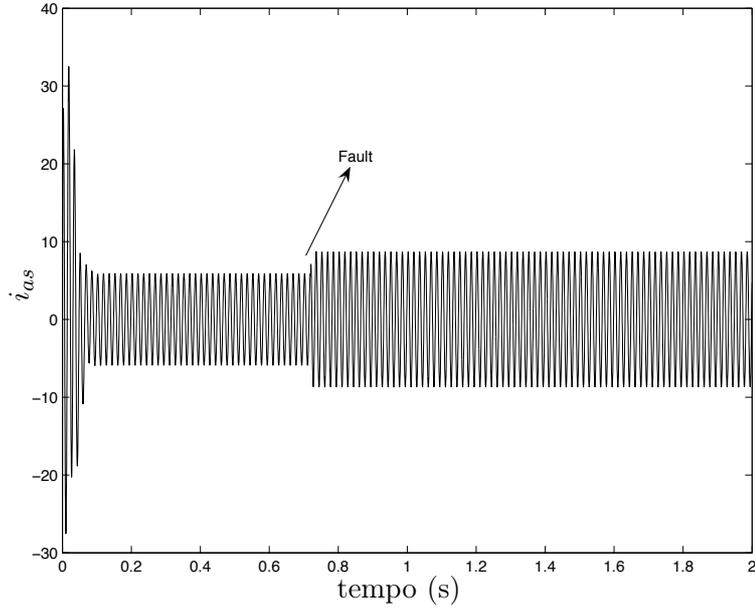


Figura 5.2: Corrente da fase a .

SE $m(\bar{i}_{as}) \cong m(\bar{i}_{cs}) > m(\bar{i}_{bs})$ **ENTÃO** falha na fase a ;

SE $m(\bar{i}_{bs}) \cong m(\bar{i}_{cs}) > m(\bar{i}_{as})$ **ENTÃO** falha na fase c ;

SE $m(\bar{i}_{bs}) \cong m(\bar{i}_{cs}) \cong m(\bar{i}_{as})$ **ENTÃO** não há falha.

No caso da máquina de indução com conexão em estrela, o conjunto de regras para detecção de falha é dado por:

SE $m(\bar{i}_{as}) > m(\bar{i}_{bs}) \cong m(\bar{i}_{cs})$ **ENTÃO** falha na fase a ;

SE $m(\bar{i}_{bs}) > m(\bar{i}_{as}) \cong m(\bar{i}_{cs})$ **ENTÃO** falha na fase b ;

SE $m(\bar{i}_{cs}) > m(\bar{i}_{as}) \cong m(\bar{i}_{bs})$ **ENTÃO** falha na fase c ;

SE $m(\bar{i}_{bs}) \cong m(\bar{i}_{cs}) \cong m(\bar{i}_{as})$ **ENTÃO** não há falha.

onde $m(\nu)$ indica a probabilidade de mudança na série temporal da variável $i \nu$. Tais conjuntos de regras foram criados pelo fato de haver mudanças nas correntes quando a máquina de indução muda de ponto de operação, todavia essas mudanças são balanceadas.

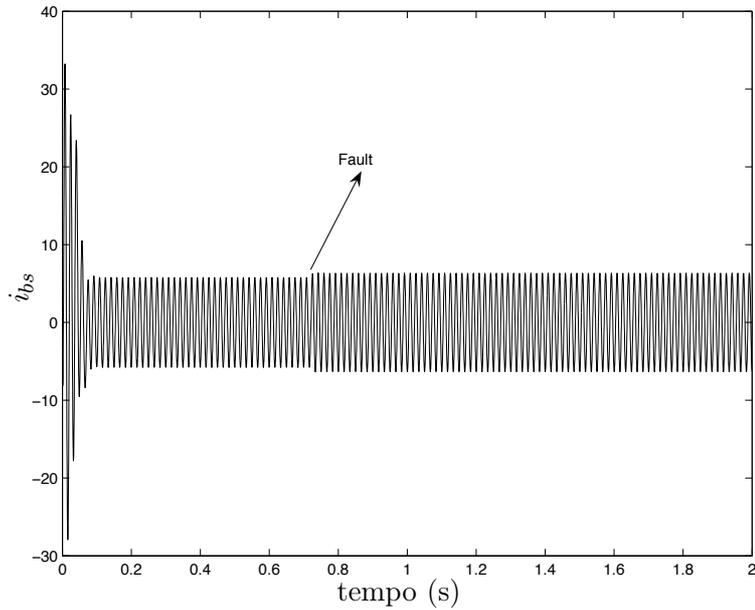


Figura 5.3: Corrente da fase b .

5.2.1 Resultados de Simulação

Os resultados de simulação para detecção de falhas incipientes no enrolamento estático de um motor de indução conectado em estrela são mostrados nas Figuras 5.9–5.14, considerando o conjunto de regras para conexão em estrela e 0.1% de espiras em curto-circuito na fase a . Estes resultados foram obtidos por simulação da máquina de indução usando o modelo descrito na Seção 5.1 e a metodologia de detecção de ponto de mudança apresentada no Capítulo 3.

Como pode ser visto nas Figuras 5.10, 5.12 e 5.14, a detecção da falha foi feita no tempo correto e na fase correta, com o sistema, indicando que a probabilidade de mudança na fase a é cerca de 60%, enquanto a probabilidade de mudança na corrente das fases b e c são menores que 10%, com um desequilíbrio claro de mudanças entre as fases. O sistema indicou, corretamente, que a falha ocorreu na fase de a . Para o caso onde não ocorreu falha, a probabilidade de mudança em cada corrente de fase é nula.

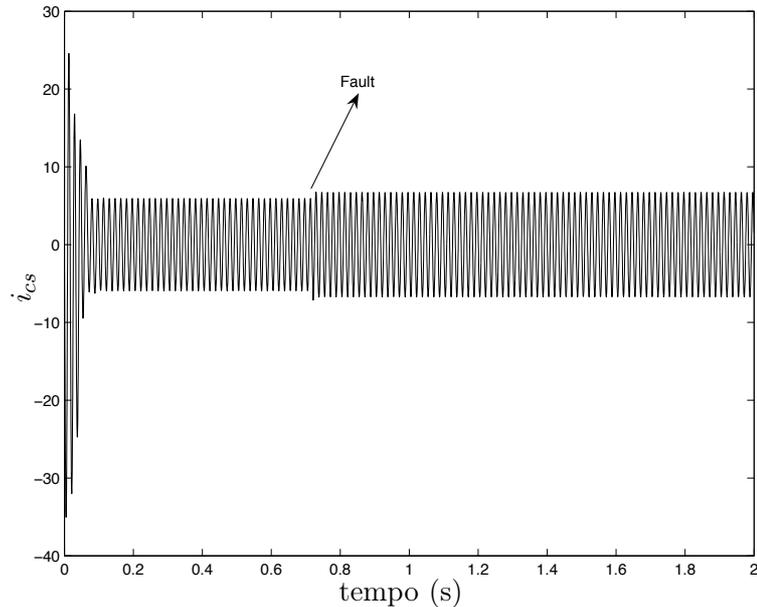


Figura 5.4: Corrente da fase c .

5.2.2 Resultados Práticos

A Figura 5.15 ilustra a bancada experimental utilizada no trabalho. Ela consiste de um motor de indução com rotor em gaiola de 3HP, 220/380V, 60Hz, 4 polos.

Os enrolamentos de cada fase são compostos por dois grupos de fases com três bobinas em cada uma. Cada bobina é composta por 33 espiras. A Figura 5.16 mostra detalhes do diagrama de conexão do enrolamento estático. O motor de indução foi especialmente projetado com *taps* para inserir curto-circuito entre espiras de uma fase (Figura 5.17).

A carga mecânica é fornecida por um gerador DC alimentando um resistor variável. Para permitir que os testes fossem realizados em diferentes níveis de carga, a excitação da corrente do gerador DC e resistência da carga são, ambos, controláveis.

O sistema de aquisição de dados consiste de:

- três sensores de corrente de efeito *hall* (LEM, LTA50P);
- três sensores de tensão de efeito *hall* (LEM, LV 100-300);
- placa de aquisição de dados (National Instruments PCI 6013).

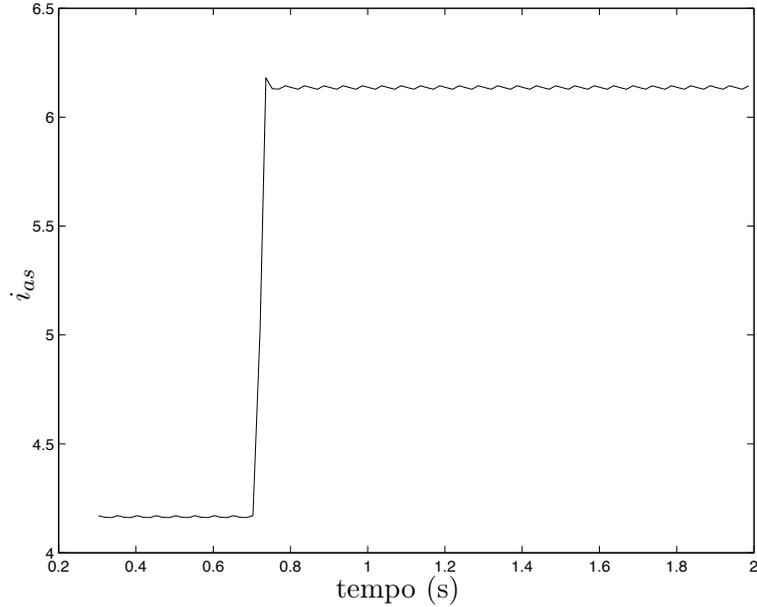


Figura 5.5: Corrente da fase a (rms).

Em todos os testes experimentais, o estator estava conectado em delta. Quando curto-circuitos são introduzidos, é inserida uma resistência no curto-circuito com a finalidade de limitar o valor da corrente no curto-circuito, protegendo assim os enrolamentos do motor.

As Figuras 5.18 – 5.20 mostram as correntes instantâneas das fases a (i_{as}), b (i_{bs}) e c (i_{cs}) com $\sim 1.5\%$ de espiras curto-circuitadas na fase b . O curto-circuito foi estabelecido no tempo $t \cong 2$ s. As Figuras 5.21 – 5.23 mostram os valores *rms* das correntes das fases a (i_{as}), b (i_{bs}) e c (i_{cs}), para o mesmo experimento.

Os resultados da detecção de falhas incipientes no enrolamento estático do motor de indução são mostrados nas Figuras 5.24–5.26, considerando o conjunto de regras para conexão delta e 1.5% de espiras curto-circuitadas na fase b . Para ilustrar a detecção de ponto de mudança usando a abordagem proposta, serão considerados uma janela sem falha e uma janela onde ocorre a falha incipiente. Para a janela sem falha (Figuras 5.24a, 5.25a e 5.26a), as Figuras 5.24c, 5.25c e 5.26c mostram que a probabilidade de mudança em cada corrente de fase é nula quando usa-se a metodologia proposta. Para a janela com falha incipiente (Figuras 5.24b, 5.25b e 5.26b), a detecção da falha foi feita no instante de tempo correto e na fase correta, como mostrado nas Figuras 5.24d, 5.25d e 5.26d. Neste caso, o sistema indicou que a probabilidade de mudança nas correntes da fase a e b são

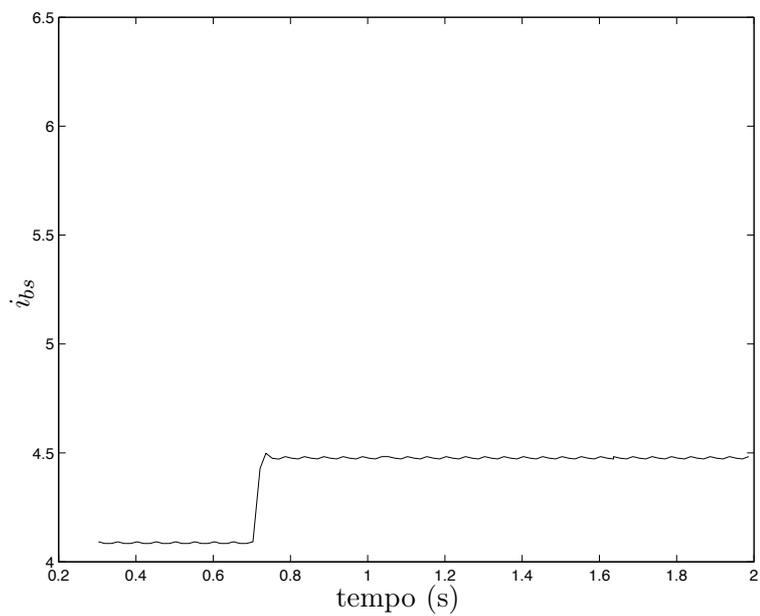


Figura 5.6: Corrente da fase b (rms).

aproximadamente 10%, enquanto a probabilidade de mudança na corrente da fase c é nula, com um desequilíbrio claro nas mudanças entre as fases. Estas informações levam o sistema a indicar (corretamente) que a falha ocorreu na fase de b .

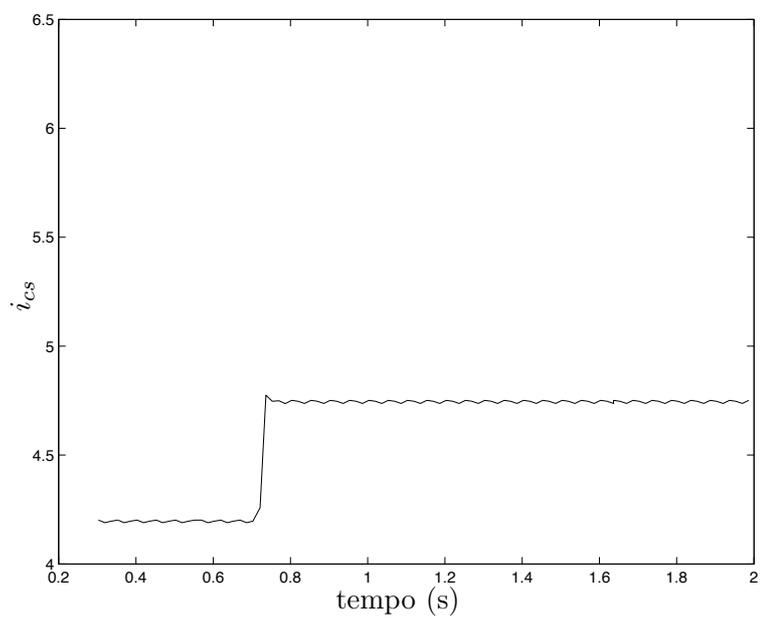


Figura 5.7: Corrente da fase c (rms).

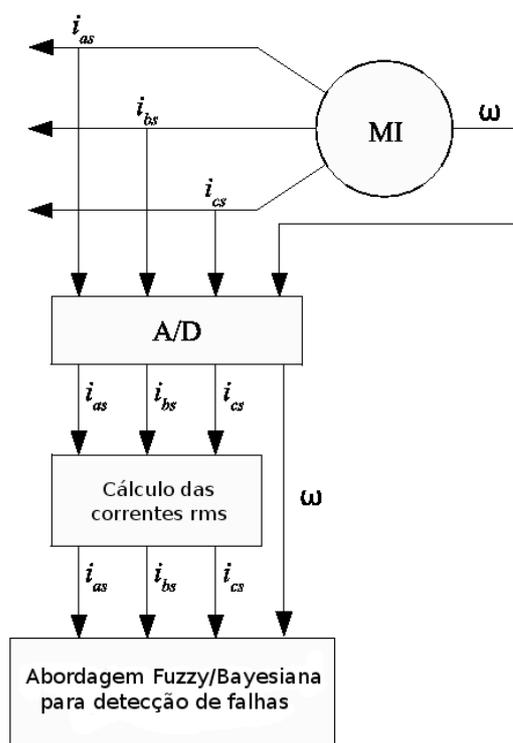


Figura 5.8: Diagrama de blocos da metodologia proposta.

CAPÍTULO 5. APLICAÇÃO EM MOTORES DE INDUÇÃO 91

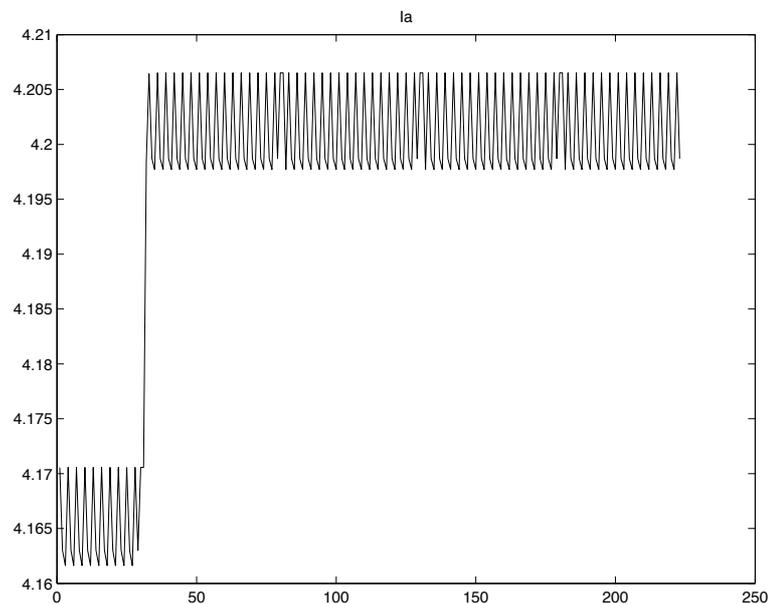


Figura 5.9: Corrente da fase a (rms): i_{as} com 0.1% de espiras curto-circuitadas na fase a .

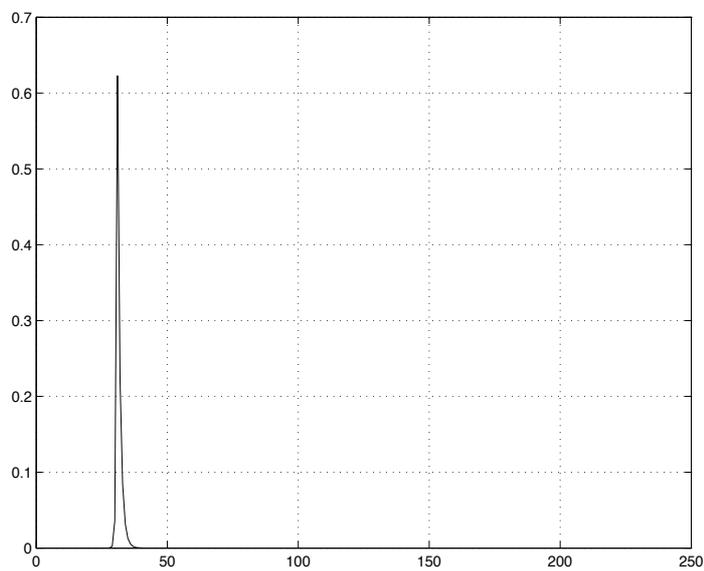


Figura 5.10: Detecção de mudança na corrente i_{as} .

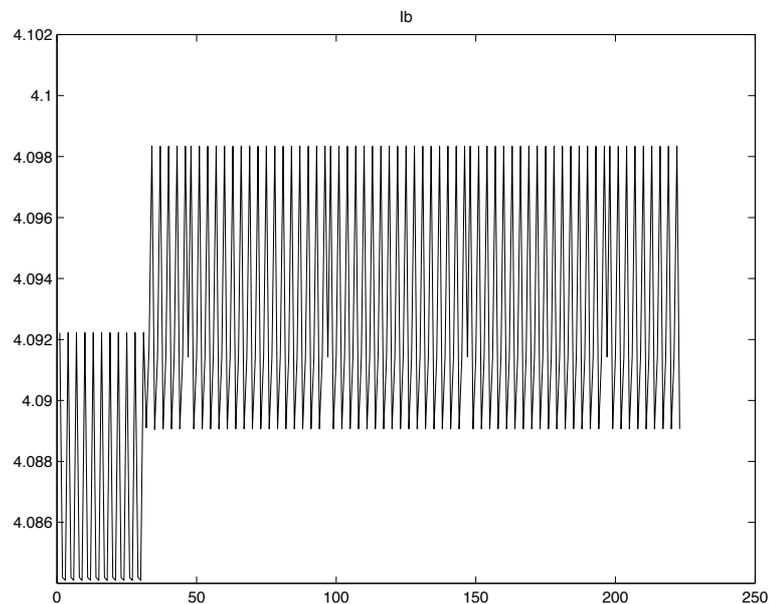


Figura 5.11: Corrente da fase b (rms): i_{bs} com 0.1% de espiras curto-circuitadas na fase a .

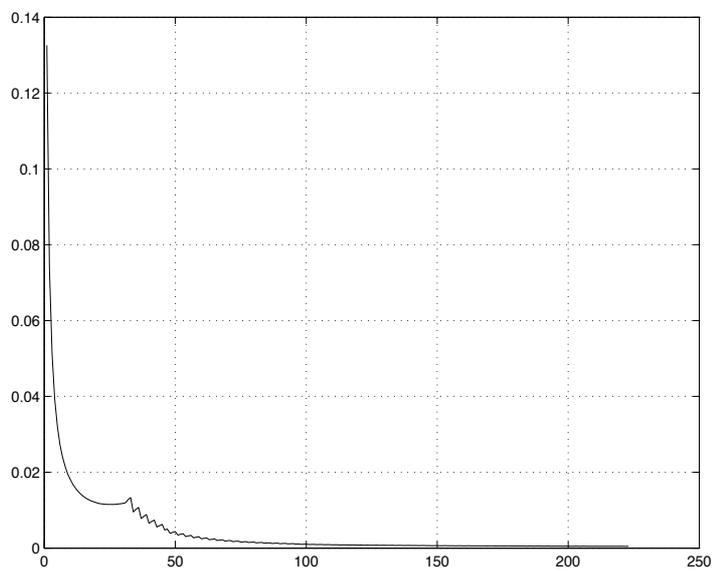


Figura 5.12: Detecção de mudança na corrente i_{bs} .

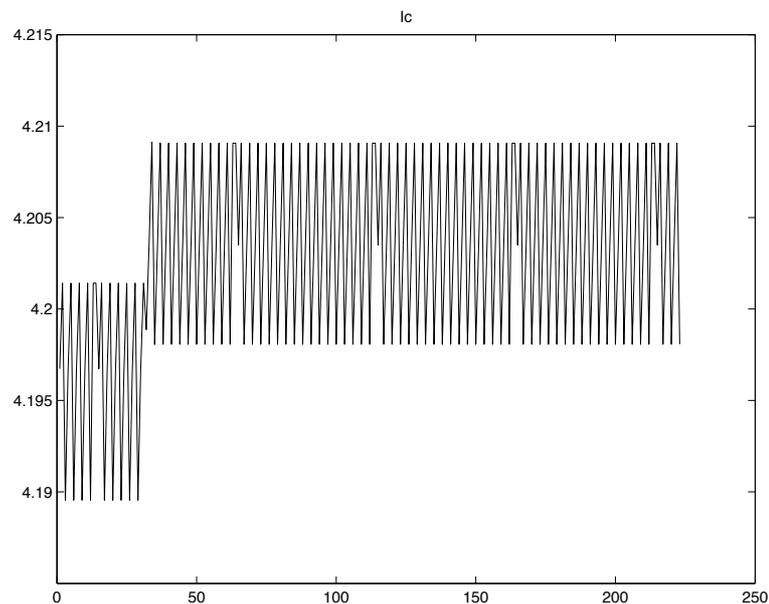


Figura 5.13: Corrente da fase c (rms): i_{cs} com 0.1% de espiras curto-circuitadas na fase a .

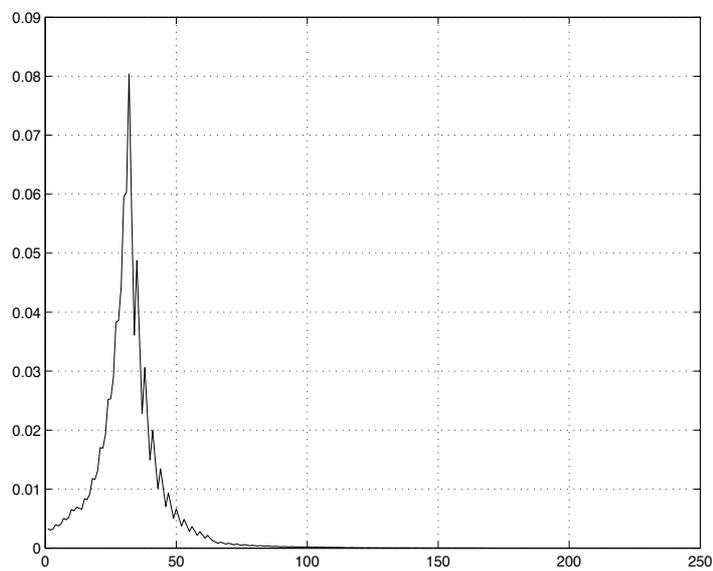


Figura 5.14: Detecção de mudança na corrente i_{cs} .



Figura 5.15: Bancada experimental.

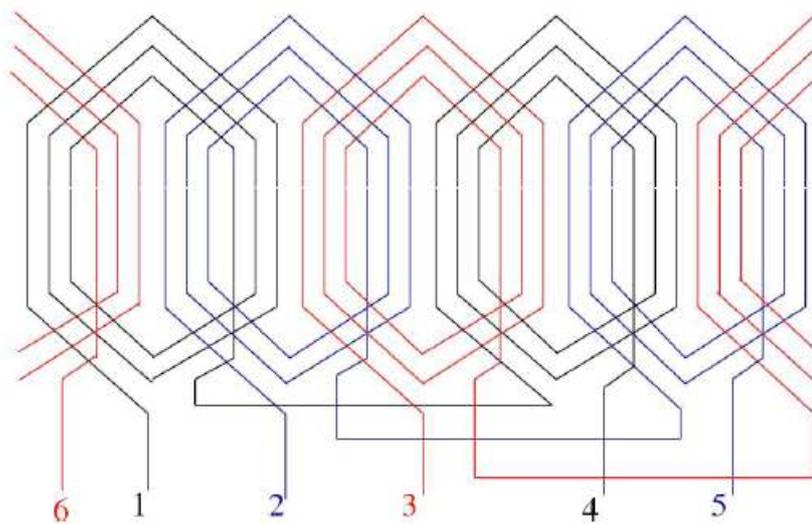


Figura 5.16: Diagrama de conexão do enrolamento estático.

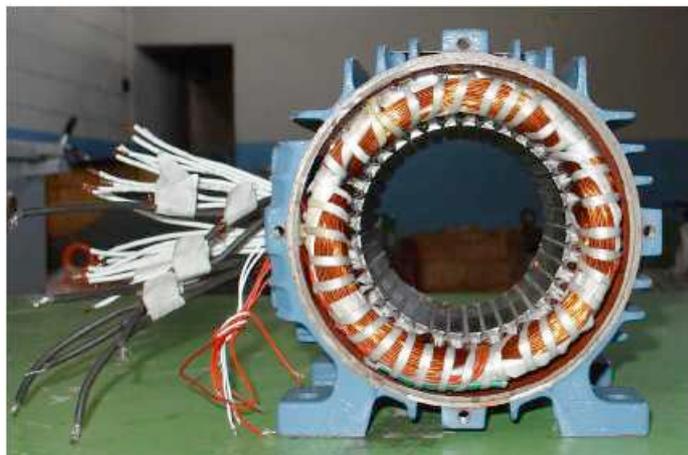


Figura 5.17: Terminais do estator.

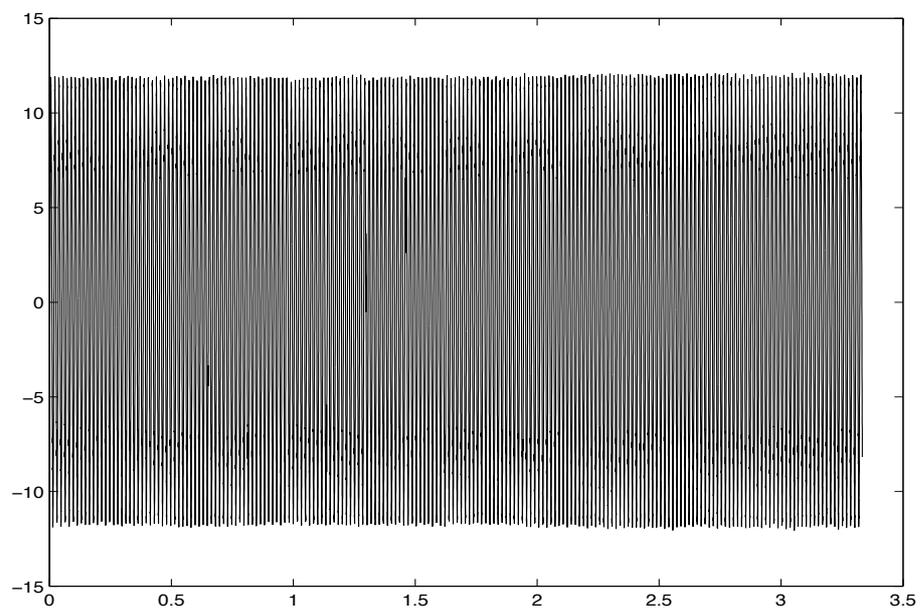


Figura 5.18: Corrente da fase a : i_{as} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b .

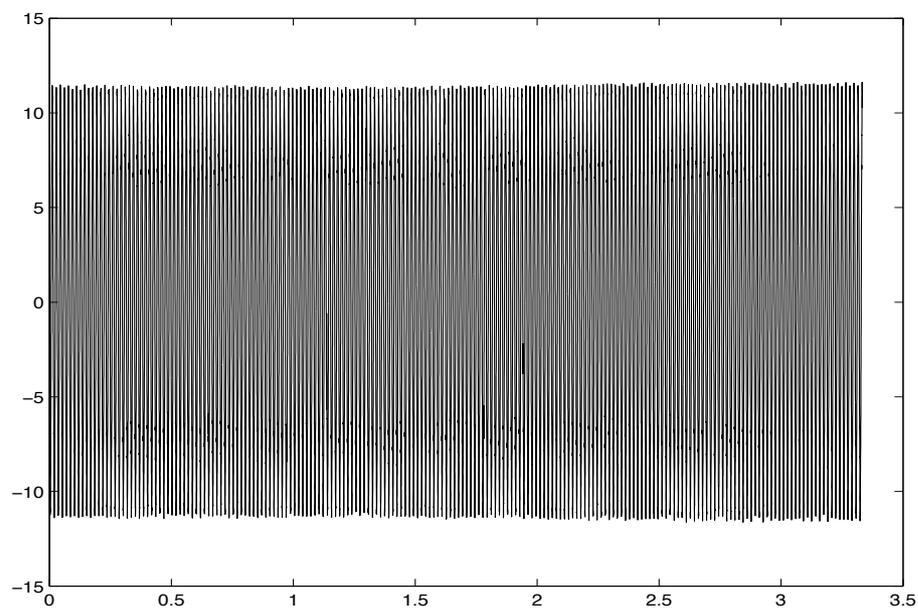


Figura 5.19: Corrente da fase b : i_{bs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b .

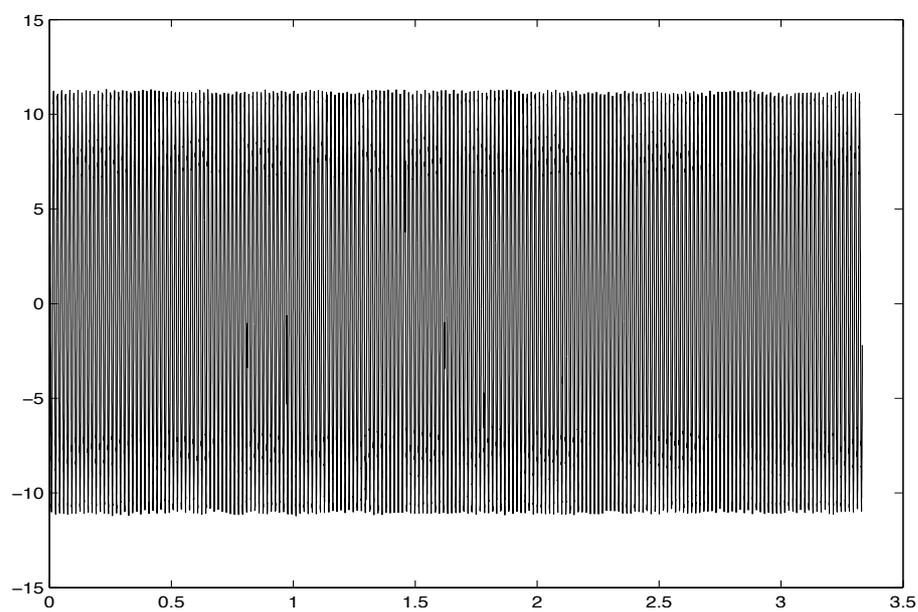


Figura 5.20: Corrente da fase c : i_{cs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b .

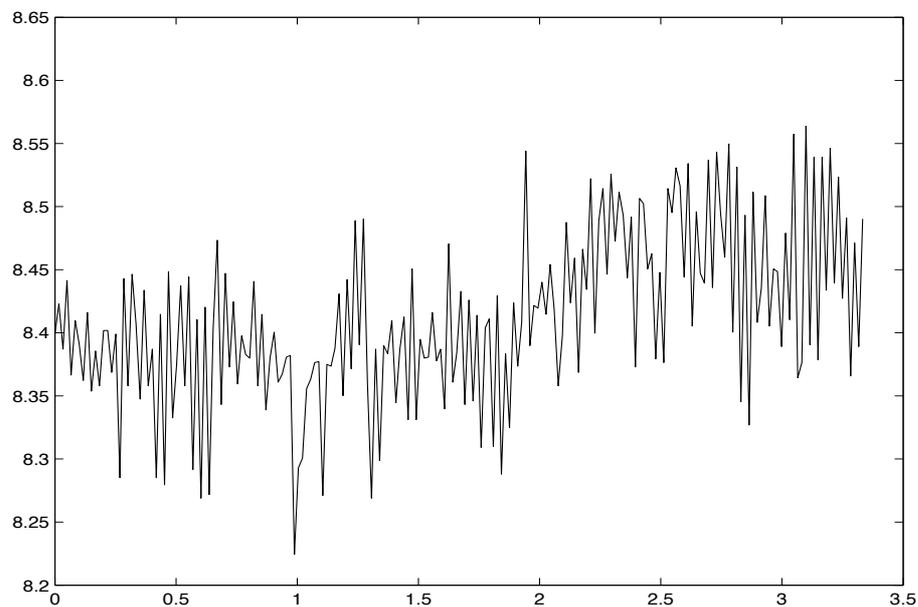


Figura 5.21: Corrente da fase a (rms): i_{as} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b .

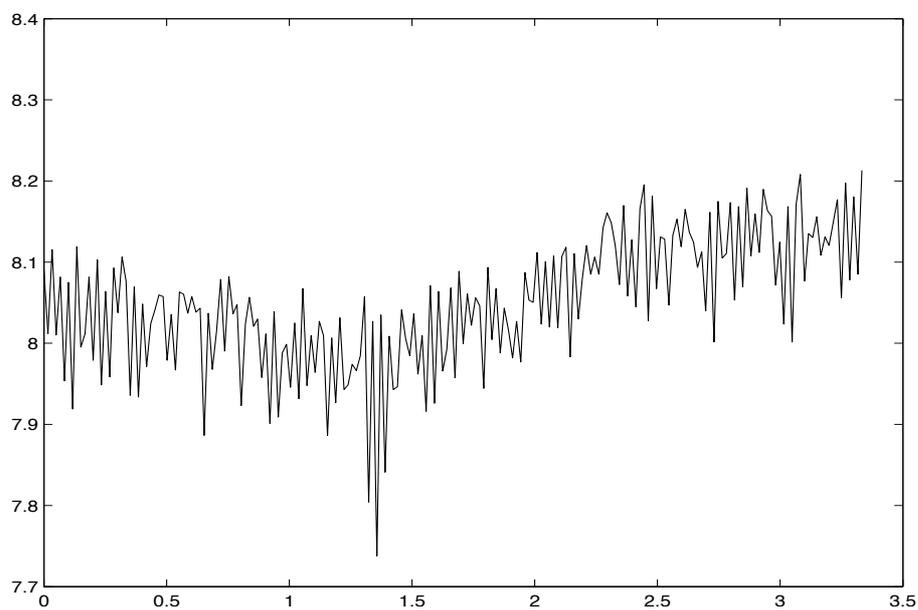


Figura 5.22: Corrente da fase b (rms): i_{bs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b .

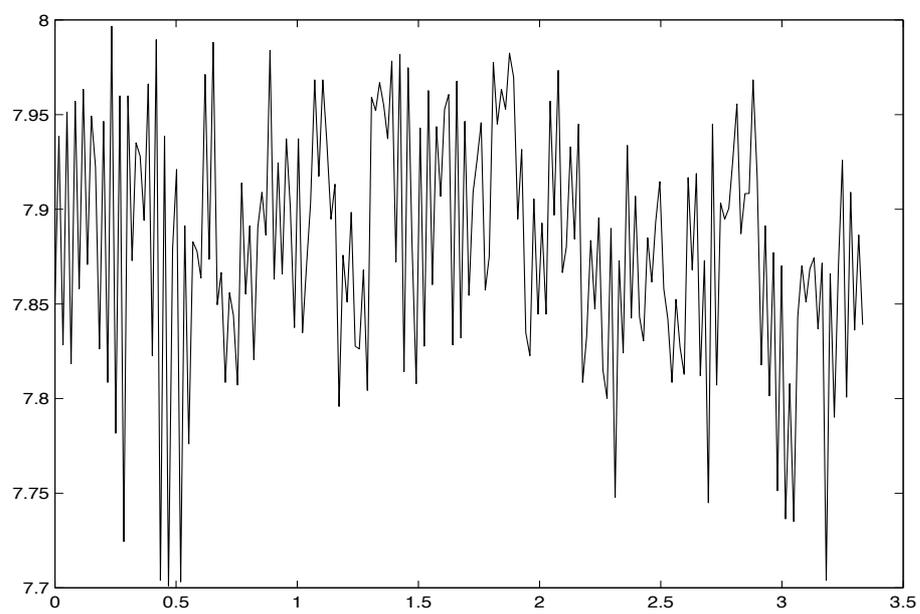


Figura 5.23: Corrente da fase c (rms): i_{cs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b .

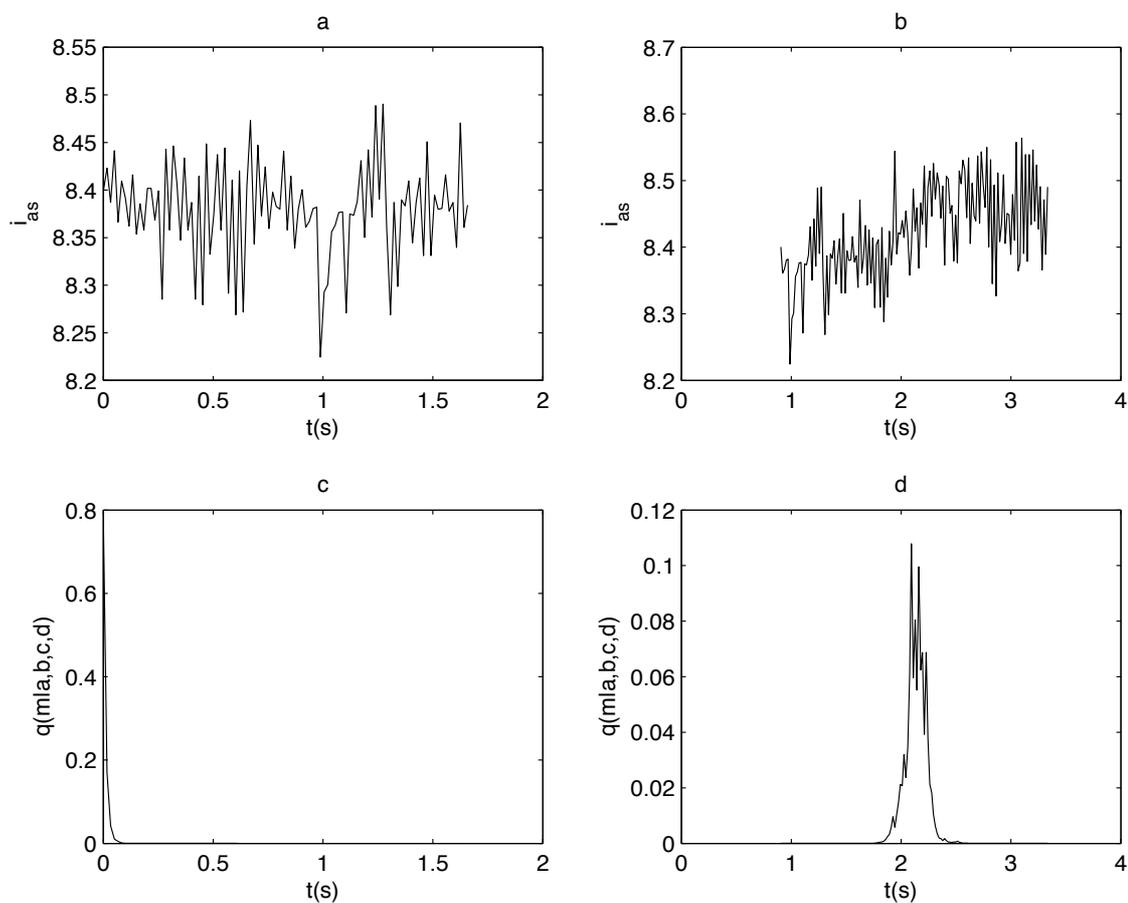


Figura 5.24: a - i_{as} em operação normal; b - i_{as} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b ; c - Detecção de mudança na corrente i_{as} para operação normal; d - Detecção de mudança na corrente i_{as} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b .

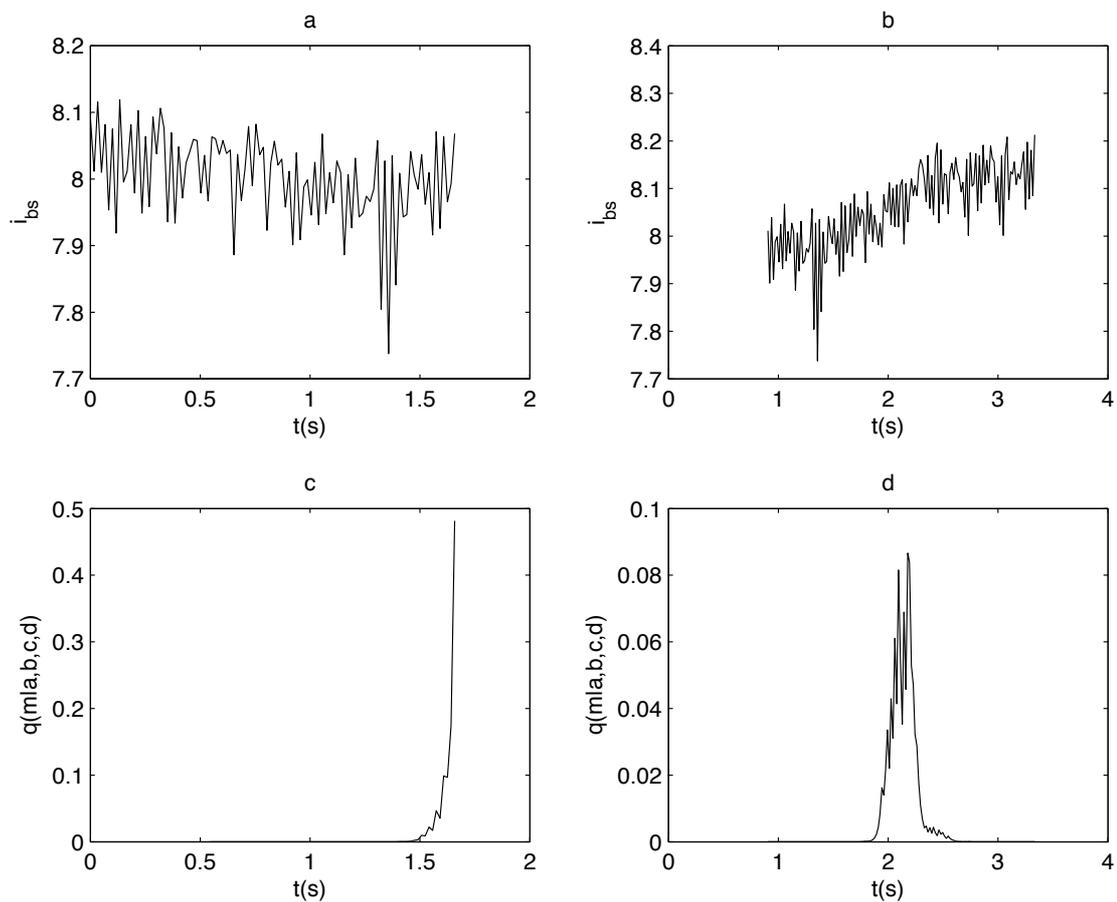


Figura 5.25: a - i_{bs} em operação normal; b - i_{bs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b ; c - Detecção de mudança na corrente i_{bs} para operação normal; d - Detecção de mudança na corrente i_{bs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b .

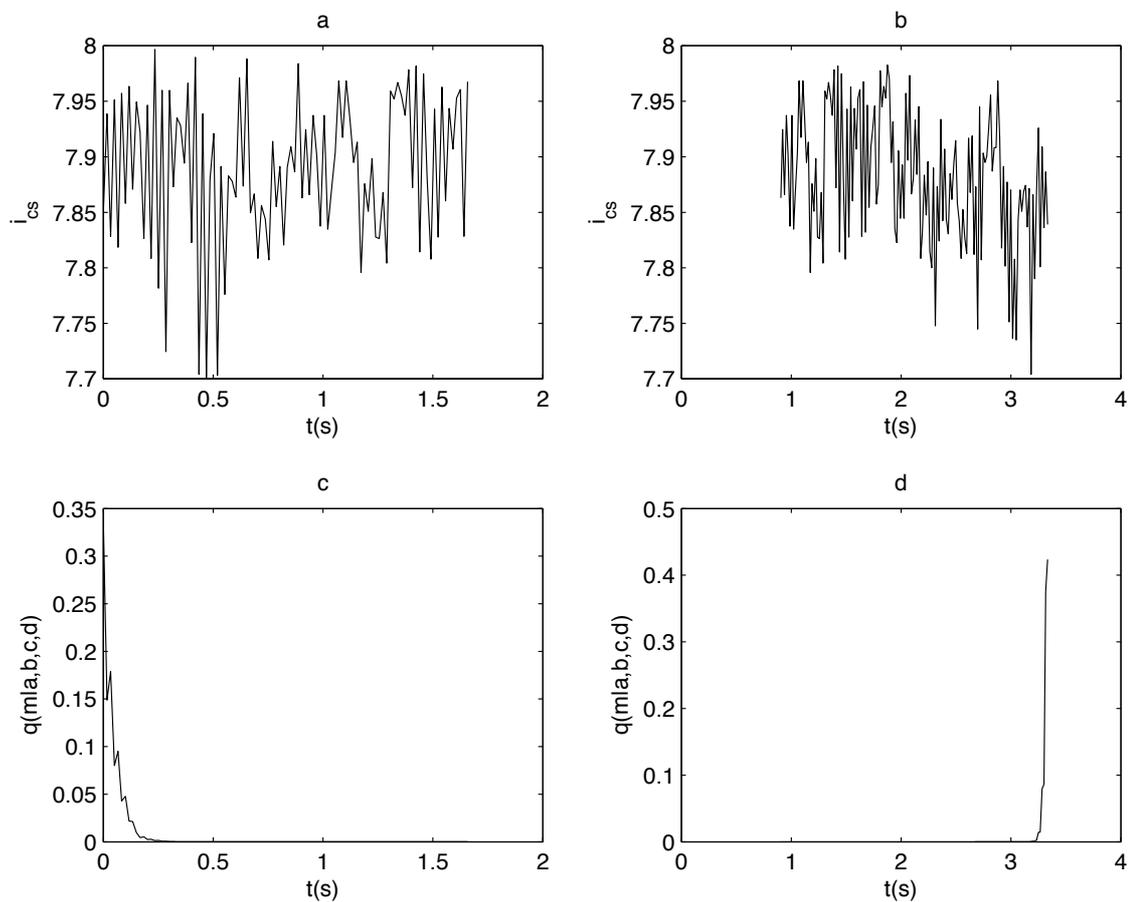


Figura 5.26: a - i_{cs} em operação normal; b - i_{cs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b ; c - Detecção de mudança na corrente i_{cs} para operação normal; d - Detecção de mudança na corrente i_{cs} com $\sim 1.5\%$ de espiras curto-circuitadas na fase b .

Capítulo 6

Discussão Final

Nesse trabalho uma nova metodologia *fuzzy/bayesiana* para detecção de pontos de mudança em séries temporais foi utilizada para tratar o problema na detecção de falhas incipientes em sistemas dinâmicos. A metodologia proposta tem como vantagens, comparada com outras técnicas de FDI, não requerer modelo matemático, especificação de limiares e algum grau de conhecimento prévio do comportamento do sistema dinâmico. A metodologia é baseada numa formulação de duas etapas. Na primeira etapa, a teoria dos conjuntos fuzzy é aplicada na série temporal com o objetivo de aglomerar e transformar os dados iniciais, com distribuição arbitrária, em dados que podem ser aproximados por uma distribuição beta. A segunda etapa consiste em usar modelagem *bayesiana* (o algoritmo de Metropolis-Hastings) para detectar ponto de mudança na série temporal transformada, isto é, com características estatísticas fixas. Essa formulação de duas etapas permitiu uma sistemática eficiente para resolver o problema de detecção de ponto de mudança, que é utilizado para detectar falhas incipientes, as quais podem ser caracterizadas como mudanças em sinais do sistema dinâmico. Esta metodologia foi aplicada com sucesso para o problema de detecção de falhas incipientes no *benchmark* de FDI no European RTN DAMADICS e no enrolamento estatístico de máquinas de indução.

Os resultados obtidos no problema de detecção de pontos de mudança foram apresentados no trabalho de forma empírica, apesar de serem facilmente demonstrados quando se assume que sempre que tem-se um conjunto de dados pertencentes ao $[0, 1]$, esses podem ser aproximados por uma distribuição *beta*, para tratar o problema de detecção de falhas incipientes. As principais contribuições desse trabalho podem ser destacadas como:

- No Capítulo 3 é proposta uma metodologia alternativa para detecção de ponto de

mudança em séries temporais. Através de estudos de simulação mostrou-se a eficiência do uso de técnicas da teoria dos conjuntos fuzzy associadas a uma técnica bayesiana no problema de detecção de pontos de mudança em séries temporais, tanto para mudanças abruptas como para pequenas mudanças. Pelos estudos experimentais, sugere-se que uma vantagem da metodologia adotada é o fato desta não requerer nenhum conhecimento prévio sobre a estrutura dos dados, sendo mais facilmente aplicável em situações práticas.

- Nos Capítulos 4 e 5, dois exemplos práticos de detecção de falhas incipientes são tratados como problemas de detecção de pontos de mudança. Em um primeiro momento, foi tratado o problema de detecção de falhas incipientes no *benchmark* de FDI introduzido por Bartys et al. (2006), problema esse que ainda não tinha um tratamento apropriado, visto que os trabalhos existentes que tratam esse problema se concentram em detectar falhas abruptas, as quais (opinião pessoal) são mais fáceis de serem detectadas. No segundo momento, é tratado o problema de detecção de espiras em curto-circuito no enrolamento estatórico, onde a metodologia proposta apresentou bons resultados para detecção de falhas incipientes.

6.1 Trabalhos Futuros

No presente trabalho foi mostrada uma formulação alternativa para detecção de ponto de mudança em séries temporais. Essa formulação se mostrou eficiente nos casos apresentados no decorrer da tese, todavia, faz-se necessário ainda um estudo sobre a geração de falsos alarmes, tanto do tipo *falso positivo* quanto do tipo *falso negativo*. Para fins de ilustração, a Figura 6.1(a) ilustra uma série temporal de um ruído com distribuição $N(0, 1)$, com 100 amostras e sem nenhum ponto de mudança, depois de passado em um filtro passa-baixa. A metodologia proposta indica uma probabilidade de mudança nessa amostra da série, como ilustrado na Figura 6.1(b), mas sabe-se, *a priori*, que não há mudança na série temporal.

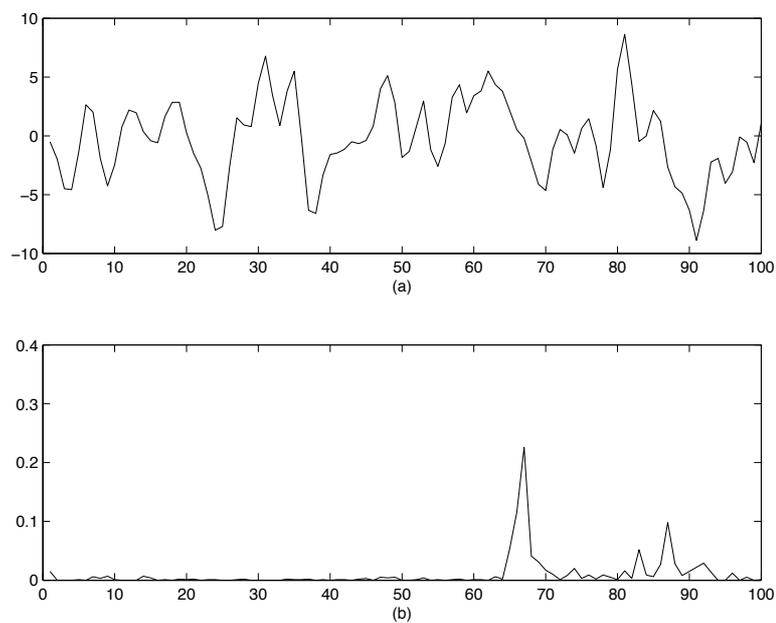


Figura 6.1: (a) Série temporal gerada sem nenhum ponto de mudança; (b) Resultado da metodologia proposta.

Apêndice A

Lista de Distribuições

Neste apêndice são listadas as distribuições de probabilidade utilizadas no texto. São apresentadas suas funções de densidade de probabilidade, média e variância.

A.1 Distribuição Uniforme

X tem distribuição uniforme com parâmetros a e b , denotando-se $X \sim U(a, b)$, se sua função de densidade é dada por:

$$p(x | a, b) = \frac{1}{b-a}, \quad a < x < b$$

$$E(X) = \frac{a+b}{2}, \quad V(X) = \frac{(b-a)^2}{12}$$

A.2 Distribuição Normal

X tem distribuição normal com parâmetros μ e σ^2 , denotando-se $X \sim N(\mu, \sigma^2)$, se sua função de densidade é dada por:

$$p(x | \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\pi\sigma^2}}, \quad -\infty < x < \infty$$

para $-\infty < \mu < \infty$ e $\sigma^2 > 0$. Quando $\mu = 0$ e $\sigma^2 = 1$ a distribuição é chamada normal padrão.

A.3 Distribuição Gama

X tem distribuição Gama com parâmetros α e β , denotando-se $X \sim G(\alpha, \beta)$, se sua função de densidade é dada por:

$$p(x | \alpha, \beta) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x}$$

para $\alpha, \beta > 0$.

$$E(X) = \frac{\alpha}{\beta} \text{ e } V(X) = \frac{\alpha}{\beta^2}$$

A.4 Distribuição Beta

X tem distribuição Beta com parâmetros α e β , denotando-se $X \sim \text{beta}(\alpha, \beta)$, se sua função de densidade é dada por:

$$p(x | \alpha, \beta) = \frac{\beta^{\alpha+\beta}}{\Gamma(\alpha)\Gamma(\beta)} x^{\alpha-1}(1-x)^{\beta-1}, \quad 0 < x < 1,$$

para $\alpha, \beta > 0$.

$$E(X) = \frac{\alpha}{\alpha+\beta} \text{ e } V(X) = \frac{\alpha\beta}{(\alpha+\beta)^2(\alpha+\beta+1)}$$

A.5 Distribuição t de Student

X tem distribuição t de Student (ou simplesmente t) com média μ , parâmetro de escala σ e v graus de liberdade, denotando-se $X \sim t(\mu, \sigma^2)$, se sua função de densidade é dada por:

$$p(x | v, \mu, \sigma^2) = \frac{\Gamma((v+1)/2)v^{v/2}}{\Gamma(v/2)\sqrt{\pi}\sigma} v + \frac{(x-\mu)^2}{\sigma^2}^{-(v+1)/2}, \quad x \in$$

para $v > 0, \mu \in \mathbb{R}$ e $\sigma^2 > 0$.

$$E(X) = \mu, \text{ para } v > 1 \text{ e } V(X) = \frac{v}{v-2}, \text{ para } v > 2$$

Referências Bibliográficas

- Aguirre, L. A. (2007). *Introdução à Identificação de Sistemas – Técnicas Lineares e Não Lineares Aplicadas a Sistemas Reais*. Editora UFMG, Belo Horizonte, MG, Brasil, 2^a edição edition.
- Alag, S. S. S. (1996). *A Bayesian Decision-Theoretic Framework for Real-Time Monitoring and Diagnosis of Complex Systems: Theory and Application*. PhD thesis, University of California at Berkeley.
- Albrecht, P. F., Appiarius, J. C., and Sharma, D. K. (1987). Assessment of reliability of motors in utility applications. *IEEE Transactions On Energy Conversion.*, EC-2(3):396–406.
- Baccarini, L. M. R., de Menezes, B. R., Guimarães, H. N., and Caminhas, W. M. (2004). Modelagem, simulação e detecção de curto-circuito entre espiras nos enrolamentos do estator de motores de indução. In *Anais do XV Congresso Brasileiro de Automática*, pages 1930–1935, Gramado.
- Baccarini, L. M. R., Menezes, B. R., and Caminhas, W. M. (2010). Fault induction dynamic model, suitable for computer simulation: simulation results and experimental validation. *Mechanical Systems and Signal Processing*, 24:300–311.
- Barry, D. and Hartigan, J. A. (1993). A bayesian analysis for change point problems. *Journal of the American Statistical Association*, 88(421):309–319.
- Bartys, M., Patton, R., Syfert, M., de las Heras, S., and Quevedo, J. (2006). Introduction to the DAMADICS actuator FDI benchmark study. *Control Engineering Practice*, 14(6):577–596.
- Basseville, M. (1988). Detecting changes in signals and systems: a survey. *Automatica*, 24(3):309–326.
- Beckage, B., Joseph, L., Belisle, P., Wolfson, D. B., and Platt, W. J. (2007). Bayesian change-point analyses in ecology. *New Phytologist*, 174(2):456–467.

- Berec, L. (1998). A multi-model method to fault detection and diagnosis: Bayesian solution. an introductory treatise. *International Journal of Adaptive Control and Signal Processing*, 12:81–92.
- Bezdek, J. C. (1981). *Pattern recognition with fuzzy objective function algorithms*. Plenum Press.
- Bilski, P. and Wojciechowski, J. M. (2007). Automated diagnostics of analog systems using fuzzy logic approach. *IEEE Transactions on Instrumentation and Measurement*, 56(6):2175–2185.
- Bocaniala, C. D. and da Costa, J. S. (2006). Application of a novel fuzzy classifier to fault detection and isolation of the DAMADICS benchmark problem. *Control Engineering Practice*, 14(6):653–669.
- Bonnett, A. H. and Soukup, G. C. (1992). Causes and analysis of stator and rotor failures in three-phase induction motors. *IEEE Transactions On Industry Applications*, 28(4):921–937.
- Boqiang, X., Heming, L., and Liling, J. S. (2003). Apparent impedance angle based detection of stator winding interturn short circuit fault in induction motors. In *Proceedings of the Industry Application Conference*, pages 1118–1125.
- Bose, B. K. (1986). *Power Electronic A.C. Drives*. Prentice Hall.
- Calado, J. M. F., Korbicz, J., Pattan, K., Patton, R. J., and da Costa, J. M. G. S. (2001). Soft computing approaches to fault diagnosis for dynamic systems. *European Journal Control*, 7(2-3):248–286.
- Caminhas, W. M. (1997). *Estratégias de Detecção e Diagnóstico de Falhas em Sistemas Dinâmicos*. PhD thesis, Universidade Estadual de Campinas, UNICAMP, Brasil.
- Caminhas, W. M. and Gomide, F. A. C. (2008). Neurofuzzy network with on-line learning in fault detection of dynamic systems. In Bouchon-Meunier, B., Marsala, C., Rifqi, M., and Yager, R., editors, *Uncertainty and Intelligent Information Systems*, volume 1, pages 375–387. World Scientific.
- Caminhas, W. M. and Takahashi, R. H. C. (2001). Dynamic system failure detection and diagnosis employing sliding mode observers and fuzzy neural networks. In *Proceedings of the Joint 9th IFSA and 20th NAFIPS*, pages 304–309, Vancouver.
- Caminhas, W. M., Tavares, H. M. F., and Gomide, F. A. C. (1996). Rede lógica neuro-fuzzy: Aplicação em diagnóstico de falhas em sistemas dinâmicos. In *Anais do XI Congresso Brasileiro de Automática*, pages 459–464.

- Casavola, A., Famularo, D., and Franze, G. (2008). Robust fault detection of uncertain linear systems via quasi-lmis. *Automatica*, 44(1):289–295.
- Castilloa, E., Sarabiab, J. M., Solaresa, C., and Gómez, P. (1999). Uncertainty analyses in fault trees and bayesian networks using form/sorm methods. *Reliability Engineering and System Safety*, 65:29–40.
- Chan, C. W., Jin, H., Cheung, K. C., and Zhang, H. Y. (2001). Fault detection of systems with redundant sensors using constrained kohonen networks. *Automatica*, 37(10):1671–1676.
- Chen, J. and Patton, R. J. (1996). Optimal filtering and robust fault diagnosis of stochastic systems with unknown disturbances. *IEE Proceedings - Control Theory Application*, 143:31–36.
- Chen, J. and Patton, R. J. (1999). *Robust model-based fault diagnosis for dynamic systems*. Dordrecht: Kluwer Academic Publishers.
- Cruz, S. M. A. and Cardoso, J. (2004). Diagnosis of stator interturn short circuits in dtc induction motor drives. *IEEE Transactions on Industry Applications*, 40(5):1349–1360.
- Dai, X., Gao, Z., Breikin, T., and Wang, H. (2009). Zero assignment for robust H_2/H_∞ fault detection filter design. *IEEE Transactions on Signal Processing*, 57(4):1363–1372.
- D’Angelo, M. F. S. V. and Costa, P. P. (2001). Detection of shorted turns in the field winding of turbogenerators using the neural network mlp. In *Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics*, pages 1930–1935, Tucson.
- D’Angelo, M. F. S. V., Palhares, R. M., Caminhas, W. M., Takahashi, R. H. C., Maia, R. D., Lemos, A. P., and Inácio, M. J. (2009a). Detecção de falhas: uma revisão com aplicações. *Revista Controle & Automação*, submetido.
- D’Angelo, M. F. S. V., Palhares, R. M., Takahashi, R. H. C., and Loschi, R. H. (2007). Uma abordagem fuzzy/bayesiana para o problema de detecção de pontos de mudança em séries temporais. In *XXXIX Simpósio Brasileiro de Pesquisa Operacional*, pages 2530–2541.
- D’Angelo, M. F. S. V., Palhares, R. M., Takahashi, R. H. C., and Loschi, R. H. (2008a). Uma abordagem fuzzy/bayesiana para o problema de detecção de falhas incipientes. In *XVII Congresso Brasileiro de Automática*, pages 1–6.
- D’Angelo, M. F. S. V., Palhares, R. M., Takahashi, R. H. C., and Loschi, R. H. (2009b). Fuzzy/bayesian change point detection approach to incipient fault detection. *IET Control Theory & Applications*, submetido (duas revisões já realizadas).

- D'Angelo, M. F. S. V., Palhares, R. M., Takahashi, R. H. C., and Loschi, R. H. (2009c). Uma abordagem fuzzy/bayesiana para o problema de detecção de ponto de mudança em séries temporais. *Pesquisa Operacional*, submetido (uma revisão já realizada).
- D'Angelo, M. F. S. V., Palhares, R. M., Takahashi, R. H. C., Loschi, R. H., and Baccharini, L. M. R. (2008b). Detecção de falhas incipientes no estator de máquinas de indução através de uma abordagem fuzzy/bayesiana. In *XVII Congresso Brasileiro de Automática*, pages 1–6.
- D'Angelo, M. F. S. V., Palhares, R. M., Takahashi, R. H. C., Loschi, R. H., Baccharini, L. M. R., and Caminhas, W. M. (2009d). Incipient fault detection in induction machine stator-winding using a fuzzy-bayesian change point detection approach. *Applied Soft Computing*, *aceito*.
- Dash, S., Rengaswamy, R., and Venkatasubramanian, V. (2003). Fuzzy-logic based trend classification for fault diagnosis of chemical processes. *Computers and Chemical Engineering*, 27(3):347–362.
- Douglas, R. K. and Speyer, J. L. (1996). Robust fault detection filter design. *Journal of Guidance, Control, and Dynamics*, 19(1):214–218.
- Douglas, R. K. and Speyer, J. L. (1999). \mathcal{H}_∞ bounded fault detection filter. *Journal of Guidance, Control, and Dynamics*, 22(1):129–138.
- Frank, P. M. (1994). On-line fault detection in uncertain nonlinear systems using diagnostic observers: a survey. *International Journal Systems Science*, 25(12):2129–2154.
- Gamerman, D. (1997). *Markov chain Monte Carlo: stochastic simulation for Bayesian inference*. Chapman & Hall.
- Gertler, J. (1991). Analytical redundancy methods in fault detection and isolation. In *Proceedings of IFAC/IAMCS symposium on safe process*, page 91, Baden-Baden.
- Gertler, J. (1997). Fault detection and isolation using parity relations. *Control Engineering Practice*, 5(5):653–661.
- Gertler, J. and Singer, D. (1995). A new structural framework for parity equation-based failure detection and isolation. *Automatica*, 26:381–388.
- Hadjiliadis, O. and Moustakides, V. (2006). Optimal and asymptotically optimal cusum rules for change point detection in the brownian motion model with multiple alternatives. *Theory of Probability and its Applications*, 50(1):75–85.
- Hartigan, J. A. (1990). Partition models. *Communication in Statistics-Theory and Methods*, 19(8):2745–2756.

- Hinkey, D. V. (1971). Inference about the change point from cumulative sum test. *Biometria*, 26:279–284.
- Hou, M. and Patton, R. J. (1998). Optimal filtering for systems with unknown inputs. *IEEE Transactions on Automatic Control*, 43(3):445–449.
- Isermann, R. and Balle, P. (1997). Trends in the application of model-based fault detection and diagnosis of technical processes. *Control Engineering Practice*, 5(5):707–719.
- Jang, J. S. R. and Sun, E. M. C.-T. (1997). *Neuro-Fuzzy and Soft Computing*. Pearson Education.
- Jiang, C. and Zhou, D. H. (2005). Fault detection and identification for uncertain linear time-delay systems. *Computers & Chemical Engineering*, 30:228–242.
- Johansson, A., Bask, M., and Norlander, T. (2006). Dynamic threshold generators for robust fault detection in linear systems with parameter uncertainty. *Automatica*, 42(7):1095–1106.
- Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Transactions of the ASME—Journal of Basic Engineering*, 82(Series D):35–45.
- Kaufman, L. and Rousseeuw, P. J. (1990). *Finding groups in data: An introduction to cluster analysis*. John Wiley & Sons.
- Kohonen, T. (2001). *Self-organizing maps*. Springer Series in Information Sciences. Springer.
- Kullback, S. and Leibler, R. A. (1951). On information and sufficiency. *Annals of Mathematical Statistics*, 22(1):79–86.
- Lee, S., Nishiyama, Y., and Yoshida, N. (2006a). Test for parameter change in diffusion processes by cusum statistics based on one-step estimators. *Annals of the Institute of Statistical Mathematics*, 58(2):211–222.
- Lee, S., Park, S., Maekawa, K., and Kawai, K. (2006b). Test for parameter change in arima models. *Communications in Statistics: Simulation and Computation*, 35(2):429–439.
- Lemos, A. P. (2007). Proposta de um algoritmo genérico de detecção de novidades em séries temporais utilizando modelos de previsão. Master’s thesis, Universidade Federal de Minas Gerais, Belo Horizonte, Brasil.
- Lo, C. H., Fung, E. H. K., and Wong, Y. K. (2009). Intelligent automatic fault detection for actuator failures in aircraft. *IEEE Transactions on Industrial Informatics*, 5(1):50–55.

- Loschi, R. and Cruz, F. (2005a). Bayesian identification of multiple change points in poisson data. *Advances in Complex Systems*, 8:465–482.
- Loschi, R. and Cruz, F. (2005b). Extension to the product partition model: computing the probability of a change. *Computational Statistics and Data Analysis*, 48(2):255–268.
- Loschi, R., Gonçalves, F. B., and Cruz, F. (2005). Avaliação de uma medida de evidência de um ponto de mudança e sua utilização na identificação de mudanças na taxa de criminalidade em belo horizonte. *Pesquisa Operacional*, 25(3):459–463.
- Mamdani, E. (1974). Application of fuzzy algorithms for the control of a dynamic plant. *IEE Proceedings*, 121:1585–1588.
- Markou, M. and Singh, S. (2003a). Novelty detection: A review part 1: Statistical approaches. *Signal Processing*, 83:2499–2521.
- Markou, M. and Singh, S. (2003b). Novelty detection: A review part 2: Neural networks based approaches. *Signal Processing*, 83:2481–2497.
- Marquardt, D. (1963). An algorithm for least-squares estimation of nonlinear parameters. *SIAM Journal of Applied Mathematics*, 11:164–168.
- Mast, T. A., Reed, A. T., Yurkovich, S., Ashby, M., and Adibhatla, S. (1999). Bayesian belief networks for fault identification in aircraft gas turbine engines. In *Proceedings of the 1999 IEEE International Conference on Control Applications*, pages 39–44, Hawaii, USA.
- Masters, T. (1995). *Neural, Novel and Hybrid Algorithms for Time Series Prediction*. John Wiley & Sons, Inc., New York, NY, USA.
- Maurya, M. R., Rengaswamy, R., and Venkatasubramanian, V. (2007). Fault diagnosis using dynamic trend analysis: A review and recent developments. *Engineering Applications of Artificial Intelligence*, 20(2):133–146.
- Montgomery, D. (2001). *Introduction to Statistical Quality Control*. Wiley, fourth edition.
- Nguyen, N. T. and Lee, H. H. (2008). Decision tree with optimal feature selection for hearing fault detection. *Journal of Power Electronics*, 8(1):101–107.
- O’Donnell, P. (1985). Report of large motor reliability survey of industrial and commercial installations: Part i. *IEEE Transactions On Industry Applications*, IA-21(4):853–864.
- Oh, K. J., Roh, T. H., and Moon, M. S. (2005). Developing time-based clustering neural networks to use change-point detection: Application to financial time series. *Asia-Pacific Journal Of Operational Research*, 22(1):51–70.

- O'Reilly, P. G. (1998). Trends in the application of model-based fault detection and diagnosis of technical processes. In *UKACC International Conference on CONTROL '98*, pages 247–251.
- Palhares, R. M. (2009). DC machine benchmark fault simulation – MATLAB code. <http://www.cpdee.ufmg.br/~palhares/deteccao.html>.
- Ploix, S. and Adrot, O. (2006). Parity relations for linear uncertain dynamic systems. *Automatica*, 42(9):1553–1562.
- Policarpou, M. M. and Trunov, A. B. (2000). Learning approach to nonlinear fault diagnosis: Detectability analysis. *IEEE Transactions on Automatic Control*, 45(4):806–812.
- Previdi, F. and Parisini, T. (2006). Model-free actuator fault detection using a spectral estimation approach: the case of the DAMADICS benchmark problem. *Control Engineering Practice*, 14(6):635–644.
- Puig, V., Stancu, A., Escobet, T., Nejjari, F., Quevedo, J., and Patton, R. (2006). Passive robust fault detection using interval observers: Application to the DAMADICS benchmark problem. *Control Engineering Practice*, 14(6):621–633.
- Rigatos, G. and Zhang, Q. (2009). Fuzzy model validation using the local statistical approach. *Fuzzy Sets and Systems*, 160(7):882–904.
- Saravanan, N., Cholairajan, S., and Ramachandran, K. (2009). Vibration-based fault diagnosis of spur bevel gear box using fuzzy technique. *Expert Systems with Applications*, 36(2):3119–3135.
- Selmic, R. R., Polycarpou, M. M., and Parisini, T. (2009). Actuator fault detection in nonlinear uncertain systems using neural on-line approximation models. *European Journal of Control*, 15(1):29–44.
- Sheng, Y. and Rovnyak, S. M. (2004). Decision tree-based methodology for high impedance fault detection. *IEEE Transactions on Power Delivery*, 19(2):533–536.

- Silvino, J. L., Bottura, C. P., and Resende, P. (1993). Observadores de fluxo e estimação de parâmetros da máquina de indução via modelamento discreto não-estacionário. *Revista Controle & Automação*, 4(6):11–22.
- Simões, S. (2006). *Análise de árvore de falhas considerando incertezas na definição dos eventos básicos*. PhD thesis, Universidade Federal do Rio de Janeiro.
- Stephanopoulos, G., Locher, G., Duff, M., Kamimura, R., and Stephanopoulos, G. (1995). Fermentation database mining by pattern recognition. *Biotechnology and Bioengineering*, 53(5):443–452.
- Supavatanakul, P., Lunze, J., Puig, V., and Quevedo, J. (2006). Diagnosis of timed automata: Theory and application to the DAMADICS actuator benchmark problem. *Control Engineering Practice*, 14(6):609–619.
- Syfert, M., Bartys, M., and Quevedo, J. (2002). Benchmark definition. <http://diag.mchtr.pw.edu.pl/damadics>.
- Takahashi, R. H. C., Palhares, R. M., and Peres, P. L. D. (1999). Discrete-time singular observers: $\mathcal{H}_2/\mathcal{H}_\infty$ optimality and unknown inputs. *International Journal of Control*, 72(6):481–492.
- Takahashi, R. H. C. and Peres, P. L. D. (1999). Unknown input observers for uncertain systems: A unifying approach. *European Journal of Control*, 5(2–4):261–275.
- Tang, F. (2000). *A Model-Based Bayesian Fault Diagnostic Systems – With Applications to Semiconductor Manufacturing Processes*. PhD thesis, Carnegie Mellon University.
- Thorsen, O. V. and Dalva, M. (1999). Failure identification and analysis for high voltage induction motors in the petrochemical industry. *IEEE Transactions On Industry Applications*, 35(4):810–818.
- Uppal, F. J., Patton, R. J., and Witczak, M. (2006). A neuro-fuzzy multiple-model observer approach to robust fault diagnosis based on the DAMADICS benchmark problem. *Control Engineering Practice*, 14(6):699–717.

- Vedam, H. and Venkatasubramanian, V. (1997). A wavelet theory-based adaptive trend analysis system for process monitoring and diagnosis. In *Proceedings of the American Control Conference*, pages 309–313, Piscataway.
- Venkatasubramanian, V., Rengaswamy, R., and Kavuri, S. N. (2003a). A review of process fault detection and diagnosis – part II: Qualitative models and search strategies. *Computers and Chemical Engineering*, 27:313–326.
- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S. N., and Yin, K. (2003b). A review of process fault detection and diagnosis – part III: Process history based methods. *Computers and Chemical Engineering*, 27:327–346.
- Venkatasubramanian, V., Rengaswamy, R., Yin, K., and Kavuri, S. N. (2003c). A review of process fault detection and diagnosis – part I: Quantitative model-based methods. *Computers and Chemical Engineering*, 27:293–311.
- Wang, Y., Ding, S. X., Ye, H., and Wang, G. (2008). A new fault detection scheme for networked control systems subject to uncertain time-varying delay. *IEEE Transactions on Signal Processing*, 56(10):5228–5268.
- Wilsky, A. (1976). A survey of design methods for failure detection in dynamic systems. *Automatica*, 12:601–611.
- Witczak, M., Korbicz, J., Mrugalski, M., and Patton, R. J. (2006). A gmdh neural network-based approach to robust fault diagnosis: Application to the DAMADICS benchmark problem. *Control Engineering Practice*, 14(6):671–683.
- W.T.Thomson and Fenger, M. (2001). Current signature analysis to detect induction motor faults. *IEEE Industry Applications Magazine*, 7:26–34.
- Wu, B. and Chen, M. (1999). Use of fuzzy statistical technique in change periods detection of nonlinear time series. *Applied Mathematics and Computation*, 99(2–3):241–254.

Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3):338–353.

Zadeh, L. A. (2008). Is there a need for fuzzy logic? *Information Sciences*, 178(13):2751–2779.

Zhang, X. D., Polycarpou, M. M., and Parisini, T. (2002). A robust detection and isolation scheme for abrupt and incipient faults in nonlinear systems. *IEEE Transactions on Automatic Control*, 47(4):576–593.

Zorriassatine, F., Tannock, J., and O’Brien, C. (2003). Using novelty detection to identify abnormalities caused by mean shifts in bivariate processes. *Computers & Industrial Engineering*, 44(3):385–408.