

ESTE EXEMPLAR CORRESPONDE A REDAÇÃO FINAL DA
TESE DEFENDIDA POR SAMUEL DA SILVA

..... E APROVADA
PELA COMISSÃO JULGADORA EM 14 / 02 / 2008


.....
ORIENTADOR

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
COMISSÃO DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

**Detecção de danos estruturais
usando análise de séries temporais e
atuadores e sensores piezelétricos**

Autor: **Samuel da Silva**

Orientador: **Prof. Dr. Milton Dias Júnior**

Co-orientador: **Prof. Dr. Vicente Lopes Junior**

10/2008

**UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
COMISSÃO DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA
DEPARTAMENTO DE PROJETO MECÂNICO**

**Detecção de danos estruturais
usando análise de séries temporais e
atuadores e sensores piezelétricos**

Autor: **Samuel da Silva**

Orientador: **Prof. Dr. Milton Dias Júnior**

Co-Orientador: **Prof. Dr. Vicente Lopes Junior**

Curso: Engenharia Mecânica

Área de Concentração: Mecânica dos Sólidos e Projeto Mecânico

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

Campinas, 2008

SP - Brasil

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

Si38d Silva, Samuel da
Detecção de danos estruturais usando análise de séries temporais e atuadores e sensores piezelétricos / Samuel da Silva.--Campinas, SP: [s.n.], 2008.

Orientadores: Milton Dias Júnior e Vicente Lopes Júnior.
Tese (Doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica.

1. Localização de falhas (Engenharia). 2. Análise de séries temporais – Processamento de dados. 3. Reconhecimento de padrões. 4. Materiais inteligentes. 5. Volterra, Séries de. I. Dias Júnior, Milton. II. Lopes Júnior, Vicente. III. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica. IV. Título.

Titulo em Inglês: Structural damage detection using time series analysis and piezoelectrics actuators and sensors.

Palavras-chave em Inglês: Structural health monitoring, Smart structures, Time series analysis, Kautz-Volterra series, Statistical pattern recognition.

Área de concentração: Mecânica dos Sólidos e Projeto Mecânico.

Titulação: Doutor em Engenharia Mecânica

Banca examinadora: José Roberto de França Arruda, Katia Lucchesi Cavalca Dedini, Paulo Tadeu de Mello Lourenção e Valder Steffen Junior.

Data da defesa: 14/02/2008

Programa de Pós-Graduação: Engenharia Mecânica

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA

TESE DE DOUTORADO

**Detecção de danos estruturais
usando análise de séries temporais
e atuadores e sensores piezelétricos**

Autor: Samuel da Silva

Orientador: Prof. Dr. Milton Dias Júnior

Co-orientador: Prof. Dr. Vicente Lopes Junior

Banca Examinadora



Prof. Dr. Milton Dias Júnior, Presidente

Faculdade de Engenharia Mecânica - UNICAMP



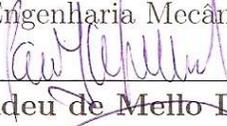
Prof. Dr. José Roberto de França Arruda

Faculdade de Engenharia Mecânica - UNICAMP



Prof. Dra. Katia Lucchesi Cavalca Dedini

Faculdade de Engenharia Mecânica - UNICAMP



Dr. Paulo Tadeu de Mello Lourenção

Empresa Brasileira de Aeronáutica S.A. - EMBRAER



Prof. Dr. Valder Steffen Junior

Faculdade de Engenharia Mecânica - UFU

Campinas, 14 de Fevereiro de 2008.

À Carol e Gabriel pelo amor, carinho e compreensão.

Agradecimentos

Primeiro, gostaria de agradecer a Deus por toda benção que tenho recebido.

Em segundo lugar, esta tese representa o final de uma etapa e projeto de vida que contou com a participação de vários amigos. Em especial gostaria de agradecer o apoio das seguintes pessoas e instituições:

Ao meu orientador, Prof. Milton Dias Júnior, pelas discussões que levaram a esta tese. A liberdade e confiança do Prof. Milton foram um grande fator motivador para concluir este passo na minha trajetória.

Ao meu co-orientador, Prof. Vicente Lopes Junior, por toda ajuda e comentários nos inúmeros trabalhos que fizemos. O Prof. Vicente é o grande responsável por eu ter chegado até esta tese.

Ao Prof. Michael J. Brennan da University of Southampton pelos comentários e inúmeras dicas e pelo auxílio nos resultados da seção 5.2 deste trabalho.

Aos amigos de Besançon, MC Emmanuel Foltête e CR Scott Cogan, que durante o meu estágio de pesquisa no Laboratoire de Mécanique Appliquée Raymond Chaléat (LMARC) da Université de Franche-Comté, me abriram para novos horizontes de pesquisa. Gostaria também de agradecer ao EGIDE - *Centre Français pour l'Accueil et les Echanges Internationaux* e ao CNES - *Centre National d'Études Spatiales* pela bolsa e apoio financeiro concedido durante este estágio.

Aos membros da banca por todos os comentários e sugestões pertinentes.

Os testes experimentais da tese foram realizados na UNESP/Ilha Solteira e só foram possíveis devido ao apoio dos amigos Clayton Rodrigo Marqui e Douglas Domingues Bueno. Gostaria de agradecer este precioso auxílio.

Aos professores, funcionários e companheiros da FEM nestes anos de doutorado, em especial a Sérgio Junichi Idehara, por longas conversas e troca de idéias.

A minha esposa Carol e meu filho Gabriel por serem a razão e o sentido da minha vida.

À Pró-Reitoria de Pós-Graduação da UNICAMP pela bolsa de doutorado fundamental para minha dedicação integral à pesquisa e docência.

"There are two kinds of people, those who do the work and those who take the credit. Try to be in the first group; there is less competition there."

Indira Gandhi

Resumo

SILVA, Samuel da, *Detecção de danos estruturais usando análise de séries temporais e atuadores e sensores piezelétricos*. Campinas,: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2008. 157 p. Tese (Doutorado)

A contribuição deste trabalho foi desenvolver uma metodologia para detecção e localização de danos considerando apenas respostas de deslocamento ou aceleração e medidas obtidas por atuadores e sensores piezelétricos (PZTs) distribuídos e colados em estruturas flexíveis. Modelos de filtros discretos do tipo auto-regressivos, como AR-ARX, ARMA e ARMAX, são usados para extrair um indicador de danos a partir dos erros de predição linear destes filtros. Investiga-se também o uso de séries discretas de Wiener/Volterra escritas com filtros de Kautz para obtenção de erros de predição não-lineares. Para classificar os erros de predição (lineares ou não-lineares) nas classes “sem dano” ou “com dano” comparou-se o uso de ferramentas não-supervisionadas de classificação de padrões estatísticos, como agrupamento *fuzzy* e controle estatístico de processos. Testes numéricos e experimentais foram realizados e os resultados alcançados com a metodologia desenvolvida apresentaram vantagens em relação aos métodos convencionais que são discutidas no decorrer do trabalho.

Palavras-chave

Monitoramento de integridade estrutural, estruturas inteligentes, análise de séries temporais, séries de Kautz-Volterra, reconhecimento estatístico de padrões.

Abstract

SILVA, Samuel da, *Structural damage detection using time series analysis and piezoelectrics actuators and sensors*. Campinas,: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2007. 157 p. Tese (Doutorado)

This work proposes a novel approach to detect and locate incipient damage in structures by using only acceleration responses and coupled piezoelectric actuators and sensors. Though the major focus in smart damage detection is given by on the monitoring of the electrical impedance in the frequency-domain, the current contribution applies a novel technique based on time series analysis. Regressive models, such as AR-ARX, ARMA and ARMAX, are employed to extract a feature index using the linear prediction errors. The use of nonlinear prediction by using discrete-time Wiener/Volterra models expanded by Kautz filter is also investigated. In order to decide correctly whether damage exists or not, a set of unsupervised statistical pattern recognition techniques, namely the fuzzy clustering and the statistical process control, are implemented. Several numerical and experimental tests are performed to illustrate and compare the methodology developed with classical approaches. The efficacy of the approach is demonstrated through these tests.

Keywords

Structural health monitoring, smart structures, time series analysis, Kautz-Volterra series, statistical pattern recognition.

Índice

Lista de Figuras	xv
Lista de Tabelas	xix
Nomenclatura	xxi
1 Introdução	1
1.1 Contribuições da tese	3
1.2 Objetivos	4
1.3 Organização do trabalho	5
2 Revisão Bibliográfica	7
2.1 Métodos globais - baseados apenas em sinais de resposta	10
2.2 Métodos locais - baseados em sinais de entrada-saída de PZTs	16
2.3 Conclusões	23
3 Análise de Séries Temporais	25
3.1 Modelo AR-ARX	26
3.1.1 Procedimento de padronização	26
3.1.2 Compressão de dados via análise de componentes principais	27
3.1.3 Extração do indicador AR-ARX	29
3.2 Modelo ARMA	32
3.3 Modelo ARMAX	35
3.4 Modelos discretos de Volterra	36

3.4.1	Séries de Wiener/Volterra	41
3.4.2	Filtros de Kautz	43
3.4.3	Detecção de danos usando modelos de Kautz-Volterra	44
3.5	Determinação de ordem de modelos	46
3.6	Validação de modelos	47
3.7	Conclusões	48
4	Técnicas de Detecção e Localização de Danos	51
4.1	Indicadores convencionais	52
4.1.1	Indicador γ	52
4.1.2	Indicador falha métrica RMSD	53
4.2	Agrupamento fuzzy	56
4.2.1	Divisão de <i>Clusters</i>	58
4.2.2	Algoritmo fuzzy c-means	59
4.2.3	Algoritmo Gustafson-Kessel	60
4.3	Controle estatístico de processos	62
4.4	Conclusões	63
5	Resultados Baseados Apenas em Medidas de Respostas	65
5.1	Estrutura teste ASCE	65
5.1.1	Descrição da estrutura	66
5.1.2	Extração do indicador	66
5.1.3	Resultados via FCM	81
5.1.4	Resultados via GK	84
5.1.5	Conclusões	86
5.2	Estrutura teste LANL	87
5.2.1	Descrição dos ensaios	87
5.2.2	Resultados via FCM e GK	94
5.2.3	Conclusões	98
5.3	Rotor estacionário	99

5.3.1	Descrição do teste	100
5.3.2	Resultados via SPC	102
5.3.3	Conclusões	104
6	Detecção de Danos em Estruturas Inteligentes	109
6.1	Viga ativa com PZTs acoplados	110
6.1.1	Descrição do ensaio	110
6.1.2	Diagnóstico via falha métrica	114
6.1.3	Construção do modelo ARMAX	116
6.1.4	Diagnóstico via SPC	118
6.1.5	Conclusões	121
6.2	Estrutura portal com PZTs acoplados	123
6.2.1	Descrição do ensaio	124
6.2.2	Diagnóstico via falha métrica	127
6.2.3	Diagnóstico via SPC	129
6.2.4	Diagnóstico usando modelos de Kautz-Volterra	135
6.2.5	Conclusões	140
6.3	Observações finais	141
7	Considerações Finais	143
7.1	Conclusões	143
7.2	Sugestões para futuros trabalhos	145
	Referências Bibliográficas	149

Lista de Figuras

1.1	Exemplos de tragédias provocadas por danos estruturais.	2
4.1	Diagrama do circuito ligado ao PZT indicando as voltagens V_{in} e V_{out} [64].	54
4.2	Dispositivo de baixo custo para condicionamento dos sinais V_{in} e V_{out} [31].	54
4.3	<i>Clusters</i> com diferentes formas e dimensões no espaço \mathcal{R}^2	58
5.1	Esquema da estrutura <i>benchmark</i> [35].	67
5.2	Resposta temporal representativa para o caso sem dano (Caso 1).	71
5.3	Resposta temporal representativa para o caso com dano (Caso 12).	71
5.4	PCA da matriz de covariância com 16 sinais de aceleração para o caso 1.	72
5.5	Resposta temporal projetada no 1.º PC para o caso sem dano (Caso 1).	72
5.6	Resposta temporal projetada no 1.º PC para o caso com dano (Caso 12).	73
5.7	Valor do AIC para várias ordens para os casos sem dano.	74
5.8	Saída medida e saída do modelo AR(13) para o caso 5 (sem dano).	75
5.9	Função de correlação cruzada do resíduo do modelo AR(13) para o caso 5.	75
5.10	Erro de predição de um passo-à-frente AR(13) para os casos sem dano.	76
5.11	<i>Zoom</i> na comparação entre o erro de predição ARX entre referência e caso desconhecido.	77
5.12	Distribuição normal para o erro residual ARX (Caso 2).	79
5.13	Comparação entre as PDFs do erro residual do caso com dano e de referência.	79
5.14	Conjunto de dados à ser classificado.	81
5.15	Agrupamento fuzzy dos dados via <i>FCM</i> em três <i>clusters</i> : saudável, com dano e com dano severo.	82

5.16	Evolução da função objetivo do <i>FCM</i>	82
5.17	Função de pertinência para o <i>FCM</i>	83
5.18	Agrupamento fuzzy dos dados via <i>GK</i> em três <i>clusters</i> : saudável, com dano e com dano severo.	84
5.19	Evolução do <i>GK</i>	85
5.20	Função de pertinência para o <i>GK</i>	86
5.21	Estrutura benchmark LANL.	88
5.22	PCA da matriz de covariância com 24 sinais de aceleração para o caso 9.	90
5.23	Seleção da ordem do filtro ARMA usando o AIC para o caso 1.	91
5.24	Detalhe da saída medida e da saída do modelo de predição para o caso 6 (dados sem dano), com todas as medidas projetadas no 1.º componente principal com um modelo ARMA.	93
5.25	Comparação entre as PDFs do erro residual do caso 25 (com dano) e do sinal de referência (caso 6) para a estrutura LANL.	94
5.26	Agrupamento fuzzy dos dados via FCM e GK com $m = 2$ and $c = 2$	95
5.27	Evolução da função objetivo do agrupamento FCM e GK.	96
5.28	Função de pertinência para o agrupamento FCM e GK.	97
5.29	Rotor com seis graus de liberdade.	100
5.30	Erro de predição AR-ARX para o caso 6 (condição desconhecida) e sua referência (caso 2). O número de <i>outliers</i> em (b) indica sistema sem dano.	104
5.31	Erro de predição AR-ARX para o caso 11 (condição desconhecida) e sua referência (caso 1). O número de <i>outliers</i> em (b) indica sistema com dano.	105
5.32	Razão γ entre os erros de predição.	105
5.33	Evolução dos <i>outliers</i>	106
6.1	Viga com PZTs acoplados usada nos testes experimentais.	111
6.2	Diagrama esquemático da montagem experimental. As dimensões estão em mm.	112
6.3	Sinais de entrada-saída para o sistema sem dano medidos com o PZT1.	113
6.4	Parte real e imaginária da função de transferência estimada entre os sinais de entrada e saída medidas com o PZT1 (diversas condições estruturais).	114

6.5	Parte real e imaginária da função de transferência estimada entre os sinais de entrada e saída medidas com o PZT2 (diversas condições estruturais).	115
6.6	Função de coerência das estimativas usando as medidas do PZT1 e PZT2.	116
6.7	Índice falha métrica M obtido à partir das medidas do PZT1 e PZT2.	116
6.8	Análise de resíduos do modelo construído com medidas do PZT1 considerando o sistema na condição estrutural saudável.	117
6.9	Gráfico de probabilidade do erro residual ARMAX no estado saudável para o PZT1, com valor <i>kurtosis</i> 3.06 e <i>skewness</i> -0.01.	119
6.10	Erro de predição ARMAX para o sinal de referência no PZT1. O número de <i>outliers</i> mostra condição normal (17 <i>outliers</i>). Menor do que o valor de alarme de 20 <i>outliers</i>	120
6.11	Dois sinais de erro ARMAX medidos com o PZT1 para verificação de falsos-positivos. O número de <i>outliers</i> em ambos os gráficos mostra condições sem dano (14 e 19 <i>outliers</i> , respectivamente). Menores do que o valor limiar de 20 <i>outliers</i>	121
6.12	Casos com dano considerando-os como condição estrutural desconhecida no PZT1. O número de <i>outliers</i> em ambos os gráficos mostra condições com dano (28, 31 e 34 <i>outliers</i> , respectivamente). Maiores do que o valor limiar de 20 <i>outliers</i>	122
6.13	Resultados para todas as condições estudadas. Os limites de controle foram baseados no conjunto de dados sem dano de referência. O número de <i>outliers</i> maior no PZT1 indica que o dano é localizado na região próxima a este sensor.	123
6.14	Estrutura portal utilizada como bancada experimental.	124
6.15	Esquema da montagem experimental mostrando o posicionamento dos PZTs e dos danos induzidos. As dimensões estão em mm.	125
6.16	Sinais de impedância eletromecânica para os PZT1 e PZT2 em diversas condições estruturais.	128
6.17	Índice falha métrica M obtido à partir das medidas no portal com o PZT1 e PZT2.	129
6.18	Resultado de simulação livre para os dados do PZT1 e PZT2 na condição saudável sd1.	130
6.19	Erro de predição ARMAX para o sinal de referência no PZT1. O número de <i>outliers</i> mostra condição normal (25 <i>outliers</i>).	131

6.20	Erros ARMAX para o PZT1 considerando várias condições estruturais. O valor limiar para o dano é de 50 <i>outliers</i>	132
6.21	Erro de predição ARMAX para o sinal de referência no PZT2. O número de <i>outliers</i> mostra condição normal (28 <i>outliers</i>).	133
6.22	Erros ARMAX para o PZT2 considerando várias condições estruturais. O valor limiar para o dano é de 50 <i>outliers</i>	134
6.23	Número de <i>outliers</i> para todas as condições estudadas na estrutura portal. A linha pontilhada — se refere ao valor limiar de 50 pontos.	135
6.24	Primeiro kernel de Volterra $h_1(n_1)$ estimado para o PZT1 na condição sem dano sd1.	137
6.25	Segundo kernel de Volterra $h_2(n_1, n_2)$ estimado para o PZT1 na condição sem dano sd1.	138
6.26	Comparação do sinal real $x(k)$ e as estimativas com o 1.º e 2.º kernel de Volterra.	139
6.27	Comparação das funções densidade de probabilidades para o PZT1 usando predição linear somente com o 1.º kernel $h_1(n_1)$ de Volterra.	139
6.28	Comparação das funções densidade de probabilidades para o PZT1 usando predição não-linear com o 1.º e 2.º kernel de Volterra, $h_1(n_1)$ e $h_2(n_1, n_2)$ respectivamente.	140

Lista de Tabelas

5.1	Propriedades da estrutura.	67
5.2	Padrões de dano definidos para o <i>benchmark</i> ASCE.	68
5.3	Conjunto de dados sem dano (referência) para a estrutura ASCE.	69
5.4	Conjunto de dados em condição estrutural desconhecida para a estrutura ASCE. . . .	70
5.5	Propriedades estatísticas básicas das séries temporais.	78
5.6	Desvio padrão do erro residual para várias condições estruturais.	80
5.7	Padrões de dano definidos para a estrutura LANL.	88
5.8	Conjunto de dados sem dano (referência) para a estrutura LANL.	89
5.9	Conjunto de dados desconhecidos para a estrutura LANL (Dados sem danos).	90
5.10	Conjunto de dados desconhecidos para a estrutura LANL (Dados com dano 1).	91
5.11	Conjunto de dados desconhecidos para a estrutura LANL (Dados com dano 2).	92
5.12	Conjunto de dados desconhecidos para a estrutura LANL (Dados com dano 3).	93
5.13	Conjunto de dados desconhecidos para a estrutura LANL (Dados com dano 4).	94
5.14	Propriedades do rotor.	101
5.15	Padrões de danos para o rotor.	102
5.16	Dados de referência para o sistema rotativo.	102
5.17	Condições desconhecidas do sistema rotativo.	103
6.1	Dimensões da estrutura e dos PZTs modelos PSI-5A-S4 (Piezo Systems®).	110
6.2	Condições estruturais investigadas na viga ativa.	112
6.3	Dimensões da estrutura portal e dos PZTs modelos PSI-5A-S4 (Piezo Systems®). . . .	125
6.4	Condições estruturais investigadas na estrutura portal.	126
6.5	Resultados da detecção com modelos de Kautz-Volterra.	138

7.1 Exemplos utilizados na tese.	144
--	-----

Nomenclatura

Letras latinas

$A(q)$	- parte AR do modelo.
$A_{x_i}(q)$	- polinômio relativo a saídas na condição estrutural conhecida.
$A_{x_r}(q)$	- polinômio relativo a saídas no sinal de referência.
$A_y(q)$	- polinômio relativo a saídas no sinal na condição estrutural desconhecida.
a_{xil}	- coeficientes do i -ésimo polinômio $A_{x_i}(q)$.
a_{yi}	- i -ésimo coeficiente do polinômio $A_y(q)$.
$B(q)$	- polinômio relacionado aos sinais de entrada.
$B_{x_r}(q)$	- polinômio relativo a entrada no sinal de referência.
c	- número de <i>clusters</i> .
C_i	- centróide do i -ésimo <i>cluster</i> .
$C(q)$	- parte MA de modelos ARMA e ARMAX.
$e_x(k)$	- erro de predição na condição conhecida no instante k .
$e_{x_r}(k)$	- erro de predição na referência.
$e_y(k)$	- erro de predição em condição desconhecida a ser determinada.
f_{ij}	- função de pertinência associada ao j -ésimo objeto do i -ésimo <i>cluster</i> .
$g_j(k)$	- aceleração na localização j no instante k .
$G(\omega_i)$	- função de transferência entre os sinais V_{in} e V_{out} .
$h_m(n_1, n_2, \dots, n_m)$	- m -ésimo kernel de Volterra.
m	- número de localizações de medidas.
$m(*)$	- operador média.

M	- índice falha métrica.
N	- número de condições operacionais/ambientais para ser observado.
n_a	- ordem do polinômio $A(q)$.
n_b	- ordem do polinômio $B(q)$.
n_c	- ordem do polinômio $C(q)$.
n_k	- tempo de atraso do sinal de entrada $u(k)$.
p	- ordem do polinômio AR.
q	- ordem do polinômio MA.
q^{-1}	- operador de atraso temporal.
$R_{i_{xx}}(r)$	- função de correlação do sinal $x_i(k)$ no atraso r .
$u(k)$	- sinal de entrada em condição conhecida.
$u_y(k)$	- sinal de entrada em condição desconhecida.
\mathbf{v}	- componente principal.
V_{in}	- sinal de voltagem na entrada do PZT.
V_{out}	- sinal de voltagem na saída do circuito condicionador.
$x_i(k)$	- sinal na condição sem dano.
$x_r(k)$	- sinal de referência.
$y(k)$	- sinal em condição desconhecida.
$z(k)$	- vetor de respostas.
Z_p	- sinal de impedância eletromecânica.

Letras gregas

$\alpha_{i_m}(i_1, i_1, \dots, i_m)$	- m -ésimo kernel ortogonal de Wiener/Volterra.
$\beta, \bar{\beta}$	- pólo complexo de Kautz.
Ψ	- matriz de covariâncias $m \times m$.
ψ_{i_j}	- filtro de Kautz.
θ	- vetor de parâmetros à estimar em séries de Wiener/Volterra.
λ	- autovalores da matriz covariâncias.

- $\lambda'(k)$ - vetor auto-regressivo com os sinais $u(k)$.
- $\varepsilon_{x_r}(k)$ - erro de predição ARX de referência.
- $\varepsilon_y(k)$ - erro de predição ARX na condição desconhecida.
- γ - razão entre os erros de predição.
- γ_{lin} - razão entre os erros de predição do 1.º kernel de Volterra.
- γ_{nl} - razão entre os erros de predição não-linear do modelo Kautz-Volterra.
- $\sigma(*)$ - operador desvio padrão.
- ω_i - *i-ésimo* ponto de frequência.

Abreviaturas

- AIC - critério de informações de Akaike.
- AR - modelo auto-regressivo.
- ARX - modelo auto-regressivo com entradas exógenas.
- ARMA - modelo auto-regressivo com média móvel.
- ARMAX - modelo auto-regressivo com média móvel e entradas exógenas.
- CL - linha central.
- FCM - algoritmo de agrupamento *fuzzy c-means*.
- FIR - resposta finita ao impulso.
- FPE - erro final de predição.
- GK - algoritmo de agrupamento Gustafson-Kessel.
- IIR - resposta infinita ao impulso.
- LCL - limite de controle inferior.
- NIIR - resposta não-linear infinita ao impulso.
- NFIR - resposta não-linear finita ao impulso.
- PCA - análise de componentes principais.
- PVDF - sensor piezopolímero (PolyVinylidenoFluoride).
- PZT - atuador/sensor piezocerâmico (*Lead Zirconate Titanate*).
- RMSD - desvio médio quadrático.
- SHM - *Structural Health Monitoring*.
- SPC - controle estatístico de processos.
- UCL - limite de controle superior.

Capítulo 1

Introdução

Hoje em dia muitos acidentes em sistemas estruturais causados por vários fatores têm atraído a atenção de engenheiros e pesquisadores para a necessidade de se desenvolverem estratégias de monitoramento de integridade estrutural, do inglês *Structural Health Monitoring (SHM)*¹. Estes acidentes têm sido causados por eventos extremos, como terremotos e outros desastres naturais; eventos graduais, e.g. trincas por fadiga, delaminação em compósitos, etc; e eventos previstos e discretos, como esforços em trens de pousos de aeronaves no momento de decolagem e aterrissagem, etc.

Como exemplo pode-se citar a separação da fuselagem de um Boeing 737 da *Aloha Airlines* em 1988, ilustrado na figura 1.1(a), que trouxe à tona o problema do envelhecimento de aeronaves. Investigações posteriores ao acidente apontaram para um programa de manutenção deficiente na detecção de falhas de corrosão, o que acelerou o processo de fadiga na fuselagem, ocasionando o dano [79]. Outro acidente estrutural que teve destaque recente na mídia foi a queda de uma ponte sobre o rio Mississípi, na cidade de Minéapolis nos Estados Unidos [18], figura 1.1(b). A ponte tinha sido inspecionada em 2005 e 2006 através de medidas de vibrações e na ocasião nenhum defeito estrutural foi encontrado, porém um estudo conduzido anteriormente em 2001 pelo Departamento de transportes de Minnesota mostrou vários defeitos por tempo de uso² que foram ignorados pelas autoridades. O desastre teve um saldo trágico de 7 mortos e dezenas de feridos.

¹O termo *SHM* será usado em todo texto para designar monitoramento de integridade estrutural.

²A ponte foi construída em 1967.



(a) Colapso na fuselagem de uma aeronave da *Aloha Airlines* [79]. (b) Desabamento de ponte sobre o rio Mississípi [18].

Fig. 1.1: Exemplos de tragédias provocadas por danos estruturais.

Inman et al. [34] comentam que o interesse em *SHM* é motivado também por questões econômicas. Estima-se que o custo anual associado com falhas mecânicas, estruturais e por desastres é em torno de 60 bilhões de dólares. Somente na indústria petroquímica, as falhas em serviço correspondem de 20 a 40 % de todas as perdas do setor [34].

Além disto, as estruturas modernas de engenharia estão cada vez mais leves e flexíveis e sujeitas a frequências de excitação que podem causar falhas aos sistemas causadas por carregamento dinâmico [90]. Porém, a maioria das metodologias *SHM* utilizadas para fins práticos se baseiam em métodos visuais e ou experimentais localizados, como exemplo os métodos ultra-sônicos [40]. Um ponto negativo nestes métodos é a necessidade de se conhecer a priori a localização da região onde o dano ocorre. Isto motivou as pesquisas de metodologias baseadas em medidas de vibração mecânica, que têm sido muito investigadas nos últimos 30 anos [11].

O grande interesse atual em técnicas de diagnóstico e prognóstico via medidas de vibração é resultado do desenvolvimento de sensores e hardwares mais baratos e de diversas técnicas de detecção global bem consolidadas, a maioria baseada em conceitos de análise modal [21, 79].

Nos últimos 10 anos uma poderosa tecnologia envolvendo materiais inteligentes, com destaque

para atuadores e sensores piezelétricos (PZTs)³, tem sido exaustivamente estudada. O acoplamento eletromecânico entre os PZTs e a estrutura possui enormes vantagens quando comparado com a maioria dos procedimentos modais convencionais. A principal vantagem desta formulação é a grande sensibilidade a mudanças estruturais mínimas, uma vez que danos, como trincas, são fenômenos locais. A técnica envolvendo medidas em PZTs exige também baixa voltagem de entrada (geralmente menor que 1 volt) e alta frequência de excitação nas faces dos PZTs colados na estrutura, tipicamente maiores do que 30 kHz [54, 37, 34]. Estruturas com PZTs acoplados são chamadas na literatura de estruturas inteligentes.

Entretanto, esta técnica não está desenvolvida de maneira suficiente para ser um sistema *plug-and-play* devido a várias razões práticas, muitas delas discutidas, por exemplo, no trabalho [58]. Uma delas é o fato da técnica não se basear em nenhum modelo matemático do sistema dinâmico e sim em estimativas não-paramétricas no domínio da frequência. Isto acarreta algumas limitações e problemas que serão revistos no capítulo 2 deste trabalho.

Neste contexto, esta tese busca contornar estas limitações a partir da proposição de uma nova forma de detectar e localizar danos em estruturas inteligentes usando, ao invés de dados frequenciais, dados no domínio do tempo, e aplicando resultados já conhecidos de análise de séries temporais. Os métodos estudados e propostos também podem ser aplicados no monitoramento de integridade estrutural baseados apenas em medidas de vibração (seja deslocamento, velocidade ou aceleração) em alguns pontos do sistema. Sendo assim, esta possível aplicação também é avaliada neste trabalho a partir de simulações numéricas e experimentais.

1.1 Contribuições da tese

Esta tese busca contribuir essencialmente em três tópicos:

Algoritmos para detecção de danos: A tese busca analisar; a partir de comparações envolvendo exemplos diversos; os métodos para separação de classes em modo não-supervisionado que são

³uma classe especial são os atuadores/sensores piezocerâmicos, entre eles os PZTs (*Lead Zirconate Titanate*).

convencionais e já amplamente empregados, como as formulações usando controle estatístico de processos, com métodos não usuais na comunidade de SHM, como os usando agrupamento fuzzy. Neste tópico pode-se destacar as publicações em periódicos dos trabalhos [71], [75] e [69], feitas pelo autor durante a execução desta pesquisa.

Uso de séries temporais obtidas de PZTs: Tradicionalmente as aplicações envolvendo PZTs são baseadas no monitoramento do sinal de impedância elétrica no domínio da frequência. Porém, esta tese investiga o emprego direto dos sinais temporais de voltagens de entradas e saídas aplicados aos PZTs. O enfoque é monitorar os sinais elétricos provenientes dos PZTs usando erros de predição de filtros lineares ou não-lineares previamente identificados. Embora a ideia do uso de séries temporais em aplicações SHM seja usual e já divulgada em trabalhos anteriores, por exemplo [78] ou [52], este ponto não havia sido anteriormente abordado por outros autores em aplicações com estruturas inteligentes da mesma forma feita nesta tese. Este tópico de pesquisa foi publicado em periódico internacional especializado no tema SHM [74].

Séries de Kautz-Volterra para detecção de danos: Séries discretas de Volterra escritas em termos de filtros de Kautz são extremamente úteis em problemas de identificação não-paramétrica de sistemas não-lineares e se encontram em estágio de grande desenvolvimento [17]. Contudo, o uso destes modelos em aplicações SHM é inédito. Esta tese apresenta uma nova metodologia para aplicação de modelos Kautz-Volterra visando a detecção de danos estruturais.

1.2 Objetivos

A meta principal deste trabalho é propor uma técnica temporal rápida e de baixo custo, admitindo nenhum conhecimento de modelo matemático do sistema dinâmico, visando detectar e localizar danos em estruturas flexíveis com PZTs acoplados ou ainda empregando apenas medidas de vibração. O método proposto é dividido em duas fases: a primeira é a extração de um índice à partir de erros de predição linear ou não-linear de filtros discretos calculados com base em séries temporais de entrada/saída de voltagens em PZTs ou ainda a partir de medidas de respostas de deslocamento ou aceleração; a segunda fase é a classificação deste índice em uma classe sem dano ou com dano usando um método não-supervisionado.

1.3 Organização do trabalho

Este trabalho está organizado em 7 capítulos que descrevem:

- Capítulo 1: Introdução e motivação para a proposta da metodologia.
- Capítulo 2: Revisão bibliográfica do estado de arte em *SHM*, dividindo o estudo em métodos temporais globais e locais, com destaque para aplicações envolvendo estruturas inteligentes.
- Capítulo 3: Descrição de modelos de predição do tipo auto-regressivos que podem ser usados para extração de indicadores de danos estruturais. Apresenta-se também o emprego de modelos de Kautz-Volterra para obtenção de erros de predição não-lineares. Estes erros podem ser usados como eficientes indicadores de danos.
- Capítulo 4: Técnicas de detecção e localização de danos usando ferramentas de reconhecimento estatístico de padrões em modo não-supervisionado.
- Capítulo 5: Resultados simulados e experimentais para descrição e comparação das técnicas propostas usando apenas medidas de respostas em alguns pontos de estruturas/máquinas. Neste capítulo o enfoque é a aplicação de métodos globais para detecção de danos.
- Capítulo 6: Resultados experimentais baseados em medidas de entrada/saída de PZTs colados em estruturas inteligentes. Neste capítulo a meta é a aplicação de métodos locais para detecção e localização de danos.
- Capítulo 7: Conclusões com as principais contribuições desta tese e sugestões para futuros trabalhos.

Capítulo 2

Revisão Bibliográfica

Muitas estruturas de engenharia mecânica, civil e aeronáutica continuam sendo utilizadas apesar do grande tempo de vida e da possibilidade de apresentarem danos acumulados; ou mesmo contendo erros de projeto, fabricação e/ou montagem que poderão originar defeitos futuros. Portanto, a capacidade de monitorar a condição destes sistemas, ou seja, sua integridade estrutural, tem se tornado nos últimos anos uma área de pesquisa muito importante do ponto de vista econômico e de segurança, particularmente em áreas envolvendo estruturas aeronáuticas [36] e infra-estruturas de engenharia civil [71]. Esta área é usualmente denominada de *Structural Health Monitoring* (SHM).

SHM é definido como um processo de implementação de uma estratégia de decisão para detecção de falhas em estruturas de engenharia. Este processo envolve: a observação das medidas de respostas dinâmicas de uma estrutura, que podem ser obtidas através de uma grande diversidade de sensores; a extração de indicadores sensíveis à falha a partir destas medidas ou da sua correlação com modelos matemáticos¹; e a análise estatística destes indicadores para determinar a condição estrutural real do sistema em questão.

Doebeling et al. [21] separaram formalmente o processo SHM em quatro sub-níveis baseados em medidas de vibração:

Nível 1: Detectar o dano.

¹A maioria dos trabalhos de pesquisa se concentram neste tópico, segundo [25].

Nível 2: Detectar e localizar o dano.

Nível 3: Detectar, localizar e quantificar a severidade do dano.

Nível 4: Detectar, localizar, quantificar a severidade e obter informações sobre a vida remanescente da estrutura (prognóstico).

Inman [33] propôs mais três sub-níveis mesclando o uso de materiais inteligentes e englobando técnicas de auto-reparo estrutural e controle. Atingir todos estes níveis no monitoramento de um sistema real é um enorme desafio que ainda não se encontra totalmente vencido. Na verdade atingir apenas o nível 1 ainda é difícil em aplicações envolvendo estruturas reais, segundo Worden et al. [91]. Este autores discutem que entre todos estes níveis de um problema SHM, o mais fundamental é detectar com confiabilidade se o dano está presente ou não na estrutura. Entre as inúmeras razões desta dificuldade podem-se citar [13]: complexidade de estruturas reais, presenças de incertezas, desconhecimento de todas as fontes de excitação, etc.

O desafio torna-se maior quando não é possível excitar a estrutura com fonte ativa devido às restrições de peso e/ou potência e quando condições ambientais e/ou operacionais são desconhecidas. Nestes casos, o SHM deve ser feito com base em medidas somente de respostas de vibração. Por outro lado, quando algum conhecimento sobre a estrutura é disponível, seu comportamento pode ser simulado numericamente.

Trabalhos de revisão como [21], [79] e [11] descrevem várias técnicas para diagnóstico de falhas estruturais e constatam que a maioria dos trabalhos existentes são baseados na modelagem por elementos finitos e/ou na extração de parâmetros modais aliada ao ajuste de modelos lineares [61]. Para aplicações práticas, a grande maioria destes métodos tem se mostrado ineficientes devido ao intensivo trabalho laboratorial e incertezas significativas causadas por interação com o usuário e erros de modelagem. Além do mais, estas formulações em geral podem se tornar muito caras e complexas, além do fato de invariavelmente se considerarem grandes simplificações nos modelos ou desconhecimento de como modelar um dano ou um determinado comportamento.

Uma outra forma de realizar o monitoramento seria se basear apenas em dados medidos previa-

mente em condições da estrutura intacta e observar possíveis modificações estruturais, geométricas ou de contorno usando alguma métrica indicativa.

A idéia básica do problema SHM, baseado em sinais de vibração, é que a presença de falhas altera “significativamente” as propriedades físicas do sistema – por exemplo, redução de rigidez causada pela presença de trincas² – e/ou provoca variações das propriedades geométricas que podem vir a mudar as condições de contorno e a conectividade do sistema. Todos estes fatores podem comprometer o desempenho futuro da estrutura e resultar em uma mudança na resposta dinâmica do sistema. Portanto, na definição de falha está implícito que o problema de diagnóstico é uma comparação entre dois estados de um sistema: um estado sem falha e outro estado com falha.

Embora a grande maioria dos métodos baseados em dados experimentais de vibração possa parecer intuitiva, existem enormes desafios a serem vencidos. Entre eles se destacam [25]:

1. Realizar uma melhor caracterização de respostas não-lineares, uma vez que a maioria dos métodos admite que o sistema possa ser modelado como linear, tanto antes quanto depois da falha, o que nem sempre é válido, pois respostas de estruturas com danos podem apresentar características não-lineares acentuadas.
2. Desenvolvimento de métodos para definir o número e localização ótima de sensores.
3. Identificação de indicadores sensíveis a falhas incipientes.
4. Algoritmos SHM devem (ou deveriam) ser implementados em um modo de aprendizagem não-supervisionado, o que implica que os dados do sistema com falha não são disponíveis.
5. Habilidade para distinguir mudanças dos indicadores causadas por danos daquelas causadas por variações nas condições operacionais e/ou ambientais, ou seja, definição de um valor de *threshold* baseado em métodos estatísticos.

Algumas formulações combinam o uso de modelos matemáticos e o uso de medidas experimentais para alcançar um melhor nível de confiança estatística. Na presente tese, o esforço será em usar

²Dependendo do grau e da criticidade do dano.

somente técnicas baseadas em medidas experimentais³. Em especial esta tese procura contribuir para tentar vencer os tópicos desta lista de desafios. Em especial o tópico (4) apresenta uma das grandes limitações. Esta consideração é verdade para a grande maioria das aplicações em estruturas reais, conforme descrito em [29]. Isto leva à necessidade de se utilizar com mais vigor as metodologias estatísticas. Entretanto, observam-se poucos estudos citados na referência clássica [21] que aplicam análise estatística de dados medidos; apesar de a grande maioria dos métodos relatados nesta referência poderem ser descritos dentro do paradigma de reconhecimento não-supervisionado de padrões. A falta de análise estatística apresenta um potencial problema para o desenvolvimento da tecnologia de detecção de falhas, baseada em medidas de vibração para aplicações reais, conforme trabalhos como [25] ou [79].

Nesta concepção, esta tese propõe contribuir para o problema SHM através basicamente da investigação do uso de séries temporais conjuntamente com ferramentas de reconhecimento estatístico de padrões em modo não-supervisionado. Em particular, emprega-se a filosofia de se utilizar filtros auto-regressivos, identificados a partir de sinais temporais da estrutura saudável em condição de referência, e realizar a comparação estatística com dados filtrados pelo mesmo modelo de referência em condição considerada ser de natureza desconhecida (com dano ou sem dano).

Na seqüência se apresenta uma divisão entre duas grandes classes de métodos temporais. Primeiramente os métodos considerados globais, que são baseados apenas em respostas medidas de deslocamento e/ou aceleração em alguns pontos estratégicos de estruturas. No segundo conjunto de formulações encontram-se os chamados métodos locais, baseados em medidas elétricas obtidas por atuadores/sensores piezocerâmicos (PZTs) distribuídos em estruturas flexíveis. A grande parte dos trabalhos citados neste capítulo se concentram em métodos temporais.

2.1 Métodos globais - baseados apenas em sinais de resposta

Uma metodologia SHM temporal foi proposta pelo Los Alamos National Laboratory (LANL), USA, para se atingir os níveis (1) e (2) do problema de detecção de falhas. Esta técnica é baseada

³ou respostas pseudo-experimentais obtidas por um simulador numérico.

exclusivamente na análise estatística de séries temporais de sinais de vibrações. Alguns exemplos ilustrativos desta formulação podem ser encontrados nas referências [77], [78], [29] ou ainda [89].

A principal justificativa para a investigação desta técnica se deve ao fato de que nenhuma formulação sofisticada, como método de elementos finitos ou análise modal clássica, precisa ser empregado na implementação do procedimento do LANL, ao contrário de outras metodologias na literatura discutidas e referenciadas no trabalho de revisão [79]. Isto permite, a priori, se considerar problemas mais complexos e próximos de casos reais. Adicionalmente, não é necessária nenhuma medição ou estimação de forças de excitação, apenas as respostas temporais medidas diretamente da estrutura são empregadas.

O método se insere na classe de reconhecimento estatístico de padrões. Portanto, esta formulação se mostra muito atraente e promissora para aplicações práticas principalmente para o desenvolvimento de um sistema de monitoramento automático, devido a sua simplicidade e exigência mínima de interação com o usuário⁴. Além disto, o diagnóstico do dano pode ser conduzido independentemente em cada ponto de medida da estrutura e não é necessária a sincronização de tempo em cada sensor [78].

Do ponto de vista técnico, a metodologia de Sohn e Farrar [78] foi composta por um modelo de predição de dois estágios, combinando um modelo auto-regressivo (AR) e um modelo auto-regressivo com entradas exógenas (ARX). O modelo foi construído com sinais de aceleração normalizados e em posições selecionadas, obtidos na estrutura sem dano. No caso do trabalho específico [78] o método foi testado em uma aplicação envolvendo um modelo massa-mola com oito graus de liberdade. O dano foi simulado com a aplicação de um amortecedor entre duas massas, o que gerou um maior movimento vibratório do tipo "abre-fecha". Este efeito pode simular uma trinca em uma estrutura real. Os autores consideraram medidas de diferentes condições ambientais tomadas da estrutura na condição saudável e intacta. O erro de predição de um passo-à-frente do modelo AR-ARX foi definido como um indicador sensível à modificações estruturais. Se algum dano estivesse presente na estrutura, o modelo previamente obtido usando o sinal de referência não seria capaz de reproduzir

⁴A interação com o usuário ocorre somente na fase de ajuste das ordens e do cálculo dos coeficientes dos modelos auto-regressivos na condição de referência.

novas séries temporais medidas nestas condições danificadas. Uma análise estatística Gaussiana, baseada na razão dos desvios padrões destes erros, foi usada para detectar e, eventualmente, localizar o dano propriamente dito. Uma descrição matemática desta formulação é encontrada nesta tese na seção 3.1.3.

A partir deste trabalho, inúmeros outros foram propostos em linhas similares. Muitos deles buscando incorporar novas contribuições ao método desenvolvido pelo LANL. Lei et al. [43] modificaram esta formulação considerando a influência da variabilidade do sinal de excitação e a ordem do modelo de predição ARX na obtenção do indicador estatístico do dano. Os resultados investigados foram avaliados em uma estrutura *benchmark* da ASCE [46]. Porém uma limitação da metodologia de [43] foi o enorme número de pontos de medidas, gerando dificuldades práticas para visualização e processamento de sinais. Nesta linha, acredita-se que o uso de ferramentas de compressão espacial de dados, como as baseadas na decomposição de Karhunen-Loève, também conhecida como análise de componentes principais (PCA), possa ser extremamente útil em um problema SHM.

Um bom exemplo prático do potencial de redução espacial via PCA foi proposto no trabalho [77]. Neste trabalho os autores utilizaram, no monitoramento de uma coluna de concreto de uma ponte, medidas de cerca de 40 acelerômetros, o que tornou a visualização e o tratamento dos dados muito difícil. Para contornar o problema, os autores usaram PCA para comprimir os dados. Este processo transforma séries temporais de múltiplos pontos de medidas em um vetor simples, preservando as informações relevantes das características dinâmicas da estrutura, antes da extração dos indicadores de danos. O único ponto negativo é talvez perder a informação da localização da falha. Entretanto, em aplicações envolvendo estruturas de grande porte, como a discutida em [77], detectar qual o pilar da ponte apresenta dano, já cumpre o objetivo do processo de SHM.

Lu e Gao [45] propuseram um modelo linear diferente na forma ARX, sem o termo de excitação. Neste caso, o sinal de aceleração em outras posições foi usado como uma *entrada* no modelo ARX. Este procedimento difere de forma significativa do método proposto por Sohn e Farrar [78], pois a formulação de [45] permite se desconsiderar a parte de se obter um modelo AR que corresponde a estimativa do sinal de entrada. Vale lembrar que no método proposto por Sohn e Farrar [78] o erro do modelo AR é empregado como entrada de um modelo ARX. No trabalho de Lu e Gao [45] os

resultados foram avaliados no mesmo *benchmark* de oito graus de liberdade do trabalho de Sohn e Farrar [78]. Os autores concluíram que seu método ARX modificado teve um melhor desempenho para o caso de presença de danos simultâneos e em localizações diferentes. Uma das justificativas de Lu e Gao [45] foi que o indicador ARX modificado apresentaria uma suposta sensibilidade maior a mudanças na matriz de rigidez. Entretanto, nenhuma simulação foi feita considerando um nível de ruído ou desconhecimento maior. Assim, futura investigação é necessária para se avaliar a real aplicabilidade deste método em estruturais reais.

Modelos sem o termo de excitação também podem ser usados para detecção de danos. Bodeux e Golinval [7] usaram um modelo multi-váriavel auto-regressivo com média móvel (ARMAV). Neste trabalho o enfoque foi bem diferente, pois, ao invés de monitorar um erro de predição, o que se buscou foi extrair os parâmetros modais⁵ com incertezas a partir de um modelo ARMAV. Este procedimento tem algumas desvantagens práticas relacionadas à possível baixa sensibilidade para algumas variações de parâmetros. Nestes casos o indicador pode ser mascarado por erros experimentais.

Nair et al. [52] também modelaram os sinais obtidos como um modelo ARMA. Eles propuseram um indicador sensível ao dano como uma função direta dos três primeiros coeficientes da parte AR do modelo. Um teste de hipóteses *t-test* foi usado para obter a decisão se houve ou não uma variação neste indicador em cada ponto de medida. Esta variação foi capaz de detectar e localizar a presença de danos. A técnica também foi avaliada na estrutura *benchmark* da ASCE [46].

Fassois e Sakellariou, nos trabalhos [65] e [26], investigaram o uso de modelos ARX mas considerando que o modelo continha relações não-lineares entre os regressores, formando um modelo conhecido como NARX [2]. Testes numéricos foram feitos em um sistema de dois graus de liberdade com um termo de rigidez cúbica. A formulação apresentada foi feita com base em uma técnica chamada pelos autores de método baseado em modelo funcional e em testes de hipóteses. Basicamente este método considera reparametrizar em termos de magnitude e variância uma variável conhecida como *magnitude da falha*. Maiores detalhes técnicos do método são encontrados nas referências [65] e [26]. Os resultados foram satisfatórios, conduzidos inclusive com simulações de Monte Carlo, porém cabe ressaltar que a variação de rigidez imposta para simular o dano foi feita apenas nos termos

⁵No caso do trabalho [7] se extraíram as frequências naturais e as formas modais.

lineares do modelo. Seria interessante, no futuro, avaliar modificações estruturais ocorridas diretamente nos parâmetros não-lineares concentrados.

Dentre outras formas de se obter modelos de predição que levem em conta termos não-lineares, se destaca o uso de modelos de Volterra. Contudo uma das inúmeras exigências deste tipo de modelo é o conhecimento dos sinais de excitação, o que pode comprometer seu uso em métodos baseados apenas no conhecimento de sinais de respostas. Porém, em aplicações envolvendo estruturas inteligentes isto não é uma limitação. A próxima seção aborda melhor este tipo de modelo de predição.

Modelos mais simples, envolvendo apenas a parte auto-regressiva (modelos AR) também podem ser usados com sucesso. Fugate et al. [30] exemplificaram esta constatação na mesma coluna de concreto do trabalho [77]. Os autores monitoraram o erro de predição de um modelo AR de apenas um sensor de aceleração. Para classificar o dano, foram empregados gráficos de controle estatístico de processos (SPC), comparando o uso de gráficos *X-bar* e controle *S*. Estes gráficos monitoram a média e a variância, respectivamente, do erro de predição AR. Um número significativo de termos de erros fora dos limites de controle, chamados de *outliers* indicaram uma transição do estado saudável para o estado com dano. O trabalho anterior de Sohn et al. [77] usou o mesmo sistema, porém obteve um indicador mais geral devido à projeção dos 40 pontos de medidas em um único vetor representativo, como já discutido em parágrafos anteriores.

Além de se escolher um bom indicador sensível a variações estruturais, outro fator que influencia uma técnica SHM é o método para se realizar a discriminação da métrica indicativa em uma classe com dano ou sem dano. Nos trabalhos citados anteriormente usando modelos auto-regressivos de séries temporais, a grande parte usou apenas uma análise da razão entre desvios padrões de um erro de referência e de um erro em condição desconhecida, sejam eles extraídos de modelos do tipo AR, ARX, AR-ARX, ARMA ou ARMAX ou ainda de suas variantes não-lineares. Apesar de ser um bom método na maioria dos casos, devido a sua simplicidade e rapidez, desejáveis em aplicações práticas envolvendo estruturas reais, há outros métodos mais rigorosos do ponto de vista estatístico. Mattson e Pandit [47] estudaram o uso de razões indicativas de danos envolvendo momentos estatísticos de

ordem superior, como *skewness*⁶ e *kurtosis*⁷ dos erros residuais. Porém, neste trabalho específico o uso de desvios padrões ainda mostrou-se mais confiável.

Outra formulação promissora é a própria construção de limites de gráficos de controle (SPC) usando erros de predição em condição saudável, conforme os trabalhos previamente citados [77] e [30], por exemplo. SPC é uma ferramenta clássica para monitoramento de controle de qualidade em linhas de produção, serviços ao consumidor, etc. e já é usada com relativo sucesso no monitoramento de máquinas rotativas [49]. Porém, seu uso em aplicações de SHM é mais recente. Uma aplicação interessante de SPC foi feita em um trabalho do autor usando medidas obtidas por atuadores e sensores piezelétricos (PZTs) [74], trabalho este apresentado nesta tese na seção 6.1.

Uma técnica também não usual em SHM é o uso de métodos de agrupamento de classe envolvendo conceitos de lógica fuzzy, conhecidos como métodos *fuzzy clustering*. Uso de lógica fuzzy em si é comum em aplicações de detecção e localização de falhas. Podem-se citar trabalhos onde sistemas fuzzy têm sido aplicados para resolver problemas inversos relacionados à detecção de falhas. Um exemplo é o trabalho de Pawar e Ganguli [57] que usaram lógica fuzzy acoplada com algoritmos genéticos para desenvolver um procedimento *online* que permitisse, detectar trincas e delaminação em compósitos de hélices de helicópteros. Entretanto, poucos trabalhos têm sido feitos com o uso exclusivo de *fuzzy clustering* para SHM.

Um exemplo do uso de *fuzzy clustering* é o trabalho de Verboven et al. [84] que propuseram uma técnica de monitoramento de danos baseados em parâmetros modais extraídos a partir de um método automático envolvendo estimadores de máxima verosimilhança. Porém, neste trabalho específico, o agrupamento fuzzy foi usado somente para auxiliar na validação de modelos. Aplicações do uso direto de algoritmos de agrupamento fuzzy, como os métodos fuzzy c-means (FCM) ou algoritmo Gustafson-Kessel (GK) são mais escassas na literatura. Porém alguns trabalhos do autor demonstram⁸ que algoritmos de agrupamento fuzzy são eficientes como uma forma rápida para tomada

⁶*skewness* é o 3.º momento estatístico em relação a média nula, indicando o grau de simetria ou assimetria de uma distribuição.

⁷*kurtosis* é o 4.º momento estatístico em relação a média nula, indicando o quanto uma distribuição é tem forte tendência central ou não.

⁸Alguns destes trabalhos são apresentados nesta tese.

de decisões se um indicador está em uma classe com dano ou sem dano; entre estes trabalhos se destacam [70], [71] e [75].

2.2 Métodos locais - baseados em sinais de entrada-saída de PZTs

Um dos desafios fundamentais de um processo de SHM vem do fato de que uma falha estrutural em seus estágios iniciais é tipicamente um fenômeno localizado em uma pequena região e pode não influenciar significativamente a resposta global da estrutura, principalmente nas baixas frequências, que são normalmente excitadas e medidas durante os testes convencionais de vibração [25].

Entretanto, a popularização dos materiais inteligentes nos últimos anos tem possibilitado o monitoramento de impedância elétrica para SHM. Uma vez que a impedância elétrica é adquirida em altas frequências, ela contém informações sobre modos locais, ou seja, permite a detecção de falhas incipientes que ainda não influenciaram significativamente a resposta global [38] e [34]. Além desta grande vantagem, aplicações envolvendo estruturas inteligentes combinadas com a formulação de impedância elétrica de PZTs apresentam inúmeros outros pontos positivos quando comparadas com técnicas concorrentes [56]:

- A técnica não é baseada em qualquer modelo, e assim pode ser aplicada diretamente em estruturas complexas.
- A técnica envolve atuadores/sensores piezocerâmicos (PZTs) que são pequenos e não-invasivos, permitindo atingir pontos de difícil acesso de estruturas.
- Os dados medidos podem ser facilmente interpretados.
- O sensor PZT exibe um excelente comportamento com enorme faixa de linearidade, resposta rápida, baixo peso, alta conversão de energia e grande estabilidade para uma longa vida útil, uma vez bem acoplado em uma estrutura.
- Possibilidade de implementação para monitoramento em tempo real.

- Exigência de baixa voltagem de excitação, geralmente menor do que 1 V, e baixa potência, da ordem de microwatts. Com isto o método é um candidato ideal para ser usado em um sistema do tipo auto-sustentável.

Apesar destes pontos favoráveis para a formulação, algumas limitações não permitem o uso em larga escala envolvendo estruturas reais, como exemplo:

1. A técnica é baseada em duas estimativas não-paramétricas no domínio da frequência, uma na condição saudável e outra na condição desconhecida a ser determinada. Seria interessante obter uma formulação que fosse apenas dependente de uma única estimativa paramétrica na condição saudável, chamada aqui de *baseline*.
2. A maioria dos estudos de aplicações experimentais é feita em estruturas de escala de laboratório. Estes testes são conduzidos em condições controladas, que podem ser muito diferentes das condições de trabalho de uma estrutura real.
3. A faixa de frequência de análise deve ser bem escolhida a priori.
4. A falta de um modelo matemático para a estrutura pode ser um ponto positivo para detecção e localização de danos em estruturas complexas, porém ao mesmo tempo compromete etapas futuras de quantificação e prognóstico de danos pelo desconhecimento de matrizes estruturais.

Em especial, o item (4) da lista anterior é um problema sério envolvendo medidas de PZTs, uma vez que estas medições são feitas em altas frequências. Modelos matemáticos convencionais de elementos finitos não são satisfatórios para prever as características dinâmicas que são normalmente encontradas nestas faixas de operação. Nestes casos, métodos de elementos espectrais (SEM) podem ser mais interessantes [22]. Uma contribuição muito importante nesta linha foi feita pela tese [58] que propôs um modelo SEM de uma viga com PZTs acoplados e comparou as respostas frequenciais destes modelos com resultado experimentais. Este trabalho ajudará em etapas futuras para a realização de um possível prognóstico da saúde estrutural à partir diretamente de medidas elétricas de PZTs desde estágios iniciais da falha. Atualmente a grande parte das metodologias empregadas para

prognóstico são feitas utilizando-se modelos de elementos finitos quando o dano já esta em uma fase avançada.

O uso de modelos de predição linear, como modelos auto-regressivos de séries temporais, apresenta claramente duas vantagens para vencer as limitações descritas anteriormente. Primeiro permite um procedimento que vence a limitação (1), pois com o uso de modelos de séries temporais basta a estimativa de um filtro regressivo na condição da estrutura saudável, ou seja, apenas uma estimativa paramétrica e não duas estimativas não-paramétricas como nos casos clássicos. Segundo, permite obter uma informação paramétrica pelos próprios coeficientes auto-regressivos que pode ser usada em uma futura etapa de prognóstico, vencendo a limitação (4). Além destes dois pontos, pode-se constatar também que o uso de modelos auto-regressivos apresenta uma forma mais prática para automação do monitoramento, pois um modelo AR, ARX ou ARMAX nada mais é do que um filtro discreto que pode ser facilmente programado em uma placa de aquisição de dados dedicada a este fim.

Nos últimos anos, várias aplicações experimentais em estruturas de laboratório provaram a aplicabilidade de materiais inteligentes em SHM, como exemplo os trabalhos [83], [55] e [42]. De uma maneira tradicional o procedimento de separação do índice sensível à falha é conduzido no domínio da frequência. Entre os vários índices o mais usual é a construção de uma carta métrica baseada no desvio médio quadrático do sinal de impedância elétrica [37]. Outros índices usuais compreendem, por exemplo, coeficientes de correlação [93], mudança em covariância, normas de sistemas, como normas H_2 ⁹ e H_∞ ¹⁰ [10], etc.

Um método local bastante investigado para teste ultra-sônico e avaliação de materiais emprega o uso de ondas de Lamb. Ondas de Lamb são uma forma de perturbação elástica que se propaga em duas superfícies livres e paralelas, como as faces superiores e inferiores de uma viga, placa ou casca. Estas ondas são geradas quando um atuador excita a estrutura com um pulso depois de receber um sinal [62]. Este tipo de fenômeno de onda foi descrito pela primeira vez por Horace Lamb em 1917. Moulin et al. [51] usou um elemento piezolétrico incorporado em uma placa de compósito de fibra de carbono, agindo como um atuador, para gerar ondas de Lamb. A superfície do campo

⁹A norma H_2 está relacionada a área sobre curvas frequenciais.

¹⁰A norma H_∞ está relacionada aos picos de respostas frequenciais.

de deslocamento foi simulada por um modelo de elementos finitos acoplado e os resultados foram verificados por medidas óticas. Keilers e Chang [39] usaram estas ondas para detectar o tamanho do dano e sua localização em lâminas de compósitos. Elementos piezelétricos distribuídos colados em uma viga de compósito geraram e receberam os sinais usados no diagnóstico. Os dados experimentais foram muito promissores como métricas de danos. Porém, pouco esforço tem sido feito no estudo analítico de sinais transientes quando ambos os transmissores e receptores das ondas de Lamb estão nos materiais piezelétricos que são integrados dentro da estrutura.

Como se vê em artigos estudados na revisão, raros trabalhos são feitos com o uso de modelos temporais envolvendo estruturas inteligentes. A tendência atual das pesquisas básicas em SHM é o emprego de índices mais complexos, principalmente na investigação de indicadores em função de séries temporais de sinais de entrada-saída. Um interessante exemplo nesta linha usando medidas de PZTs foi apresentado por Lynch [46] que ajustou um modelo auto-regressivo com entrada exôgena a partir de sinais de entrada-saída na condição saudável. As raízes complexas do modelo ARX foram usadas para caracterizar o dano estrutural. Os resultados mostraram que certos grupos de pólos são muito sensíveis a danos e, sendo assim, a migração destes pólos no plano complexo z poderia eventualmente ser bem correlacionada a modificações estruturais, como por exemplo trincas em estruturas metálicas. Uma extensão deste procedimento é apresentada na presente tese, onde em vez de se monitorarem os pólos dos modelos auto-regressivos se emprega um índice obtido diretamente dos erros de predição.

Bueno et al. [9] também empregou sinais temporais de respostas em velocidade obtidas a partir da aplicação de excitações aleatórias feitas com atuadores piezelétricos (PZTs). Como forma de classificar a condição estrutural o trabalho usou estimativas de funções de densidades de probabilidades (PDF) e regras de decisão estatística envolvendo testes de hipóteses. Os resultados foram comprovados experimentalmente em uma placa de alumínio com um PZT acoplado e um acelerômetro. Os testes foram satisfatórios para a aplicação em questão. O trabalho de Peairs et al. [60] também faz uso de testes de hipóteses, no caso o z -teste, para estudar a correlação entre os picos de ressonância de sinais de impedância elétrica, intervalos de frequência e a presença de variações estruturais representando danos.

O trabalho anterior do autor [72]¹¹ utilizou modelos do tipo auto-regressivos com média móvel e entradas exógenas (ARMAX) de sinais de entrada/saídas de PZTs colados em um estrutura do tipo frame. Esta estrutura foi formada por três vigas de alumínio conectadas por junções parafusadas. Os danos simulados foram apertos/desapertos nestes parafusos, que causaram variação estrutural. Para detectar estas modificações os autores investigaram o uso de análise de variâncias e procedimentos de múltiplas comparações.

É possível também usar um modelo ARX no domínio da frequência, que foi originalmente proposto por Adams e Allemang [1] para identificação de sistemas não-lineares. Park et al. [55] combinaram este modelo modificado com atuadores piezelétricos colados na estrutura. Um indicador foi usado para quantificar as diferenças entre as medidas experimentais de impedância elétrica e as saídas do modelo ARX frequencial. Como forma de separar os estados com dano ou sem dano foi empregada a análise de valores estatísticos extremos em virtude da natureza não-Gaussiana do indicador proposto.

Wei et al. [87] empregaram um modelo ARMAX, porém envolvendo regressores não-lineares nomeado de modelo NARMAX. Este modelo foi utilizado para detecção de danos em placas de material compósito. As excitações foram aplicadas na placa usando um par de cerâmicas piezelétricas como entrada e o sinal de saída usado foi obtido por um acelerômetro. Testes dinâmicos e estáticos foram investigados para observar a natureza não-linear do sistema. Modelos NARMAX para a estrutura intacta e em condição com delaminação foram estimados. A partir das variações dos coeficientes do modelo dos dados de entrada/saída e dos erros de predição foi possível detectar uma variação estrutural provocada pela delaminação na placa.

Apesar de alguns trabalhos usarem modelos do tipo NARX ou NARMAX para propor indicadores de danos estruturais considerando características não-lineares, o problema de se estimar a ordem e os coeficientes destes modelos é muito mais complexo do que a contrapartida linear. Como já discutido anteriormente, o uso de modelos discretos de Volterra tem sido muito aplicado nos últimos anos em problemas de identificação de sistemas não-lineares visando principalmente controle preditivo, [16] ou [53]. Neste tipo de modelo deve ser conhecido o sinal de excitação. Para aplicações envolvendo

¹¹Estes resultados não são apresentados nesta tese.

estruturas inteligentes se conhece o par de voltagens de entrada/saída aplicadas em cada cerâmica piezolétrica e, assim, esta exigência é satisfeita. Ao contrário de modelos paramétricos, como NARX ou NARMAX, o que se teria em mãos seria um modelo não-linear e não-paramétrico. Com isto, problemas de escolha de ordem de modelos e estimação de coeficientes poderiam ser minimizados. Contudo, o problema de se estimar os núcleos ou kernels característicos de um modelo de Volterra é um problema difícil¹² o que limita muito suas aplicações práticas. Porém, se observa nos últimos anos formas efetivas de se empregar funções ortonormais para minimizar estes problemas de estimação, entres estas funções se destacam o uso de filtros de Kautz. Uma vez conhecidos estes filtros através de um par de pólos complexos, pode-se estimar com um número reduzido de parâmetros os kernels característicos de um modelo de Volterra. Esta tese chama este modelo como modelo de Kautz-Volterra.

Em aplicações de dinâmica de estruturas o uso de séries de Volterra tem sido muito restrito. As poucas aplicações na literatura envolvem apenas exemplos acadêmicos de sistemas de um ou no máximo dois graus de liberdade. No geral, se usa como forma de identificar os kernels de Volterra métodos analíticos, como o método *Probing* [4] e [92]. Estes métodos descrevem um kernel de ordem elevada em função de kernels de ordem mais baixa e de parâmetros do modelo matemático, como valores de rigidez, amortecimento, termos não-lineares, etc. Com o uso de um modelo de Volterra com filtros de Kautz a filosofia de trabalho é completamente diferente, pois se é capaz de identificar um kernel a partir somente dos sinais de entrada/saída aplicados ao sistema em estudo.

Uma das principais contribuições desta tese é apresentar uma forma de se usar kernels de modelos de Kautz-Volterra como filtros de predição não-linear de sinais. Obtido um modelo de Kautz-Volterra de referência, monitora-se os sinais de entrada/saída em condições desconhecidas. Caso o sistema contenha alguma variação o erro de predição será modificado, como sua contrapartida linear nos métodos usando séries temporais propostos pelo LANL [77], [78], etc. Porém, um modelo de Kautz-Volterra em tese apresenta inúmeras vantagens em relação a um modelo de predição linear, entre elas:

¹²A seção 3.4 apresenta em detalhes as razões técnicas desta dificuldade.

1. Capacidade de detectar danos estruturais provocadas por variações de parâmetros não-lineares concentrados.
2. Maior facilidade no difícil problema de identificação experimental dos kernels de Volterra, ao contrário de métodos analíticos mais difíceis e que exigem maior conhecimento do sistema.
3. Caso a estrutura apresente uma variação de sua condição de excitação ou ambiente que excite a dinâmica não-linear do sistema o modelo linear de predição detectará uma modificação no erro, que pode ser detectada como um falso-alarme positivo de dano. Com o uso de um modelo de Kautz-Volterra isto não ocorre¹³.
4. Capacidade para detectar danos com base em sistemas que se comportem de forma não-linear na condição saudável.
5. A não-linearidade modelada é não-paramétrica, estática e do tipo caixa-preta. Assim, não se tem problemas de se definir estruturas e modelos para parâmetros não-lineares, como no caso de modelos NARX ou NARMAX.

Mesmo com estas vantagens, o autor lista alguns pontos negativos nesta formulação que precisam ser melhor adaptados para aplicações SHM:

1. Dificuldade para se encontrar um número ideal de filtros de Kautz para se empregar.
2. Enorme dependência entre a qualidade dos resultados e da escolha dos pólos do filtro de Kautz. Uma forma de minimizar este tópico é a proposição de técnicas para identificação simultânea dos pólos e dos núcleos de Volterra.
3. Caso a variação estrutural não seja refletida pelos pólos de Kautz, o modelo Kautz-Volterra pode não levar a uma boa predição do sinal de saída e não detectar a variação estrutural.
4. Se o dano causar uma variação em um kernel de alta-ordem não modelado, o método pode não detectar a variação estrutural.

¹³Desde que a variação não afete kernels de Volterra de ordem superior que não foram modelados.

No que se diz respeito ao item (2) da lista anterior, o conhecimento de um modelo linear ARMAX identificado experimentalmente pode conduzir a um conjunto de pólos no plano z . O pólo dominante pode ser escolhido com base nesta lista. Outra forma seria usar a formulação proposta por Rosa et al. [17] para identificação simultânea do pólo e do kernel do modelo de Kautz-Volterra. Todos estes pontos são discutidos e melhor comentados no decorrer desta tese, e principalmente nos resultados experimentais da seção 6.2.4.

2.3 Conclusões

Com base nesta revisão bibliográfica destaca-se que:

- O problema de detecção de danos baseados em medidas de vibrações é um problema de classificação em duas classes, saudável ou danificada, envolvendo uma métrica indicativa.
- O uso de diferentes modelos auto-regressivos envolvendo séries temporais já se encontra bem documentado na literatura, assim como indicadores diversos extraídos destes modelos. Porém, no que diz respeito à classificação destes índices este problema não está ainda solucionado de forma clara, uma vez que há inúmeras combinações de métodos possíveis para se utilizar.
- O sucesso de um modelo de predição está ligado diretamente ao número de testes realizados na condição saudável. Quanto mais rico for este conjunto de medidas¹⁴, maior será o número de diagnósticos corretos. Outro fator delicado refere-se à ordem¹⁵ usada nestes modelos. Se não for bem escolhida pode-se comprometer seriamente o diagnóstico.
- O emprego de modelos auto-regressivos de séries temporais obtidos por PZTs é um problema teoricamente mais fácil do que o uso de modelos auto-regressivos envolvendo apenas sinais de respostas (métodos globais), uma vez que com o uso de PZTs se conhece o sinal de excitação aplicado na estrutura.

¹⁴Ou seja, quanto mais variabilidade ele contiver, o que não quer dizer tamanho de amostra e sim de condições representativas de diversas variações ambientais e operacionais.

¹⁵A ordem de um modelo discreto de predição se refere ao número de amostras passadas que deve ser armazenado em memória para predizer um instante $k + 1$.

- No caso de um método global deve-se implementar algum método a priori visando normalizar ou diminuir os efeitos de excitações diversas ou variações do ambiente.
- O uso de modelos de Kautz-Volterra é inédito para aplicações SHM. No capítulo seguinte apresenta-se uma nova metodologia para seu uso em detecção de danos.

Conforme mencionado anteriormente, com este trabalho procura-se analisar como o uso de modelos de predição construídos com sinais temporais em condição estrutural saudável podem ser usados para aplicações em SHM, em especial as envolvendo estruturas inteligentes com PZTs acoplados. Compara-se também o desempenho entre métodos de separação de classes.

Capítulo 3

Análise de Séries Temporais

Este capítulo apresenta os conceitos básicos envolvidos na identificação de modelos discretos lineares ou não-lineares capazes de prever a relação entre sinais de entrada (excitação) e/ou saída (respostas) medidos em estruturas reais.

Existe uma infinidade de modelos capazes de fazer esta previsão. Uma classe interessante envolve dois grandes grupos que usam o conceito de regressão de sinais: modelos com resposta ao impulso infinita (IIR) e modelos com resposta ao impulso finita (FIR). Modelos IIR, em geral, são de ordem muito inferior e se baseiam no conceito de realimentação de sinais de saída, ou seja, acabam contendo pólos que caracterizam a dinâmica dominante do sistema. Porém não são garantidos estáveis a priori e esta estabilidade deve ser verificada.

Já modelos FIR são estáveis (desde que a entrada seja limitada), uma vez que a dinâmica do sistema é descrita apenas por um funcional envolvendo os sinais de entrada. Um exemplo de modelo do tipo FIR é a própria série de Volterra, que neste caso é melhor nomeada como modelo NFIR (por envolver um funcional não-linear dos sinais de entrada). O preço a pagar por esta estabilidade garantida é o enorme número de parâmetros neste tipo de modelo, ou seja, sua ordem é muito superior à ordem de um modelo IIR.

Neste capítulo é apresentado como estes modelos IIR ou NFIR podem ser utilizados de modo eficiente para cálculo de erros de previsão e indicadores para servirem de métricas em problemas

SHM. Também se discutem neste capítulo conceitos de compressão de dados usando decomposição de Karhunen-Loève, determinação de ordens de modelos e formas de se validar um modelo de predição após à sua obtenção.

Quatro tipos de modelos são descritos neste capítulo: modelos auto-regressivos e auto-regressivo com entradas exógenas (AR-ARX), auto-regressivos com termo média-móvel (ARMA), auto-regressivos com termo média móvel e entradas exógenas (ARMAX) e finalmente os modelos não-lineares de Kautz-Volterra. Nos dois primeiros tipos, considera-se que o sinal de entrada não é medido (apesar de ser admitido de natureza conhecida). Estes modelos são úteis para serem usados na detecção de danos em estruturas a partir de medidas apenas de respostas (métodos globais). Já nos dois últimos modelos, ARMAX e Kautz-Volterra, o sinal de entrada é considerado ser medido. Este tipo de modelo será empregado para detecção de danos em estruturas inteligentes, uma vez que, neste tipo de sistema, o sinal de entrada (excitação) no PZT é conhecido. Todos estes modelos foram obtidos nesta tese com o auxílio de rotinas do *toolbox* de identificação de sistemas para Matlab®, escrito pelo mesmo autor do clássico livro [44] e com rotinas próprias do autor.

3.1 Modelo AR-ARX

Esta seção apresenta um modelo misto AR-ARX utilizado para extrair um erro de predição. Este método visando detecção de danos foi proposto por Sohn e Farrar [78]. Inicialmente é apresentada uma forma de padronização dos dados para remover tendências e efeitos diversos e em seguida algumas considerações sobre compressão espacial de dados. Por fim, o método para extrair o erro de predição AR-ARX é formalmente descrito.

3.1.1 Procedimento de padronização

Um conjunto de medidas de deslocamento, velocidade ou aceleração $g_j(k)$, $j = 1, 2, \dots, m$ e $k = 1, 2, \dots, n$, representa as séries temporais correspondentes a m posições de medidas e n instantes discretos de tempo. No primeiro estágio, cada série temporal, $g_j(k)$ é normalizada para remover tendências [88]:

$$z_j(k) = \frac{g_j(k) - m(g_j)}{\sigma(g_j)} \quad (3.1)$$

sendo $z_j(k)$ o sinal padronizado no k -ésimo instante e $m(\cdot)$ e $\sigma(\cdot)$ são respectivamente os operadores média e desvio padrão da seqüência $g_j(k)$.

Esta padronização é interessante, pois uma vez que se pode admitir que o sinal de excitação não é medido, é necessária alguma forma de extrair dos sinais de saída os efeitos diversos do ambiente e de níveis diferentes de excitação não relacionados com as variações da condição estrutural. Porém, em alguns casos, este procedimento pode comprometer a identificação de alguns tipos de danos. Mesmo assim, seus benefícios compensam seus pontos fracos. Sohn e Farrar [78] também usaram esta padronização.

O leitor interessado em uma discussão mais profunda sobre formas de padronização, remoção de tendências e ruídos de sinais pode consultar o trabalho [32]. Neste trabalho os autores usaram filtros FIR híbridos para extrair *outliers* (descontinuidades) em sinais reais de turbinas.

3.1.2 Compressão de dados via análise de componentes principais

A análise de componentes principais (PCA) é uma técnica para extração de informação compacta de uma matriz pela investigação de sua dimensionalidade, que foi introduzida na área de estatística multi-variável para redução de dados [15].

Neste trabalho, PCA é usada para comprimir dados de múltiplos pontos de medidas. Este procedimento transforma uma matriz de medidas em um número menor de vetores projetados em outro espaço, mantendo a informação principal nestes vetores reduzidos. Ressalta-se que PCA pode ser chamada também de decomposição de Karhunen-Loève ou ainda decomposição ortogonal própria (POD), dependendo da área de aplicação.

Diferentes aplicações envolvendo PCA são citadas na literatura. Feeny e Kappagantu [27] demonstraram a ligação entre POD e os modos próprios lineares de estruturas mecânicas a partir das equações de movimento livre. Uma extensão considerando um sistema vibratório com vários graus

de liberdade foi estudada pelos autores em [28]. Kerschen e Golinval [41] fizeram uma interpretação física de PCA, mas obtendo-os através da decomposição em valores singulares das matriz de covariância dos históricos temporais da estrutura. Trindade et al. [82] a utilizaram como base modal empírica para compreender o acoplamento não-linear de vibrações de modelos dinâmicos reduzidos e caracterizados por somente alguns poucos modos.

O procedimento começa considerando o vetor $\mathbf{z}(k)$ de respostas correspondentes a m localizações de medidas (já normalizado pela Eq. (3.1) em cada instante de tempo k):

$$\mathbf{z}(k) = \begin{bmatrix} z_1(k) & z_2(k) & \cdots & z_m(k) \end{bmatrix}^T \quad (3.2)$$

Uma matriz de covariâncias Ψ de tamanho $m \times m$, entre as localizações de medidas somadas sobre todos os intervalos discretos é obtida por:

$$\Psi = \sum_{k=1}^n \mathbf{z}(k)\mathbf{z}(k)^T \quad (3.3)$$

Um problema de autovalor da matrix de covariância pode ser resolvido tal que satisfaça a relação $\Psi \mathbf{v}_i = \lambda_i \mathbf{v}_i$, sendo λ_i e \mathbf{v}_i os autovalores e autovetores da matriz de covariâncias Ψ , respectivamente. O autovetor \mathbf{v}_i é chamado de componente principal.

A meta é reduzir um vetor $\mathbf{z}(k)$ m -dimensional em um vetor d -dimensional $\mathbf{x}(k)$, onde $d \ll m$. Finalmente, $\mathbf{z}(k)$ é projetado nos autovetores correspondentes ao primeiros d maiores autovalores:

$$\mathbf{x}(k) = \begin{bmatrix} \mathbf{v}_1 & \mathbf{v}_2 & \cdots & \mathbf{v}_d \end{bmatrix}^T \mathbf{z}(k) \quad (3.4)$$

Uma questão é a escolha de quantos componentes d são necessários para realizar a projeção da Eq. (3.4), visando uma boa representatividade do vetor $\mathbf{x}(k)$. Neste trabalho, admitiu-se que apenas o primeiro componente é representativo¹, ou seja, assume-se que sua contribuição é dominante em relação aos outros. Sendo assim, daqui para frente o vetor $\mathbf{x}(k)$ será denotado neste trabalho simplesmente por $x(k)$.

¹Nos exemplos simulados uma análise desta consideração é feita em maiores detalhes.

3.1.3 Extração do indicador AR-ARX

Como já discutido no capítulo 2 a distinção entre os sinais em uma classe com dano ou sem dano é o passo mais importante e crucial em um procedimento SHM. Nesta seção o erro residual de um modelo discreto de predição misto AR-ARX é proposto para ser utilizado como um indicador razoável para realizar esta tarefa.

A primeira fase desta técnica é considerar sinais da estrutura na condição de referência sem dano (estado "saudável") em N condições experimentais, com condições operacionais e ambientais diferentes. Cada conjunto de dados é padronizado pela Eq. (3.1) e comprimido pela Eq. (3.4). O sinal final é um vetor de padrões $x_i(k)$, sendo $i = 1, 2, \dots, N$.

A próxima fase é construir um modelo AR com ordem p , para cada sinal sem dano $x_i(k)$. O modelo AR(p) é escrito como [44]:

$$A_{x_i}(q)x_i(k) = e_{x_i}(k) \quad (3.5)$$

sendo $e_{x_i}(k)$ o i -ésimo erro entre o sinal medido e o sinal de saída do modelo de predição. O polinômio $A_{x_i}(q)$ é o i -ésimo polinômio no operador de atraso q^{-1} escrito como:

$$A_{x_i}(q) = 1 + a_{x_{i1}}q^{-1} + a_{x_{i2}}q^{-2} + \dots + a_{x_{ip}}q^{-p} \quad (3.6)$$

sendo $a_{x_{i1}}, \dots, a_{x_{ip}}$ os coeficientes do i -ésimo polinômio $A_{x_i}(q)$, $i = 1, 2, \dots, N$. Aqui a ordem p significa o número de amostras passadas necessárias para se fazer as operações de regressão em cada instante k . Por exemplo, $2q^{-3}x(k)$ significa $2x(k-3)$.

Os coeficientes do modelo AR podem ser encontrados a partir de muitos métodos, como o algoritmo de Burg, mínimos quadrados, entre outros [2]. Neste trabalho, o conjunto de coeficientes na Eq. (3.6) são estimados pela minimização da potência de cada erro de predição, $\|e_{x_i}(k)\|^2$. Este procedimento conduz as equações de Yule-Walker dadas por [86]:

$$\begin{cases} R_{i_{xx}}(r) = -\sum_{l=1}^p a_{x_{il}} R_{i_{xx}}(r-l) & \text{para } r > 0 \\ R_{i_{xx}}(0) = -\sum_{l=1}^p a_{x_{il}} R_{i_{xx}}(-l) + \sigma^2 \end{cases} \quad (3.7)$$

onde $R_{i_{xx}}(r)$ é a função de correlação de $x_i(k)$ no r -ésimo atraso e σ^2 é a potência estimada do erro. Para estimar as funções de auto-correlação, o método recursivo de Levinson-Durbin pode ser usado. A Eq. (3.7) pode ser expressa na forma matricial como:

$$\begin{bmatrix} R_{i_{xx}}(0) & R_{i_{xx}}(-1) & \cdots & R_{i_{xx}}(-p+1) \\ R_{i_{xx}}(-1) & R_{i_{xx}}(0) & \cdots & R_{i_{xx}}(-p+2) \\ \vdots & \vdots & \ddots & \vdots \\ R_{i_{xx}}(p-1) & R_{i_{xx}}(p-2) & \cdots & R_{i_{xx}}(0) \end{bmatrix} \begin{bmatrix} a_{x_{i1}} \\ a_{x_{i2}} \\ \vdots \\ a_{x_{ip}} \end{bmatrix} = \begin{bmatrix} R_{i_{xx}}(1) \\ R_{i_{xx}}(2) \\ \vdots \\ R_{i_{xx}}(p) \end{bmatrix} \quad (3.8)$$

Os autores em [86] mostram que a solução das equações de Yule-Walker conduzem a uma solução ótima do modelo AR de predição linear. A ordem p deste modelo, em geral, não é conhecida a priori. Vários métodos podem ser usados para estimar este valor. A seção 3.5 mostra algumas considerações nesta escolha.

O monitoramento da estrutura é realizado pela obtenção de novos vetores de dados em condições estruturais desconhecidas (com dano ou sem dano). Esta nova seqüência $y(k)$ tem o mesmo tamanho do sinal $x_i(k)$. Em outras palavras, o mesmo número n de pontos discretos é usado. Nesta fase, o passo prévio dado pela Eq. (3.5) é repetido com a mesma ordem p :

$$A_y(q)y(k) = e_y(k) \quad (3.9)$$

onde $A_y(q)$ é o polinômio:

$$A_y(q) = 1 + a_{y_1}q^{-1} + a_{y_2}q^{-2} + \cdots + a_{y_p}q^{-p} \quad (3.10)$$

e a_{y_1}, \dots, a_{y_p} são coeficientes do polinômio $A_y(q)$ obtido pelo uso das equações de Yule-Walker previamente descritos.

Este novo modelo AR é comparado com cada modelo AR dos sinais sem dano $x_i(k)$ no conjunto de base de referência para selecionar um sinal $x_r(k)$ próximo ao bloco na condição desconhecida $y(k)$. Isto é obtido através da minimização da seguinte norma:

$$Dist = \sum_{l=1}^p (a_{y_l} - a_{x_{il}})^2 \quad (3.11)$$

O sinal $x_r(k)$ cujos coeficientes satisfazem a distância mínima da Eq. (3.11) é chamado sinal de referência. Este procedimento é definido pela normalização do vetor de padrões da base de referências. Se o sinal $y(k)$ é obtido da mesma condição operacional e não há nenhuma mudança estrutural no sistema, o modelo AR será capaz de prever o comportamento dinâmico do sistema, que é dado pelos coeficientes AR², e será similar ao sinal de referência [78].

Em seguida, um modelo auto-regressivo com entradas exógenas (ARX) é obtido deste sinal de referência $x_r(k)$ para cada instante k :

$$A_{x_r}(q)x_r(k) = B_{x_r}(q)e_{x_r}(k) + \varepsilon_{x_r}(k) \quad (3.12)$$

sendo $\varepsilon_{x_r}(k)$ o erro residual do polinômio ARX(n_a, n_b), $e_{x_r}(k)$ é o erro residual AR(p) dado pela Eq. (3.5) e os polinômios são:

$$A_{x_r}(q) = 1 + a_{x_{r1}}q^{-1} + a_{x_{r2}}q^{-2} + \dots + a_{x_{rn_a}}q^{-n_a} \quad (3.13)$$

$$B_{x_r}(q) = 1 + b_{x_{r1}}q^{-1} + b_{x_{r2}}q^{-2} + \dots + a_{x_{rn_b}}q^{-n_b} \quad (3.14)$$

onde n_a e n_b são as ordens dos polinômios $A_{x_r}(q)$ e $B_{x_r}(q)$, respectivamente. Existe uma infinidade de técnicas clássicas que podem ser utilizadas para se estimar os polinômios $A_{x_r}(q)$ e $B_{x_r}(q)$, como por exemplo, método das variáveis instrumentais, método de mínimos quadrados, etc. Uma vez que a maioria deles são descritos em livros textos básicos da área de identificação de sistemas, como os livros [44] e [2], estes métodos não são descritos nesta tese.

²Pode-se mostrar que o polinômio $A(q)$ em um modelo AR é relacionado diretamente as frequências naturais e aos coeficientes de amortecimento de uma estrutura.

A Eq. (3.12) representa as relações entre a saída $x_r(k)$ e a entrada $e_{x_r}(k)$. O erro residual $e_{x_r}(k)$ é uma função de todas as entradas externas desconhecidas e é considerado ser uma aproximação da entrada estimada do sistema.

O modelo associado à Eq. (3.12) é agora aplicado para investigar os vetores de dados na condição desconhecida $y(k)$ e $e_y(k)$:

$$A_{x_r}(q)y(k) = B_{x_r}(q)e_y(k) + \varepsilon_y(k) \quad (3.15)$$

Se o modelo ARX da Eq. (3.12) não é um bom modelo de predição para os sinais $y(k)$ e $e_y(k)$, então o erro residual $\varepsilon_y(k)$ da Eq. (3.15) e sua distribuição de probabilidade irão mudar em relação ao sinal de referência $\varepsilon_{x_r}(k)$.

Vários procedimentos podem ser usados para decidir se houve uma mudança estatisticamente significativa entre $\varepsilon_{x_r}(k)$ e $\varepsilon_y(k)$, ou seja, se houve um dano. O capítulo 4 apresenta vários métodos para auxiliar nesta classificação.

3.2 Modelo ARMA

Uma outra forma de obter um erro de predição sem admitir conhecido o sinal de entrada é através de um modelo do tipo auto-regressivo com média móvel (ARMA). Ao contrário do caso anterior, com este modelo pode-se obter um indicador de forma um pouco mais rápida e sem estimativas de um sinal de entrada a partir de um procedimento de dois passos como no modelo AR-ARX.

O primeiro passo para obter este modelo é igual ao caso AR-ARX. Primeiro se constrói um modelo AR(p) para cada sinal já normalizado $x(k)$ considerando o sistema sem dano em diferentes condições operacionais e ambientais. Assumindo a transformada z da série temporal $x(k)$ ³ como sendo $X(z)$, onde z é uma variável complexa [20]:

$$X(z) = \sum_{k=0}^n x(k)z^{-k} \quad (3.16)$$

³Se assume que o sistema é causal.

Assim um modelo AR pode ser escrito com uso da transformada z :

$$A(z)X(z) = R(z) \quad (3.17)$$

nestes casos $A(z)$, $X(z)$ e $R(z)$ são polinômios no operador z^{-1} . No caso $R(z)$ é a transformada z do erro de predição $r(k)$. Caso o sinal $r(k)$ seja totalmente aleatório, o modelo da Eq. (3.17) pode ser usado sem nenhuma limitação. Entretanto, em geral este sinal não é aleatório e não pode ser aproximado para ruído branco. Nestes casos, um modelo do tipo média móvel (MA) $R(z) = C(z)E(z)$ pode ser usado para obter o modelo de ruído, sendo $C(z)$ um filtro MA e $E(z)$ a transformada z do erro $e(k)$, que neste caso é um ruído do tipo branco. Combinando o modelo de ruído do tipo MA com o modelo AR da Eq. (3.17) tem-se a seguinte equação do modelo ARMA:

$$A(z)X(z) = C(z)E(z) \quad (3.18)$$

O método de Burg pode ser usado para estimar os coeficientes dos polinômios $A(z)$ e $C(z)$, com as ordens p e q , respectivamente. Estas ordens na maioria das vezes não são conhecidas a priori. A seção 3.5 apresenta algumas considerações para auxiliar nesta escolha.

O monitoramento da estrutura é feito pelo exame do erro $e(k)$. Neste caso, é apropriado rescrever a Eq. (3.18) da seguinte forma:

$$E(z) = \frac{A(z)}{C(z)}X(z) = \frac{a_0 + a_1z^{-1} + \dots + a_pz^{-p}}{c_0 + c_1z^{-1} + \dots + c_qz^{-q}}X(z) \quad (3.19)$$

uma vez que, em geral, $p > q$ não é possível programar a filtragem da Eq. (3.19) em tempo real, pois o sistema é não causal. Para contornar isto, o filtro acima pode ser arranjado em série. Inicialmente, o sinal $x(k)$ pode ser processado por um filtro com resposta ao impulso infinita (IIR), descrito por $H(z) = 1/C(z)$, resultando em um grupo de sinais filtrados $f(k)$. Por fim, este sinal $f(k)$ é processado por um filtro FIR dado por $A(z)$. Assim:

$$F(z) = \left(\frac{1}{c_0 + c_1z^{-1} + \dots + c_qz^{-q}} \right) X(z) = H(z)X(z) \quad (3.20)$$

$$E(z) = (a_0 + a_1 z^{-1} + \dots + a_p z^{-p}) F(z) = A(z)F(z) \quad (3.21)$$

Os dois filtros discretos, $H(z)$ e $A(z)$, são os filtros de referência construídos considerando o sistema não apresentando nenhum dano. Uma vez que são obtidos diversos sinais na condição sem dano, a base de referências será formada por vários filtros $H(z)$ e $A(z)$. Os filtros a serem usados são escolhidos tal que o valor RMS⁴ do sinal $x(k)$ de referência é próximo do RMS do sinal $y(k)$, que é o sinal em uma condição desconhecida.

O erro de predição de um passo à frente do sinal $x(k)$ é definido aqui como sinal de referência $e_r(k)$. Assim o sinal sendo monitorado depende das escolhas dos filtros $H(z)$ e $A(z)$ do conjunto de referência. Se o sinal $y(k)$ é diferente da referência, a distribuição de probabilidade da série $e_y(k)$, que é o erro residual ARMA na condição desconhecida, será diferente com relação ao sinal de referência $e_r(k)$, que é calculado por:

$$E_y(z) = A(z)H(z)Y(z) \quad (3.22)$$

É importante destacar que nem toda diferença encontrada no sinal de referência é atribuída a presença de danos. Nestes casos, o sinal de referência e nas condições desconhecidas devem ser normalizados a priori para filtrarem informações de variações operacionais e ambientais. Porém, mesmos nestes casos estas ferramentas só são adequadas se os danos excitam características dinâmicas essencialmente lineares. Para o caso de danos que conduzam à um comportamento dinâmico não-linear, a série de Volterra⁵ é um bom candidato para modelo de predição.

O processo de se escolher um valor *threshold* para identificar se a condição da estrutura é saudável ou danificada será visto no capítulo 4. Em resumo a idéia geral é comparar os sinais $e_r(k)$ e $e_y(k)$. Uma das formulações comuns é avaliar a razão entre os desvios padrões do sinal desconhecido $e_y(k)$ com o sinal de referência $e_r(k)$ [78]:

$$\gamma = \frac{\sigma(e_y)}{\sigma(e_r)} \quad (3.23)$$

⁴root means square.

⁵Descrita neste capítulo na seção 3.4.

Porém, como já discutido anteriormente, no capítulo 4 são destacados algumas formulações para ajudar na classificação do indicador γ da Eq. (3.23).

3.3 Modelo ARMAX

Modelos ARMAX são basicamente idênticos ao modelo ARMA apresentado anteriormente, porém com uma parcela correspondente à filtragem do sinal de entrada $u(k)$, que neste caso é assumido ser medido. Este tipo de modelo é usado nesta tese com fins em aplicações envolvendo estruturas inteligentes, uma vez que, nestes casos, os sinais de excitação aplicados ao PZT são conhecidos.

O modelo de predição linear ARMAX(n_a, n_b, n_c) relaciona portanto os sinais $u(k)$ e $x(k)$ medidos em condições estruturais sem dano. Este modelo é dado por [2]:

$$A(q)x(k) = B(q)u(k - n_k) + C(q)e_x(k) \quad (3.24)$$

sendo $e_x(k)$ o erro entre os sinais medidos e o sinal de saída do modelo de predição e n_k é um atraso temporal do sinal de entrada. Os termos $A(q)$, $B(q)$ e $C(q)$ são polinômios no operador de atraso q^{-1} escritos como⁶ [44]:

$$A(q) = 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a} \quad (3.25)$$

$$B(q) = b_1 + b_2q^{-1} + \dots + b_{n_b}q^{-n_b+1} \quad (3.26)$$

$$C(q) = 1 + c_1q^{-1} + \dots + b_{n_c}q^{-n} \quad (3.27)$$

Mais uma vez uma infinidade de métodos diferentes podem ser usados para estimar os coeficientes destes polinômios. O modelo da Eq. (3.24) é usado então para tentar avaliar se um erro residual $e_y(k)$ de um par de sinais $u_y(k)$ e $y(k)$ em uma condição estrutural desconhecida é diferente do sinal de erro de um modelo referência. Assim:

$$A(q)y(k) = B(q)u_y(k - n_k) + C(q)e_y(k) \quad (3.28)$$

⁶Assume-se que $n_k = 1$.

A meta final é comparar o erro de referência $e_x(k)$ com o erro em condição estrutural desconhecida $e_y(k)$.

3.4 Modelos discretos de Volterra

Até este ponto todos os modelos para séries temporais envolveram relações lineares entre os sinais de entrada/saída. Caso o sistema em análise contenha características dinâmicas não-lineares e os sinais de entrada excitem estes termos, este conjunto de modelos pode não ser adequado para fins de predição e conseqüentemente detecção de danos. Neste ponto, a série de Volterra pode ser usada para construção de um modelo de predição que considere as características não-lineares dos sinais.

A série de Volterra é uma generalização direta do conceito de resposta ao impulso de sistemas lineares. Após o trabalho de Vito Volterra em 1879, vários esforços foram feitos para se pesquisarem aplicações práticas para estes funcionais. De um ponto de vista clássico a série de Volterra considera escrever a resposta $x(t)$ de um sistema dinâmico a um sinal de excitação $u(t)$ como:

$$x(t) = x_{lin}(t) + x_{quad}(t) + x_{cub}(t) + \dots \quad (3.29)$$

onde os termos $x_{lin}(t)$, $x_{quad}(t)$, \dots são as contribuições lineares e não-lineares da resposta $x(t)$. Uma vez que os sinais de entrada/saída são obtidos de uma forma discreta a partir de medições experimentais a Eq. (3.29) é escrita novamente para cada amostra k :

$$x(k) = x_{lin}(k) + x_{quad}(k) + x_{cub}(k) + \dots \quad (3.30)$$

Após 1980, com a popularização de computadores, as pesquisas com os funcionais de Volterra tiveram grande interesse, sobretudo em aplicações de identificação e controle de processos. Infelizmente, não se observou o mesmo esforço na área de dinâmica estrutural. Tawfiq e Vinh discutiram no trabalho [81] que a maior parte das críticas que a série de Volterra sofrem por parte da comunidade de dinâmica de estruturas são sem fundamentos convincentes.

A aplicação da série discreta de Volterra⁷ à Eq. (3.30) conduz à seguinte expressão [63]:

⁷Dentro das poucas aplicações em engenharia de estruturas os autores utilizam mais a versão contínua da série de

$$x(k) = \sum_{m=1}^{\infty} \sum_{n_1=-\infty}^{+\infty} \cdots \sum_{n_m=-\infty}^{+\infty} h_m(n_1, n_2, \dots, n_m) \prod_{i=1}^m u(k - n_i) \quad (3.31)$$

sendo m o número de termos não-lineares; em geral m é truncado em um número M de ordem baixa, $M = 2, 3$ é suficiente para modelar os termos não-lineares mais comuns, com exceção de atrito de Coulomb, não-linearidades histéreticas, *backslash*, etc. A equação acima pode ser escrita de uma forma mais amigável através da separação de componentes:

$$\begin{aligned} x(k) = & \sum_{n_1=-\infty}^{+\infty} h_1(n_1)u(k - n_1) + \sum_{n_1=-\infty}^{+\infty} \sum_{n_2=-\infty}^{+\infty} h_2(n_1, n_2)u(k - n_1)u(k - n_2) + \\ & + \sum_{n_1=-\infty}^{+\infty} \sum_{n_2=-\infty}^{+\infty} \sum_{n_3=-\infty}^{+\infty} h_3(n_1, n_2, n_3)u(k - n_1)u(k - n_2)u(k - n_3) + \cdots \end{aligned} \quad (3.32)$$

sendo os termos $h_1(n_1), h_2(n_1, n_2), \dots$ os núcleos da séries (em inglês *kernels*⁸). O termo $h_1(n_1)$ é o termo clássico de contribuição linear. Este termo é conhecido como função de resposta ao impulso (*impulse response function* (IRF)) e usado comumente em análise modal e relacionado diretamente com as funções de resposta em frequência (FRFs).

A partir de uma simples observação da Eq. (3.32), pode-se constar que a série de Volterra é composta por operações de múltiplas convoluções no espaço dimensional. Ou seja, é um banco em paralelo de filtragens lineares com o primeiro kernel $h_1(n_1)$ e não-lineares com os kernels $h_2(n_1, n_2), h_3(n_1, n_2, n_3), \dots$. Outra constatação com a análise da Eq. (3.32) é que os efeitos não-lineares são escritos por funções estáticas, assim as não-linearidades não têm uma dinâmica, o que significa que não há realimentação de sinais de saída⁹. Estas características fazem com que o número necessário de parâmetros para permitir o truncamento destas séries seja, em geral, de ordem muito elevada. Mesmo assim, os kernels de Volterra podem ter algumas propriedades interessantes, como por exemplo:

- $h_n(n_1, n_2, \dots, n_n)$ podem ser construídos de forma simétrica.

Volterra, que será evitada nesta pesquisa uma vez que os sinais experimentais são obtidos por discretização em instantes k .

⁸Que será o termo usado neste texto.

⁹Em outras palavras não existem pólos dentro da dinâmica não-linear, exceto na origem.

- $\lim_{n_l \rightarrow \infty} h_n(n_1, n_2, \dots, n_n) = 0$ para $l = 1, 2, \dots, n$.
- $h_n(n_1, n_2, \dots, n_n) = 0$ para $\forall n_i < 0$.

A Eq. (3.32) pode ser truncada em termos superiores e considerando que o sistema é causal. Nestes casos os termos de ordem $M \geq 3$ são normalmente desconsiderados. A expressão mais comum encontrada na literatura para estas séries pode ser escrita da seguinte forma:

$$x(k) = \sum_{n_1=0}^{N_1} h_1(n_1)u(k - n_1) + \sum_{n_1=0}^{N_2} \sum_{n_2=0}^{N_2} h_2(n_1, n_2)u(k - n_1)u(k - n_2) \quad (3.33)$$

Outra questão de interesse prático é que todos os kernels podem ser escritos de uma forma simétrica, isto quer dizer por exemplo que $h_2(n_1, n_2) = h_2(n_2, n_1)$. A regra geral para simetrizar um kernel não-simétrico é [63]:

$$h_n(n_1, \dots, n_n)^{sym} = \frac{1}{n!} \sum_{\pi(\cdot)} h_n^{asym}(n_{\pi(1)}, \dots, n_{\pi(n)}) \quad (3.34)$$

onde $\pi(\cdot)$ significa todas as permutações possíveis dos números inteiros $1, 2, \dots, n$. Por exemplo, o núcleo de segunda ordem pode ser simetrizado por:

$$h_2(n_1, n_2)^{sym} = \frac{h_2(n_1, n_2)^{asym} + h_2(n_2, n_1)^{asym}}{2} \quad (3.35)$$

Nestas condições a Eq. (3.33) é escrita de novo como:

$$x(k) = \sum_{n_1=0}^{N_1} h_1(n_1)u(k - n_1) + \sum_{n_1=0}^{N_2} \sum_{n_2=0}^{n_1} h_2(n_1, n_2)u(k - n_1)u(k - n_2) \quad (3.36)$$

A grande vantagem da expressão (3.36) é separar de uma maneira clara as contribuições lineares e não-lineares. Assim, pode-se escrever as participações lineares $x_{lin}(k)$ e não-lineares $x_{quad}(k)$ da Eq. (3.30) como:

$$x_{lin}(k) = \sum_{n_1=0}^{N_1} h_1(n_1)u(k - n_1) \quad (3.37)$$

$$x_{quad}(k) = \sum_{n_1=0}^{N_2} \sum_{n_2=0}^{n_1} h_2(n_1, n_2)u(k - n_1)u(k - n_2) \quad (3.38)$$

O problema agora é identificar experimentalmente quem são os kernels $h_1(n_1)$ e $h_2(n_1, n_2)$ a partir somente do conhecimento dos sinais de entrada/saída. Infelizmente, encontrar estes valores não é uma tarefa simples.

Uma das linhas de aplicação com séries de Volterra em dinâmica de estruturas é através de uma técnica conhecida como método harmônico *Probing* [4] e [92]. Neste método a idéia central é descrever os kernels de ordem superior como funções de um kernel de primeira ordem¹⁰ e dos parâmetros não-lineares. Este tipo de solução é baseada em escrever os kernels como funções analíticas do sistema de interesse.

Com este método existem algumas aplicações da série de Volterra visando identificação de parâmetros não-lineares. Por exemplo, Chatterjee et Vyas [14] usaram séries de Volterra para realizar a identificação de parâmetros não-lineares em máquinas rotativas. Porém todos estes resultados com o método *Probing* são em geral muito longe de serem aplicáveis em estruturas com não-linearidades localizadas, sobretudo em sistemas complexos modelados com elementos finitos. Duas razões podem ser apontadas pelo autor para explicar estas limitações:

- É quase impossível imaginar escrever analiticamente um kernel de Volterra de ordem elevada para uma estrutura complexa real.
- A necessidade de um número muito grande de parâmetros para descrever os kernels $h_1(n_1)$, $h_2(n_1, n_2), \dots$. A razão para este grande número de parâmetros é relativa ao enorme montante de pontos para realizar a filtragem NFIR da Eq. (3.36).

O número de parâmetros N_p para estimar os kernels é dado por:

$$N_p = \frac{1}{2} \left(1 + N_1 + \sum_{i=1}^M (N_i^i + N_i^{i-1}) \right) - 1 \quad (3.39)$$

onde M é o grau da não-linearidade. Assim, os resultados práticos com os funcionais de Volterra em dinâmica de estruturas são limitados aos sistemas com poucos graus de liberdade.

¹⁰Que pode ser facilmente extraído dos sinais experimentais de entradas-saídas.

Uma forma diferente proposta em [92] consiste em observar observar que a Eq. (3.36) pode ser reorganizada da seguinte maneira:

$$x(k) = \Theta^T \lambda'(k) \quad (3.40)$$

onde Θ é o vetor de parâmetros à estimar. Neste casos os valores dos kernels de 1.º e 2.º ordem estão descritos dentro deste vetor:

$$\Theta = \begin{bmatrix} h_1(0) & h_1(1) & \dots & h_1(N_1) & h_2(0,0) & h_2(1,0) & h_2(1,1) \\ h_2(2,0) & h_2(2,1) & h_2(2,2) & h_2(3,0) & \dots & h_2(N_2,0) & \dots & h_2(N_2,N_2) \end{bmatrix}^T \quad (3.41)$$

O vetor regressivo $\lambda'(k)$ é também escrito para cada instante k :

$$\lambda'(k) = \begin{bmatrix} u(k) & u(k-1) & \dots & u(k-N_1) & u(k)^2 & u(k-1)u(k) \\ u(k-1)^2 & u(k-2)u(k) & u(k-2)u(k-1) & u(k-2)^2 \\ \dots & u(k-N_2)u(k) & u(k-N_2)u(k-1) & \dots & u(k-N_2)^2 \end{bmatrix}^T \quad (3.42)$$

A Eq. (3.40) pode ser resolvida pelo método de mínimos quadrados clássico. É interessante observar que apesar de conter não-linearidades estáticas dentro do vetor $\lambda'(k)$, a Eq. (3.40) é linear nos parâmetros. Infelizmente, como já discutido, os números de amostras para truncamento N_1 e N_2 são impraticáveis para um cálculo efetivo envolvendo sistemas reais.

A solução é expandir a série de Volterra usando funções ortogonais. A escolha de qual função ortogonal usar influencia bastante o número de parâmetros à estimar, pois caso se escolha uma função ortogonal composta por pólos próximos a dinâmica linear dominante do sistema o número destes parâmetros pode ser reduzido, uma vez que nestes casos se aproxima um modelo NFIR com pólos apenas na origem, e portanto, estático, para um modelo NIIR, com pólos em posições próximas a dinâmica linear do sistema (ou próximo à um comportamento dinâmico de interesse para modelagem). Uma função muito interessante para fazer esta expansão é a função de Kautz que será detalhada na seção 3.4.2.

3.4.1 Séries de Wiener/Volterra

A série de Wiener/Volterra é conhecida como uma expansão ortogonal da série de Volterra. Porém a série clássica de Volterra é uma série de Wiener [63]. A série de Wiener/Volterra é composta por uma dinâmica linear seguida por um funcional não-linear estático.

A idéia básica é descrever os núcleos truncados $h_n(n_1, n_2, \dots, n_n)$ pelo emprego de bases de funções ortogonais $\psi_{i_j}(n_j)$ ¹¹:

$$h_n(n_1, n_2, \dots, n_n) \approx \sum_{i_1=1}^{M_1} \cdots \sum_{i_n=1}^{M_n} \alpha(i_1, \dots, i_n) \prod_{j=1}^n \psi_{i_j}(n_j) \quad (3.43)$$

É assumido que os kernels são somáveis em $[0, \infty)$. A ortonormalidade de $\psi_{i_j}(n_j)$ é dada por $\sum_{k=0}^{\infty} \psi_q(k)\psi_r(k) = \delta_{qr}$, sendo δ_{qr} o delta de Kronecker. Os coeficientes $\alpha(i_1, \dots, i_n)$ são as projeções dos kernels dentro da base $\psi_{i_j}(n_j)$.

Para o caso investigado nesta tese os dois kernels são escritos dentro de uma base ortogonal a partir da Eq. (3.43) da seguinte forma¹²:

$$h_1(n_1) = \sum_{i_1=1}^{M_1} \alpha(i_1)\psi_{i_1}(n_1) \quad (3.44)$$

$$h_2(n_1, n_2) = \sum_{i_1=1}^{M_2} \sum_{i_2=1}^{i_1} \alpha(i_1, i_2)\psi_{i_1}(n_1)\psi_{i_2}(n_2) \quad (3.45)$$

onde M_1 e M_2 são os números de filtros ortogonais para descrever os kernels. As Eqs. (3.44) e (3.45) são usadas para substituir os kernels na Eq. (3.36):

$$\begin{aligned} x(k) = & \sum_{n_1=0}^{N_1} \sum_{i_1=1}^{M_1} \alpha(i_1)\psi_{i_1}(n_1)u(k - n_1) + \\ & + \sum_{n_1=0}^{N_2} \sum_{n_2=0}^{n_1} \sum_{i_1=1}^{M_2} \sum_{i_2=1}^{i_1} \alpha(i_1, i_2)\psi_{i_1}(n_1)\psi_{i_2}(n_2)u(k - n_1)u(k - n_2) \end{aligned} \quad (3.46)$$

A Eq. (3.46) pode ser reorganizada:

¹¹Aqui $\psi_{i_j}(n_j)$ é a IRF de um filtro discreto $\Psi(z)$, onde z é a variável complexa.

¹²É considerado que o kernel $\alpha(i_1, \dots, i_n)$ é simétrico.

$$\begin{aligned}
x(k) &= \sum_{i_1=1}^{M_1} \alpha(i_1) \sum_{n_1=0}^{N_1} \psi_{i_1}(n_1) u(k - n_1) + \\
&+ \sum_{i_1=1}^{M_2} \sum_{i_2=1}^{i_1} \alpha(i_1, i_2) \sum_{n_1=0}^{N_2} \psi_{i_1}(n_1) u(k - n_1) \sum_{n_2=0}^{n_1} \psi_{i_2}(n_2) u(k - n_2)
\end{aligned} \tag{3.47}$$

Depois de uma análise na Eq. (3.47), pode-se ver que em uma série de Wiener/Volterra os sinais de entrada $u(k)$ são filtrados por filtros $\Psi(z)$ com resposta ao impulso $\psi(k)$ [67]. Assim:

$$l_{i_1}(k) = \sum_{n_1=0}^{\varepsilon} \psi_{i_1}(n_1) u(k - n_1) \tag{3.48}$$

$$l_{i_2}(k) = \sum_{n_2=0}^{\varepsilon} \psi_{i_2}(n_2) u(k - n_2) \tag{3.49}$$

sendo $\varepsilon = \max(N_1, N_2)$. As Eqs. (3.48) e (3.49) são levadas à Eq. (3.47):

$$x(k) = \sum_{i_1=1}^{M_1} \alpha(i_1) l_{i_1}(k) + \sum_{i_1=1}^{M_2} \sum_{i_2=1}^{i_1} \alpha(i_1, i_2) l_{i_1}(k) l_{i_2}(k) \tag{3.50}$$

A vantagem é que dentro desta nova configuração, deve-se estimar os kernels ortogonais $\alpha(i_1)$ e $\alpha(i_1, i_2)$ com número de parâmetros N_w :

$$N_w = \frac{1}{2} \left(1 + M_1 + \sum_{i=1}^M (M_i^i + M_i^{i-1}) \right) - 1 \tag{3.51}$$

Como M_1 e M_2 são bem menores que N_1 e N_2 , o número de termos para estimar em uma série de Wiener/Volterra é $N_w \ll N_p$. Portanto, é muito mais fácil estimar os kernels $\alpha(i_1)$ e $\alpha(i_1, i_2)$ do que os kernels $h_1(n_1)$ e $h_2(n_1, n_2)$. Uma vez conhecidos os kernels ortogonais, os kernels físicos $h_1(n_1)$ e $h_2(n_1, n_2)$ podem ser obtidos com as relações (3.44) e (3.45). Pode-se generalizar a Eq. (3.31) truncada com funções ortogonais, assim:

$$x(k) = \sum_{m=1}^M \sum_{i_1=1}^{N_1} \cdots \sum_{i_m=1}^{N_m} \alpha(i_1, \dots, i_m) \prod_{j=1}^m l_{i_j}(k) \tag{3.52}$$

Para o caso considerado nesta tese, com dois kernels a estimar, pode-se utilizar a Eq. (3.40), mas nestes casos o vetor de parâmetros procurados será dado por:

$$\Theta = \left[\alpha(1) \quad \dots \quad \alpha(M_1) \quad \alpha(1,1) \quad \alpha(2,1) \quad \alpha(2,2) \quad \alpha(3,1) \quad \dots \quad \alpha(M_2, M_2) \right]^T \quad (3.53)$$

O vetor regressivo $\lambda'(k)$ é também escrito para cada instante de tempo k como:

$$\lambda'(k) = \left[l_1(k) \quad l_2(k) \quad \dots \quad l_{M_1}(k) \quad l_1(k)^2 \quad l_2(k)l_1(k) \right. \\ \left. l_2(k)^2 \quad l_3(k)l_1(k) \quad l_3(k)l_2(k) \quad l_3(k)^2 \quad \dots \quad l_{M_2}(k)^2 \right]^T \quad (3.54)$$

3.4.2 Filtros de Kautz

Existem diferentes bases ortogonais $\psi_{i_j}(n_j)$ que podem ser empregadas para escrever os kernels $h_1(n_1)$ e $h_2(n_1, n_2)$, podem-se citar as funções de Fourier, Chebyshev ou Legendre. Porém, grande parte destas funções não são relacionadas diretamente à dinâmica de sistemas a partir de uma equação a diferenças, por exemplo. Então, mesmo com as expansões das Eqs. (3.44) e (3.45) feitas com estas funções, o número de parâmetros para estimação em uma série de Wiener/Volterra pode ainda continuar elevado.

Felizmente, nestes casos, os filtros discretos de Kautz podem ser efetivos para desenvolver os núcleos das Eqs. (3.44) e (3.45). Os filtros de Kautz são funções ortogonais com pólos visando descrever a dinâmica dominante do sistema [85] e [19]. Esta informação é capaz de reduzir de forma considerável o montante de parâmetros para descrever os kernels $\alpha(i_1)$ e $\alpha(i_1, i_2)$. Nota-se que o primeiro *kernel* ortogonal de Volterra $\alpha(i_1)$ pode ser estimado usando o método das covariâncias escrito em uma base de Kautz, como proposto originalmente no artigo [73] do presente autor.

O filtro de Kautz $\Psi_n(z)$ tem pólos complexos conjugados escolhidos por $\beta = \sigma + j\omega$ e $\bar{\beta} = \sigma - j\omega$. Estes pólos complexos são parametrizados por dois valores escalares reais b e c , sendo $|b| < 1$ et $|c| < 1$ para obtenção de sistemas estáveis. Estes filtros são muito úteis para representar a dinâmica de sistemas oscilatórios de 2.º ordem.

Uma questão prática é definir os pólos β e $\bar{\beta}$ empregados para construir estes filtros. Trabalhos de Rosa et al. [17] e [16] propuseram um algoritmo que permite estimar simultaneamente os kernels

ortogonais $\alpha(i_1)$ e $\alpha(i_1, i_2)$ e os pólos de Kautz. Estes trabalhos [17] e [16] constataram que os pólos de Kautz são próximos aos pólos da dinâmica linear dominante. Uma vez que em dinâmica de estruturas pode-se ter conhecimento prévio das matrizes estruturais lineares (\mathbf{M} , \mathbf{C} e \mathbf{K}), pode-se pensar em estimar estes pólos no plano z que representem bem a dinâmica dominante do sistema em torno do modo linear equivalente de interesse. Porém, como se empregará séries de Volterra com aplicações em estruturas inteligentes, se admitirá como hipótese o não conhecimento das matrizes lineares de massa, rigidez ou amortecimento. A seção 6.2.4 apresenta uma forma de se estimar os pólos de Kautz para estes casos.

Os elementos de um banco de filtros de Kautz são dados por [19], [85] e [17]:

$$\Psi_{2n}(z) = \frac{\sqrt{(1-c^2)(1-b^2)}z}{z^2 + b(c-1)z - c} \left[\frac{-cz^2 + b(c-1)z + 1}{z^2 + b(c-1)z - c} \right]^{n-1} \quad (3.55)$$

$$\Psi_{2n-1}(z) = \frac{\sqrt{1-c^2}z(z-b)}{z^2 + b(c-1)z - c} \left[\frac{-cz^2 + b(c-1)z + 1}{z^2 + b(c-1)z - c} \right]^{n-1} \quad (3.56)$$

onde as constantes b e c são relacionadas aos pólos β e $\bar{\beta}$ pelas relações seguintes:

$$b = \frac{(\beta + \bar{\beta})}{(1 + \beta\bar{\beta})} \quad (3.57)$$

$$c = -\beta\bar{\beta} \quad (3.58)$$

Com as Eqs. (3.55) e (3.56) os sinais de entradas $u(t)$ são filtrados para obter os sinais $l_{i_1}(k)$ e $l_{i_2}(k)$. As respostas ao impulsos dos filtros das Eqs. (3.55) e (3.56) são armazenadas para estimação dos kernels. Os filtros de Kautz têm informação da dinâmica dominante do sistema, o que permite reduzir o número de parâmetros a estimar. A série de Wiener/Volterra escrita com filtros de Kautz é nomeada nesta tese como modelo de Kautz-Volterra.

3.4.3 Detecção de danos usando modelos de Kautz-Volterra

A idéia de usar modelos de Kautz-Volterra para detectar danos é a mesma dos casos de modelos auto-regressivos de saída. Porém, com um modelo de Kautz-Volterra se é capaz de realizar uma predição não-linear de um sinal de saída a partir do conhecimento do sinal de entrada $u(k)$ e dos

kernels de Volterra. Nestes casos, a aplicação de um modelo deste tipo só é possível quando se conhece o sinal de excitação; o que é caso das aplicações com estruturas inteligentes, onde se tem acesso ao sinal de excitação aplicado em cada atuador piezocerâmico.

Quando se tem um conjunto de sinais de voltagens $u(k)$ e $x(k)$ em condição estrutural saudável, podem-se extrair os kernels de Volterra de 1.º ordem $h_1(n_1)$ e 2.º ordem $h_2(n_1, n_2)$ que caracterizam este sistema usando a formulação apresentada nas seções anteriores envolvendo os modelos de Wiener e filtros de Kautz. Uma vez obtidos os kernels dos dados experimentais, estes são usados para prever o sinal $x(k)$. Este sinal obtido pelo modelo de Kautz-Volterra é nomeado de $\hat{x}(k)$ e é calculado através da equação a seguir:

$$\hat{x}(k) = \sum_{n_1=0}^{N_1} h_1(n_1)u(k - n_1) + \sum_{n_1=0}^{N_2} \sum_{n_2=0}^{n_1} h_2(n_1, n_2)u(k - n_1)u(k - n_2) \quad (3.59)$$

Uma análise na Eq. (3.59) permite verificar que $\hat{x}(k) = \hat{x}_{lin}(k) + \hat{x}_{nl}(k)$, sendo $\hat{x}_{lin}(k)$ a contribuição linear da predição, obtida com o kernel $h_1(n_1)$, e $\hat{x}_{nl}(k)$ a contribuição não-linear, obtida com o kernel de Volterra $h_2(n_1, n_2)$. Estes modelos podem conduzir a um erro de predição linear $e_x^{lin}(k)$ e a um erro de predição não-linear $e_x^{nl}(k)$ na condição saudável de referência, que são definidos como:

$$e_x^{lin}(k) = x(k) - \hat{x}_{lin}(k) \quad (3.60)$$

$$e_x^{nl}(k) = x(k) - \hat{x}(k) \quad (3.61)$$

A próxima fase é investigar se os kernels $h_1(n_1)$ e $h_2(n_1, n_2)$ extraídos da condição saudável são capazes de prever um sinal em uma condição desconhecida, representado por um par de sinais de entrada $u_y(k)$ e de saída $y(k)$. A predição feita é dada por:

$$\hat{y}(k) = \sum_{n_1=0}^{N_1} h_1(n_1)u_y(k - n_1) + \sum_{n_1=0}^{N_2} \sum_{n_2=0}^{n_1} h_2(n_1, n_2)u_y(k - n_1)u_y(k - n_2) \quad (3.62)$$

A Eq. (3.62) também é formada por dois termos, assim com esta equação também pode-se obter um erro de predição na condição desconhecida linear e não-linear, respectivamente $e_y^{lin}(k)$ e $e_y^{nl}(k)$:

$$e_y^{lin}(k) = y(k) - \hat{y}_{lin}(k) \quad (3.63)$$

$$e_y^{nl}(k) = y(k) - \hat{y}(k) \quad (3.64)$$

Se o modelo de Kautz-Volterra não leva a uma boa predição é indício de que o sistema apresentou alguma variação estrutural e o erro na condição desconhecida será diferente do erro de referência saudável. A avaliação dos erros de referência e desconhecidos com um indicador γ envolvendo os desvios padrões dos erros de predição linear ou não-linear conduz à um bom diagnóstico da saúde estrutural. Estes indicadores são definidos como:

$$\gamma_{lin} = \frac{\sigma(e_y^{lin})}{\sigma(e_x^{lin})} \quad (3.65)$$

$$\gamma_{nl} = \frac{\sigma(e_y^{nl})}{\sigma(e_x^{nl})} \quad (3.66)$$

Inúmeras outras ferramentas estatísticas podem ser usadas para auxiliar nesta classificação e definir se houve variação dos termos desconhecidos em relação ao sinal de referência.

3.5 Determinação de ordem de modelos

Uma das questões que mais compromete a capacidade de predição e/ou simulação de um modelo discreto são as ordens escolhidas para os polinômios $A(q)$, $B(q)$ e $C(q)$, respectivamente, chamadas aqui de n_a , n_b e n_c . Esta ordem é relacionada diretamente com o número de regressores passados dos sinais de saída e/ou entrada necessários para descrever uma saída amostrada em um instante k .

Em geral, estas ordens são desconhecidas. Felizmente, há várias técnicas que podem ser utilizadas para auxiliar nesta escolha. Por exemplo, a ordem n_a quase sempre é maior ou igual que n_b . Além disto a ordem do polinômio que modela o ruído, $C(q)$, geralmente é baixa, inferior a 5. Com isto, pode-se supor de início que: $n_c < n_b < n_a$.

Os dois métodos mais usados são o critério de informações de Akaike (AIC) e o erro final de predição de Akaike (FPE), [2]. Porém, existem outros métodos, como o proposto por Shin et al. [66] que usaram um critério baseado em uma decomposição em valores-singulares.

Nesta tese foi utilizado o AIC por ser o mais básico e bem documentado na literatura. Este

critério consiste em avaliar o indicador seguinte a partir de um modelo com ordem variável em uma faixa inicial de busca:

$$AIC(n_\theta) = N \ln(\sigma_{error}^2(n_\theta)) + 2n_\theta \quad (3.67)$$

sendo n_θ o número de parâmetros estimados, ou seja, número de coeficientes dos polinômios de interesse do modelo, N é o número de pontos temporais usados e $\sigma_{error}^2(n_\theta)$ é a variância do erro de estimação em função do vetor de parâmetros.

O AIC é composto por duas parcelas, a primeira mostra que quanto maior o número de parâmetros, menor será a variância do erro estimado. Porém a segunda parcela penaliza esta primeira, pois ela é função do número de parâmetros do modelo. Sendo assim, a meta é encontrar um valor AIC mínimo, ou seja que faça um balanço e equilíbrio entre o número de parâmetros n_θ a estimar e com uma baixa variância $\sigma_{error}^2(n_\theta)$.

O mais comum é calcular o AIC para uma combinação de valores n_a , n_b e n_c e avaliá-lo para cada situação. Este procedimento fornece boas estimativas para estas ordens, porém isto não significa que a ordem escolhida será a ordem real. Uma discussão sucinta sobre validação de modelos é dada na seção 3.6.

É importante comentar que o *toolbox* de identificação de sistemas para Matlab®, escrito pelo mesmo autor do clássico livro [44], contém muitas rotinas computacionais úteis para estimação de ordens de modelos discretos auto-regressivos. Este pacote é usado nos resultados desta tese.

3.6 Validação de modelos

Após obter um modelo discreto auto-regressivo é importante verificar se ele é válido para cumprir seu objetivo. Basicamente, um modelo deste tipo pode ser usado para dois fins específicos: predição e/ou simulação. Modelos para predição são usados para tentar prever as saídas em um instante $k + 1$, dado o conhecimento de medidas em instantes k inferiores, ou seja utiliza-se na regressão sinais medidos. Já um modelo para fins de simulação, tem como meta descrever algum comportamento

dinâmico em uma faixa de operações, sem necessariamente ter acesso às medidas; nesta situação a regressão é feita com sinais simulados. Nesta tese usou-se modelos para fins de predição. O leitor interessado em uma descrição mais completa sobre estas diferenças pode consultar a referência [44].

Há duas formas básicas para verificação de validade de modelos discretos, uma delas é uma simulação livre, ou seja, utilizar um conjunto de dados diferentes dos usados na estimação para verificar se existe uma concordância qualitativa (visual) entre as saídas do modelo identificado e dos sinais reais. Este tipo de verificação é bastante comum em dinâmica de estruturas, onde usualmente se vê a comparação entre duas curvas: a experimental e a simulada pelo modelo. Porém, ao contrário do senso comum, uma perfeita concordância entre estas curvas não significa necessariamente a obtenção de um bom modelo para predição de sinais de vibração ou de voltagens medidas com PZTs [2].

Uma forma mais efetiva é realizar uma análise de resíduos, ou seja, calcular a correlação entre a saída do modelo e o erro de predição. Em um bom modelo de predição é esperado que esta função tenha características de ruído branco. Isto quer dizer que caso o sinal de saída não possua nenhuma correlação com o sinal de erro, o modelo de predição em questão é capaz de descrever a informação dominante contida nos sinais e descrita pelo modelo extraído a priori. Esta análise de resíduos também se mostra útil na avaliação sobre a validade de um conjunto de ordens de modelos e ajuda a explicar bem a dinâmica presente nos sinais medidos.

Nos exemplos feitos nesta tese, todos os modelos obtidos a partir dos sinais saudáveis são validados através de uma análise de resíduos e por uma simulação livre.

3.7 Conclusões

Este capítulo abordou o uso de modelos discretos de predição que podem ser usados para extração de métricas sensíveis a presença de danos estruturais baseadas em erros ou resíduos de predição. No total quatro tipos de modelos foram revistos. Primeiramente, os modelos com desconhecimento do sinal de excitação:

Modelo AR-ARX: tem uma fase AR inicial para estimar o sinal de entrada desconhecida com base

nas respostas.

Modelo ARMA: método direto baseado na filtragem da resposta por um banco de filtros de referência implementados em séries.

E na seqüência os modelos onde se admite que o sinal de excitação dominante é medido:

Modelo ARMAX: modelo utilizado em aplicações locais envolvendo sensores PZTs.

Modelo de Volterra com filtros de Kautz: modelo com termos para descrever características não-lineares que podem ser excitadas pela presença de danos.

Constata-se que os modelos lineares são úteis quando se têm garantias de que o dano não excite predominantemente características dinâmicas não-lineares. Caso isto ocorra o modelo de Volterra com filtros de Kautz se mostra um candidato para extração de uma métrica de danos. Ressalta-se mais uma vez que a proposição de modelos de Kautz-Volterra para aplicações SHM é uma nova abordagem, pois envolve uma predição com características não-lineares.

Capítulo 4

Técnicas de Detecção e Localização de Danos

O processo de escolha de um valor limiar para separar o estado da estrutura intacta com um estado desconhecido é um passo extremamente importante em um problema SHM [91]. Este capítulo irá descrever algumas formulações que podem ser usadas para realizar esta classificação com base em erros de predição de séries temporais. Todos os métodos têm como hipótese básica o conhecimento apenas dos dados em uma condição saudável¹ (métodos em modo não-supervisionados).

Inicialmente é feita uma revisão em alguns indicadores convencionais envolvendo o uso da razão γ dada pela Eq. (3.23) e uso de indicadores falha métrica baseados em valores rms, que são muito usados em monitoramento via medidas de impedância eletromecânica [38]. Em seguida é investigada uma formulação diferente, que apesar de ser popular para agrupamento é pouco aplicada em problemas práticos de SHM: agrupamento fuzzy, proposto em [5]. Em um agrupamento fuzzy o objetivo é identificar um número finito de grupos (“clusters”) para descrever um conjunto de dados. No agrupamento fuzzy, os membros de um grupo obedecem a uma decisão fuzzy. Assim, um ponto na massa de dados pertence a priori a todos os grupos com um dado valor de possibilidade variando de 0 até 1. A função objetivo do algoritmo fuzzy é baseada na seleção de objetos representativos do conjunto de dados tal que a dissimilaridade de um grupo seja minimizada em um modo não-supervisionado. Dois métodos populares são descritos neste capítulo, o fuzzy c-means e o algoritmo Gustafson-Kessel.

Na seqüência uma formulação muito usada recentemente é apresentada: controle estatístico de

¹A condição saudável é uma condição de referência para comparação.

processos (SPC). Este método é baseado em cartas de controle para monitoramento contínuo automático. Diversos trabalhos na literatura têm utilizado SPC para monitorar diferentes índices sensíveis a falhas, como por exemplo, os trabalhos [77], [30] ou ainda o [76].

É importante destacar que os tipos de danos simulados numericamente e experimentalmente nos capítulos 5 e 6 corresponderam a variações nas respostas dinâmicas provocadas por remoção de suportes, barras de travamento, entalhes inseridos ou ainda apertos e desapertos em junções parafusadas interligando subestruturas.

4.1 Indicadores convencionais

4.1.1 Indicador γ

No capítulo 3 foram apresentados procedimentos para extrair um índice a partir de séries temporais onde os efeitos de entradas, como variações ambientais, fossem normalizados. Este procedimento de normalização é necessário quando diferentes medidas são disponíveis para construir modelos autorregressivos.

Para obter o indicador da Eq. (3.23) foi admitido que $\sigma(e_y)$ e $\sigma(e_r)$ são distribuídos de forma normal. Caso esta consideração não seja satisfeita, implica que os desvios padrões $\sigma(e_y)$ e $\sigma(e_r)$ possam ser diferentes em razão de possuírem distribuições diferentes. Lu e Gao [45] investigaram um índice para diagnóstico baseados na razões entre $\sigma(e_y)$ e $\sigma(e_r)$ e os resultados foram satisfatórios. A Eq. (3.23) é repetida aqui:

$$\gamma = \frac{\sigma(e_y)}{\sigma(e_r)} \quad (4.1)$$

Se este indicador apresenta uma distribuição não-Gaussiana, esta formulação deve ser modificada, o que pode ser feito pelo uso de estatísticas de valores extremos (EVS) [89]. EVS ajusta somente as distribuições nos extremos das amostras e relaciona a significância dos dados. Porém, se é razoável admitir que este conjunto de dados tem distribuição normal, este procedimento não necessita ser empregado.

Um aumento no índice da Eq. (4.1) indica que a localização da medida é próxima à posição do dano, pois o indicador é relacionado diretamente ao sinal de vibração no ponto de medida. Portanto, com este procedimento é possível obter informação conjunta tanto sobre a ocorrência de uma modificação estrutural, quanto sua posição (atingir o 2.º nível do problema SHM).

Mattson e Pandit [47] estudaram uma formulação estatística similar ao índice da Eq. (4.1) mas comparando o uso de momentos estatísticos de ordem superior. Eles utilizaram *skewness* e *kurtosis* para especificar o valor *threshold* do indicador que separa as condições com danos e sem danos. Entretanto, os resultados foram menos confiáveis do que usando o desvio padrão.

Nesta tese é usado o indicador da Eq. (4.1), mas também com outras formas de realizar a classificação, e. g., uso de agrupamento fuzzy. Além deste índice, apresenta-se o uso da análise direta do sinal do erro de predição na condição estrutural desconhecida $e_y(k)$ e sua comparação com uma referência através do controle estatístico de processos.

4.1.2 Indicador falha métrica RMSD

O indicador conhecido como falha métrica é um índice baseado no desvio RMSD^2 entre duas curvas de respostas frequenciais de sinais de impedância elétrica do acoplamento estrutura-PZT, nomeado aqui de Z_p . Tradicionalmente, um sinal de impedância eletro-mecânica é obtido pela divisão entre a voltagem aplicada no PZT acoplado na estrutura e a corrente que o atravessa e passa por um circuito condicionador. A figura 4.1 mostra um circuito acoplado a um PZT/estrutura que pode ser usado para se extrair um sinal de impedância [64]. Neste caso o sinal de impedância seria dado por:

$$Z_p = \frac{V_p}{I_p} = \frac{V_{in} - V_{out}}{V_{out}/R} = R \left(\frac{V_{in}}{V_{out}} - 1 \right) \quad (4.2)$$

No mercado existem aparelhos comerciais para calcular um sinal Z_p . Porém são caros e dificultam um trabalho de campo. Nestas condições, alguns autores propuseram circuitos alternativos de baixo custo que podem ser usados para estimação do sinal Z_p . Peairs et al. [59] e Furtado e Lopes Jr. [31] exemplificaram alguns circuitos alternativos que poderiam ser usados para este fim. No presente

²Desvio médio quadrático.

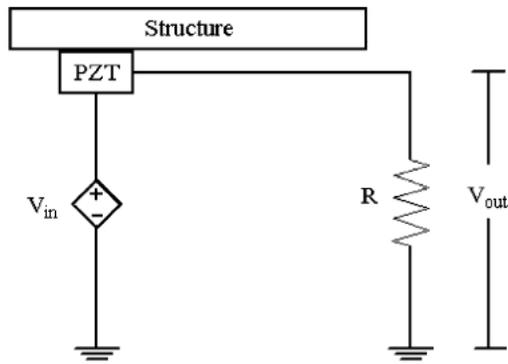


Fig. 4.1: Diagrama do circuito ligado ao PZT indicando as voltagens V_{in} e V_{out} [64].

trabalho, os sinais elétricos provenientes de PZTs que são usados no capítulo 6, foram processados pelo mesmo dispositivo desenvolvido por Furtado e Lopes Jr [31], que é mostrado na figura 6.16. Maiores detalhes deste circuito de condicionamento podem ser encontrados nesta referência.



Fig. 4.2: Dispositivo de baixo custo para condicionamento dos sinais V_{in} e V_{out} [31].

Entretanto, este sinal Z_p não será usado diretamente nesta tese. O que será feito é medir os sinais de tensão aplicados na entrada e saída e em seguida estimar a relação entrada-saída de cada PZT, respectivamente V_{in} e V_{out} . A diferença entre ambos os procedimentos é o ganho constante causado pelas resistências do circuito, dada por R . A estimativa não-paramétrica entre a função de

transferência relacionando os sinais V_{in} e V_{out} pode ser estimada usando técnicas clássicas de análise espectral, como o estimador H_1 usando o método de Welch [80].

Esta função de transferência no domínio da frequência pode ser chamada de $G(\omega)$. O índice falha métrica RMS pode ser definido então da seguinte forma [37]:

$$M = \sum_{i=1}^n \sqrt{\frac{\left\{ \Re(G_h(\omega_i)) - \Re(G_{unk}(\omega_i)) \right\}^2}{\left\{ \Re(G_h(\omega_i)) \right\}^2}} \quad (4.3)$$

sendo que o subscrito h significa função de transferência na condição saudável, o subscrito unk função de transferência em uma condição estrutural desconhecida, $\Re(\cdot)$ é a parte real do sinal em um ponto de frequência ω_i e n é o número de pontos de frequência usados. Somente a parte real do sinal $G(\omega)$ é usada por ser mais sensível a modificações estruturais do que a parte imaginária. Este termo é dominado pela resposta capacitiva do PZT e portanto, é mais sensível a efeitos de danos estruturais, fato este já bem documentado na literatura, como exemplo o trabalho [54].

Assim, depois de obtido um conjunto de medidas sem danos e calculado um sinal base (*baseline*), o indicador falha métrica dado pela Eq. (4.3) é calculado e o valor M para cada novo conjunto de sinais V_{in} e V_{out} em condição estrutural desconhecida é avaliado. Este procedimento é feito individualmente em cada PZT acoplado em uma estrutura sob análise. Se existe um dano próximo a um PZT, o valor de M aumentará. Consequentemente, a localização do dano pode ser aproximadamente prevista por este simples índice.

O aumento no valor de M também é bem correlacionado qualitativamente à severidade do dano. Porém, este método apresenta alguns possíveis pontos negativos:

- Necessidade de escolha adequada da faixa de frequência para amostrar os sinais, em geral da ordem de 30 kHz [54].
- Necessidade de se estimar de forma não-paramétrica o conjunto de sinais em uma condição sem dano e em uma condição com dano, neste caso aspectos como escolha errônea do tipo de janela,

intervalo de medida, número de pontos, *overlap*, etc, poderiam comprometer a estimativa de $G(\omega)$ e a análise.

Estes pontos negativos motivam o uso de métodos temporais envolvendo análise de séries temporais. Nesta concepção, os sinais V_{in} e V_{out} na condição de referência, admitida como estando no estado estrutural saudável, podem ser usados para se construir um modelo de predição e em vez de se monitorar a partir do valor do indicador falha métrica M , usaria-se o erro de predição deste modelo discreto. Com este procedimento, se dispensaria a necessidade de se estimar de forma não-paramétrica uma nova relação de voltagem de entrada-saída toda vez que se obtivesse uma nova medida. Como já discutido no capítulo 2, o único trabalho que sugere algo nesta linha³ foi feito por Lynch [46].

4.2 Agrupamento fuzzy

As metas dos métodos de agrupamentos são a classificação de objetos de acordo com a similaridade entre eles, e a organização dos dados em grupos. Várias definições de cluster podem ser formuladas, mas de forma geral, um *cluster* pode ser entendido como um grupo de objetos que são mais similares a outros membros de outros *clusters*. O termo “similaridade” deve ser entendido como uma similaridade matemática, ou seja, uma medida bem-definida. Outra característica importante é que técnicas de agrupamento estão entre os métodos de reconhecimento não-supervisionado, ou seja, nestes métodos não se utiliza a priori identificadores de classe.

A principal característica destes métodos é a detecção de dissimilaridades nos dados de observação do sistema, não somente para finalidades de classificação e reconhecimento de padrões, mas também para redução e otimização de modelos. Neste sentido estas técnicas podem ser aplicadas buscando uma análise quantitativa, qualitativa, ou uma mistura de ambas. Neste trabalho, o esforço é concentrado em agrupamentos quantitativos.

Os dados são considerados como observações de algum processo físico. Cada observação con-

³Excluindo-se os trabalhos publicados pelo autor e colaboradores.

siste de n variáveis de medidas, agrupadas em um vetor coluna com dimensão n . Normalmente são consideradas L observações diferentes. Os dados são agrupados e escritos na seguinte forma matricial:

$$\mathbf{T} = \begin{bmatrix} m_{11} & m_{12} & \cdots & m_{1n} \\ m_{21} & m_{22} & \cdots & m_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ m_{L1} & m_{L2} & \cdots & m_{Ln} \end{bmatrix} \quad (4.4)$$

Na terminologia de agrupamento a matriz \mathbf{T} é conhecida com matriz de dados e representa uma matriz $L \times n$. As linhas desta matriz são chamadas padrões ou objetos e as colunas são conhecidas como atributos do conjunto de dados. Os significados físicos das linhas e das colunas desta matriz dependem do contexto do problema. Para a finalidade deste trabalho foram considerados três atributos, correspondendo respectivamente aos valores dos desvios padrões dos erros residuais do sinal de referência, $\sigma(e_r)$, e do sinal desconhecido, $\sigma(e_y)$, e mais a razão γ calculada pela Eq. (4.1). O número de linhas desta matriz (número de objetos) variou conforme o número de testes realizados.

As medidas de dissimilaridade e/ou similaridade em geral são métricas espaciais e são definidas como normas de distâncias. Estas distâncias podem ser medidas entre os vetores de dados entre si, ou como uma distância de um vetor de dados a um objeto protótipo do cluster. Em geral estes protótipos são desconhecidos quando se trabalha em modo não-supervisionado. Os algoritmos de agrupamento calculam simultaneamente a partição dos dados junto com as estimativas destes protótipos.

Os dados podem conter clusters com diferentes formas, densidades e geometrias. A figura 4.3 mostra algumas formas básicas. O desempenho da maioria dos algoritmos de agrupamentos é influenciado não somente pela geometria, forma e densidade, mas também pela relação espacial e distância entre os clusters. Clusters podem ser bem separados, continuamente conectados ou sobrepostos.

Poucos trabalhos têm sido feitos com o uso de agrupamento fuzzy para SHM, como já discutido no capítulo 2. Nesta seção os dois métodos mais comuns de classificadores fuzzy, o fuzzy c-means (FCM) e o algoritmos Gustafson-Kessel (GK) são apresentados.

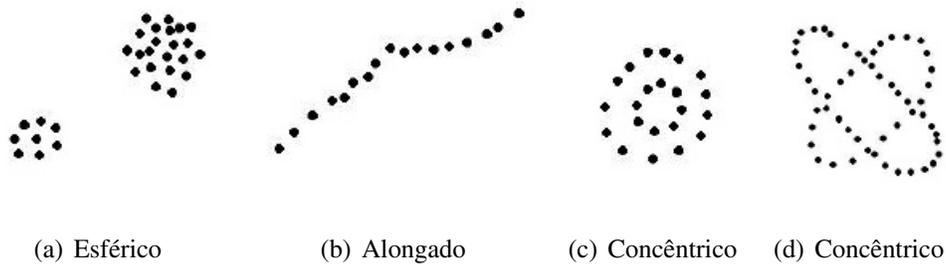


Fig. 4.3: *Clusters* com diferentes formas e dimensões no espaço \mathbb{R}^2 .

4.2.1 Divisão de *Clusters*

Uma vez que clusters podem ser encarados como subconjuntos de um conjunto de dados, uma possível forma de classificação pode ser reconhecer se estes subconjuntos são *fuzzy* ou *crisp* (hard).

Um agrupamento *hard* se baseia na teoria clássica dos conjuntos e verifica se um objeto pertence ou não a um cluster. Assim, neste tipo de agrupamento um conjunto de dados \mathbf{T} é dividido em um número finito de subgrupos mutuamente exclusivos de \mathbf{T} . O número de subconjuntos (*clusters*) é denotado por c . Um método muito comum nesta classe é o algoritmo *k-means*. Dentre as diferentes abordagens e enfoques para a solução desse problema, a maioria requer que o usuário especifique a priori o número de grupos c , enquanto algumas são capazes de determinar automaticamente essa quantidade com base em algum critério de otimalidade.

Na prática, no entanto, muitos problemas envolvem grupos mal delineados que não podem ser separados dessa maneira. Nestes casos, os métodos de agrupamento fuzzy são uma escolha adequada, pois consideram que todos os objetos de \mathbf{T} pertencem simultaneamente a todos os clusters, com diferentes graus de pertinência. Assim, o conjunto de dados \mathbf{T} é dividido em c subconjuntos fuzzy. Além disto, em muitas situações reais o agrupamento fuzzy é mais natural do que o agrupamento hard, uma vez que a natureza discreta do agrupamento hard pode causar vários problemas analíticos na maioria dos métodos, uma vez que os funcionais envolvidos não são diferenciáveis. Portanto, neste trabalho o enfoque será somente em agrupamentos fuzzy.

4.2.2 Algoritmo fuzzy c-means

Nesta seção o algoritmo fuzzy c-means (FCM) é usado para caracterizar um valor limiar. A meta é identificar um número finito de grupos para descrever um conjunto de dados, admitindo que estes grupos são fuzzy. O FCM básico é dado pelo seguinte problema de minimização [5]:

$$\min_{f_{ij}, C_i} J = \sum_{j=1}^N \sum_{i=1}^c f_{ij}^m \left\| x_j - C_i \right\|_A^2 \quad (4.5)$$

com as seguintes exigências:

- sujeito à $0 \leq f_{ij} \leq 1$
- $\sum_{i=1}^c f_{ij} = 1 \quad \forall j \in \{1, 2, \dots, N\}$
- $0 < \sum_{j=1}^N f_{ij} < N \quad \forall i \in \{1, 2, \dots, c\}$

sendo f_{ij} uma função de pertinência associada ao j -ésimo objeto e ao i -ésimo grupo, C_i é o centróide do i -ésimo grupo, c é o número de grupos e $m > 1$ é uma constante que determina a posição relativa do grupo. Este valor m é normalmente escolhido como 2 e será o valor usado aqui; x_j são as características, que são ajustadas para serem γ , $\sigma(e_r)$ e $\sigma(e_y)$. N é o número de objetos⁴ que depende do número de conjunto de dados.

A norma da distância pode ser escrita como:

$$D_{ijA}^2 = \|x_j - C_i\|_A^2 = (x_j - C_i)^T \mathbf{A} (x_j - C_i) \quad (4.6)$$

sendo que \mathbf{A} é conhecida como matriz com norma-induzida. No algoritmo FCM esta matriz é a matriz identidade. Assim, pode-se detectar somente grupos com a mesma forma e orientação. Uma forma de melhorar o algoritmo seria propor formas de tornar esta matriz adaptativa, o que na verdade é a idéia básica do algoritmo Gustafson-Kessel [3].

⁴No presente trabalho, N é relacionado com as situações investigadas.

A função de custo ótima J pode ser obtida pelo seguinte procedimento [6]:

1. Escolha o número c de clusters para agrupar e os centróides iniciais C_1, C_2, \dots, C_c .
2. Calcule f_{ij} para cada $j \in \{1, 2, \dots, L\}$ sendo L o número de características de cada grupo. Neste trabalho estas características são $\gamma, \sigma(e_r)$ e $\sigma(e_y)$. Se $\|x_j - C_i\|^2 > 0$ para $i = 1, \dots, c$, então:

$$f_{ij} = \left\{ \sum_{l=1}^c \left(\frac{\|x_j - C_l\|^2}{\|x_j - C_i\|^2} \right)^{\frac{1}{m-1}} \right\}^{-1} \quad (4.7)$$

Se $\|z_j - C_i\|^2 = 0$ para $i \in 1 \subset \{1, 2, \dots, c\}$, então defina $f_{ij}, i \in 1$, como um número real não-negativo que satisfaça $\sum_{i \in I} f_{ij} = 0$ para $i \in \{1, 2, \dots, c\} - I$.

3. Ajuste os centros:

$$C_i = \frac{\sum_{j=1}^N f_{ij}^m x_j}{\sum_{j=1}^N f_{ij}^m} \quad (4.8)$$

4. Se um critério de convergência pré-definido é alcançado⁵, o procedimento é encerrado, caso contrário retorne ao passo 2.

Detalhes da obtenção destes passos para solução do problema (4.5) podem ser encontrados na referência [6]. O *toolbox* de lógica fuzzy para Matlab® contém rotinas que implementam este método de agrupamento. Nos exemplos desta tese estas funções foram empregadas para se realizar o agrupamento nas classes com dano ou sem dano.

4.2.3 Algoritmo Gustafson-Kessel

O algoritmo Gustafson-Kessel (GK) é baseado diretamente no FCM. Este procedimento considera uma distância adaptativa que é capaz de introduzir grupos elipsoidais e/ou circulares com diferentes

⁵No presente trabalho definiu-se o número máximo de iterações permitidas como um critério de parada.

distribuições geométricas. Esta formulação permite seguir os mesmo passos de solução de um problema envolvendo FCM. Entretanto, a distância entre os j -ésimos objetos e os i -ésimos grupos é calculada usando uma função adaptativa. Assim, a distância entre cada grupo é dada por:

$$D_{ijA_i}^2 = (x_j - C_i)^T \mathbf{A}_i (x_j - C_i), \quad 1 \leq i \leq c, \quad 1 \leq j \leq N \quad (4.9)$$

Cada grupo pode ser adaptado com uma função custo que reflita a topologia local dos dados, informação esta dada pela matriz \mathbf{A}_i . A função de custo do algoritmo GK é dada por:

$$J = \sum_{j=1}^N \sum_{i=1}^c (f_{ij})^m D_{ijA_i}^2 \quad (4.10)$$

Esta função não pode ser usada diretamente como métrica para as distâncias entre os *clusters* com respeito à matriz com norma-induzida \mathbf{A}_i . Para obter uma solução factível, a matriz \mathbf{A}_i é restringida de alguma forma. O mais comum é permitir à matriz \mathbf{A}_i variar, mas com seu determinante fixo. Isto corresponde à otimização de grupos com formas diferentes, mas volumes constantes, tal que $\|\mathbf{A}_i\| = \rho_i$, sendo ρ_i positivo e fixo para cada grupo.

A matriz \mathbf{A}_i pode ser encontrada por [3]:

$$\mathbf{A}_i = \left(\rho_i \det(\mathbf{K}_i) \right)^{\frac{1}{n}} \mathbf{K}_i^{-1} \quad (4.11)$$

sendo $\det(\cdot)$ o determinante e \mathbf{K}_i a matriz de covariância fuzzy do i -ésimo grupo que é dada por:

$$\mathbf{K}_i = \frac{\sum_{j=1}^N (f_{ij})^m (x_j - C_i)(x_j - C_i)^T}{\sum_{j=1}^N (f_{ij})^m} \quad (4.12)$$

pela combinação das Eqs. (4.9), (4.11) e (4.12) a distância generalizada de Mahalonobis entre o objeto x_j e o centróide C_i é obtida. Um procedimento numérico satisfatório foi proposto por Babuska et al. [3] para resolver este problema. Este algoritmo foi incorporado no *toolbox* livre para Matlab® *Fuzzy Clustering and Data Analysis*⁶. Este programa é usado para implementar o agrupamento GK nos exemplos apresentados nesta tese.

⁶Disponível em www.fmt.vein.hu/softcomp.

4.3 Controle estatístico de processos

Uma formulação bastante usada recentemente em SHM é o controle estatístico de processos (SPC). O leitor interessado pode, por exemplo, ler os trabalhos [77], [30] e [69] para uma visão geral de como SPC pode ser bem aplicado e adaptado para problemas de detecção e localização de danos em estruturas mecânicas. Este método é baseado em cartas de controle, que são tradicionalmente usadas para monitoramento automático de qualidade [50].

Uma carta de controle é composta por uma linha central (CL) localizada no valor médio do erro residual $e_x(k)$ e duas linhas adicionais horizontais, correspondendo aos limites de controle superior (*upper*) e inferior (*lower*), nomeadas aqui de UCL e LCL , respectivamente, versus o número de amostras. As linhas CL , UCL e LCL são dados por:

$$CL = m(\bar{X}) \quad (4.13)$$

$$UCL = CL + Z_{\alpha/2} \frac{S}{\sqrt{n}} \quad (4.14)$$

$$LCL = CL - Z_{\alpha/2} \frac{S}{\sqrt{n}} \quad (4.15)$$

sendo $m(*)$ o operador média, \bar{X} o valor médio do erro residual $e_x(k)$ separado em observações e S o desvio padrão, ambos relativos a n observações em cada amostra. $Z_{\alpha/2}$ está relacionado a distribuição χ^2 . O desvio padrão S pode ser estimado por [50]:

$$S = m\left(\frac{S_1}{c}\right) \quad (4.16)$$

$$S_1 = \sigma(e_x) \quad (4.17)$$

$$c = \sqrt{\frac{2}{n-1}} \left(\frac{\Gamma(n/2)}{\Gamma(n-1/2)} \right) \quad (4.18)$$

onde $\Gamma(\)$ é a função gama.

Em geral, quando um sistema estrutural apresenta alguma deterioração, pode-se observar um número estatisticamente significativo de amostras foras dos limites UCL e LCL , conhecidos como *outliers* [30].

A idéia em usar SPC para monitoramento de integridade estrutural é construir os limites de controle UCL , CL e LCL a partir de um conjunto de erros de predição de séries temporais em condição estrutural saudável. Com estes limites projetados, estima-se o número de *outliers* em erros de predição de séries em condição estrutural desconhecida. Caso este número seja superior ao valor limiar, isto é um grande indicativo da presença de dano na estrutura sob análise.

4.4 Conclusões

Os dois métodos propostos para detecção de danos⁷ são baseados no conhecimento de métricas extraídas de séries temporais. Os algoritmos de agrupamento fuzzy têm como característica principal a necessidade da aquisição dos dados em um grande volume de quantidade para que se permita realizar a classificação em algum estado estrutural. Já o método SPC realiza o cálculo dos intervalos de confiança para classificar os estados apenas com o conhecimento das séries temporais de referência quando o sistema está na condição de referência. Com isto, em aplicações visando um procedimento mais rápido o método SPC pode ser mais interessante e melhor adaptado do que os algoritmos FCM e GK, uma vez que a cada nova medição já se pode realizar a classificação do estado estrutural e não esperar uma quantidade de dados previamente determinada.

No que diz respeito aos métodos clássicos, o índice falha métrica RMSD apresenta no geral boa correlação com o estado de estruturas, porém apresenta dificuldades na definição de valores limiares. A métrica γ relacionando a razão dos desvios padrões dos sinais de referência e desconhecidos também apresenta o mesmo ponto observado anteriormente. Com esta métrica também pode existir situações práticas onde exista dano, mas os desvios padrões de referência e desconhecidos são próximos, e conseqüentemente o valor do índice γ é próximo ao valor unitário (falso-negativo). Uma forma, talvez, mais efetiva fosse analisar a interseção das linhas de distribuição normal do erro do sinal de referência e da condição desconhecida a ser determinada. Nestas situações, a métrica talvez apresentasse uma maior robustez nos casos onde o dano exista, mas o valor do indicador γ não sofra grandes variações.

⁷Algoritmos de agrupamento fuzzy, como FCM e GK, e o SPC

Capítulo 5

Resultados Baseados Apenas em Medidas de Respostas

Este capítulo apresenta os resultados analíticos e experimentais utilizados para ilustrar os métodos estudados e propostos neste trabalho. Os exemplos são feitos com base em simulações e dados experimentais de estruturas *benchmarks* convencionais da literatura [35, 79, 24]. Nestes exemplos se admite apenas conhecimento das medidas de aceleração ou deslocamento em alguns pontos da estrutura/máquina. A meta é somente detectar o dano e em algumas ocasiões identificar qualitativamente sua severidade com base no valor da métrica sensível as variações estruturais impostas.

Os três testes feitos neste capítulo estão na classe de métodos globais. O exemplo da seção 5.3 foi realizado com base em um modelo de rotor operando em condições estacionárias, para mostrar que o método também é passível de utilização no diagnóstico de danos em máquinas rotativas.

5.1 Estrutura teste ASCE

Nesta seção são apresentadas as simulações realizadas para exemplificar a metodologia proposta para detectar danos via erros de predição AR-ARX calculados a partir de medidas de vibração. Optou-se por testar o método em um problema *benchmark* concebido pelo *International Association for Structural Control* (IASC) e pelo comitê de Dinâmica da *American Society of Civil Engineers* (ASCE). Inicialmente é mostrada a estrutura benchmark considerada, apresentando sua geometria,

padrões de dano estudados, modelo matemático usado como simulador das respostas da estrutura, etc. Na seqüência são apresentados os resultados simulados alcançados na detecção do dano usando o método *fuzzy c-means* (FCM) e o uso de séries temporais. O algoritmo *Gustafson-Kessel* (GK) é empregado em seguida. Os resultados demonstraram um bom diagnóstico, mesmo assumindo dispor de pouco conhecimento sobre as fontes de excitação e sobre a dinâmica do exemplo simulado.

Os resultados desta seção foram publicados em um trabalho do autor [71].

5.1.1 Descrição da estrutura

Os autores em [23] discutem que uma importante parte do esforço atual para conseguir o progresso na tecnologia *SHM* é o desenvolvimento de estruturas benchmarks bem-definidas que permitam a comparação do desempenho de diferentes algoritmos frente a condições reais de trabalho. O esforço associado conduziu a um problema *benchmark* proposto pela *ASCE Task Group on Health Monitoring*. Um esquema desta estrutura é mostrado na figura 5.1.

Esta estrutura é um pórtico com 4 andares construída com estrutura composta de barras de aço retangular e com aproximadamente 1/3 de escala de um modelo original. O modelo tem 3,6 metros de altura e 2,5 metros na base. As propriedades geométricas e físicas desta estrutura são mostradas na tabela 5.1. Mais detalhes são encontrados em [35].

Neste trabalho foram estudados quatro diferentes padrões de danos que foram definidos pelo comitê de dinâmica estrutural da ASCE. Estes padrões são mostrados na tabela 5.2. Destaca-se que as variações estruturais simuladas são de grande intensidade e provocam variações significativas na maioria das métricas empregadas. Em particular o padrão 2 será considerado como um dano severo.

5.1.2 Extração do indicador

Neste item a meta é extrair um indicador para reconhecer a presença de algum dano no benchmark. Este indicador será utilizado posteriormente para determinar um valor limiar que separe as classes sem dano e com dano utilizando séries temporais e algoritmos de agrupamento fuzzy. Para isto são gerados

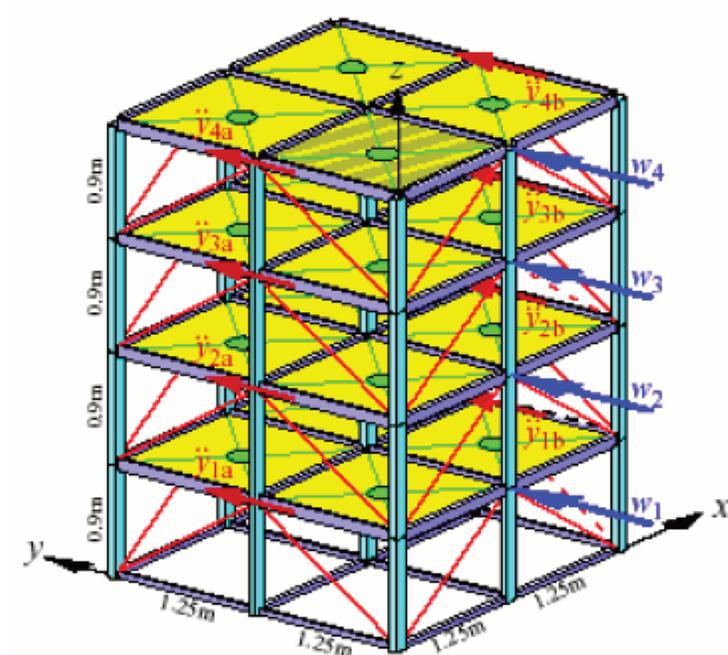


Fig. 5.1: Esquema da estrutura *benchmark* [35].

Tab. 5.1: Propriedades da estrutura.

Propriedades	Vigas	Colunas	Braços
Tipo de secção	B100 × 9	S75 × 11	1.25 × 25 × 3
Área da secção transversal [m^2]	1.133×10^{-3}	1.43×10^{-3}	0.141×10^{-3}
Momento de Inércia I_y [m^4]	1.97×10^{-6}	1.22×10^{-6}	0
Momento de Inércia I_z [m^4]	0.664×10^{-6}	0.249×10^{-6}	0
Constante de Saint Venant J [m^4]	8.01×10^{-9}	38.2×10^{-9}	0
Modulo de elasticidade E [Pa]	2×10^{11}	2×10^{11}	2×10^{11}
Massa por comprimento ρ [kg/m]	8.89	11.0	1.11

Tab. 5.2: Padrões de dano definidos para o *benchmark* ASCE.

Padrão	Descrição
1	Todos os braços do 1.º andar são removidos.
2	Todos os braços do 1.º e do 3.º andar são removidos.
3	Um braço removido no 1.º andar.
4	Um braço removido no 1.º e no 3.º andar.

inicialmente 16 sinais de aceleração contendo variabilidade de excitação e ambiente. A simulação dos dados é obtida usando-se um programa Matlab que utiliza um modelo de elementos finitos com 120 graus de liberdade. Detalhes deste programa são encontrados em [35]. Este programa tem código livre e pode ser obtido no site <http://wusceel.cive.wustl.edu/asce.shm/default.htm>.

Foram avaliados diversos cenários. Em cada um deles se considerou 16 medidas de aceleração, duas em cada direção, x e y , por nó. Na figura 5.1 são mostradas apenas as posições onde são tomadas as medidas de acelerações na direção y ¹. Para fins de simulação, a variabilidade é obtida pela variação da porcentagem RMS de ruído aleatório gaussiano adicionado nas respostas de aceleração.

As excitações são aplicadas em cada um dos andares do benchmark, ver figura 5.1, e são geradas como sendo ruído branco com distribuição de probabilidade gaussiana. Esta excitação é processada por um filtro passa-baixa Butterworth de 6.^a ordem com frequência de corte de 100 Hz. Na figura 5.1 as excitações são indicadas por w_i . A geração dos dados considerou uma taxa de amostragem de 512 Hz e 1024 amostras.

A tabela 5.3 mostra os 5 conjuntos de dados usados para obtenção do modelo de predição linear de um passo à frente AR-ARX. Todos estes dados são obtidos com uma condição estrutural conhecida (sem dano) e em condições ambientais e operacionais diversas e desconhecidas. É importante ressaltar que por se tratar de uma simulação conhecem-se quais são as condições operacionais e ambientais

¹Estas posições estão em vermelho na figura 5.1

Tab. 5.3: Conjunto de dados sem dano (referência) para a estrutura ASCE.

Caso	Padrão	Amplitude [N]	Ruído RMS (%)
1	Sem dano	150	10
2	Sem dano	200	15
3	Sem dano	120	20
4	Sem dano	180	25
5	Sem dano	230	30

em que o ensaio é gerado. Porém, estas informações não são utilizadas na implementação do método. Este é um cenário próximo ao que se encontraria na prática.

O conjunto de dados da tabela 5.3 é definido como sendo a base de dados de referência. Quanto mais geral for este conjunto de dados e maior o número de testes na condição estrutural conhecida, melhor será o procedimento de diagnóstico.

A tabela 5.4 descreve 15 casos que foram considerados estarem em condições desconhecidas (casos sem dano ou com dano). Os conjuntos de dados 6, 7 e 8 não foram utilizados para construção do modelo de predição. Estes dados foram considerados em condições desconhecidas para testes de falso-positivo.

Um sinal típico de resposta de aceleração para o caso 1 é apresentado na figura² 5.2 (um dos 16 possíveis pontos de medida). Na figura 5.3 é apresentado um sinal no caso 12 (com dano – padrão 2). Todos os sinais são normalizados a priori pelo uso da equação 3.1.

Em seguida a matriz de covariância das medidas para cada um dos casos é estimada e o problema de auto-valor como descrito na seção 3.1.2, é solucionado. Através da Eq. (3.4) projeta-se todos os 16 sinais no 1.º componente principal (maior autovalor) obtendo um único vetor com 1024 amostras que

²A maioria das figuras desta tese estão com a legenda em inglês, uma vez que foram usadas na confecção de artigos para periódicos internacionais.

Tab. 5.4: Conjunto de dados em condição estrutural desconhecida para a estrutura ASCE.

Caso	Padrão	Amplitude [N]	Ruído RMS (%)
6	Sem dano	200	25
7	Sem dano	100	15
8	Sem dano	150	20
9	Com dano 1	150	10
10	Com dano 1	200	20
11	Com dano 1	250	15
12	Com dano 2	200	15
13	Com dano 2	150	10
14	Com dano 2	250	15
15	Com dano 3	200	10
16	Com dano 3	150	20
17	Com dano 3	250	15
18	Com dano 4	150	20
19	Com dano 4	200	15
20	Com dano 4	250	15

é considerado ser representativo das informações contida na matriz de covariância influenciada pelas variações estruturais. A figura 5.4 mostra a porcentagem de variância dos autovalores da matriz de covariância para o caso 1, onde se observa que cerca de 27% da informação dos dados está contida no 1.º componente principal. Caso os dados tivessem sido projetados nos dois primeiros componentes principais, teríamos dois vetores e, portanto, dois modelos AR-ARX deveriam ser usados e neste caso cerca de 35% da informação estaria contida nestes dois modelos. As figuras 5.5 e 5.6 mostram os sinais comprimidos para os casos 1 e 12 para ilustração da PCA.

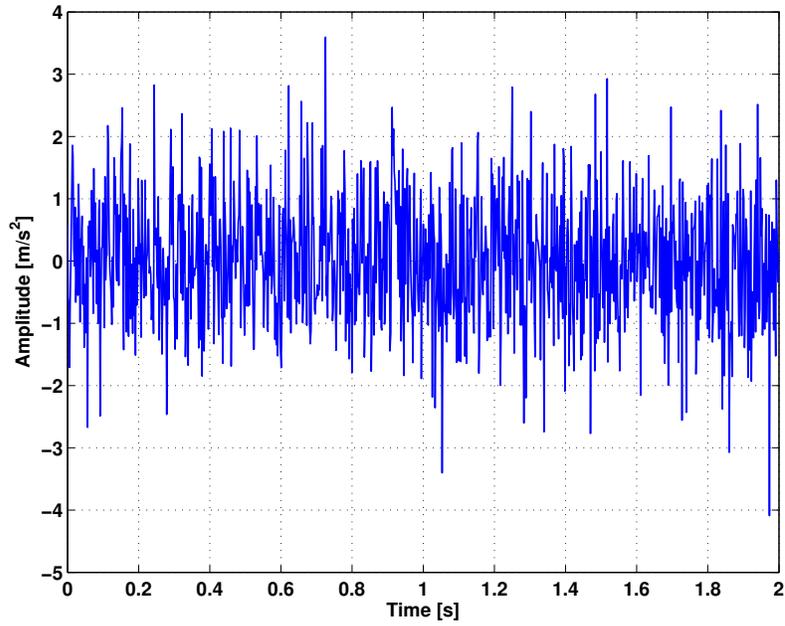


Fig. 5.2: Resposta temporal representativa para o caso sem dano (Caso 1).

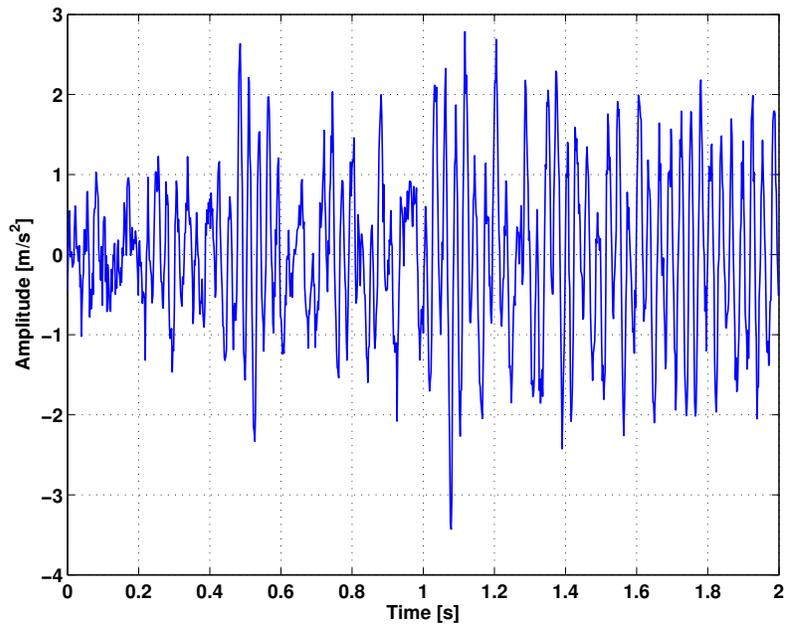


Fig. 5.3: Resposta temporal representativa para o caso com dano (Caso 12).

Uma questão central é a escolha de quantos componentes usar nesta projeção. Uma vez que os componentes principais, também conhecidos como modos próprios ortogonais (POD), estão direta-

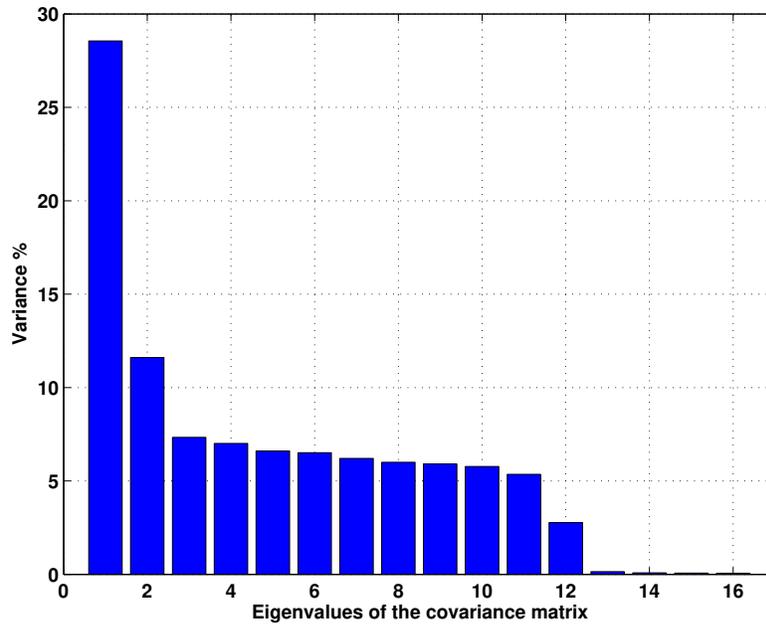


Fig. 5.4: PCA da matriz de covariância com 16 sinais de aceleração para o caso 1.

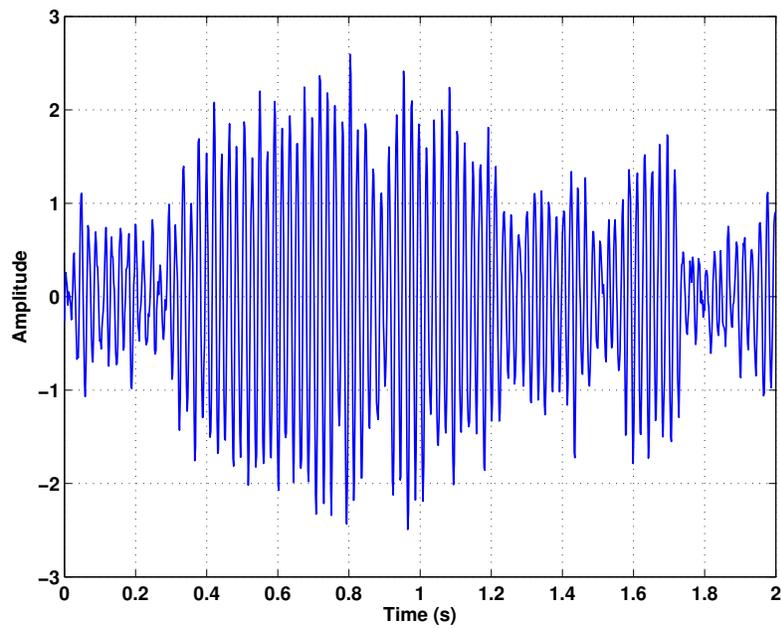


Fig. 5.5: Resposta temporal projetada no 1.º PC para o caso sem dano (Caso 1).

mente relacionados com os modos físicos de uma estrutura [41], este número irá depender de qual tipo e intensidade de dano que se irá monitorar.

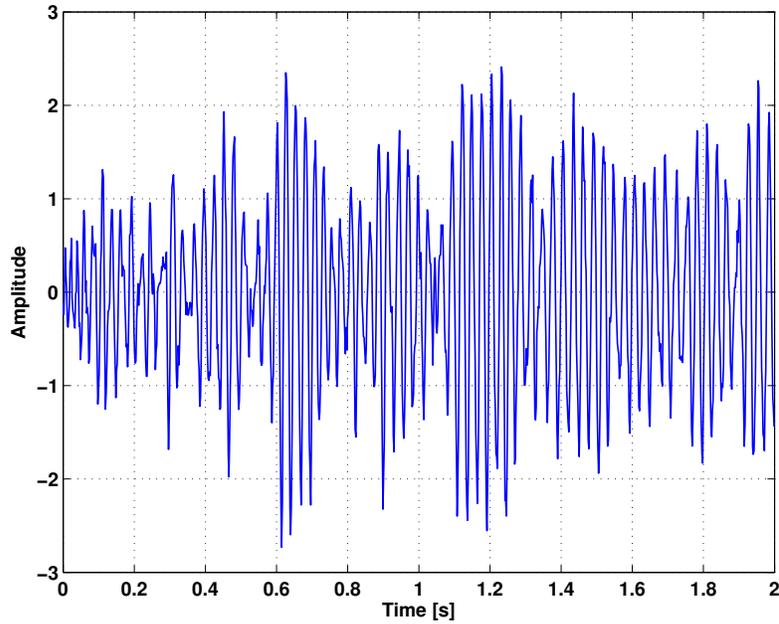


Fig. 5.6: Resposta temporal projetada no 1.º PC para o caso com dano (Caso 12).

Por exemplo, caso o dano influencie um modo local de alta frequência (e. g. um dano muito incipiente), mesmo se escolhendo os quatro primeiros componentes, dificilmente se iria diagnosticar alguma coisa com esta metodologia. Admite-se neste exemplo que os danos definidos na tabela 5.2 são todos drásticos³ e que influenciam muito mais os modos globais de baixa frequência da estrutura. É importante ressaltar que isto é uma hipótese. Uma discussão sobre este ponto é apresentada no trabalho [75]. Por esta razão somente o 1.º PC é utilizado.

A próxima etapa é definir uma ordem ótima para o modelo AR a ser obtido. Para isto os cinco dados comprimidos são ajustados por modelos AR com ordem variando de 1 até 30 e avaliando através do critério de informações de Akaike (AIC). A figura 5.7 mostra o valor do AIC em função das ordens analisadas.

Foram utilizados apenas os dados correspondentes à estrutura sem dano, dados da tabela 5.3. A

³Estes danos são provocados por grandes variações nas características dinâmicas do sistema e são em geral provocados por variações acentuadas nas matrizes de rigidez e amortecimento, influenciando essencialmente os modos de baixa frequência.

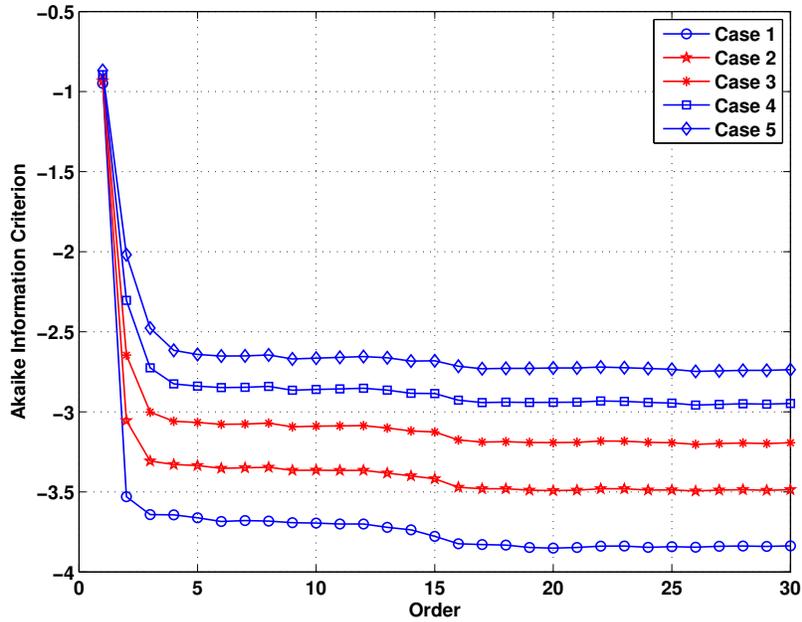


Fig. 5.7: Valor do AIC para várias ordens para os casos sem dano.

partir desta figura escolheu-se ordem igual a 13, que corresponde a um valor próximo ao mínimo encontrado em todos os 5 casos.

Os coeficientes para o polinômio $A_{x_i}(q)$ com ordem $p = 13$ foram obtidos para os casos apresentados na tabela 5.3 (sem dano) através da solução das equações de Yule-Walker. Foram considerados apenas a 1.º metade dos dados (512 pontos) para obtenção do modelo AR(13); a 2.º metade foi usada para validação do modelo.

Cada modelo foi comparado com um modelo de predição de um passo-à-frente e com a saída medida. O resultado para o caso 5 é mostrado na figura 5.8. A figura 5.9 mostra os teste para os resíduos associados com este modelo. A análise de resíduos mostra que a correlação entre a saída do modelo $x_5(k)$ e o erro residual $e_{x_5}(k)$ permanece dentro do intervalo de confiança (99%), exceto no atraso 0. Portanto, o erro de predição é próximo a um processo do tipo ruído branco. Os outros casos são muito similares com ajuste de aproximadamente 75%. Sendo assim, este conjunto de modelos na condição sem dano pode ser considerado validado.

O erro residual $e_{x_i}(k)$, $i = 1, 2, \dots, 5$ foi obtido pela Eq. (3.5) e é mostrado na figura 5.10. Estes

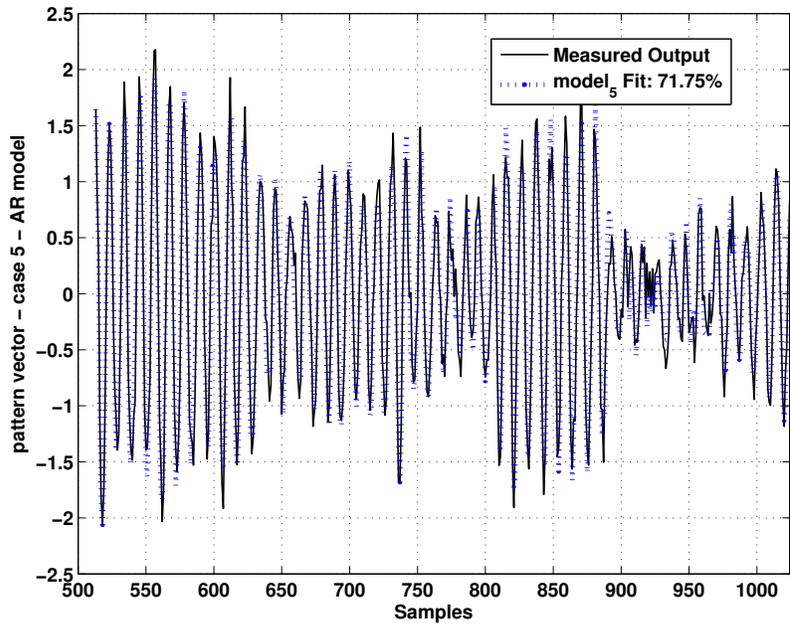


Fig. 5.8: Saída medida e saída do modelo AR(13) para o caso 5 (sem dano).

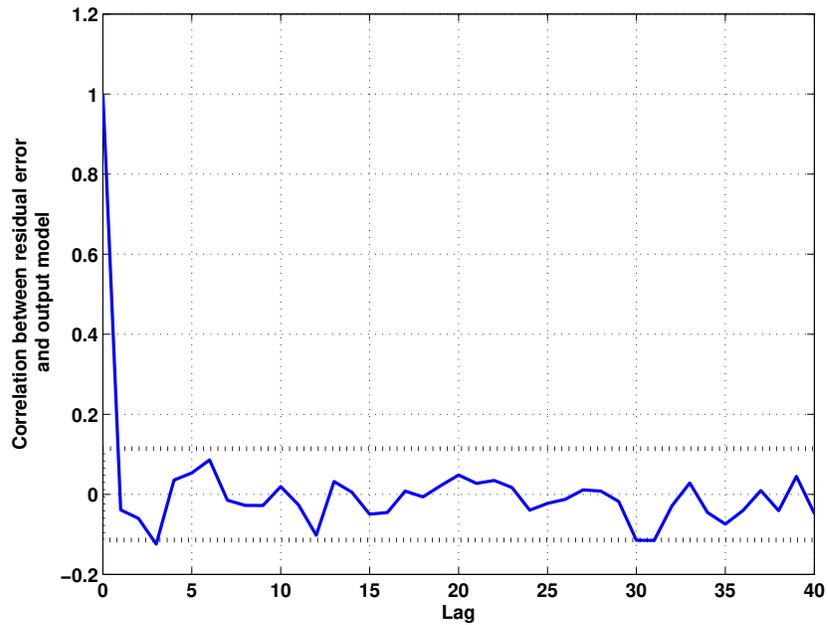


Fig. 5.9: Função de correlação cruzada do resíduo do modelo AR(13) para o caso 5.

sinais são utilizados como “entradas” de um modelo ARX com ordem ajustada arbitrariamente de

$n_a = 5$, $n_b = 5$ e tempo de atraso $n_k = 1$. O comprimento dos erros residuais dos modelos AR é 512 pontos.

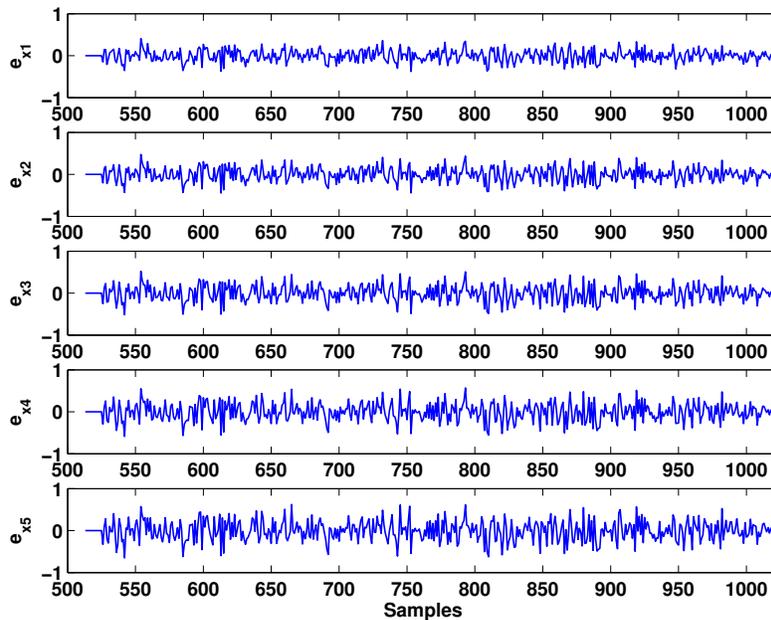


Fig. 5.10: Erro de predição de um passo-à-frente AR(13) para os casos sem dano.

Para cada sinal da tabela 5.4 (condição desconhecida) foi ajustado um modelo AR com ordem 13 e com o mesmo comprimento (512 amostras). O sinal de referência foi obtido minimizando-se a Eq. (3.11). O modelo ARX para o sinal de referência foi construído usando somente a 2.ª metade dos dados, uma vez que o sinal de “entrada” (erro residual) foi obtido usando o conjunto de dados de 513 até 1024.

Depois da construção do modelo ARX para cada sinal de referência dos 15 casos desconhecidos estudados (tabela 5.4) o modelo respectivo é utilizado para tentar prever estes sinais. Se houver um dano na estrutura, o modelo prévio ARX, obtido usando o sinal de referência, não será capaz de reproduzir a série temporal na condição com dano. Uma resposta típica é vista na figura 5.11 para o caso 2 (padrão de dano 2).

Como discutido no capítulo 3, a distribuição do erro residual ARX é próxima à distribuição normal. A figura 5.12 apresenta este fato para o caso 2. Além disto, se o valor da *kurtosis* for próximo

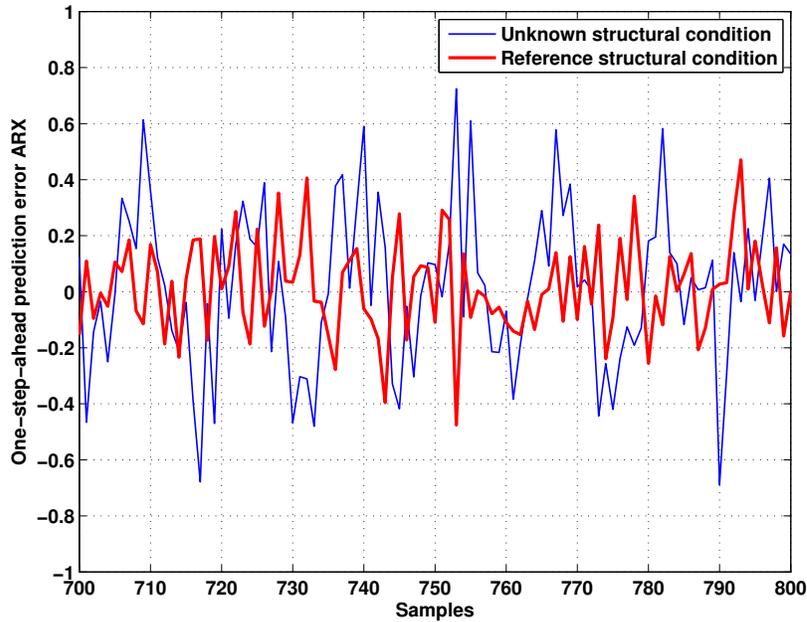


Fig. 5.11: *Zoom* na comparação entre o erro de previsão ARX entre referência e caso desconhecido.

de 3.0, indicando um pico acentuado, e do *skewness* próximo de 0, indicando que a distribuição esta sem distorções, a distribuição pode ser admitida como sendo Gaussiana. A tabela 5.5 apresenta os quatro primeiros momentos estatísticos das séries temporais $\varepsilon_y(k)$. Nesta tabela observa-se que alguns casos apresentaram *kurtosis* e *skewness* distantes dos valores para poderem continuar admitidos como sendo Gaussianos⁴. Mesmo nestas condições, continuou-se considerando a hipótese de que a distribuição era normal, para permitir se empregar as ferramentas implementadas neste trabalho.

Se existir um dano estrutural, a distribuição de probabilidade mudará, como visto na figura 5.13. A tabela 5.6 mostra o desvio padrão e o erro residual para os vários casos e também a razão γ calculada pela equação 4.1. Nesta tabela os valores em negrito aumentaram devido à ocorrência de dano e/ou variabilidade operacional. Constata-se que é muito difícil classificar estes dados no estado sem dano ou com dano somente pela simples observação do índice γ , como feito no trabalho [78]. Com o propósito de propor um rigoroso teste estatístico, este trabalho implementou dois algoritmos diferentes de agrupamento fuzzy: o fuzzy c-means (FCM) e o algoritmo Gustafson-Kessel (GK). Os

⁴Em particular os padrões de danos 3 e 4, correspondentes aos danos simultâneos e de menor intensidade (ver tabela 5.2).

Tab. 5.5: Propriedades estatísticas básicas das séries temporais.

Caso	Média	STD	Skewness	Kurtosis
1	-0.0033	0.1398	0.0432	2.9340
2	-0.0040	0.1666	0.0526	2.9812
3	-0.0047	0.1926	0.0458	2.9933
4	-0.0053	0.2171	0.0298	2.9986
5	-0.0059	0.2405	0.0116	2.9961
6	-0.0053	0.2171	0.0298	2.9986
7	-0.0040	0.1666	0.0526	2.9812
8	-0.0047	0.1926	0.0458	2.9933
9	0.0036	0.1636	0.0834	2.9823
10	0.0058	0.2237	0.0652	3.0084
11	0.0047	0.1935	0.0809	2.9849
12	0.0009	0.2814	-0.1590	2.7619
13	0.0010	0.2529	-0.1127	2.6384
14	0.0009	0.2814	-0.1590	2.7619
15	0.0100	0.3204	0.0355	3.0430
16	0.0008	0.2552	-0.0096	2.7511
17	0.0053	0.2780	0.0247	2.8342
18	-0.0007	0.2405	-0.0030	2.7709
19	0.0053	0.2613	0.0717	2.7826
20	0.0053	0.2613	0.0717	2.7826

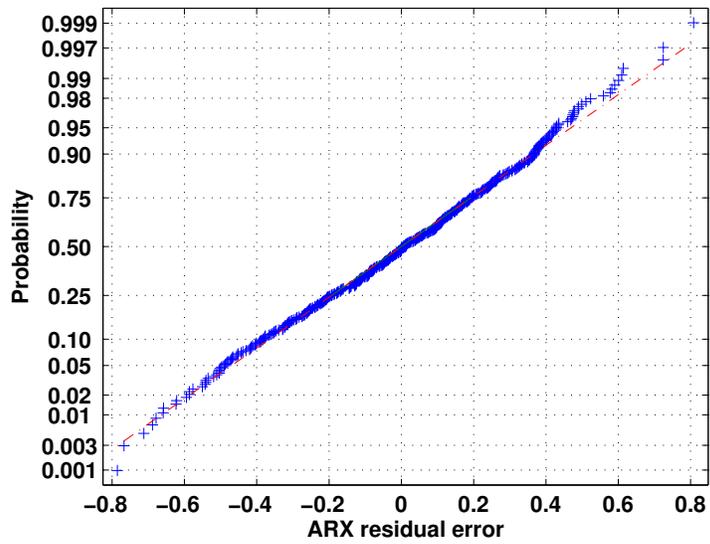


Fig. 5.12: Distribuição normal para o erro residual ARX (Caso 2).

próximos itens mostram os resultados alcançados.

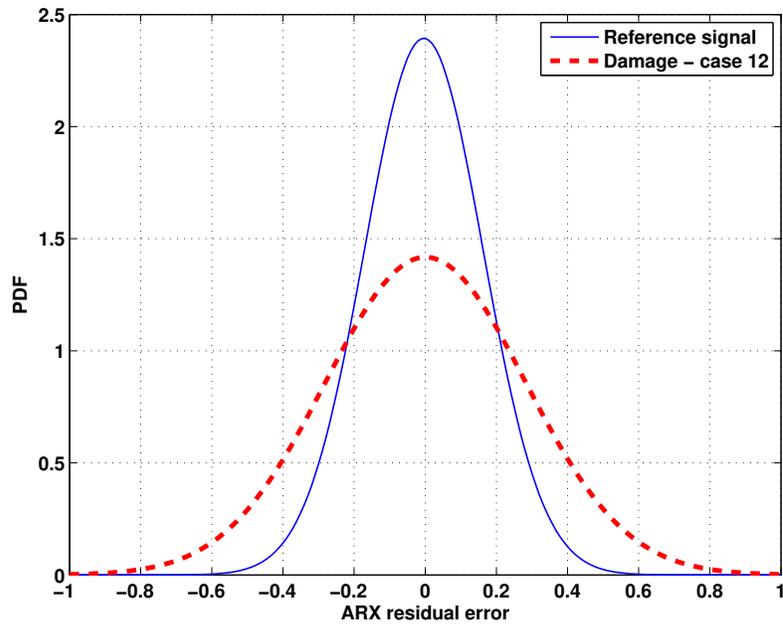


Fig. 5.13: Comparação entre as PDFs do erro residual do caso com dano e de referência.

Tab. 5.6: Desvio padrão do erro residual para várias condições estruturais.

Condição	$S(\varepsilon_{xR})$	$S(\varepsilon_y)$	γ
Sem dano (caso 1)	0.1398	0.1398	1.00
Sem dano (caso 2)	0.1666	0.1666	1.00
Sem dano (caso 3)	0.1926	0.1926	1.00
Sem dano (caso 4)	0.2171	0.2171	1.00
Sem dano (caso 5)	0.2405	0.2405	1.00
Sem dano (caso 6)	0.2171	0.2171	1.00
Sem dano (caso 7)	0.1666	0.1666	1.00
Sem dano (caso 8)	0.1926	0.1926	1.00
Com dano (padrão 1 – caso 9)	0.1398	0.1636	1.1707
Com dano (padrão 1 – caso 10)	0.2171	0.2237	1.0303
Com dano (padrão 1 – caso 11)	0.1666	0.1935	1.1610
Com dano (padrão 2 – caso 12)	0.1666	0.2814	1.6890
Com dano (padrão 2 – caso 13)	0.1398	0.2529	1.8091
Com dano (padrão 2 – caso 14)	0.1666	0.2814	1.6890
Com dano (padrão 3 – caso 15)	0.2405	0.3204	1.3320
Com dano (padrão 3 – caso 16)	0.2405	0.2552	1.0609
Com dano (padrão 3 – caso 17)	0.2405	0.2780	1.1560
Com dano (padrão 4 – caso 18)	0.2171	0.2405	1.1077
Com dano (padrão 4 – caso 19)	0.2405	0.2613	1.0864
Com dano (padrão 4 – caso 20)	0.2405	0.2613	1.0864

5.1.3 Resultados via FCM

O algoritmo FCM foi implementado para agrupamento dos dados da tabela 5.6 em 3 diferentes *clusters* associados às classificações sem dano, com dano e com dano severo. A figura 5.14 mostra o conjunto de dados a ser classificado usando $m = 2$ e $c = 3$ na Eq. (4.5).

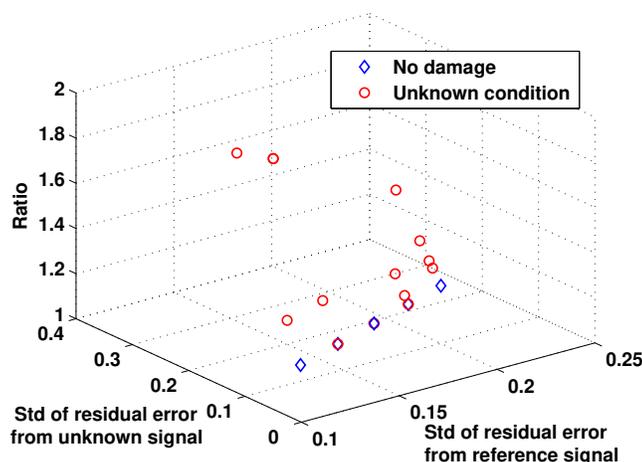


Fig. 5.14: Conjunto de dados à ser classificado.

Foram admitidos serem conhecidos os dados somente na condição sem dano. O resultado do FCM é apresentado na figura 5.15. A evolução da função de custo é vista na figura 5.16. O funcional FCM alcançou o valor mínimo depois de 6 iterações. A figura 5.17 mostra a função de pertinência da classificação de cada caso.

Analisando as figuras 5.15 e 5.17, pode-se observar que os casos 12, 13 e 14 são classificados no grupo de dano severo. Isto está correto, pois estes dados correspondem ao padrão de danos 2 (vide tabela 5.4), onde todos os braços do 1.º e do 3.º andar são removidos (vide tabela 5.2), sendo portanto um dano severo. A figura 5.17 mostra que nestes casos o valor da função de pertinência foi maior do que 95% para os casos 12,13 e 14.

Todos os casos na condição sem dano foram reconhecidos e não foi observado nenhum falso-positivo (falso alarme de dano). Porém, o caso 10 (com dano 1) não foi bem classificado. O agru-

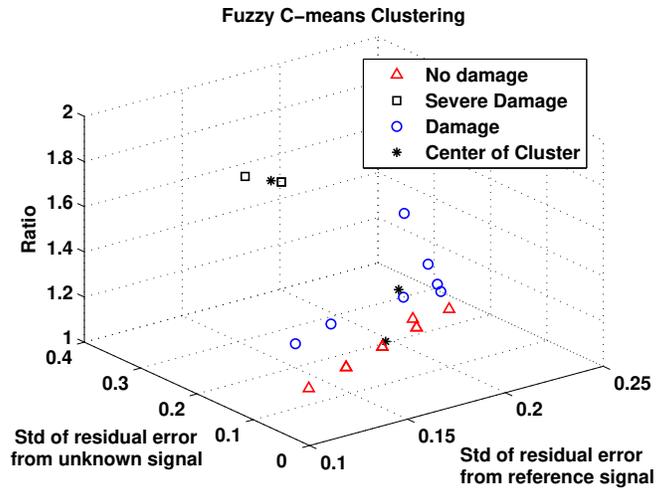


Fig. 5.15: Agrupamento fuzzy dos dados via *FCM* em três *clusters*: saudável, com dano e com dano severo.

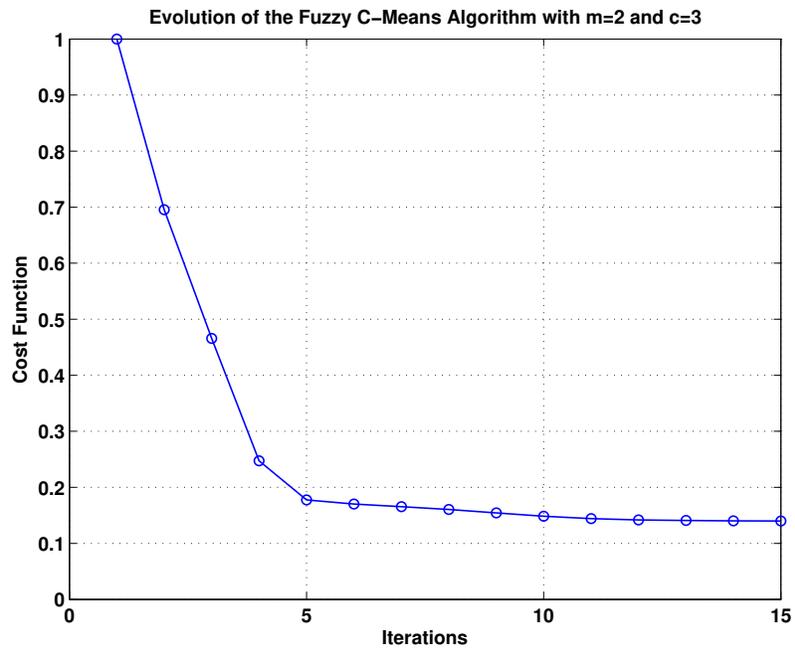


Fig. 5.16: Evolução da função objetivo do *FCM*.

pamento fuzzy indicou que este conjunto de dados está na condição sem dano, portanto ocorreu um falso-negativo na classificação. Para justificar esta classificação incorreta é importante lembrar que

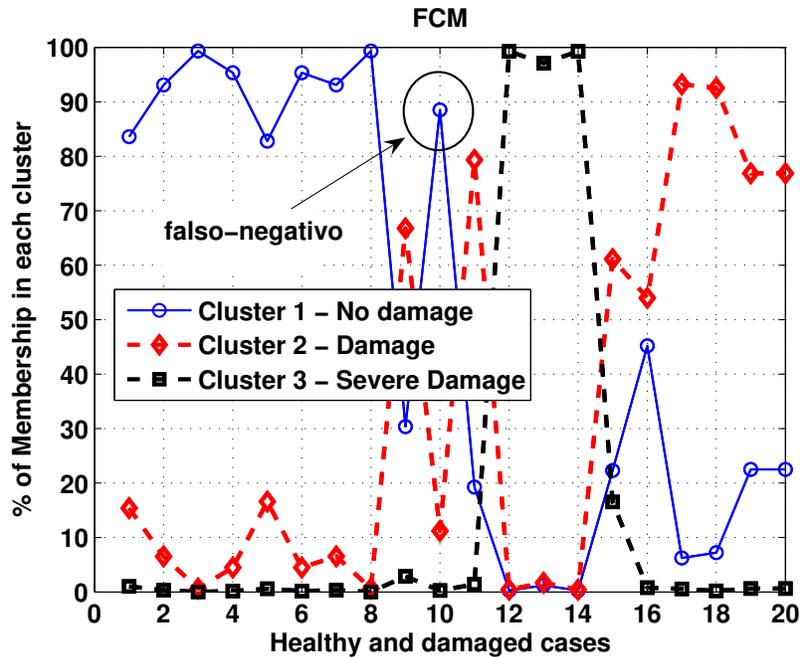


Fig. 5.17: Função de pertinência para o *FCM*.

foi utilizada compressão de dados dos 16 pontos de medidas utilizados na extração do indicador de danos.

O padrão de dano 1 (que corresponde ao caso 10) consiste da remoção de todos os braços do 1.º andar. Esta mudança afeta somente as quatro medidas feitas no 1.º andar da estrutura benchmark. Como foi conduzido um processo de PCA esta informação pode ter sido mascarada no vetor de padrões e os resultados demonstram uma classificação errada para o caso 10. Este fato é importante para destacar que o uso de PCA deve ser conduzido cuidadosamente, sobretudo quando a porcentagem da decisão é classificada próximo ao valor limiar (*threshold*). Além deste ponto, deve-se lembrar que o ajuste com a primeira etapa de estimação da parte AR do modelo conseguiu-se um ajuste de aproximadamente 75% da informação presente.

Nestes casos seria interessante tentar utilizar algumas medidas antes do processo PCA ter sido realizado para buscar ter certeza da correta classificação. Entretanto, em estruturas complexas com uma grande rede de sensores, necessidade de envio e armazenamento de dados, etc. uma grande quanti-

dade de informação seria de difícil implementação prática. Os outros casos estão bem classificados. Os casos de 15 até 20 demonstram a correta classificação dentro da classe com dano, apesar de baixa intensidade para as classificações dos casos 15 e 16, em torno de 60% e 55%, respectivamente, conforme a figura 5.17. Isto significa que não há um forte indicativo dos dados estarem contidos nestes grupos, uma vez que existem um equilíbrio entre a pertinência destas classes. É importante destacar que estes casos correspondem aos padrões de danos 3 e 4, que são variações simuladas em posições simultâneas e menos drásticas, que apresentam maiores dificuldades para detecção de danos.

5.1.4 Resultados via GK

Neste item o procedimento de classificação feito anteriormente é repetido, mas utilizando o algoritmo Gustafson-Kessel (GK). O agrupamento resultante deste método é apresentado na figura 5.18. A figura 5.19 mostra a evolução da função objetivo associada. O valor da função de pertinência para cada cluster é mostrado na figura 5.20.

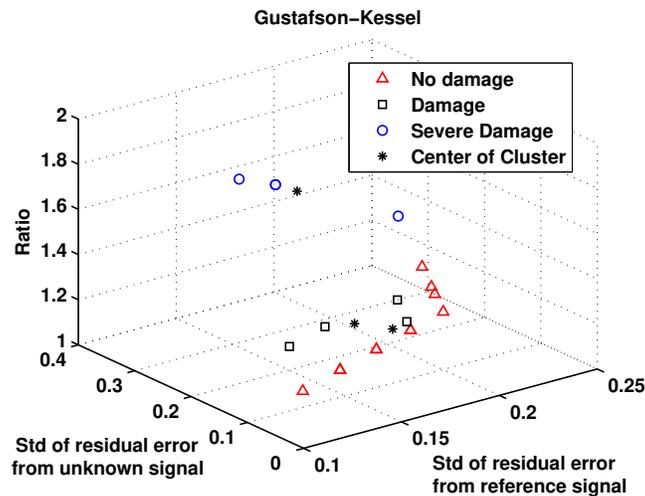


Fig. 5.18: Agrupamento fuzzy dos dados via *GK* em três *clusters*: saudável, com dano e com dano severo.

Com este método, os casos 6, 7 e 8 foram classificados corretamente no grupo sem dano e com confiança maior que 95%. O algoritmo GK agrupou melhor estes casos do que o método FCM. O

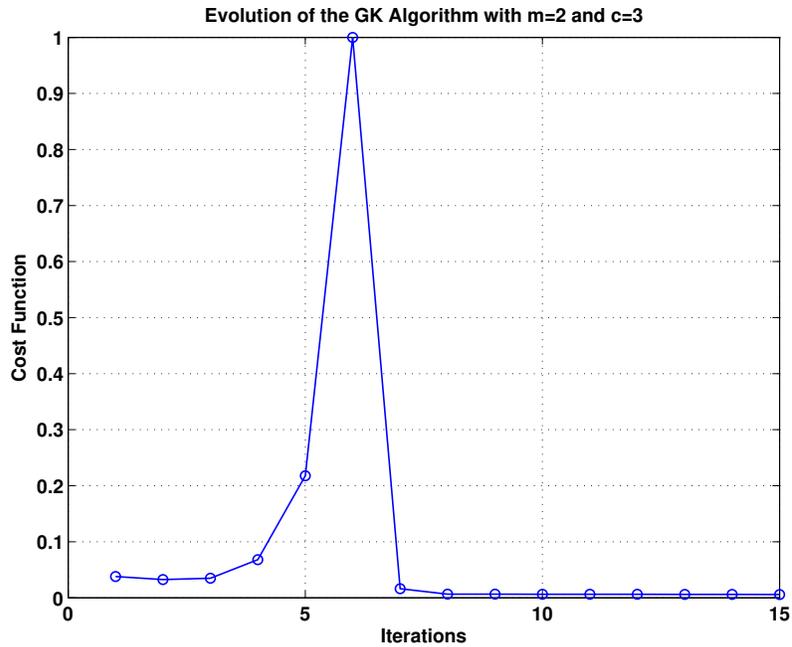


Fig. 5.19: Evolução do GK.

caso correspondente ao teste 10, que apresentou certos problemas com o método FCM, também foi agrupado com alta porcentagem na condição estrutural de dano. Isto ocorre, pois como já mencionado na teoria, o algoritmo GK induz a clusters com formatos alongados, o que podem melhorar substancialmente a classificação de dados em condições limites que não são bem classificadas via FCM. Isto é o que ocorre com os dados do caso 10 (dano 1 – retirada de todos os braços do 1.º andar, com compressão das 16 medidas de aceleração). Este alongamento no formato do cluster altera as coordenadas do centro do grupo. Comparando as figuras 5.15 e 5.18 observa-se uma pequena diferença nos centros encontrados pelo método FCM e GK, o que comprova este fato. Isto acaba conduzindo à classificação com falso-negativo do caso 15, que foi classificado no grupo de dano severo (e não na classe de dano). Apesar da classificação errada isto não é tão grave, pois em se tratando de um sistema de monitoramento real seria dado o alarme, mesmo que com intensidade errada.

Porém os casos 16, 17, 19 e 20 são agrupados erroneamente na classe sem dano, o que não é verdade, ocorrendo assim falsos-negativos, o que é algo grave e que deve ser evitado de ocorrer em sistemas SHM reais. Mais uma vez, estes casos correspondem aos padrões de dano 3 e 4 que são

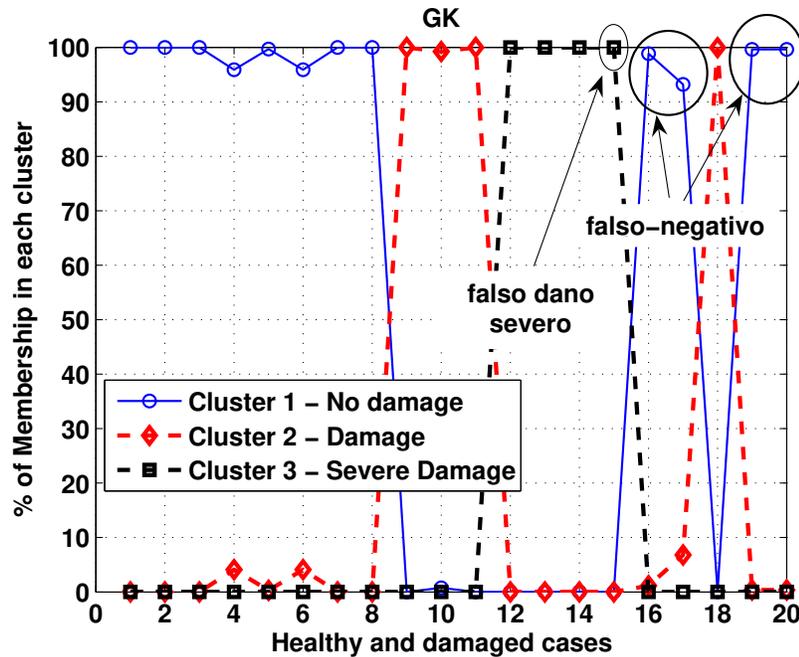


Fig. 5.20: Função de pertinência para o GK.

variações em localizações simultâneas de baixa magnitude de variação.

5.1.5 Conclusões

Os resultados apresentados neste item contêm vários pontos desejados para aplicações reais:

- Utilizar somente respostas medidas.
- Uso de um vetor de padrões simples pela aplicação de PCA.
- Procedimento conduzido em modo não supervisionado.
- Informação do nível de confiança do valor limiar devido ao uso de decisão fuzzy.

Uma forma de melhorar esta classificação seria definir mais atributos no indicador de danos, ou seja, características⁵. Outra sugestão é conduzir um treinamento supervisionado usando padrões

⁵lembrando que neste caso foram considerados apenas 3, $\sigma(e_r)$, $\sigma(e_y)$ e γ .

conhecidos. Porém, estas duas sugestões vão em sentido contrário da motivação principal deste trabalho: basear-se em poucos dados e trabalhar sem treinamento de padrões.

A idéia mais simples, a priori, seria portanto conduzir os dois métodos simultaneamente, visto a simplicidade de ambos, e comparar a classificação realizada pelo FCM e pelo GK. Uma vez que cada um deles aparenta ser melhor para classificar uma determinada condição, a informação dos dois métodos proporcionaria uma melhor detecção da possível falha na estrutura sob monitoramento. Nesta aplicação específica o FCM apresentou um número menor de falsos-negativos.

Um ponto fraco desta metodologia é a necessidade de se realizar a classificação em "batelada", ou seja, a cada número de medidas, realizar a classificação, um procedimento que pode ser caro.

5.2 Estrutura teste LANL

Esta seção mostra a aplicação das duas técnicas de agrupamento fuzzy avaliadas na seção anterior, porém com um indicador calculado a partir de erros de predição de filtros discretos do tipo ARMA. Os resultados desta seção foram publicados em um trabalho do autor em [75].

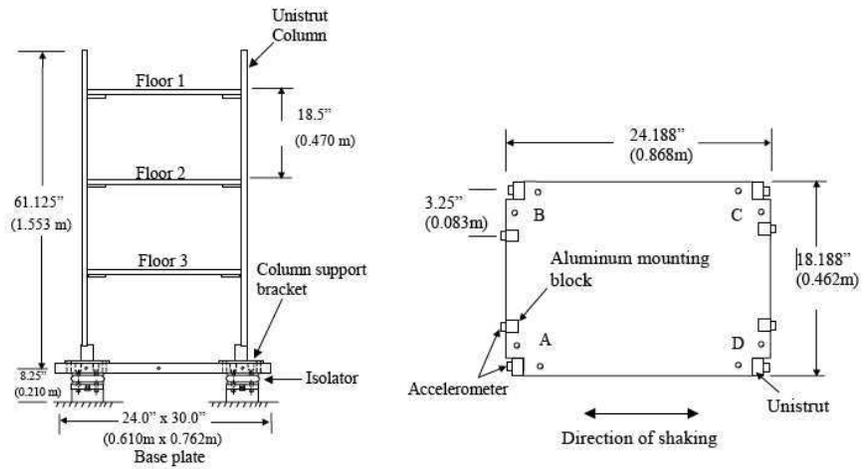
5.2.1 Descrição dos ensaios

Para verificar a metodologia usando filtros ARMA e agrupamento fuzzy, uma estrutura *frame* de três andares, mostrada na figura 5.21, é considerada. Esta estrutura foi escolhida por ser um benchmark bem definido, já construído e testado pelo *Los Alamos National Laboratory* (LANL), sendo que os dados experimentais são disponíveis no site <http://www.lanl.gov/projects/damage-id/index.htm>.

A estrutura foi construída de colunas com andares de placas de alumínio conectadas às colunas. 24 acelerômetros, dois por junta, foram montados na estrutura, oito acelerômetros são colocados em cada andar (veja figura 5.21(b)). Um excitador eletrodinâmico foi acoplado no canto D usando um *stinger* conectado à base, figura 5.21(a). Os dados foram amostrados com taxa de 1600 Hz e 8192 amostras foram capturadas em cada acelerômetro obtidas pela excitação da estrutura com um ruído branco aplicado ao excitador.



(a) Vista geral.



(b) Detalhes e dimensões.

Fig. 5.21: Estrutura benchmark LANL.

As condições de dano para esta estrutura são dadas na tabela 5.7. Observa-se que estes danos são severos. Seis diferentes cenários para o estado sem dano foram considerados como referência (casos de 1 a 6) e são vistos na tabela 5.8. As amplitudes da excitação foram ajustadas de 2 volts a 8 volts.

Tab. 5.7: Padrões de dano definidos para a estrutura LANL.

Padrão	Descrição
1	Parafusos removidos entre o suporte e a placa na posição 1C
2	Suporte completamente removido na posição 1C
3	Parafusos removidos entre o suporte e a placa na posição 3A
4	Suporte completamente removido na posição 3A

Um conjunto de 33 casos foram considerados (numerados de 7 a 39) e detalhes nas tabelas 5.9, 5.10, 5.11, 5.12 e 5.13. Estes dados consistem de 9 casos sem dano e 24 casos danificados com os padrões descritos na tabela 5.7. Para cada caso, vários níveis de excitação foram usados, também

Tab. 5.8: Conjunto de dados sem dano (referência) para a estrutura LANL.

Caso	Padrão	Amplitude [V]
1	Sem dano	2
2	Sem dano	2
3	Sem dano	5
4	Sem dano	5
5	Sem dano	8
6	Sem dano	8

descritos nestas tabelas. Pode ser notado que os casos de 7 a 15 na tabela 5.9 (dados da estrutura sem dano) não foram usados para construir o modelo ARMA. Estes casos são usados para testes de falso-positivos.

Todos os sinais foram padronizados usando a Eq. (3.1). O procedimento para redução via PCA foi então aplicado. Os componentes principais da matriz de covariância dos 24 pontos de medidas para o caso 9 (mostrado como mera ilustração) são mostrados na figura 5.22. Esta figura mostra que o primeiro componente principal contém aproximadamente 58% da informação total dos dados. Os outros casos sem dano apresentaram análise similar. Assim, as séries temporais de todos os pontos são projetadas no 1.º componente principal. O mesmo comentário feito no exemplo da estrutura ASCE, vale neste ponto: o número de componentes usados nesta projeção depende diretamente da característica do dano que se deseja monitorar, como já explicado anteriormente.

O procedimento para selecionar a ordem usando o critério AIC indicou que $p = 26$ é uma ordem apropriada para o polinômio AR e $q = 2$ é uma boa ordem para a parte MA do polinômio $C(z)$, como discutido na seção 3.5. Somente os dados da estrutura sem dano (casos 1 até 6), na tabela 5.8 foram usados para estimar esta ordem.

A figura 5.23 mostra o gráfico do AIC para o caso 1 em função da variação das ordens p e

Tab. 5.9: Conjunto de dados desconhecidos para a estrutura LANL (Dados sem danos).

Caso	Amplitude [V]
7	2
8	2
9	2
10	5
11	5
12	5
13	8
14	8
15	8

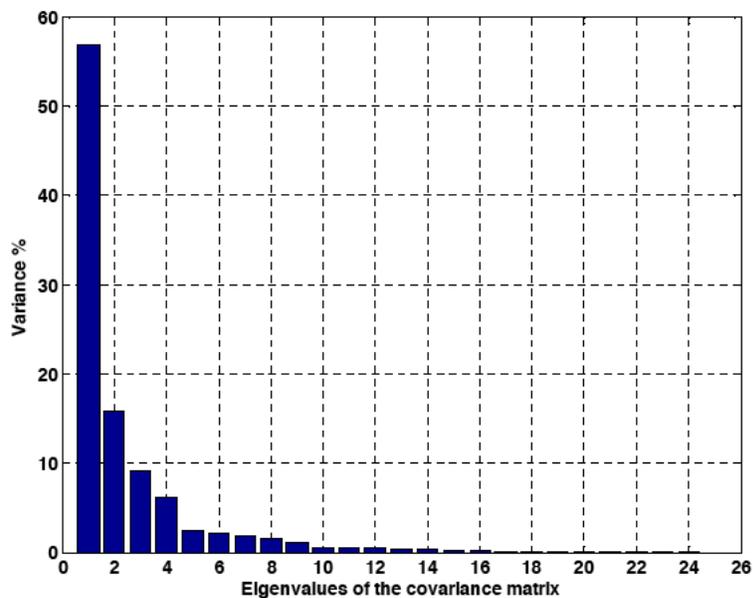


Fig. 5.22: PCA da matriz de covariância com 24 sinais de aceleração para o caso 9.

Tab. 5.10: Conjunto de dados desconhecidos para a estrutura LANL (Dados com dano 1).

Caso	Amplitude [V]
16	2
17	2
18	5
19	5
20	8
21	8

q . A primeira metade dos dados foi usada para determinar a ordem do modelo ARMA usado para fazer a predição. Silva et al. [70] compararam as diferentes ordens de modelos ARMA usadas e demonstraram que os resultados são altamente afetados por esta seleção.

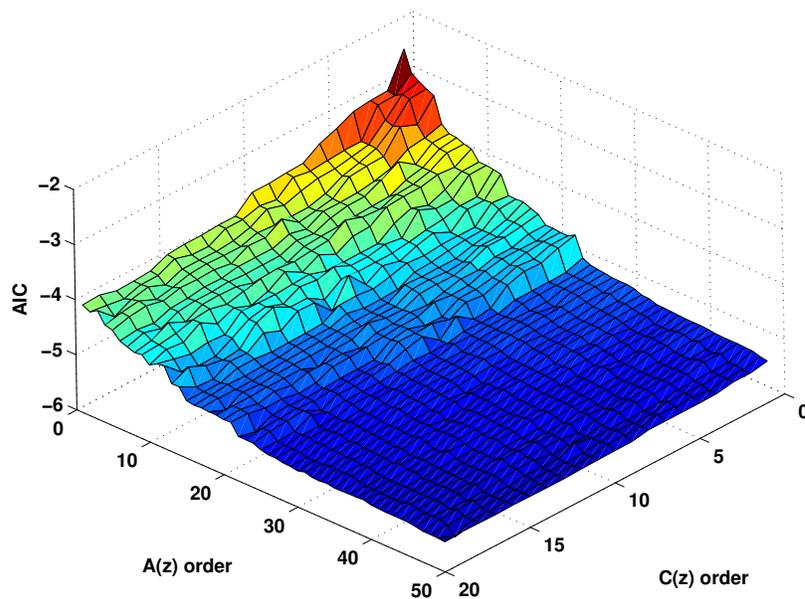


Fig. 5.23: Seleção da ordem do filtro ARMA usando o AIC para o caso 1.

Tab. 5.11: Conjunto de dados desconhecidos para a estrutura LANL (Dados com dano 2).

Caso	Amplitude [V]
22	2
23	2
24	5
25	5
26	8
27	8

Cada sinal nas condições conhecidas (tabela 5.8) foi ajustado com um modelo ARMA(26,2) e com o mesmo número de pontos. Estes modelos foram comparados com a saída de predição de um passo à frente e com a saída medida. Os resultados para o caso 6 são apresentados para ilustração na figura 5.24. Os outros casos são similares com ajuste em torno de 90%. Portanto, este conjunto de dados pode ser considerado validado.

Depois da construção do modelo ARMA para cada sinal de referência dos 6 casos conhecidos (tabela 5.8) estes respectivos modelos ARMA foram usados para predizer os sinais dos casos desconhecidos (tabelas 5.9, 5.10, 5.11, 5.12 e 5.13). Se algum dano está presente na estrutura, os modelos ARMA de referência não serão capazes de reproduzir as séries temporais das condições desconhecidas.

Quando um dano está presente na estrutura, a função densidade de distribuição de probabilidade (PDF) do erro de predição muda de forma considerável. A figura 5.25 ilustra este caso pela comparação entre a PDF do erro residual do caso 25 com o seu respectivo caso de referência, neste exemplo o caso 6.

Os desvios padrões dos erros residuais para várias fontes de danos e a razão γ dada pela Eq. (4.1) são então calculados. Um valor grande de γ é provavelmente causado por um dano ou variação

Tab. 5.12: Conjunto de dados desconhecidos para a estrutura LANL (Dados com dano 3).

Caso	Amplitude [V]
28	2
29	2
30	5
31	5
32	8
33	8

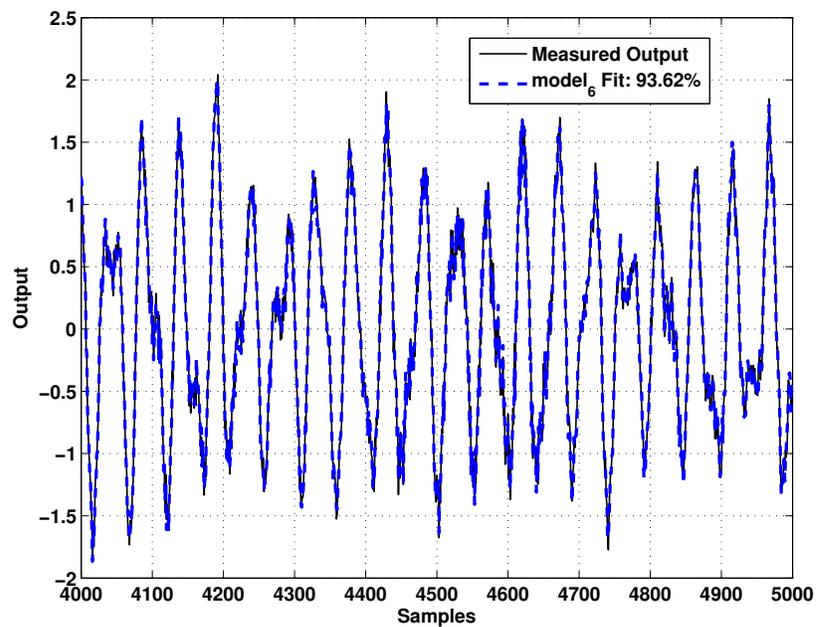


Fig. 5.24: Detalhe da saída medida e da saída do modelo de previsão para o caso 6 (dados sem dano), com todas as medidas projetadas no 1.º componente principal com um modelo ARMA.

operacional brusca. Para classificar estes dados em dois grandes grupos: sem dano e com dano, os algoritmos FCM e GK são usados e comparados na próxima seção.

Tab. 5.13: Conjunto de dados desconhecidos para a estrutura LANL (Dados com dano 4).

Caso	Amplitude [V]
34	2
35	2
36	5
37	5
38	8
39	8

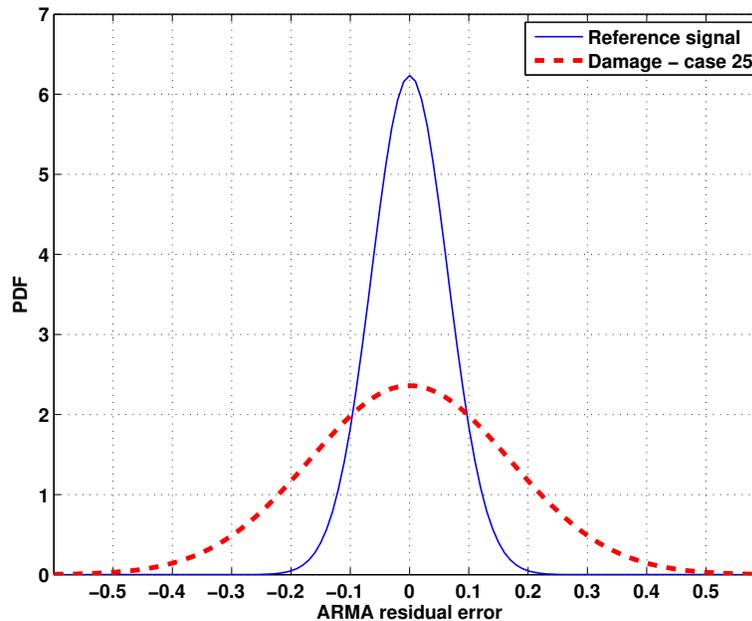
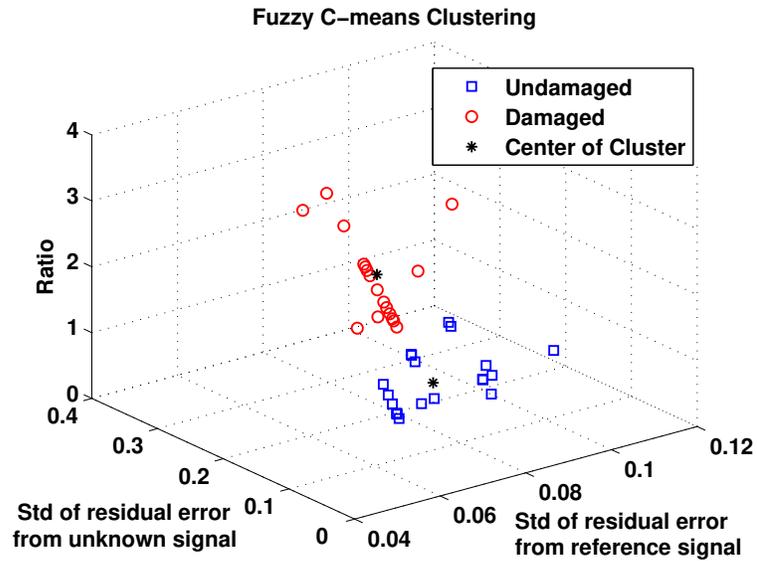


Fig. 5.25: Comparação entre as PDFs do erro residual do caso 25 (com dano) e do sinal de referência (caso 6) para a estrutura LANL.

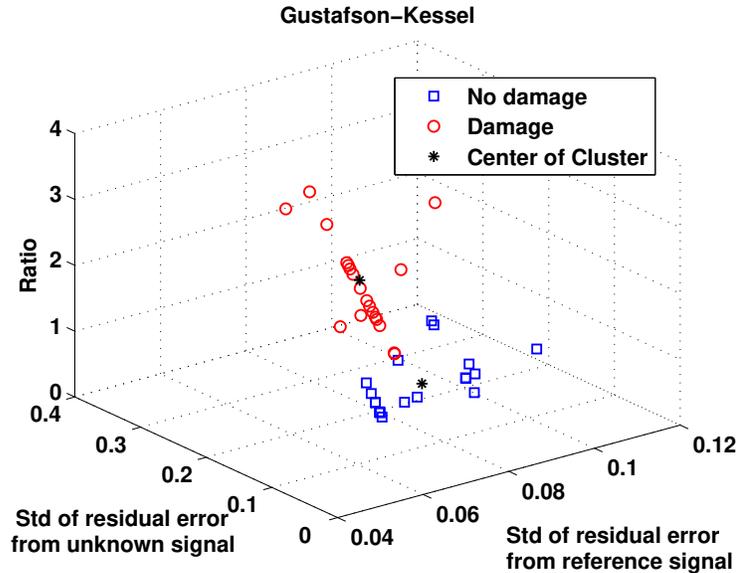
5.2.2 Resultados via FCM e GK

O número de *clusters* usados em ambos os algoritmos é $c = 2$ e $m = 2$, associados com as condições sem dano e com dano. Os resultados usando a classificação FCM são apresentados na

figura 5.26(a) , e a evolução da função custo é mostrada na figura 5.27(a) . Pode ser visto que a função custo atinge o valor mínimo após 6 iterações. A figura 5.28(a) mostra a porcentagem da função de pertinência para cada amostra usando o algoritmo FCM.

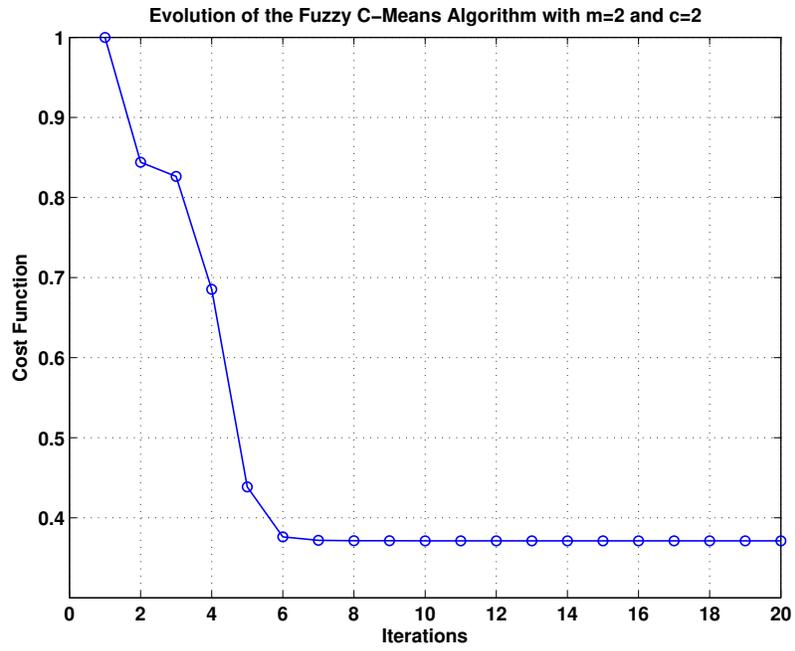


(a) resultado via FCM.

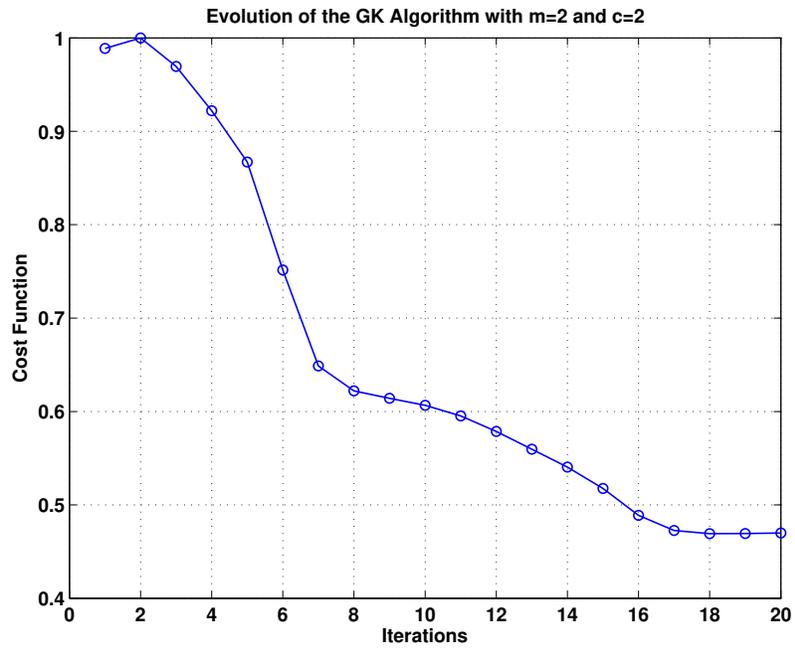


(b) Resultado via GK.

Fig. 5.26: Agrupamento fuzzy dos dados via FCM e GK com $m = 2$ and $c = 2$.

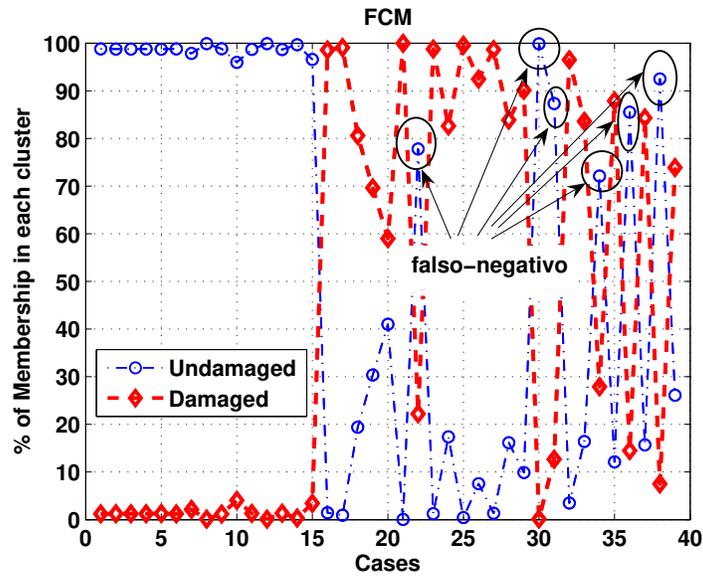


(a) Resultado via FCM.

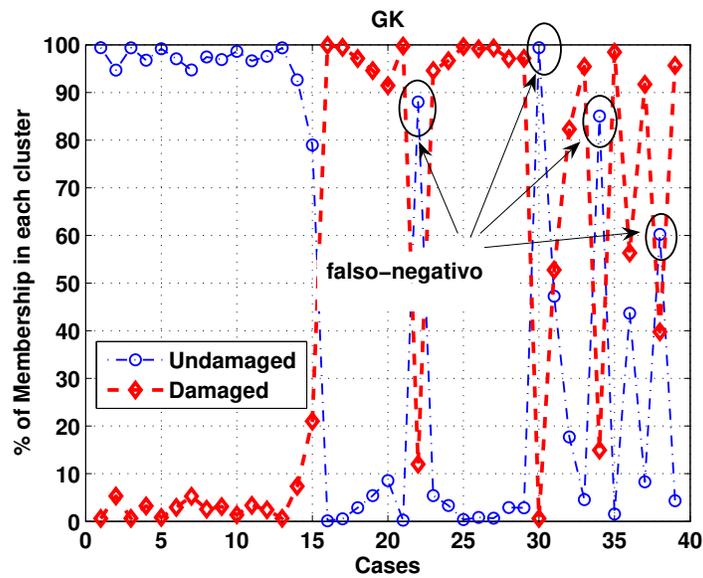


(b) Resultado via GK.

Fig. 5.27: Evolução da função objetivo do agrupamento FCM e GK.



(a) Resultado via FCM.



(b) Resultado via GK.

Fig. 5.28: Função de pertinência para o agrupamento FCM e GK.

A figura 5.26(b) mostra o agrupamento calculado usando o algoritmo GK. A função custo correspondente é mostrada na figura 5.27(b), onde se pode observar que o valor mínimo é alcançado após 15 iterações. A porcentagem de cada amostra em cada cluster pode ser vista na figura 5.28(b).

Das figuras 5.26(a) e 5.26(b) pode ser constatado que todos os casos sem dano foram bem categorizados usando ambos os algoritmos. Nenhum falso positivo foi observado, entretanto a confiança mínima desta decisão foi somente 80% no caso 15 do algoritmo GK. Todos os outros casos tiveram confiança próxima de 100%.

Para os casos com dano, o algoritmo GK foi geralmente superior, apresentando 90% de decisões corretas, com falsos-negativos nos casos 22, 30, 34 e 38. Para o algoritmo FCM houve 85% de decisões corretas, com falsos-negativos nos casos 22, 30, 31, 34, 36 e 38. Além disto, nos casos 16 a 21, correspondendo a condição com dano 1, o algoritmo GK apresentou um nível de classificação na classe de dano com chance maior do que 90%, enquanto com o algoritmo FCM este nível variou de quase 100% nos casos 16 e 17 até aproximadamente 60% no caso 20. Nos casos 24, 26, 28 e 39 o algoritmo FCM resultou em um menor nível de decisão na classe com dano do que o algoritmo GK, como pode ser visto nas figuras 5.28(a) e 5.28(b).

5.2.3 Conclusões

Esta seção descreveu os resultados da formulação via modelos ARMA e aplicação de algoritmos de agrupamento fuzzy do tipo fuzzy c-means (FCM) e Gustafsson-Kessel (GK). Para ilustrar os resultados, testes em uma estrutura *benchmark* do Los Alamos National Laboratory (LANL) foi usada. Algumas considerações são feitas:

- Assim como os resultados da seção anterior (estrutura ASCE) a formulação foi baseado apenas em medidas das respostas do sistema em estado intacto e não exige um modelo matemático da estrutura.
- Neste exemplo em vez de se utilizar modelos AR-ARX, se empregou modelos do tipo ARMA.
- Para acelerar o procedimento, a formulação envolveu primeiro a redução de múltiplas séries temporais em um simples vetor, via projeção de componentes principais.
- Comparando as saídas do modelo ARMA usando um agrupamento fuzzy, a condição da saúde da estrutura pode ser bem estimada.

- Para os dados estudados, o algoritmo GK mostrou-se ligeiramente melhor do que o algoritmo FCM devido a forma que ele pode permitir ao cluster. Porém, não é possível generalizar esta conclusão para todas as aplicações SHM.
- O número de falsos-negativos no algoritmo GK também foi pouco inferior quando comparado com o algoritmo FCM.

5.3 Rotor estacionário

A análise e monitoramento de máquinas rotativas em ambiente industrial é importante devido a inúmeras razões, muitas delas relacionadas com custo e competitividade das empresas. Portanto, o monitoramento e a manutenção deste tipo de equipamento é uma parte crucial em qualquer planta industrial.

Várias técnicas padrões adotadas usam valores RMS, e. g. a normas DIN 45666, e/ou valores *overall* de vibração, e.g. normas ISO 10816 ou ainda NBR 10082. Infelizmente, em alguns casos, estes índices são contaminados por inevitáveis erros ou efeitos dinâmicos. Para contornar estes aspectos, a análise espectral pode ser feita, porém os resultados são altamente dependentes de experiência humana [49].

Um conjunto mais elaborado de métodos para detecção de danos em máquinas rotativas, usa modelos matemáticos, que podem ser gerados numericamente, usando FEM e/ou análise modal experimental. Baseados nestes modelos, diferentes estratégias são descritas na literatura para identificar um dano, e. g., análise de correlação [24], ajuste de modelo via métodos de otimização [12], observadores de estados [48], etc. Porém, é interessante notar que formulações baseadas em modelos matemáticos são geralmente caras em termos numéricos e exigem um modelo matemático muito acurado do rotor em questão.

A presente seção mostra resultados do monitoramento de um rotor vertical excitado por forças de desbalanceamento e excitações estocásticas. A detecção do dano, simulado numericamente como variação de rigidez, amortecimento ou desbalanceamento, é feita a partir de erros de predição de mo-

delos AR-ARX construídos como base em medidas de deslocamentos nos mancais. Para classificar estes erros, o controle estatístico de processos é empregado.

Os resultados apresentados a seguir foram publicados em um trabalho do autor em [69].

5.3.1 Descrição do teste

Os testes foram feitos com base em simulação numérica de um rotor com 6 graus de liberdade operando em condição estacionária. Um desenho esquemático deste rotor é apresentado na figura 5.29.

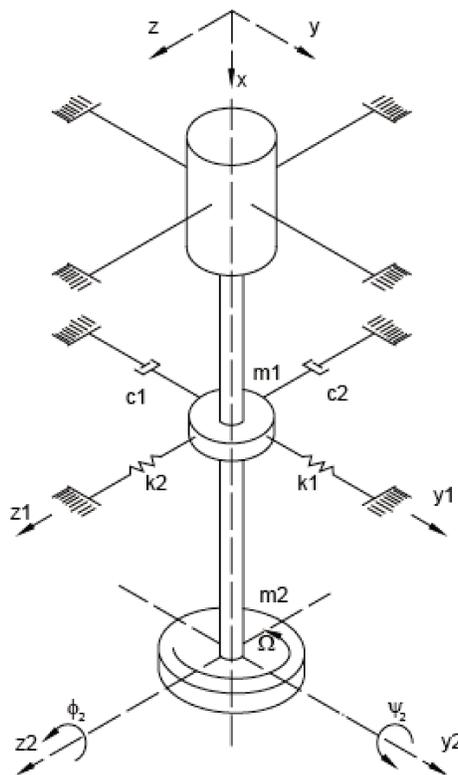


Fig. 5.29: Rotor com seis graus de liberdade.

Este sistema rotativo já foi utilizado no trabalho [24] e detalhes sobre as equações do movimento podem ser encontradas no referido trabalho. No presente texto, este modelo foi usado para obter a

vibração em regime estacionário resultante em vários pontos do rotor quando sujeito às forças de desbalanceamento e excitações estocásticas (aplicada na coordenada y_1). As propriedades geométricas e físicas do rotor são apresentadas na tabela 5.14 enquanto a tabela 5.15 mostra os cinco padrões de danos considerados para o sistema, os mesmo usados no trabalho [24].

Tab. 5.14: Propriedades do rotor.

Propriedades	Valor
m_1 : massa do mancal [kg]	15
m_2 : massa do disco [kg]	10
I_2 : momento transversal de inércia [kg.m ²]	0.25
I_{2p} : momento polar de inércia [kg.m ²]	0.5
L : comprimento do rotor [m]	0.8
k_1 : rigidez do mancal na direção y [N/m]	90×10^3
k_2 : rigidez do mancal na direção z [N/m]	120×10^3
c_1 : amortecimento do mancal na direção y [kg/s]	30×10^3
c_2 : amortecimento do manca na direção z [kg/s]	30.75×10^3
Ω : rotação constante [rad/s]	60
e : desbalanceamento [m]	1×10^{-5}

Cinco cenários diferentes sem dano foram considerados como base de referência, cada um obtido por uma variação na condição operacional (porcentagem de ruído adicionado e nível de amplitude do sinal aleatório de excitação). A lista destes 5 cenários é mostrada na tabela 5.16. A tabela 5.17 descreve as condições desconhecidas, que podem corresponder à medidas do sistema saudável ou danificado. Na tabela 5.17 os casos 6, 7 e 8 são usados para verificação de falsos-positivos.

Tab. 5.15: Padrões de danos para o rotor.

Dano	Descrição
1	Redução de 20% em k_1
2	Redução de 30% em k_1 e c_1
3	Redução de 20% em k_2
4	Redução de 30% em k_1
5	Variação de 20% no desbalanceamento do disco

Tab. 5.16: Dados de referência para o sistema rotativo.

Caso	Padrão	Amplitude [N]	Ruído RMS (%)
1	Sem dano	5	10
2	Sem dano	10	10
3	Sem dano	10	5
4	Sem dano	15	10
5	Sem dano	18	10

5.3.2 Resultados via SPC

As respostas do rotor foram obtidas por integração numérica da equação do movimento usando uma taxa de amostragem de 1000 amostras/s em um tempo de 10 segundos. A primeira metade dos pontos (5000 amostras) foi usada para obter um modelo AR(13), enquanto a segunda metade é usada para validar o modelo. Esta ordem foi encontrada após uma análise do critério de informações de Akaike.

O sinal de referência para cada caso desconhecido foi obtido usando-se a Eq. (3.11). O modelo ARX para o sinal de referência foi construído usando a segunda metade dos dados. Em seguida, este

Tab. 5.17: Condições desconhecidas do sistema rotativo.

Caso	Padrão	Amplitude [N]	Ruído RMS (%)
6	Sem dano	8	10
7	Sem dano	12	15
8	Sem dano	20	20
9	Com dano 1	10	5
10	Com dano 1	10	10
11	Com dano 2	10	5
12	Com dano 2	10	10
13	Com dano 3	10	5
14	Com dano 3	10	10
15	Com dano 4	10	5
16	Com dano 4	10	10
17	Com dano 5	10	5
18	Com dano 5	10	10

modelo foi usado para prever os sinais obtidos em condições desconhecidas. Alguns exemplos do deslocamento na coordenada y_1 são mostrados nas figuras 5.30 e 5.31 .

A figura 5.30 mostra o erro de predição para o caso 6, onde o sinal de referência é o caso 2 (ver tabela 5.16). O erro de predição $\varepsilon_y(k)$ é arranjado em 5 grupos com 1000 amostras cada um. $Z_{\alpha/2}$ foi escolhido como sendo igual a 2.57 e corresponde a 99% de confiança. Assim, 10 amostras (=1% do total de 1000 amostras) são esperadas estarem fora dos limites de controle mesmo com o rotor não apresentando nenhum dano. Portanto, os 5 *outliers* na figura 5.30(b) não indicam um dano. Entretanto, um número significativo de *outliers* (76) aparecem na figura 5.31(b), que corresponde ao

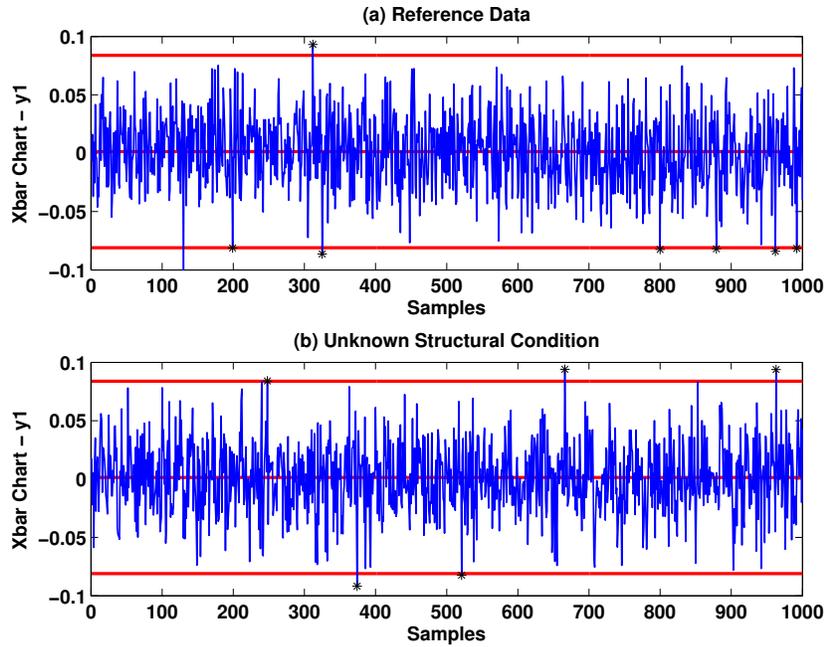


Fig. 5.30: Erro de predição AR-ARX para o caso 6 (condição desconhecida) e sua referência (caso 2). O número de *outliers* em (b) indica sistema sem dano.

caso 11 (sinal de referência: caso 1), indicando a existência de dano.

A figura 5.32 apresenta a razão γ entre o desvio padrão do erro residual dado pela Eq. (4.1) para várias fontes sem dano e com dano. Os resultados usando este procedimento, como feito em [78], não pareceu ser robusto, pois a razão γ não apresenta uma significativa mudança para dar uma clara indicação de variação estrutural. Entretanto, o controle estatístico de processos (SPC) apresenta uma detecção satisfatória, uma vez que um número grande de *outliers* são esperados estarem fora dos limites. Na figura 5.33 é mostrado o número de *outliers* das séries temporais em condições conhecidas e desconhecidas descritas por $\varepsilon_y(k)$.

5.3.3 Conclusões

Alguns comentários podem ser feitos a partir deste teste:

- A formulação demonstrou ser capaz de detectar danos em máquinas rotativas operando em

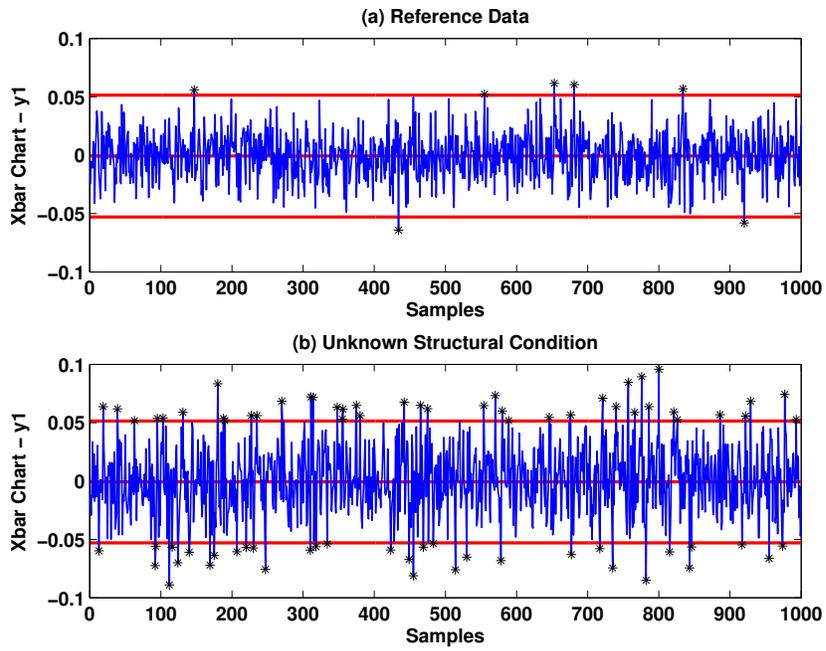


Fig. 5.31: Erro de predição AR-ARX para o caso 11 (condição desconhecida) e sua referência (caso 1). O número de *outliers* em (b) indica sistema com dano.

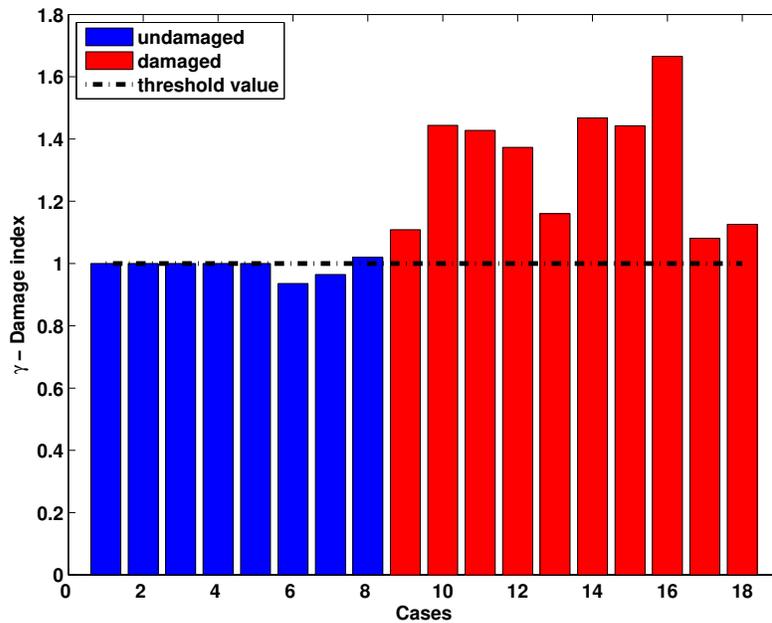


Fig. 5.32: Razão γ entre os erros de predição.

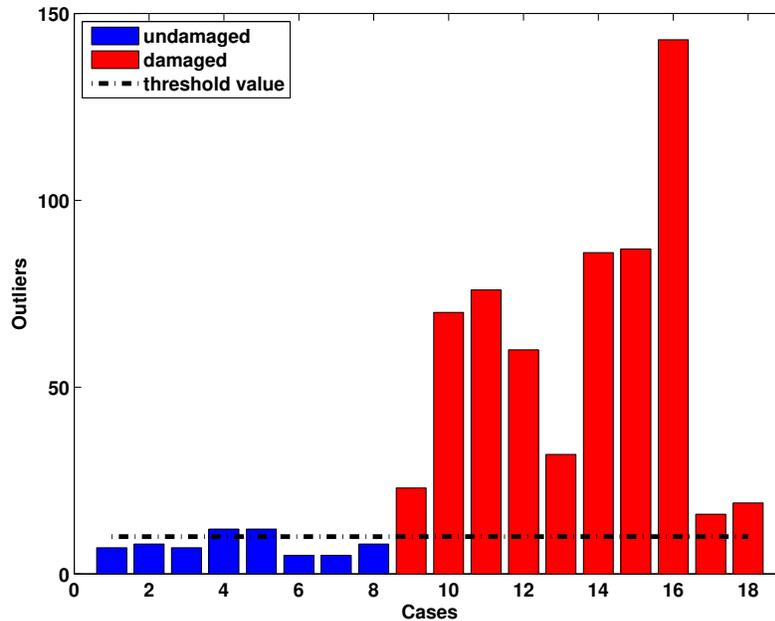


Fig. 5.33: Evolução dos *outliers*.

condições estacionárias sem profundo conhecimento do sistema.

- Os dois indicadores avaliados nas figuras 5.32 e 5.33 obtêm um valor *threshold* com mínima interação com o usuário.
- O SPC demonstrou ser mais satisfatório para um futuro monitoramento automático de um rotor real devido à sua simplicidade e melhor discriminação em relação aos sinais de referência.

Para melhorar este procedimento e classificar e quantificar o dano ou ainda tentar obter a vida remanescente (prognóstico) do rotor sem um modelo matemático, poderia se usar estes indicadores, *outliers*, erros de predição, ou até mesmo os valores RMS, considerando o sistema em diferentes níveis de falha (obviamente a partir de um histórico de sinais de uma máquina real). Nesta situação seria possível conduzir um treinamento supervisionado, por exemplo, a partir de uma clássica rede neural para obter correlações entre estes indicadores e o tipo e severidade do dano.

Entretanto, a simples questão se um dano está presente ou não em um rotor é o nível mais fundamental. Infelizmente, esta meta é ainda um sério problema para algumas aplicações práticas na

indústria. Neste sentido os resultados desta seção são interessantes e a metodologia poderia, a priori, ser usada com sucesso em casos reais, onde formulações convencionais falham.

Na presente seção os danos no rotor foram simulados numericamente como variações impostas nas matrizes de rigidez e amortecimento, o que pode não estar correlacionado sempre com danos reais que ocorrem em máquinas rotativas. Uma vez que a proposta inicial desta tese não era trabalhar com rotores, testes e simulações mais aprofundadas e em sistemas mais complexos não foram realizados. Consequentemente, os resultados deste item devem ser estendidos em pesquisas futuras.

Capítulo 6

Detecção de Danos em Estruturas Inteligentes

A meta deste capítulo é ilustrar o uso de modelos ARMAX e controle estatístico de processos, para detectar e localizar danos usando medidas experimentais de séries temporais de entrada/saídas de voltagem em PZTs colados em estruturas de laboratório. Em ambos os casos se compara o monitoramento a partir do erro de predição (seja linear ou não-linear) e dos valores RMS das diferenças entre as estimativas não-paramétricas no domínio da frequência das funções de transferência na condição da estrutura sem dano e condição desconhecida.

O primeiro exemplo consistiu-se de uma viga de alumínio com dois PZTs acoplados, sendo simulada uma trinca (entalhe) com diversas profundidades para se avaliar a sensibilidade de se monitorar o erro de predição. Neste teste, usou-se o controle estatístico de processos como ferramenta para detecção de valores limiares. Estes resultados foram publicados em um trabalho do autor em [74].

O segundo experimento foi realizado em uma estrutura do tipo *frame* com dois PZTs colados próximos de junções parafusadas. O dano é simulado por perdas de rigidez nestas juntas, obtidas por apertos/desapertos nos parafusos. Esta estrutura já foi usada anteriormente no trabalho [72] do autor. Avaliou-se com este teste o uso de métricas de falha (RMS) do sinal de impedância eletromecânica, controle estatístico de processos e modelos não-lineares de Kautz-Volterra.

6.1 Viga ativa com PZTs acoplados

O primeiro teste foi feito em uma viga de alumínio apresentada na figura 6.1. Duas cerâmicas piezelétricas, chamadas de PZT1 e PZT2, foram coladas nas faces da viga. A tabela 6.1 mostra as propriedades geométricas das cerâmicas e da viga. Na seqüência são apresentados os procedimentos e considerações feitas neste ensaio [74].

Tab. 6.1: Dimensões da estrutura e dos PZTs modelos PSI-5A-S4 (Piezo Systems®).

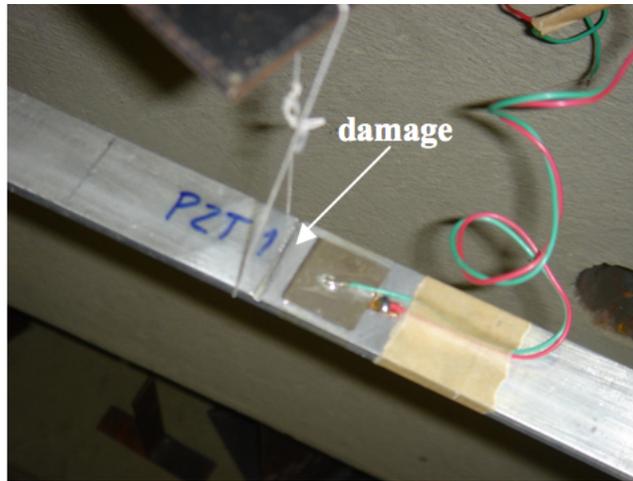
Propriedade	Viga	PZT
Comprimento	600 mm	20 mm
Largura	25 mm	20 mm
Espessura	5 mm	0.27 mm

6.1.1 Descrição do ensaio

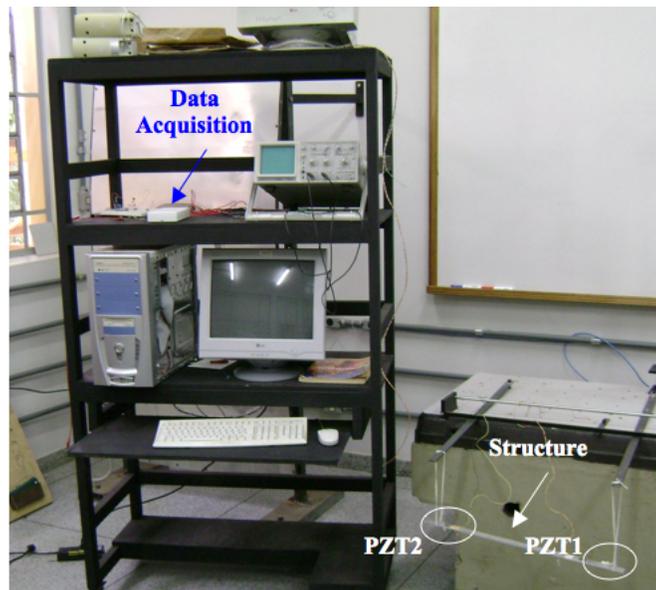
A geração do sinal de entrada e a aquisição de dados foram feitas com um sistema comercial da Data Physics com 24 bits e controlado pelo software SignalCalc Ace®. Os sinais foram adquiridos com taxa de amostragem de 102.4 kHz e dois conjuntos com 8192 amostras foram gravados em dois canais: um correspondendo ao sinal de entrada no PZT e o outro no sinal de saída do circuito condicionador, correspondendo as voltagens V_{in} e V_{out} no circuito da figura 4.1.

O *hardware* usado limitou a capacidade de amostrar os dois PZTs simultaneamente. Então, cada medida em um PZT foi conduzida separadamente. Um diagrama esquemático da montagem experimental, incluindo as posições dos PZTs é mostrado na figura 6.2.

Outra diferença com os procedimentos convencionais e o adotado neste trabalho é que o sinal de entrada no PZT (V_{in}) usado foi um sinal aleatório do tipo branco com ± 1 V de limites de saturação. Formulações convencionais envolvendo sinais de impedância elétrica geralmente usam entradas do



(a) Detalhe do dano simulado (corte transversal) próximo ao PZT1.



(b) Vista da viga e do aparato experimental.

Fig. 6.1: Viga com PZTs acoplados usada nos testes experimentais.

tipo varredura de senóides. A razão para se usar um sinal aleatório em vez de uma varredura de senóides, e. g. um *chirp*, é que a teoria de identificação de sistemas usada nesta tese tem como hipótese básica que os sinais são estacionários. Caso se empregue um sinal de entrada do tipo *chirp*, por exemplo, os sinais teriam característica não-estacionária e não poderiam ser estimados usando a teoria apresentada nesta tese.

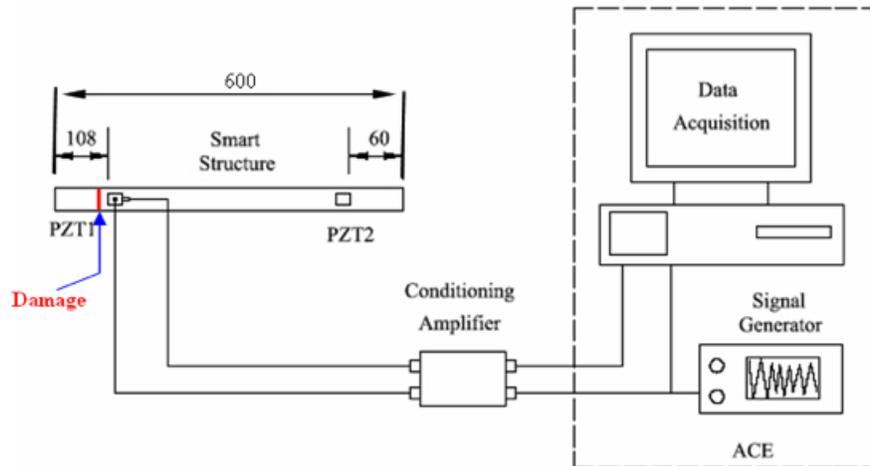


Fig. 6.2: Diagrama esquemático da montagem experimental. As dimensões estão em mm.

O pós-processamento foi feito usando Matlab®, versão 7.0, release 14. Todos os sinais foram pré-filtrados para remover componentes DC, distorções de baixa frequência e eliminar possíveis tendências lineares.

Os danos (trincas simuladas) foram introduzidos através de cortes transversais na face da viga próxima ao PZT1, a 14 mm deste PZT, conforme as figuras 6.1(a) e 6.2. Várias profundidades foram feitas para representar diferentes níveis de severidade. A tabela 6.2 resume cada condição estrutural investigada.

Tab. 6.2: Condições estruturais investigadas na viga ativa.

Padrão	Descrição
Sem dano	Nenhum dano (baseline)
Dano 1	Corte com profundidade de 1 mm e 25 mm de largura
Dano 2	Corte com profundidade de 2 mm e 25 mm de largura
Dano 3	Corte com profundidade de 3 mm e 25 mm de largura

Em cada condição três conjuntos de dados de entrada-saída do PZT1 e PZT2 foram armazenados. Estas aquisições foram feitas em dias diferentes para incluir uma variabilidade do ambiente nos dados. Em todos os testes a viga foi suspensa por cabos para simular uma condição de contorno do tipo livre-livre.

Um típico sinal de entrada, V_{in} , e saída, V_{out} , medidos no PZT1 na condição saudável são mostrados na figura 6.3.

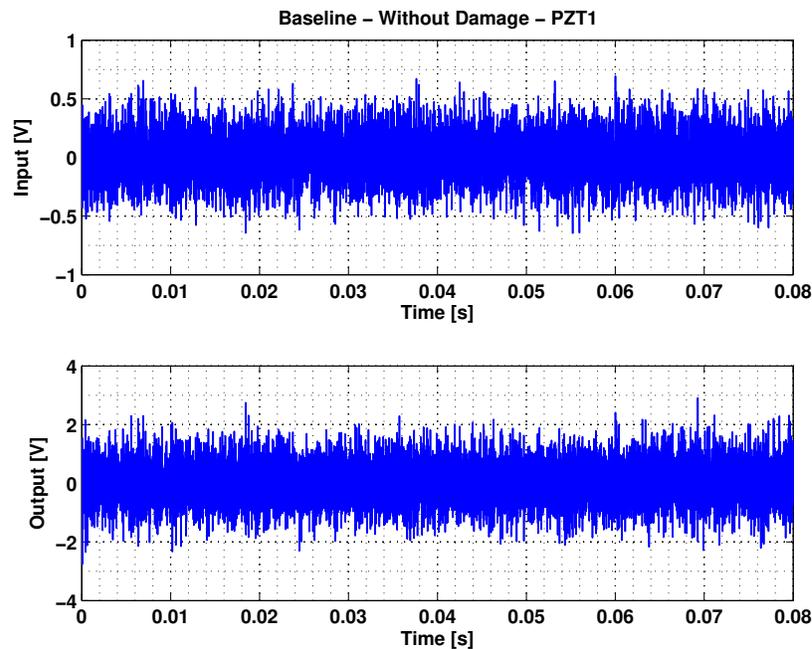


Fig. 6.3: Sinais de entrada-saída para o sistema sem dano medidos com o PZT1.

A função de transferência não-paramétrica $G(\omega)$ foi estimada a partir da densidade espectral de potência (PSD) dos sinais de entradas e saídas em todas as condições investigadas, calculada com o método do periodograma de Welch. Empregou-se janelas Hanning com 4096 pontos e 3000 pontos de sobreposição (*overlapping*). O leitor interessado em uma discussão mais detalhada sobre análise espectral pode consultar a referência [80].

As figuras 6.4 e 6.5 apresentam as partes reais e imaginárias das funções de transferência $G(\omega)$ estimadas com o PZT1 e PZT2, respectivamente, para as condições saudáveis e com o sistema com

os entalhes. Para maior clareza na visualização, estas figuras mostram somente um *baseline* e três curvas para condições danificadas. A faixa de frequências entre 25 e 45 kHz foi considerada porque corresponde ao range com maior variação dos picos observados em todas as medidas.

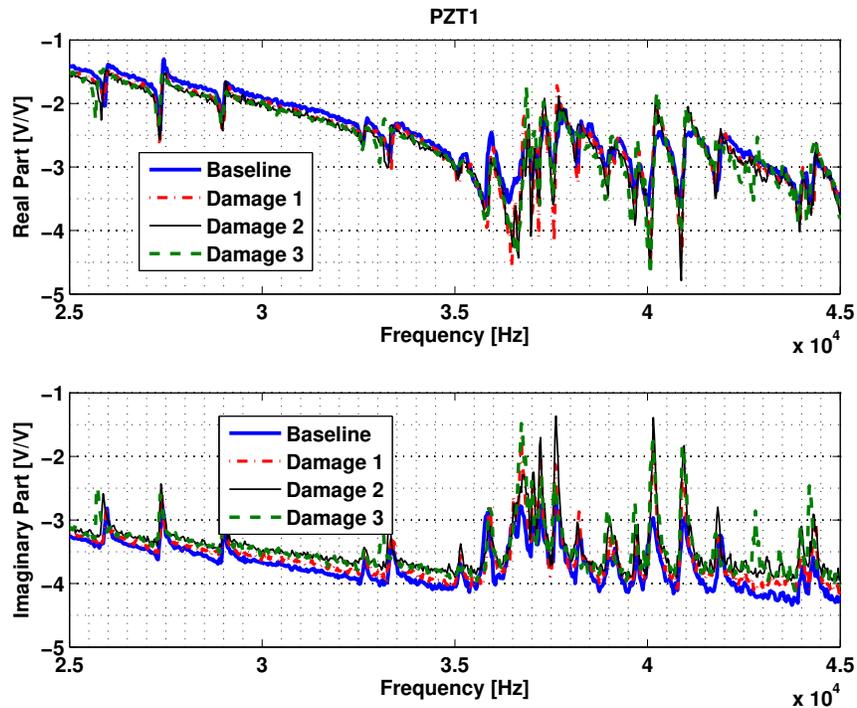


Fig. 6.4: Parte real e imaginária da função de transferência estimada entre os sinais de entrada e saída medidas com o PZT1 (diversas condições estruturais).

A figura 6.6 mostra as funções de coerência, sobre a mesma faixa de frequências, para o PZT1 e PZT2, considerando um sinal sem dano estrutural. O valor da função de coerência próximo do valor unitário em toda a faixa de frequência indica que as funções de transferência são bem estimadas a partir dos sinais de entrada-saída.

6.1.2 Diagnóstico via falha métrica

O índice falha métrica RMS M , obtido da Eq. (4.3), foi calculado para cada medida para indicar a saúde estrutural. O sinal *baseline* usado para calcular este indicador corresponde ao valor médio dos

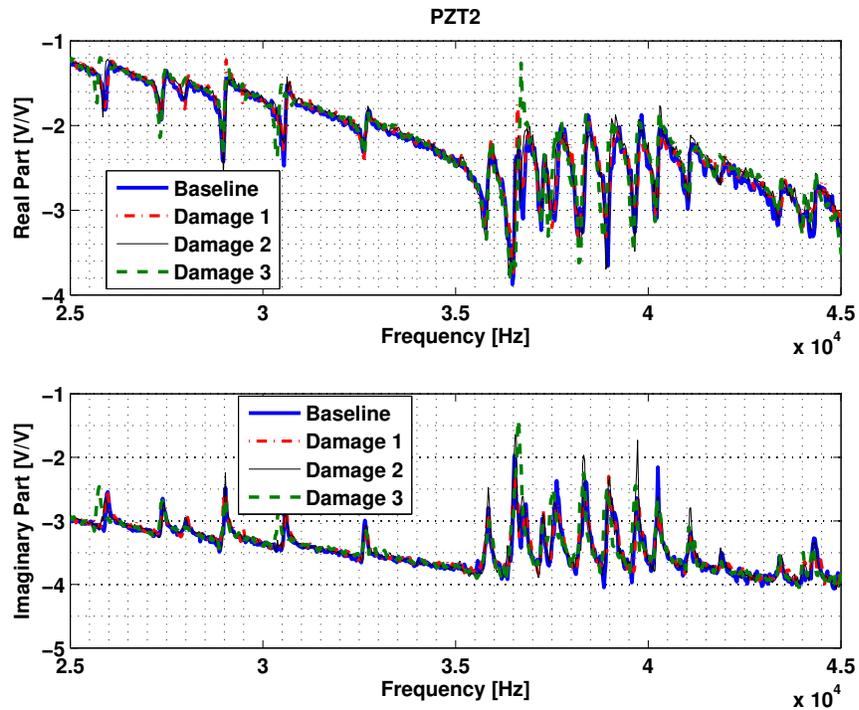


Fig. 6.5: Parte real e imaginária da função de transferência estimada entre os sinais de entrada e saída medidas com o PZT2 (diversas condições estruturais).

três sinais sem dano. Se existe um dano próximo a um PZT, o valor M aumenta. Portanto, a métrica M pode ser usada para prever a localização de uma modificação estrutural.

As figuras 6.7(a) e 6.7(b) apresentam os valores do índice M para os PZT1 e PZT2, respectivamente. Pode-se observar que o valor deste indicador é bem correlacionado a severidade do dano. Além disto, o maior valor do índice é próximo ao PZT1, o que sugere que a posição da modificação estrutural se encontra na região deste PZT. Esta constatação é mesmo verdade, uma vez que o dano foi induzido próximo à área do PZT1.

Uma característica do indicador falha métrica M é que ele correlaciona apenas as variações ocorridas em relação as amplitudes. Seria interessante se possuir um indicador que levasse em conta, além da variação dos valores dos picos, as variações que porventura podem ocorrer nas frequências dos mesmos.

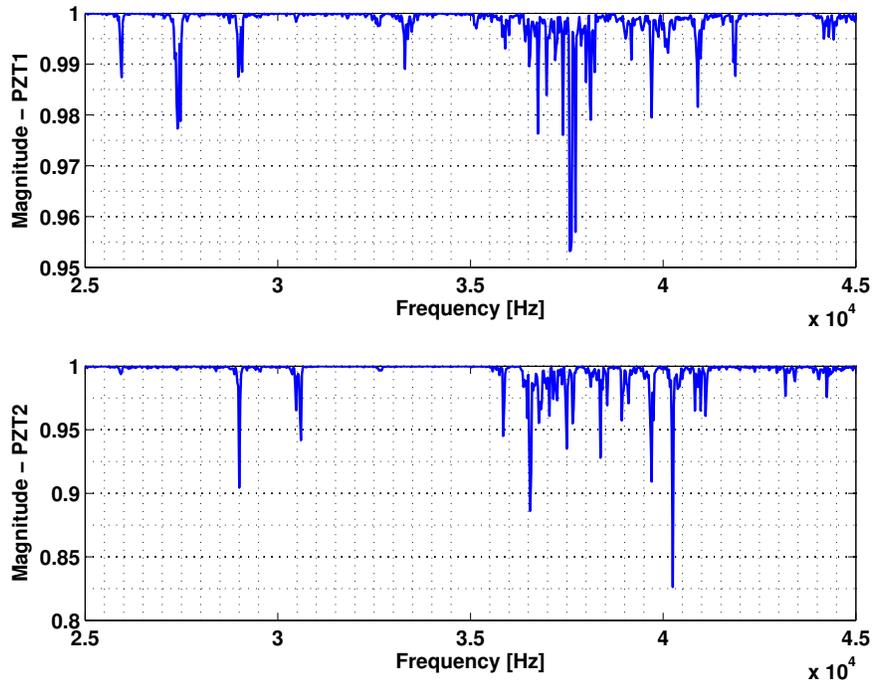


Fig. 6.6: Função de coerência das estimativas usando as medidas do PZT1 e PZT2.

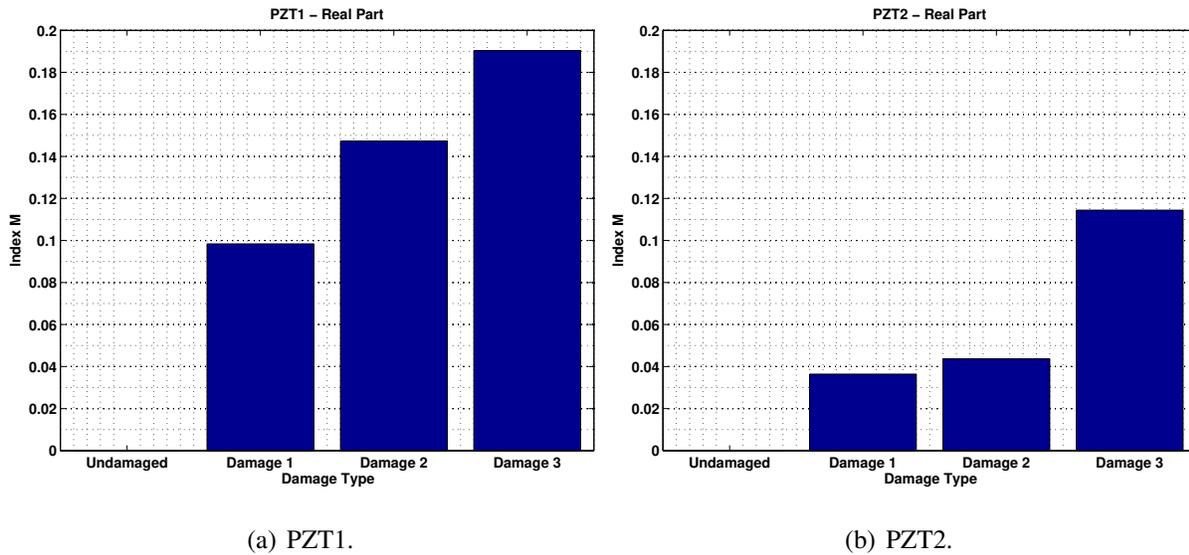


Fig. 6.7: Índice falha métrica M obtido à partir das medidas do PZT1 e PZT2.

6.1.3 Construção do modelo ARMAX

O primeiro passo é ajustar um modelo ARMAX com ordens n_a , n_b e n_c adequadas, chamado de ARMAX(n_a, n_b, n_c). Para isto empregou-se o indicador AIC com base nos sinais medidos V_{in} e

V_{out} . Após esta análise, similar à feita no capítulo 5, concluiu-se que um modelo ARMAX(34,4,4) é suficiente para finalidade de predição.

Após obter os polinômios $A(q)$, $B(q)$ e $C(q)$ para as condições sem dano (modelos de referência), efetuou-se uma análise de resíduos para avaliação dos modelos. A figura 6.8 apresenta um destes testes para um dos conjuntos de sinais de entrada-saída em uma das condições sem dano medidas que não foram usadas para obtenção dos polinômios de referência. A análise de resíduos normalizada mostra que a correlação entre as voltagens de saída $x(k)$, aqui descrito por V_{out} , e o erro residual, $e_x(k)$ e, ainda, a correlação do sinal de entrada $u(k)$, aqui descrito por V_{in} , e o erro residual $e_x(k)$, permanecem dentro do intervalo de confiança (99%), exceto no atraso nulo.

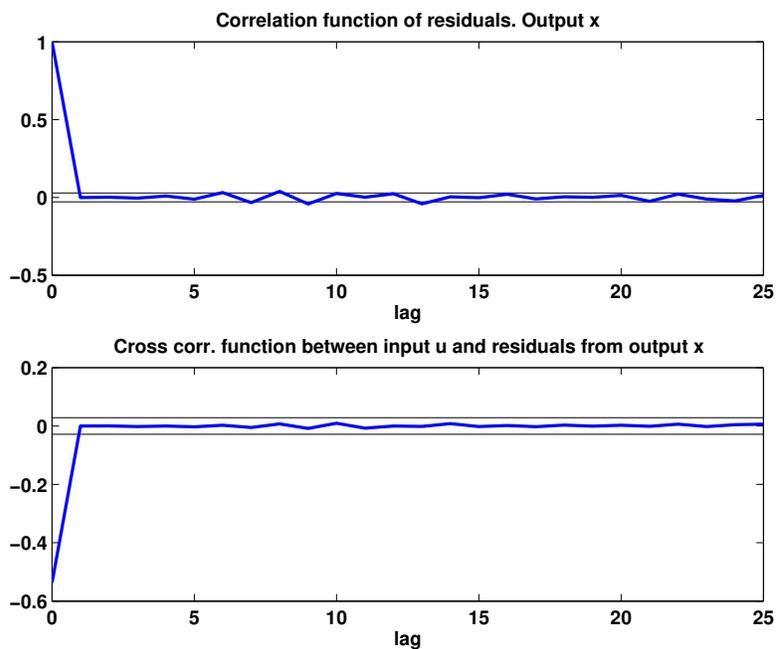


Fig. 6.8: Análise de resíduos do modelo construído com medidas do PZT1 considerando o sistema na condição estrutural saudável.

Portanto, o erro de predição $e_x(k)$ é próximo de um processo do tipo ruído branco. Então, isto é um indicativo de que o modelo é capaz de descrever toda informação que está contida nos dados. Os outros casos sem dano são similares. Sendo assim, este conjunto de modelos para a condição saudável pode ser admitido validado para cada conjunto de dados medidos nestas condições.

O próximo passo é investigar se a relação entrada $u_y(k)$ ¹ e saída em condição desconhecida $y(k)$ pode ser descrita pelo modelo ARMAX(34,4,4) previamente obtido, usando a Eq. (3.28).

Conforme descrito no capítulo 3, se o modelo ARMAX não realiza uma boa predição para os sinais de entrada e saída em condição desconhecida, respectivamente $u_y(k)$ e $y(k)$, isto significa que o erro residual na condição estrutural desconhecida $e_y(k)$ e sua distribuição de probabilidade apresentam alguma mudança quando comparada com a base de referência $e_x(k)$. Isto indica uma possível variação estrutural.

Por outro lado, se os erros de predição ficam próximos à linha normal, é razoável assumir que o erro ARMAX é normal e assintoticamente distribuído. Isto é um forte indicativo de que a estrutura permanece na condição estrutural saudável e sem nenhum dano. Além disto, se o valor da *kurtosis* é próximo a 3.0 e o *skewness* é próximo à zero, a distribuição de probabilidades pode ser assumida como Gaussiana. Como exemplo, se mostra um sinal de erro ARMAX na figura 6.9, obtido para um conjunto de dados sem dano no PZT1, onde se observa que o valor da *kurtosis* é 3.06 e do *skewness* é -0.01.

6.1.4 Diagnóstico via SPC

Em todos os casos apresentados nesta seção o modelo de referência (baseline) foi um dos três conjuntos de dados no estado saudável. O erro de predição $e_x(k)$ tem 8192 pontos. Os dados coletados foram arranjados em quatro grupos ($n = 4$) de 2000 pontos amostrados cada um para estimar as linhas de controle *CL*, *UCL* e *LCL* e, então, 192 pontos foram descartados. $Z_{\alpha/2}$ foi escolhido igual a 2.57, que corresponde a um intervalo de confiança de 99%. Portanto, um total de 20 amostras, i.e., 1% de 2000 amostras são esperadas fora dos limites de controle, mesmo para a estrutura sem nenhum dano. Portanto, o valor limiar que separa as condições com dano e sem dano é 20 amostras.

A figura 6.10 mostra o erro de referência $e_x(k)$ com os limites de controle para o PZT1. Pode-se observar 17 *outliers*, o que é uma indicação da condição saudável. Para testar a indicação de falso-

¹Aqui $u_y(k)$ é relacionado diretamente à voltagem V_{in} e o sinal $y(k)$ à voltagem V_{out} em condição estrutural desconhecida.

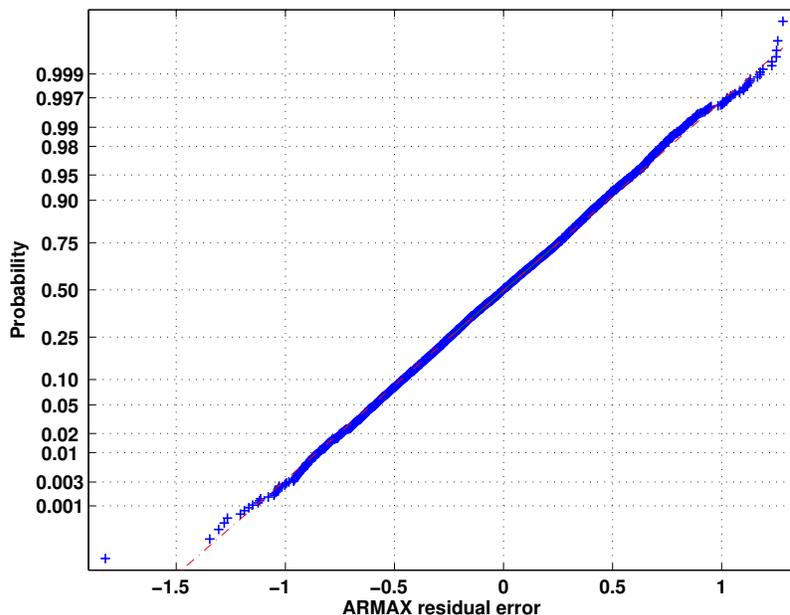


Fig. 6.9: Gráfico de probabilidade do erro residual ARMAX no estado saudável para o PZT1, com valor *kurtosis* 3.06 e *skewness* -0.01.

positivo de dano, os outros dados na condição saudável foram usados com os mesmos limites de controle previamente obtidos. Estes resultados são mostrados na figura 6.11, onde os *outliers* foram marcados por *.

Um número de *outliers* menor do que o valor limiar foi observado nos dois casos. Portanto, este modelo auto-regressivo de referência se mostra robusto contra falso alarme de mudanças estruturais. Testes similares foram alcançados quando outros dados são usados como referência para obter o modelo ARMAX. Por outro lado, o número de *outliers* aumenta quando uma variação estrutural é introduzida. A figura 6.12 mostra os resultados obtidos com o PZT1 considerando os padrões dano 1, dano 2 e dano 3 (ver tabela 6.2).

Nestes exemplos, o número de *outliers* parece aumentar quando a severidade torna-se maior. Porém, este resultado não é conclusivo devido ao baixo número de dados considerados. Testes com uma quantidade maior de dados devem ser feitos para obter melhor informação sobre o nível de severidade. Isto não foi feito pois a meta principal deste experimento foi avaliar se o uso de erros

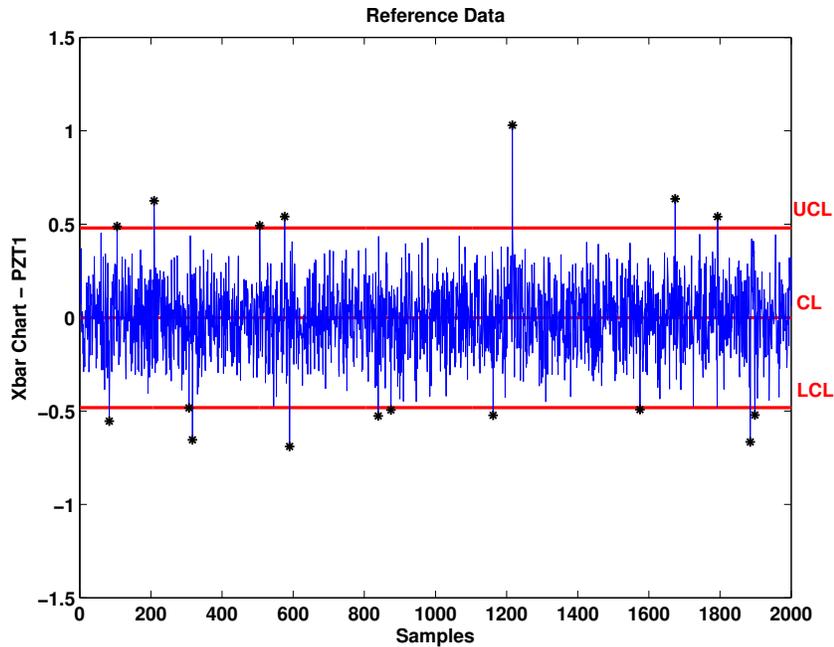


Fig. 6.10: Erro de predição ARMAX para o sinal de referência no PZT1. O número de *outliers* mostra condição normal (17 *outliers*). Menor do que o valor de alarme de 20 *outliers*.

ARMAX e SPC são gerais para detectar e localizar danos. A quantificação de danos deve ser feita em trabalhos futuros.

A figura 6.13(a) mostra as condições gerais considerando todos os dados no PZT1. Resultados similares foram analisados considerando as medidas do PZT2. A figura 6.13(b) mostra os resultados gerais considerando todos os dados deste PZT. Neste exemplo o número de *outliers* foi menor do que no caso prévio no PZT1. Este comportamento era esperado, uma vez que o dano foi introduzido próximo ao PZT1. Sendo assim, a sensibilidade do PZT2 para este dano será inferior. A diferença entre o número de *outliers* mostrado nas figuras 6.13(a) e 6.13(b) apresenta clara informação sobre a localização do dano próximo à região do PZT1, apesar de alguns falsos-positivos no PZT2. A presença de falsos-positivos é dramática para o monitoramento de alguns tipos de componentes, pois exige uma re-inspeção, o que pode encarecer bastante o processo SHM. Também é interessante notar que as mudanças estruturais na viga inteligente foram de baixa intensidade e mesmo nestas condições a metodologia foi satisfatória para detectar e localizar os danos com sucesso.

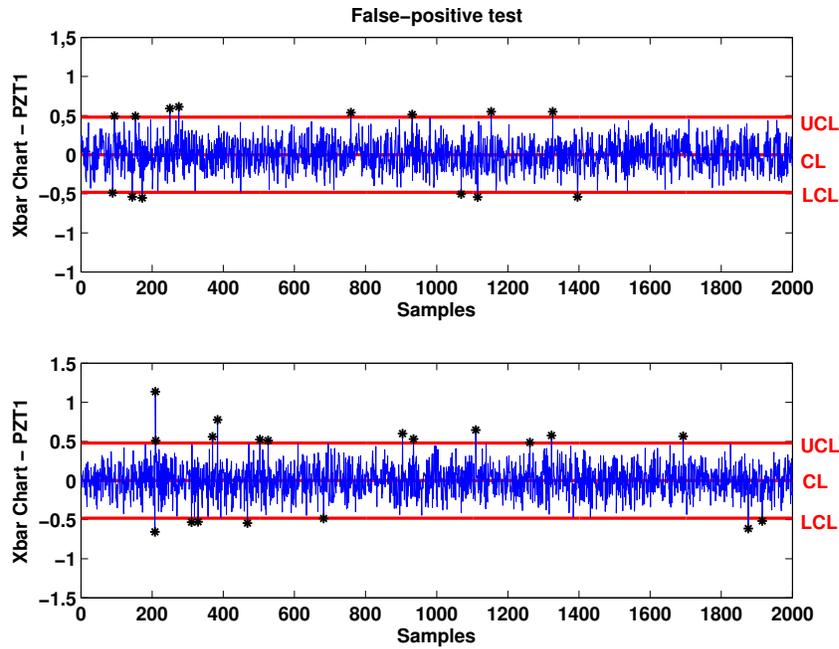


Fig. 6.11: Dois sinais de erro ARMAX medidos com o PZT1 para verificação de falsos-positivos. O número de *outliers* em ambos os gráficos mostra condições sem dano (14 e 19 *outliers*, respectivamente). Menores do que o valor limiar de 20 *outliers*.

6.1.5 Conclusões

As duas formulações descritas nesta seção mostraram ser satisfatórias para detecção de danos em estruturas inteligentes baseadas em métodos sem modelos. Excitações em alta-freqüência e baixa voltagens nas cerâmicas PZTs foram usadas para monitorar a saúde estrutural de uma viga. Estas técnicas apresentam as vantagens da tecnologia de materiais inteligentes.

O uso de cartas métricas RMS é muito dependente da estimativa não-paramétrica e da faixa de freqüências adotada. O uso de modelos ARMAX ajustados usando os dados medidos na estrutura saudável pode apresentar informação paramétrica que pode vir a ser usada com sucesso para um futuro passo de prognóstico. Além disto, modelos ARMAX são basicamente um conjunto de filtros discretos facilmente programados em placa processadora de sinais. Neste contexto, esta formulação se mostra muito atraente para monitoramento real sem supervisão humana. A determinação do valor limiar com SPC apresenta critérios estatísticos mais rigorosos do que o simples índice freqüencial

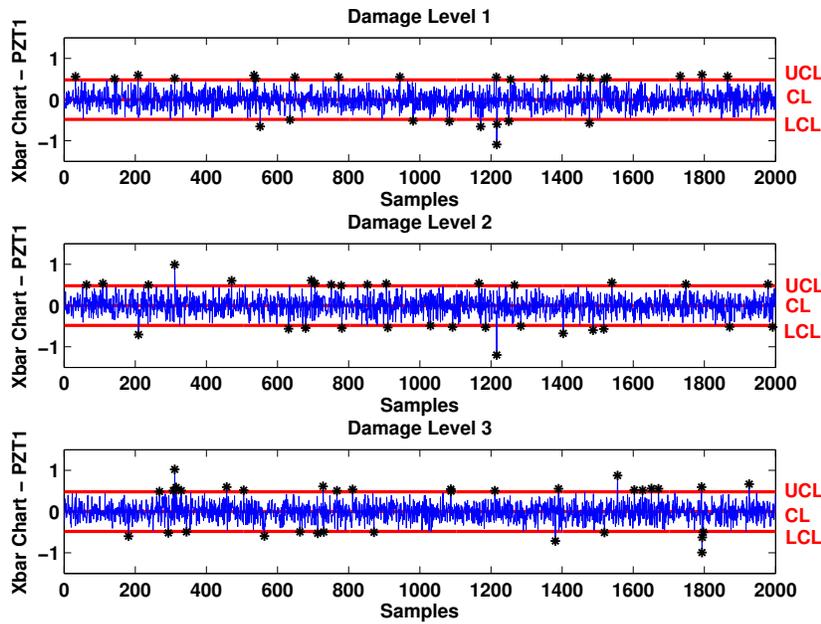


Fig. 6.12: Casos com dano considerando-os como condição estrutural desconhecida no PZT1. O número de *outliers* em ambos os gráficos mostra condições com dano (28, 31 e 34 *outliers*, respectivamente). Maiores do que o valor limiar de 20 *outliers*.

RMS usado nas cartas métricas.

Futuras pesquisas nesta área devem incluir a quantificação de danos e a estimativa restante da vida da estrutura (análise de prognóstico). Formulações não baseadas em modelos matemáticos podem considerar o uso destes indicadores, como *outliers*, erros de predição e índices RMS para o sistema associado com diferentes níveis de danos. A inclusão destas características permitem conduzir um treinamento supervisionado, como por exemplo, usando clássicas redes neurais para obter correlações entre *outliers* e severidade e tipo de dano. Obviamente, se tivermos acesso à um histórico dos dados.

Outra questão é a proposição de um índice baseado no número total de *outliers* para ter uma simples relação como o índice RMS frequencial. Com isto poderia ser mais fácil interpretar a informação da ocorrência e posição do dano do que pela análise dos gráficos das figuras 6.13(a) e 6.13(b).

Uma grande preocupação do ponto de vista de aplicação prática, sobretudo no setor aeronáutico, é a definição da quantidade e da localização de sensores para identificar a presença de dano e sua

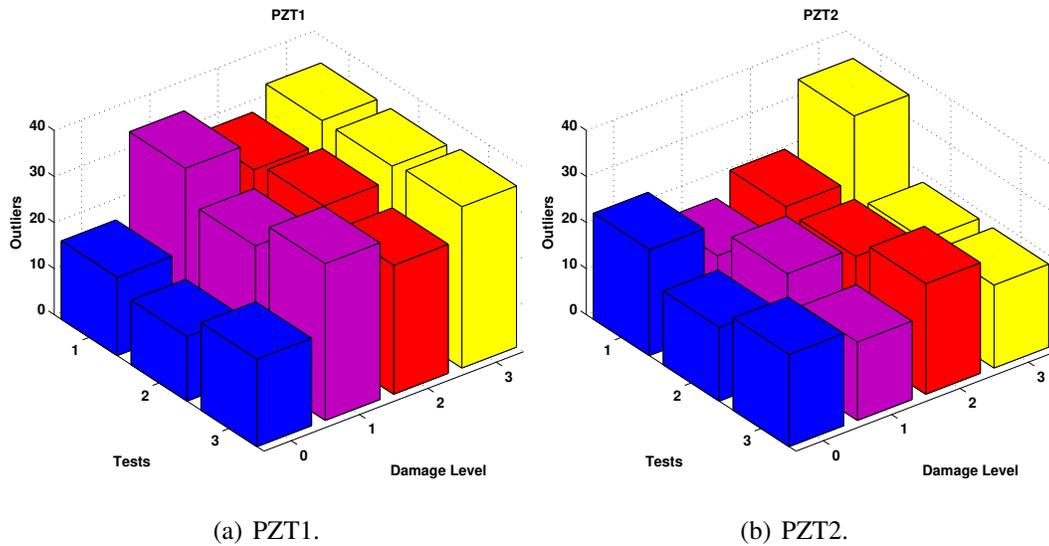
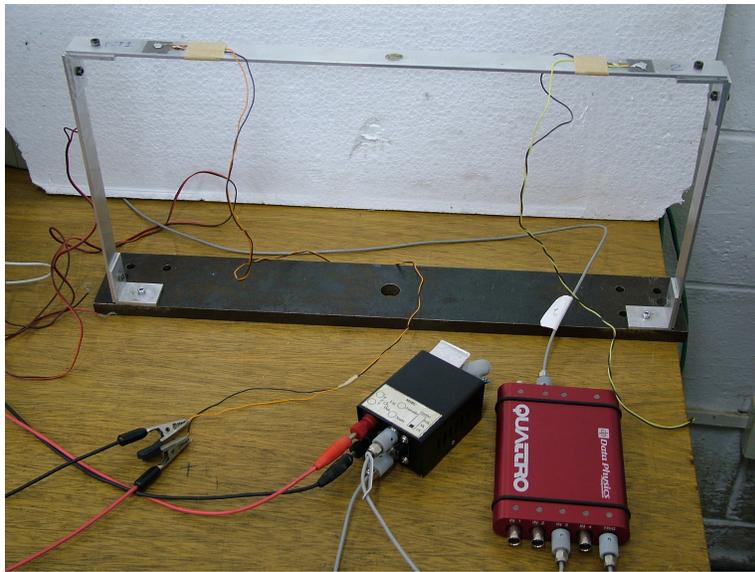


Fig. 6.13: Resultados para todas as condições estudadas. Os limites de controle foram baseados no conjunto de dados sem dano de referência. O número de *outliers* maior no PZT1 indica que o dano é localizado na região próxima a este sensor.

severidade. O ideal é propor uma rede de PZTs com sensores PVDFs para serem usados como redundância, caso algum PZT falhe. Com relação ao número e localização destes, a experiência de profissionais do setor para guiarem o especialista se faz necessária para definir corretamente as regiões da estrutura que merecem ser inspecionadas.

6.2 Estrutura portal com PZTs acoplados

O segundo exemplo foi uma estrutura do tipo *frame* portal de alumínio com junções parafusadas e presa a uma base rígida, vista na figura 6.14(a). Detalhe da junção parafusada é vista na figura 6.14(b). A viga de topo é conectada a duas vigas verticais usando braçadeiras de alumínio e parafusos. Dois PZTs colados na estrutura foram usados como sensores/atuadores, chamados de PZT1 e PZT2. A tabela 6.3 apresenta as dimensões geométricas da estrutura e das pastilhas piezocerâmicas usadas.



(a) Frame e instrumentação usada.



(b) Detalhe da junção parafusada e de um PZT colado no *frame*. As marcas nos parafusos servem como referência no momento de apertos e desapertos.

Fig. 6.14: Estrutura portal utilizada como bancada experimental.

6.2.1 Descrição do ensaio

A figura 6.15 mostra um diagrama esquemático da montagem experimental e as posições dos PZTs e localizações onde os danos foram induzidos.

Tab. 6.3: Dimensões da estrutura portal e dos PZTs modelos PSI-5A-S4 (Piezo Systems®).

Propriedade	Viga de Topo	Vigas Verticais	PZT
Comprimento	500 mm	250 mm	20 mm
Largura	25 mm	25 mm	20 mm
Espessura	2.5 mm	2.5 mm	0.27 mm

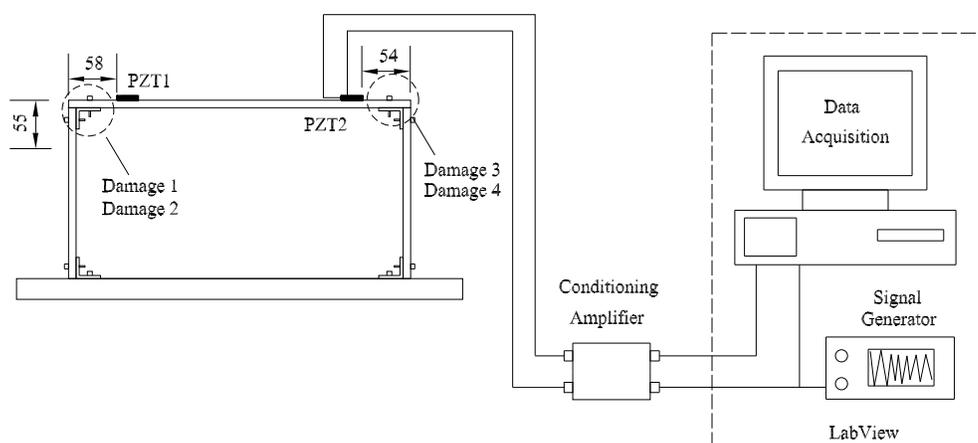


Fig. 6.15: Esquema da montagem experimental mostrando o posicionamento dos PZTs e dos danos induzidos. As dimensões estão em mm.

A geração do sinal de entrada e a aquisição dos dados foram feitas usando uma placa de aquisição da National Instruments® (NI) com 16 bits. Como esta placa não tem filtro *anti-aliasing*, um filtro analógico passa-baixa com frequência de corte de 75 kHz foi confeccionado. Em todos os testes empregou-se uma taxa de amostragem de 250 kHz² com 50000 amostras armazenadas em cada sinal/canal. O sinal aleatório de entrada V_{in} do tipo ruído branco foi gerado no computador. Este sinal

²A frequência de Nyquist é 125 kHz, mas como utilizou-se o filtro *anti-aliasing* usa-se a informação somente até 75 kHz.

foi pré-processado por um filtro digital passa-banda *Butterworth* de 10.^a ordem com banda passante de 15 kHz a 45 kHz. Somente se excitou esta faixa de frequências. A amplitude usada para este sinal de entrada foi de 4 V.

Somente o sinal de saída V_{out} é amostrado, pois como o sinal de entrada V_{in} é gerado no próprio computador ele já é armazenado. Uma questão que pode surgir é a não garantia de que o sinal armazenado seja realmente o sinal aplicado no PZT. O sinal V_{out} é pré-processado pelo circuito condicionador da figura 4.1. Todo o controle da aquisição é feito em uma rotina programada no ambiente LabView®. Estes circuitos e rotinas foram feitos para o projeto FINEP entre a UNESP/Ilha Solteira, UFU e EMBRAER.

Os danos foram considerados como desapertos³ das junções parafusadas da viga de topo (danos 1 e 2: próximos ao PZT1 e os danos 3 e 4: próximos ao PZT2). Infelizmente nestes testes não houve como controlar exatamente estes apertos/desapertos em cada parafuso. Para tentar melhor controlar utilizou-se marcas como referência para restaurar o sistema nas condições iniciais, conforme visto na figura 6.14(b). A tabela 6.4 descreve as condições estruturais investigadas.

Tab. 6.4: Condições estruturais investigadas na estrutura portal.

Padrão	Sigla	Descrição
Baseline1	sd1	Dados sem dano
Dano 1	cd1	Desaperto na junção próxima ao PZT1
Dano 2	cd2	Desaperto de maior intensidade na junção próxima ao PZT1
Baseline2	sd2	Estrutura reparada para condição inicial
Dano 3	cd3	Desaperto na junção próxima ao PZT2
Dano 4	cd4	Desaperto de maior intensidade na junção próxima ao PZT2

³Estas desapertos foram de 1 volta no sentido anti-horário nos danos 1 e 3, 2 voltas no sentido anti-horário no dano 2 e 3 voltas no sentido anti-horário no dano 4.

Antes de se inserir os danos foram medidos 6 conjuntos de sinais nas condições saudáveis sd1 para construção do modelo de referência⁴ e para verificação de falsos-positivos de alarme de dano. Depois de introduzidos os danos 1 e 2, as junções foram reparafusadas novamente para a marca inicial para reparar a estrutura, formando os dados chamados de *baseline2*. Finalmente, os danos 3 e 4 foram inseridos. Em cada condição são armazenados 6 conjuntos de dados de entrada/saída nos PZT1 e PZT2. Portanto ao todo se tem em mãos 36 conjuntos de sinais V_{in} e V_{out} em cada PZT. Todas estas aquisições foram feitas em dias diferentes para inclusão de variabilidades ambientais dentro dos dados.

6.2.2 Diagnóstico via falha métrica

A figura 6.16 mostra os sinais estimados de impedância eletromecânica para os PZT1 e PZT2 para diversas condições estruturais investigadas. Este sinal foi calculado no próprio LabView® considerando os valores de resistência e amplificadores operacionais do circuito condicionador. Como o sinal de excitação utilizado foi de banda limitada de 15 kHz a 45 kHz, se concentrou a análise na faixa de 20 a 30 kHz para se evitar distorções nas extremidades do domínio da frequência do sinal filtrado.

O indicador falha métrica RMS M , obtido da Eq. (4.3), foi calculado para cada um dos sinais considerando como sinal de referência uma média dos 6 sinais sem danos (condição sd1). A figura 6.17 apresenta estes resultados.

Pode-se constatar que todos os sinais na condição sem dano (sd1) são diagnosticados corretamente. Quando os danos 1 e 2 próximos ao PZT1 são inseridos, observa-se um aumento nos valores do indicador M para o PZT1, com o valor M do PZT2 ficando próximo à referência. É interessante notar que o indicador M no PZT1 aumentou seu valor quando se inseriu o dano 2 (cd2) de maior intensidade que o dano 1 (cd1) (ver tabela 6.4). Após estes testes a estrutura é reparafusada para a condição sd2. Na figura 6.17 vê-se uma redução do valor M no PZT1 para níveis inferiores aos dos danos 1 e 2. Entretanto, este valor é ainda maior do que o sinal de referência, sendo que o valor M no PZT2 aumenta seu valor em relação a referência. Observa-se assim, um valor residual que não

⁴Nomeado aqui de *baseline1*.

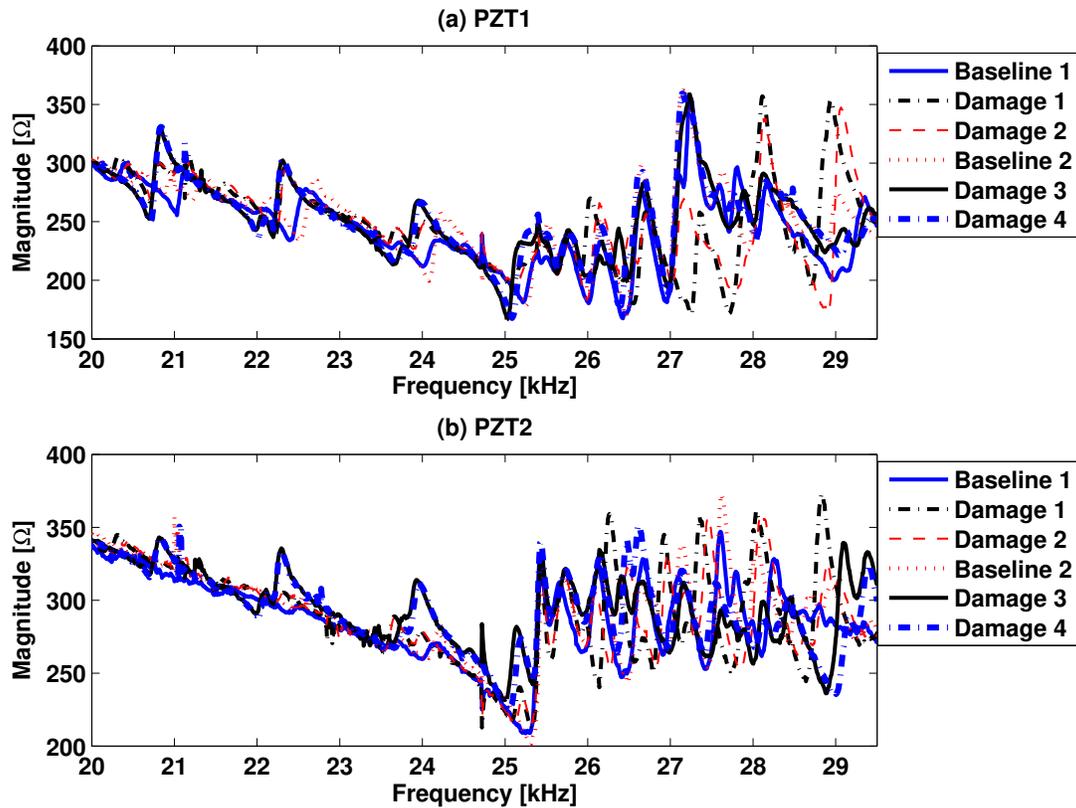


Fig. 6.16: Sinais de impedância eletromecânica para os PZT1 e PZT2 em diversas condições estruturais.

conseguiu-se controlar em virtude da própria dificuldade de se trabalhar com estruturas parafusadas. Mas neste caso constata-se que pelas diferenças e correlação com o número de voltas em cada junção, que estes dados não representam variação estrutural.

Na sequência é inserido o dano próximo a região do PZT2. Observa-se no caso cd3 que o valor do índice M é bem maior para este PZT. Como referência para este valor M continuou se assumindo o valor médio dos dados no *baseline1* sd1. O valor do índice M variou bem mais para os danos 3 e 4 do que o casos para os danos 1 e 2. As possíveis razões para isto podem ser relacionadas aos fatores: (1) Influência dos dados na condição reparada sd2; (2) Presença de um resíduo dos danos 1 e 2 nas medidas do PZT2 nestas condições. No caso cd4 detecta-se também uma variação do valor M maior para o PZT1. Por estes valores do indicador detectar-se-ia que a mudança ocorreu na região do PZT1, o que não é verdade.

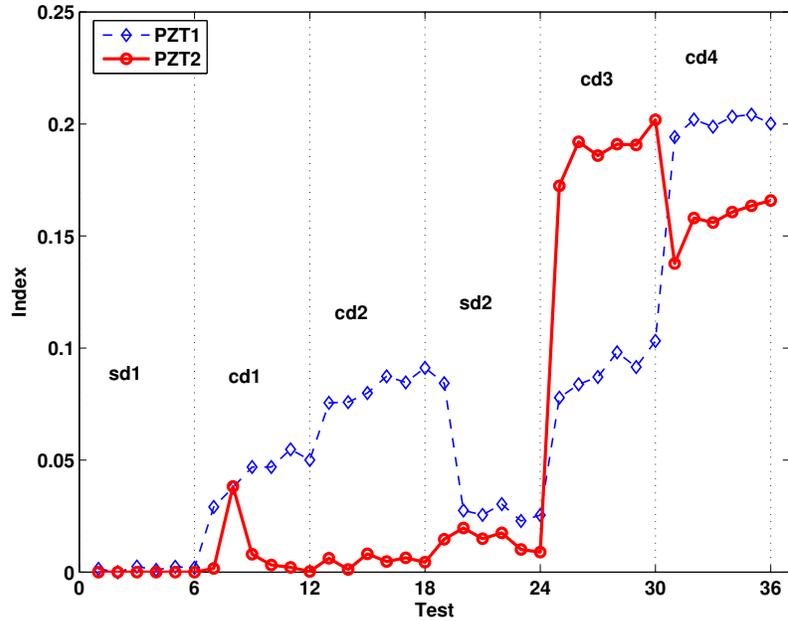


Fig. 6.17: Índice falha métrica M obtido à partir das medidas no portal com o PZT1 e PZT2.

Outro fato importante para destacar é a presença de contato que pode excitar componentes não-lineares que não são previstos no índice M . Deve-se salientar também que a transmissibilidade do sinal de impedância eletro-mecânica na estrutura em questão é grande. Assim, a influência dos danos inseridos⁵ podem afetar igualmente ambos os PZTs. Com o propósito de verificar uma melhora na classificação aplica-se nas seções seguintes o uso de modelos de predição linear e não-linear para detecção de variações estruturais.

6.2.3 Diagnóstico via SPC

Inicialmente todos os dados são padronizados pelo uso da Eq. (3.1) de forma a terem média nula e desvio padrão unitário. Na seqüência foi ajustado um modelo $ARMAX(n_a, n_b, n_c, n_k)$ para o conjunto de dados dos PZTs na condição estrutural sem dano sd1. As ordens usadas foram escolhidas após uma análise do valor AIC fixando-se $n_k = 1$ e $n_c = 2$. Após esta avaliação concluiu-se que um modelo $ARMAX(30, 20, 2, 1)$ é suficiente para a finalidade de predição linear dos sinais para o PZT1. Já para o PZT2 um modelo $ARMAX(20, 2, 2, 1)$ foi satisfatório. Ao contrário do exemplo da seção

⁵Além deste ponto, é preciso destacar que todos os danos foram inseridos somente na viga de topo.

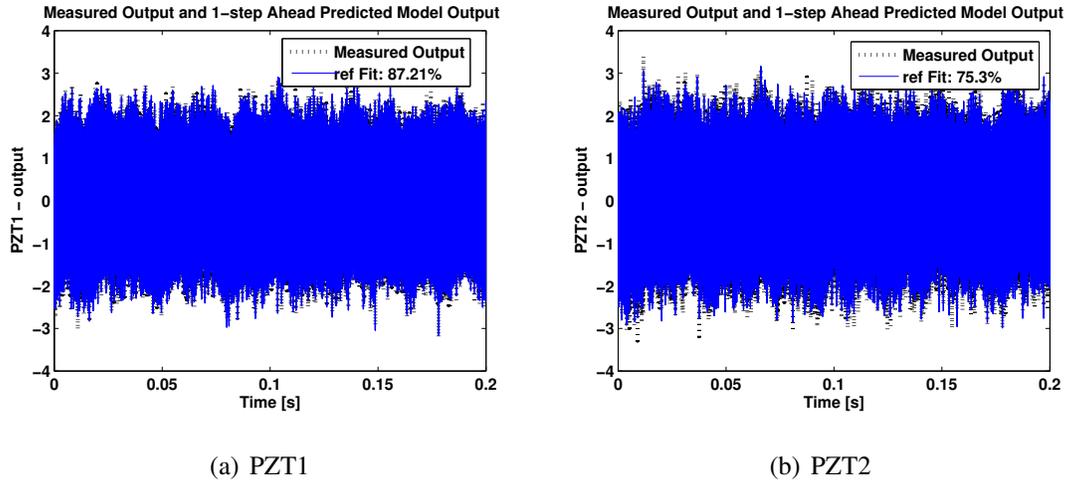


Fig. 6.18: Resultado de simulação livre para os dados do PZT1 e PZT2 na condição saudável sd1.

6.1, neste teste foi necessário usar dois modelos ARMAX diferentes, um específico para cada PZT.

Os sinais de entrada $u(k)$ e de saída $x(k)$ escolhidos como referência para construção dos modelos ARMAX nos PZT1 e PZT2 corresponderam ao valor médio de 5 sinais nas condições sem dano sd1 (baseline1)⁶. As figuras 6.18(a) e 6.18(b) apresentam exemplos de simulações livres usando dados em um dos sinais do baseline1 para o PZT1 e PZT2, respectivamente. Os modelos são considerados como sendo suficientes para a finalidade de predição e descrição da informação dinâmica presente nos sinais na condição baseline1.

Os limites de controle CL , UCL e LCL são construídos como base nos erros de predição ARMAX dos sinais de referência no PZT1 e PZT2. O conjunto de 50000 pontos é dividido em $n = 10$ observações. Assim, cada erro tem 5000 pontos. Admite-se $Z_{\alpha/2}$ como 2.57, que corresponde à um intervalo de confiança de 99%. Portanto, um total de 50 amostras, i.e., 1% de 5000 amostras, são esperadas estarem fora dos limites de controle, mesmo para a estrutura sem nenhum dano. Portanto, o valor limiar para separar as condições saudáveis e com dano é de 50 amostras.

A figura 6.19 mostra um sinal na condição sem dano sd1 para o PZT1. O número de *outliers* neste caso foi 25, menor do que o valor limiar. Assim, este sinal é considerado em condição estrutural

⁶São 6 sinais na condição sd1, mas um deles é usado para avaliar a presença de falso-positivo.

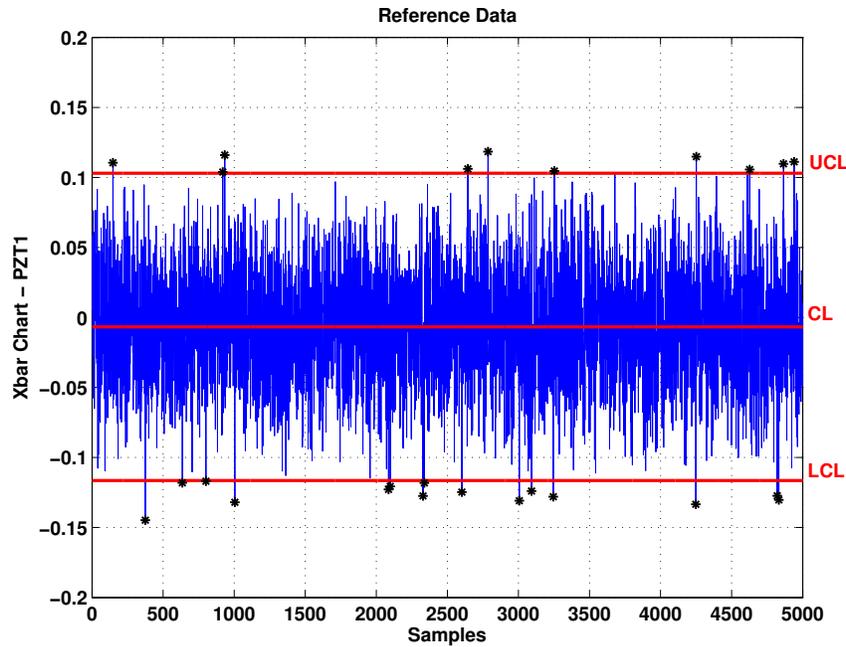
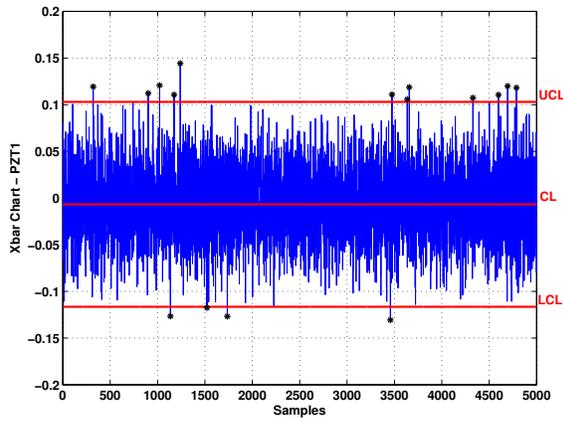


Fig. 6.19: Erro de predição ARMAX para o sinal de referência no PZT1. O número de *outliers* mostra condição normal (25 *outliers*).

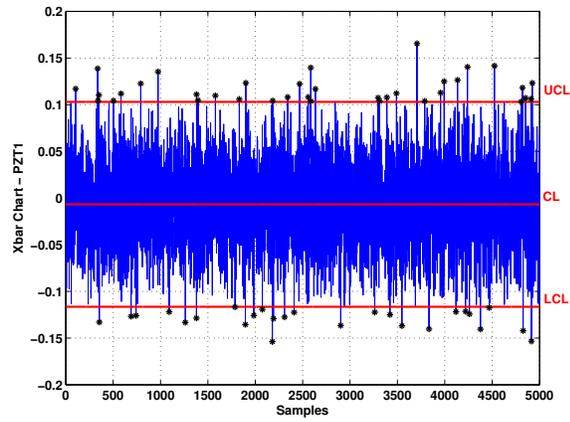
saudável. A figura 6.20(a) mostra o sinal de erro de predição na condição saudável que não foi usado para construir o modelo de referência (avaliação de falso-positivo), constata-se neste exemplo um número de *outliers* inferior ao valor *threshold*. As figuras 6.20(b) e 6.20(c) apresentam exemplos de casos para o dano 1 e danos 2 no PZT1⁷, onde o número de *outliers* em ambos é superior a 50 pontos, detectando uma variação estrutural. Já a figura 6.20(d) mostra um exemplo quando a estrutura foi reparada, neste caso o número de *outliers* ainda é inferior ao limite indicando condição estrutural saudável, porém o número de pontos é alto e próximo ao valor limite. Por fim, as figuras 6.20(e) e 6.20(f) exemplificam os casos para os danos próximos a junção do PZT2, danos 3 e danos 4. O número de pontos fora do limite de controle foi superior ao valor limiar, detectando portanto a ocorrência de dano.

Uma análise similar é feita para os dados provenientes do modelo ARMAX para o PZT2. A figura 6.21 mostra os dados de referência, onde o número de *outliers* indica condição sem dano. Já

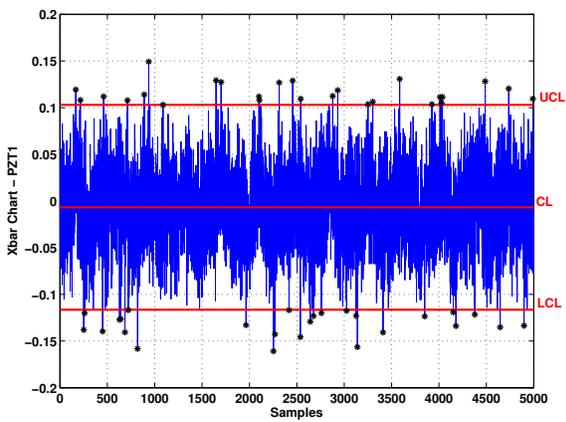
⁷Veja tabela 6.4.



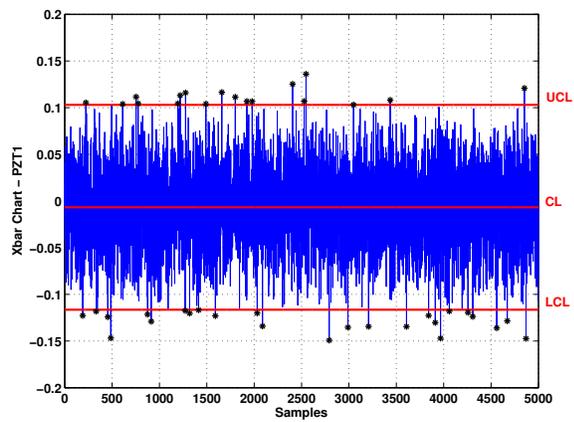
(a) Teste falso-positivo com 16 *outliers* (sem dano).



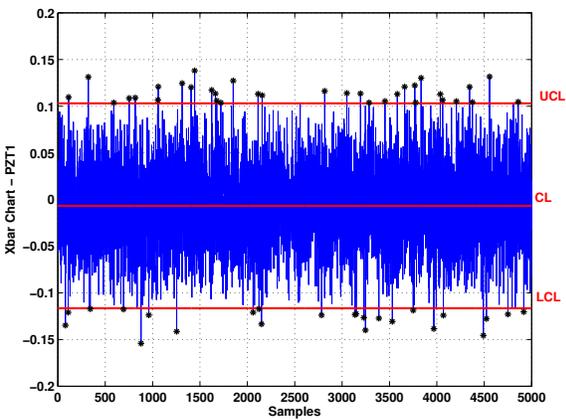
(b) Dano 1 com 62 *outliers*.



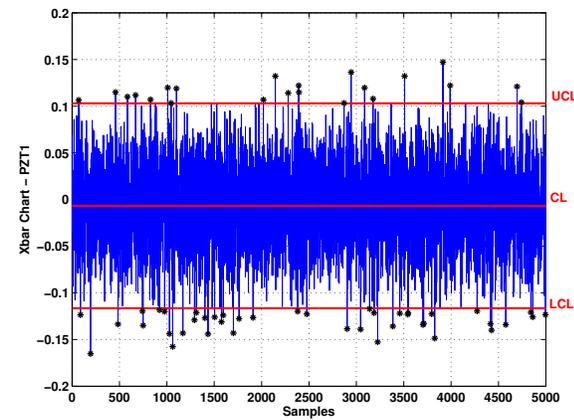
(c) Dano 2 com 52 *outliers*.



(d) Condição da estrutura reparada com 43 *outliers* (sem dano).



(e) Dano 3 com 58 *outliers*.



(f) Dano 4 com 64 *outliers*.

Fig. 6.20: Erros ARMAX para o PZT1 considerando várias condições estruturais. O valor limiar para o dano é de 50 *outliers*.

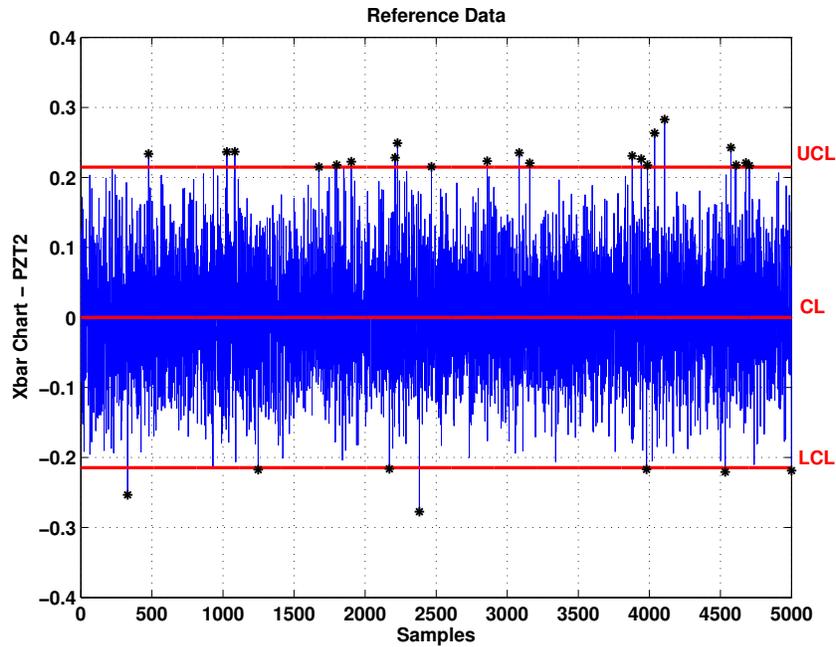
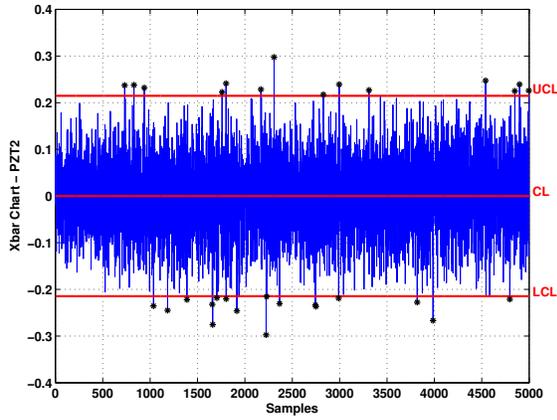


Fig. 6.21: Erro de predição ARMAX para o sinal de referência no PZT2. O número de *outliers* mostra condição normal (28 *outliers*).

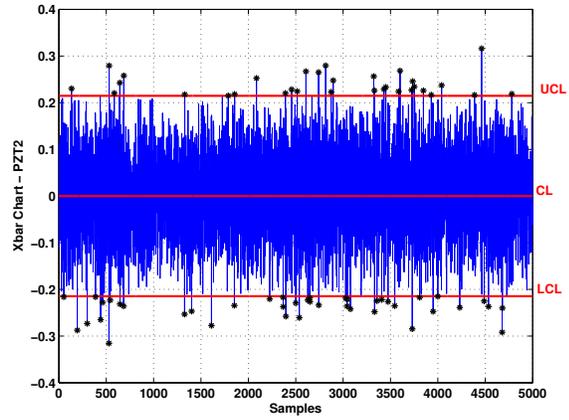
as figuras 6.22(a), 6.22(b), 6.22(c), 6.22(d), 6.22(e) e 6.22(f) apresentam os casos gerais⁸, onde se vê que o número de *outliers* para os danos 1, 2, 3 e 4 indicam condição estrutural com dano e para a estrutura reparada um estado saudável.

As figuras 6.23(a) e 6.23(b) apresentam os valores de *outliers* para todos os casos estudados da tabela 6.4. Observa-se que há uma tendência para detectar que a variação ocorreu próxima ao PZT1 no caso do dano 1(cd1) e próxima ao PZT2 nos danos 3 (cd3) e 4 (cd4), pois o número de pontos outliers é maior no PZT1 para o dano 1 e maior para o PZT2 para os danos 3 e 4. Observa-se um caso de falso-negativo de dano cd1 para o PZT1 e PZT2, respectivamente. Contudo no caso do dano 2 (cd2), apesar de se detectar que houve variação da ocorrência de dano, não foi possível localizar corretamente. Analisando as figuras 6.23(a) e 6.23(b) observou-se que houve maior variação do indicador no PZT2 do que no PZT1, o que daria a entender que o dano cd2 é próximo a região do PZT2, o que não é verdade. Assim, constata-se a ocorrência de falsa localização do dano.

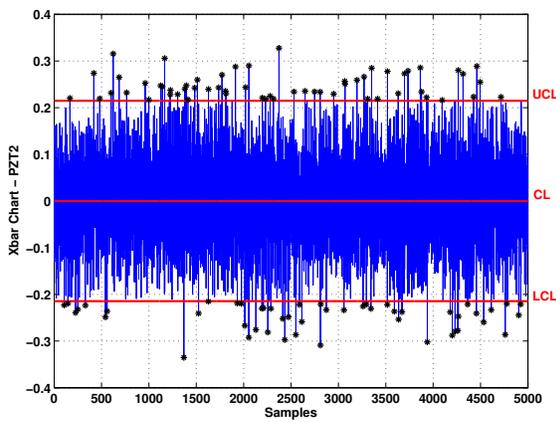
⁸Correspondentes a alguns dos testes realizados.



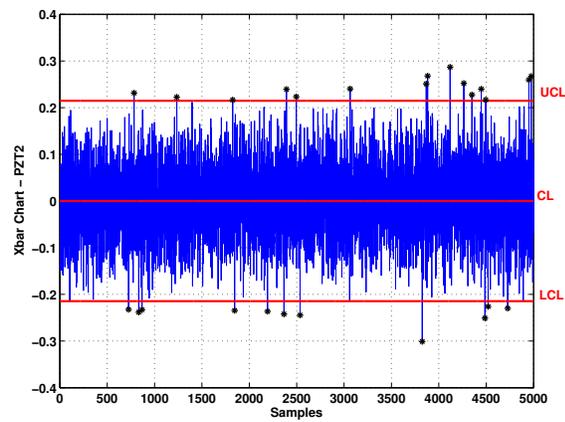
(a) Teste falso-positivo com 31 *outliers* (sem dano).



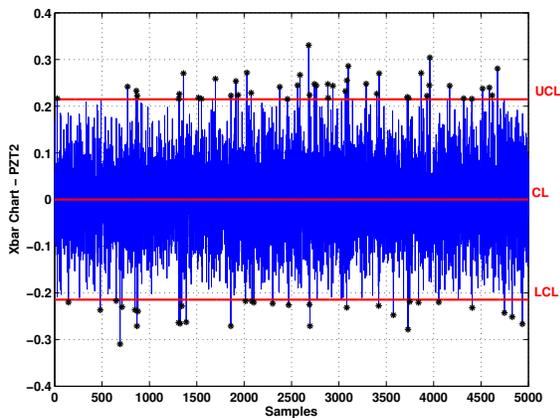
(b) Dano 1 com 74 *outliers*.



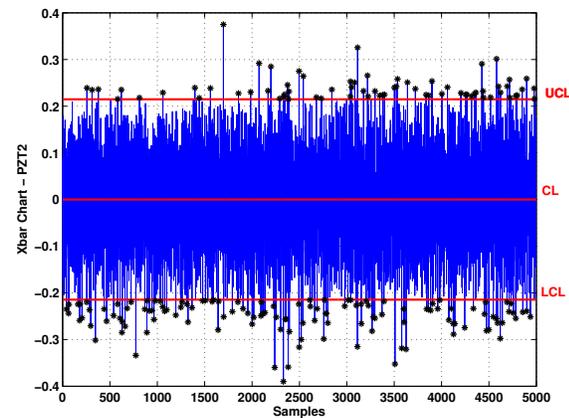
(c) Dano 2 com 109 *outliers*.



(d) Condição da estrutura reparada com 26 *outliers* (sem dano).



(e) Dano 3 com 76 *outliers*.



(f) Dano 4 com 198 *outliers*.

Fig. 6.22: Erros ARMAX para o PZT2 considerando várias condições estruturais. O valor limiar para o dano é de 50 *outliers*.

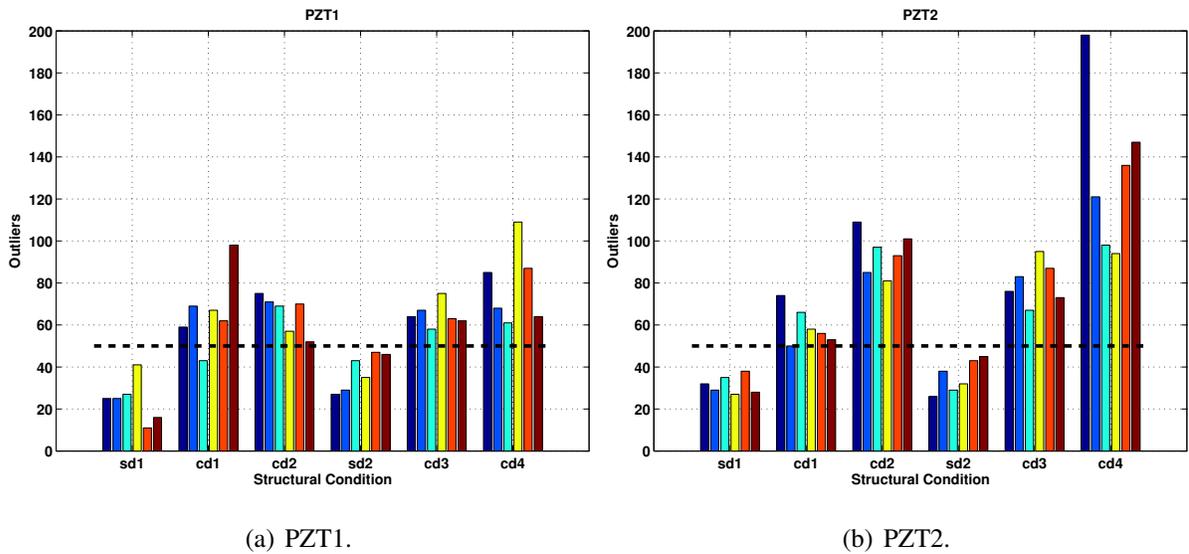


Fig. 6.23: Número de *outliers* para todas as condições estudadas na estrutura portal. A linha pontilhada — se refere ao valor limiar de 50 pontos.

Verifica-se também que os dados da estrutura reparada são bem correlacionados a condição sem dano e que os valores aumentam em relação a condição baseline sd1 em ambos os PZTs. Constata-se também que mesmo com um número maior de testes do que no exemplo da seção 6.1 não foi possível obter informações conclusivas sobre a severidade do dano. Entretanto, a detecção de variações é superior ao uso do indicador M da seção 6.2.2.

6.2.4 Diagnóstico usando modelos de Kautz-Volterra

Esta seção apresenta resultados para detecção usando os erros de predição linear e não-linear obtidos da série de Kautz-Volterra com os dois primeiros kernels. O primeiro passo é estimar os kernels de Volterra com base nos dados de entrada e saída em cada PZT considerando a condição estrutural saudável. Para efeito de apenas ilustração, será apresentado somente os sinais referentes ao PZT1. Somente 5 sinais são usados, um correspondente à condição sem dano⁹, um par de entrada/saída na condição sem dano para detectar se há ocorrência de falso-positivo, um par de sinais com dano 1, um par de sinais de entrada/saída na condição reparada (sem dano) e por fim um sinal na condição com o dano 4 inserido.

⁹Usado para estimar os dois primeiros kernels de Volterra.

Os sinais de entrada e saída são então normalizados em um intervalo de -1 à 1, conforme o exemplo experimental feito no trabalho [16] para se minimizar problemas de convergência e condicionamento numérico, e os dados filtrados em uma faixa de frequência contendo o maior número de picos no sinal de impedância eletromecânica. O modelo de Kautz-Volterra construído conteve apenas um pólo dominante em torno da frequência de 29 kHz, escolhida a partir da figura 6.16. Este pólo foi escolhido com base no sinal de impedância eletromecânica e no modelo ARMAX obtido na seção anterior para o PZT1. Este pólo no plano z é dado por $0.7273 \pm j0.6730$. Como base neste pólo se calculam os parâmetros b e c do filtro de Kautz e as respostas ao impulso deste conjunto de filtros. Empregou-se $M_1 = 2$ e $M_2 = 2$ para se estimar os kernels de Kautz $\alpha_1(i_1)$ e $\alpha_2(i_1, i_2)$. As estimativas destes kernels são dados por:

$$\alpha_1 = \begin{bmatrix} -0.6414 & -0.2637 \end{bmatrix} \quad (6.1)$$

$$\alpha_2 = 10^{-3} \times \begin{bmatrix} 0.5850 & -0.0051 \\ -0.0051 & -0.1126 \end{bmatrix} \quad (6.2)$$

Com as resposta ao impulso do filtro de Kautz projetou-se estes kernels para o espaço físico através das Eqs. (3.44) e (3.45). Para estimação dos kernels de Volterra no espaço físico se assumiu que estes são estabilizados após $N_1 = 600$ amostras para o 1.º kernel e $N_2 = 300$ amostras para o 2.º kernel, além de considerar que os kernels são simétricos para simplificar a estimação. Com a Eq. (3.51) observa-se que o número de parâmetros a estimar no modelo de Kautz-Volterra é $N_w = 5$. Caso se tivesse empregado a formulação clássica de Volterra deveriam ser estimados pela Eq. (3.39) $N_p = 45750$ parâmetros, um número bem superior.

As figuras 6.24 e 6.25 apresentam as estimativas dos dois primeiros kernels de Volterra. Por não se ter um modelo matemático do sistema de interesse, não pôde-se comparar estas estimativas com valores analíticos.

A figura 6.26 compara as estimativas do sinal $x(k)$ a partir dos kernels $h_1(n_1)$ e $h_2(n_1, n_2)$ com o sinal real medido experimentalmente para a condição sem dano de referência. Os modelos de referência com o 1.º e o 2.º kernel de Volterra são usados para monitorar os outros estados admitidos como desconhecidos. A figura 6.27(a) apresenta a função densidade de probabilidades (PDF) para o erro

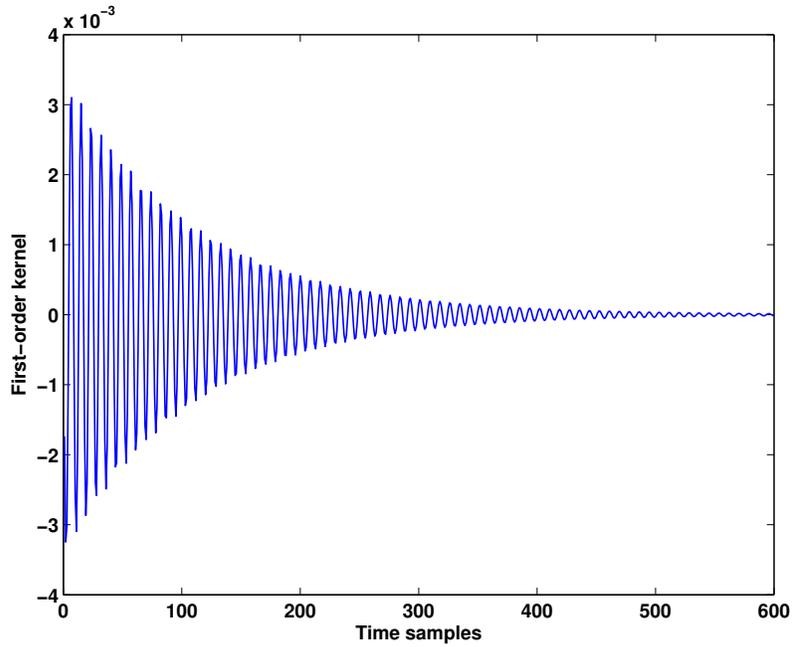


Fig. 6.24: Primeiro kernel de Volterra $h_1(n_1)$ estimado para o PZT1 na condição sem dano sd1.

usando apenas a predição linear com o 1.º kernel de Volterra. Esta PDF é estimada usando o método *Kernel Smoothing*¹⁰[8]. Na figura 6.27(b) pode se observar um *zoom* deste gráfico, onde constata-se que não há muita discriminação entre a condição baseline1, sem dano, com dano 1, reparada e com dano 4. Entretanto, quando se realiza a predição não-linear envolvendo os dois primeiros kernels de Volterra, observa-se uma maior variação entre os estados com dano e sem dano, como mostrado nas figuras 6.28(a) e 6.28(b).

A tabela 6.5 mostra o cálculo dos indicadores das Eqs. (3.65) e (3.66) e os valores dos desvios padrões dos erros de predição feitos considerando o primeiro kernel ($\sigma(e_{lin})$) e considerando os dois primeiros kernel ($\sigma(e_{nl})$).

O valor de referência no baseline1 é o valor unitário. Analisando os resultados da tabela 6.5 verifica-se que ambos os erros são diferentes e que seria possível realizar a discriminação da ocorrência de variação estrutural apenas como o indicador linear γ_{lin} , apesar do valor correspondente ao teste de falso-positivo e dano 2 não serem bem correlacionados com a correta condição estrutural.

¹⁰Função do *toolbox* de estatística do Matlab® *ksdensity*.

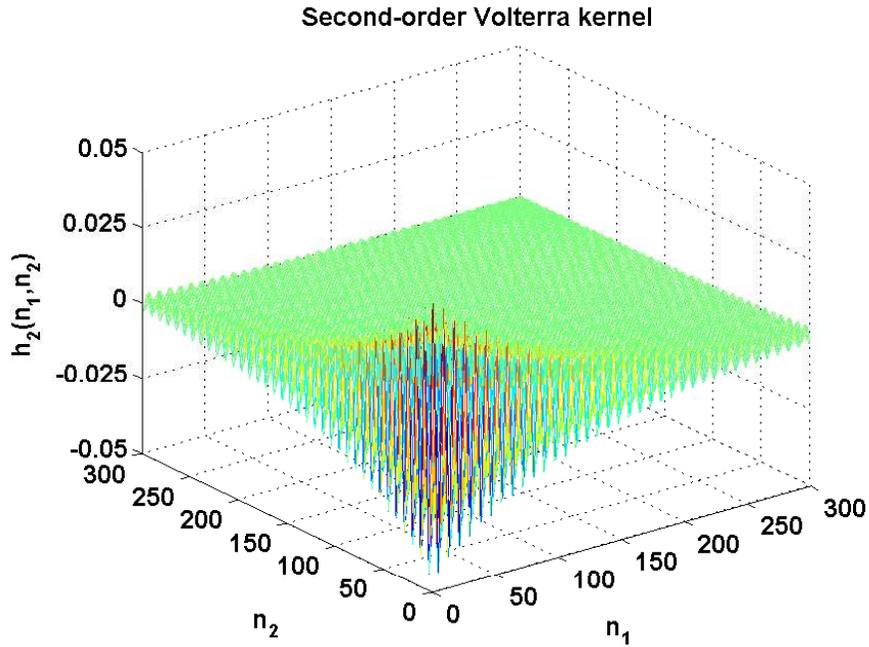


Fig. 6.25: Segundo kernel de Volterra $h_2(n_1, n_2)$ estimado para o PZT1 na condição sem dano sd1.

Tab. 6.5: Resultados da detecção com modelos de Kautz-Volterra.

Condição	$\sigma(e_{nl})$	$\sigma(e_{lin})$	γ_{nl}	γ_{lin}
Baseline1(referência)	0.3214	0.3051	1.0	1.0
Falso-positivo	0.3268	0.3111	1.0168	1.0197
Dano 1	0.3288	0.3103	1.023	1.017
Reparada	0.3239	0.3066	1.0078	1.0049
Dano 4	0.3355	0.3165	1.0439	1.0374

Porém, o indicador não-linear γ_{nl} mostra uma melhor tendência com relação a ocorrência de variação estrutural.

É importante destacar que as variações que ocorreram nestes indicadores são pequenas, por exemplo o γ_{nl} variou de 1.0168 na condição para o teste de falso-positivo para $\gamma_{nl} = 1.023$ na condição do

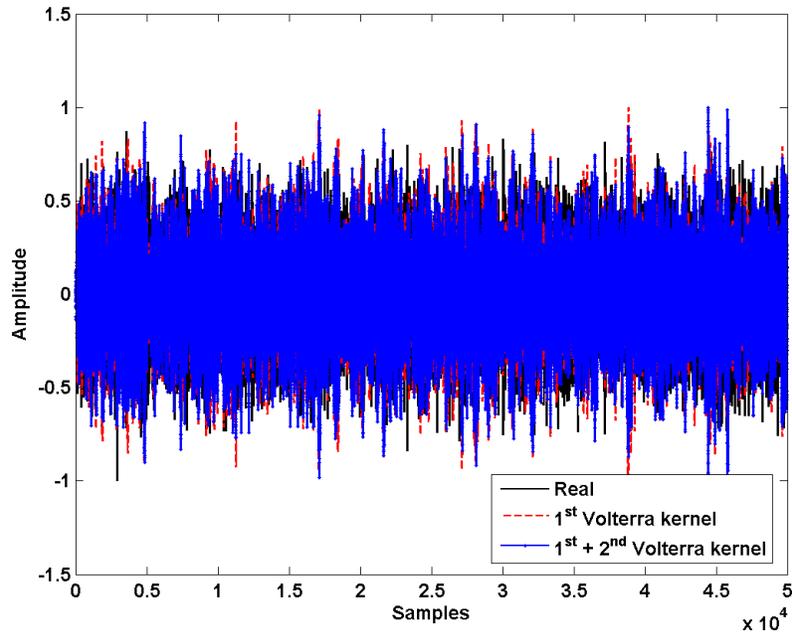


Fig. 6.26: Comparação do sinal real $x(k)$ e as estimativas com o 1.º e 2.º kernel de Volterra.

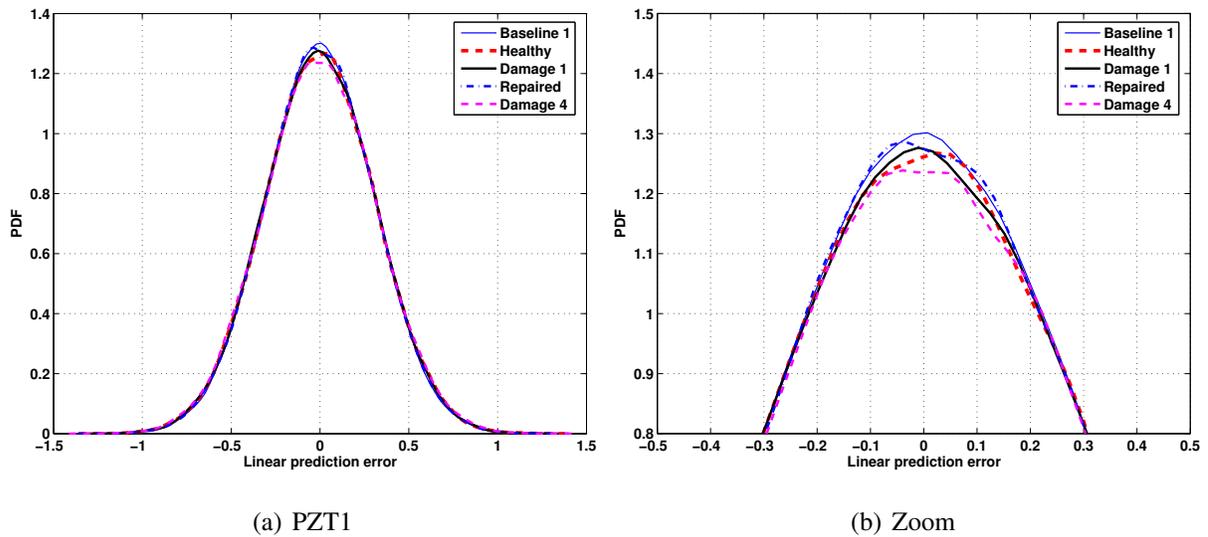


Fig. 6.27: Comparação das funções densidade de probabilidades para o PZT1 usando predição linear somente com o 1.º kernel $h_1(n_1)$ de Volterra.

dano 1. Esta pequena variação pode ser explicada pelo fato de se usar um filtro de Kautz com informação de apenas um par de pólos complexos $z = 0.7273 \pm j0.6730$. Assim, as variações estruturais

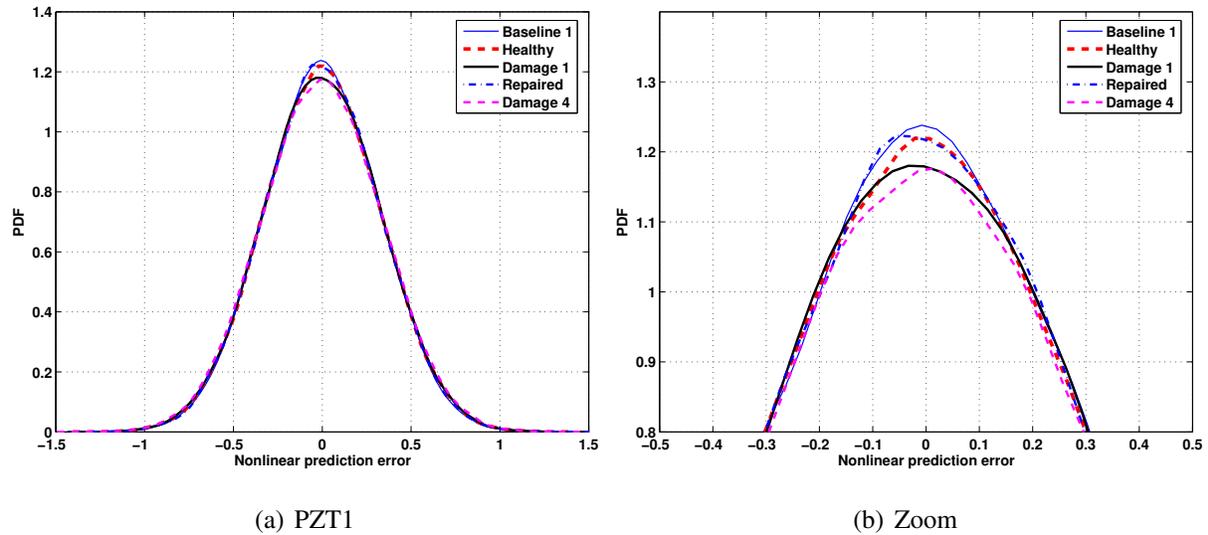


Fig. 6.28: Comparação das funções densidade de probabilidades para o PZT1 usando predição não-linear com o 1.º e 2.º kernel de Volterra, $h_1(n_1)$ e $h_2(n_1, n_2)$ respectivamente.

impostas no teste através dos apertos e desapertos podem não influenciar este pólo e, consequentemente, o indicador não ter uma variação significativa para dar um diagnóstico preciso se houve ou não a ocorrência de um defeito estrutural.

6.2.5 Conclusões

Este teste mostrou a detecção de danos usando uma estrutura formada por subestruturas com junções parafusadas entre as partes. Três métodos foram testados:

1. Uso do sinal de impedância eletromecânica nos PZTs e o desvio RMS entre curvas.
2. SPC do erro de predição linear de um filtro ARMAX de referência.
3. Análise dos indicadores γ_{lin} e γ_{nl} envolvendo erros de predição linear e não-linear extraídos de modelos de Kautz-Volterra.

Apesar de problemas já comentados anteriormente, os métodos foram gerais e permitiram um bom diagnóstico da saúde estrutural do sistema em estudo, apesar da dificuldade de se trabalhar com

estruturas parafusadas. Em especial, a formulação envolvendo modelos de Kautz-Volterra mostrou ser capaz de detectar variações estruturais se assumindo que a relação entre as voltagens de entrada e saída no PZT apresenta uma relação não-linear descrita de forma não-paramétrica pelo 2.º kernel de Volterra. Entretanto, para uma aplicação real será fundamental se desenvolver um filtro de Kautz generalizado com mais de um par de polos complexos, uma vez que o dano pode não afetar a variação de somente um par de pólos, como no filtro descrito nesta tese. Com isto espera-se que as variações dos indicadores γ_{lin} e γ_{nl} seja maior.

6.3 Observações finais

Após os exemplos experimentais usando estruturas inteligentes apresentados neste capítulo, pode-se destacar sucintamente as seguintes observações já discutidas anteriormente:

- O uso de métricas de falha RMSD de sinais de impedância eletromecânica é dependente da faixa de frequência e de duas estimativas não-paramétricas, uma na referência e outra em situação desconhecida.
- A utilização dos erros de predição de modelos ARMAX facilita o diagnóstico, uma vez que o procedimento fica dependente apenas da filtragem dos erros desconhecidos com estes sistemas previamente identificados com os sinais de referência.
- O modelo de Kautz-Volterra admite a hipótese de que o sistema se comporte de forma não-linear na condição de referência e, portanto, permite detectar variações estruturais que eventualmente afetem parâmetros não-lineares concentrados.
- O uso de SPC se mostra útil para um rápido diagnóstico inicial com boa informação e confiança na identificação da presença e localização dos danos analisados nas aplicações experimentais deste capítulo, que envolveram entalhes e apertos/desapertos em junções parafusadas.

Capítulo 7

Considerações Finais

Neste capítulo são feitas as conclusões gerais alcançadas por este trabalho de doutorado. Também são apresentadas algumas sugestões para futuros trabalhos de pesquisas.

7.1 Conclusões

Esta tese avaliou o uso de séries temporais de sinais de vibração ou voltagens de PZTs e sua discriminação nas classes sem dano ou com dano usando ferramentas de agrupamento não-supervisionado. Cinco exemplos ilustraram os resultados e são mostrados na tabela 7.1. A maior parte destes exemplos foram publicados em periódicos e anais de congressos durante a execução deste trabalho.

Como contribuições originais, este trabalho de doutorado apresentou os seguintes tópicos:

1. Comparação de algoritmos de reconhecimento de padrões em modo não-supervisionado para SHM.
2. Uso direto de séries temporais de sinais de entrada-saída de voltagens aplicadas em cerâmicas piezelétricas como métricas para dano estrutural.
3. Utilização de modelos discretos de Volterra com filtros de Kautz para predição de sinais e aplicações SHM.

Tab. 7.1: Exemplos utilizados na tese.

Exemplo	Natureza	Modelo	Método
Estrutura ASCE	Numérico	AR-ARX	FCM/GK
Estrutura LANL	Experimental	ARMA	FCM/GK
Rotor Vertical	Numérico	AR-ARX	SPC/ γ
Viga com PZTs	Experimental	ARMAX	RMSD/SPC
<i>Frame</i> com PZTs	Experimental	ARMAX/Kautz-Volterra	RMSD/SPC/ γ_{nl}

A formulação desenvolvida apresentou como pontos favoráveis as características a seguir:

- Possibilidade de realizar o diagnóstico apenas se conhecendo dados na condição sem dano e construindo um modelo auto-regressivo para estes dados. O método se baseia totalmente em uma formulação não-supervisionada, o que é extremamente desejável para aplicações envolvendo estruturas reais.
- Facilidade para programação automática do diagnóstico pelo uso de filtros digitais.
- Indicador de danos representado por duas séries temporais, uma o erro de predição de referência e outra pelo erro de predição em uma condição desconhecida. Isto permite uma enorme liberdade para proposição de técnicas de discriminação de classes, seja pelo uso de agrupamento fuzzy ou controle estatístico de processos.
- Modelos de Kautz-Volterra permitem detectar danos com base em sistemas que se comportem de forma não-linear na condição saudável e com variações estruturais que afetem termos não-lineares do sistema. Métodos lineares não permitem realizar estas detecções.

Entretanto, as metodologias propostas e investigadas nesta tese também apresentam pontos que devem ser melhor estudados e minimizados no futuro, entre eles:

- Grande dependência das ordens usadas pelos modelos de séries temporais para realizar a predição. Caso não se escolha ordens adequadas toda a análise pode ser comprometida.
- Deve se tomar cuidados quando da realização de compressão espacial de dados usando a decomposição de Karhunen-Loève, pois os danos podem não ser relacionados aos componentes principais utilizados na projeção.
- O uso de modelos de Kautz-Volterra com apenas um par de pólos complexos pode não detectar corretamente a variação estrutural caso ela não seja refletida por este pólo.
- O número de filtros de Kautz usado também influencia a estimativa dos kernels de Volterra e conseqüentemente a predição dos sinais e o indicador de variação.

No que diz respeito aos dois métodos de discriminação de classes investigados, agrupamento fuzzy versus controle estatístico de processos (SPC), o SPC não necessita de um conjunto de dados em batelada, como no caso do agrupamento fuzzy, e portanto em um primeiro momento pode ser o método escolhido para uma aplicação envolvendo uma estrutura ou um sistema real.

7.2 Sugestões para futuros trabalhos

Os resultados desta tese abrem diversos horizontes de pesquisa para SHM. Além das considerações e sugestões já propostas nos capítulos 5 e 6 podem ser feitas extensões globais para trabalhos futuros. Entre todos os tópicos imediatos que podem vir a ser implementados, se destacam:

1. Considerar modelos não-lineares de Kautz-Volterra com capacidade para trabalhar com múltiplos pólos.
2. Aplicar análise de confiabilidade, propondo modelos de predição linear com confiança estatística.
3. Implementação em *hardware* dos filtros discretos de predição para avaliação *in situ* da metodologia em uma estrutura real, assim como transmissão sem fios das informações referentes aos danos para alguma estação de trabalho ou processador dedicado.

4. Investigação da correlação entre os coeficientes de modelos de predição e a severidade do dano e suas possibilidades de uso para prognóstico aliado à algum método de ajuste de modelos dinâmicos.
5. Utilização de modelos de predição linear para detecção de danos em máquinas rotativas e turbomáquinas.
6. Substituição do uso de PZTs por sensores piezopolímeros, como o PVDF¹ por serem mais baratos.
7. Analisar a influência da implementação dos modelos de predição em filtros digitais, ou seja, investigar formas de programação digital diversas² e efeitos de quantização dos coeficientes destes filtros em aritmética finita quando programados em processadores comerciais. Deve-se realizar um estudo minucioso para ver se estes efeitos podem comprometer a tarefa de detecção de variação estrutural.

No que diz respeito as sugestão dos itens (3) e (7), seria interessante que um trabalho nesta linha fosse estudado em conjunto com algum grupo de pesquisa com formação específica em engenharia elétrica para um maior intercâmbio de experiência.

Seria interessante também que a sugestão (4) levasse em consideração ajuste de modelos não-lineares em parâmetros localizados, como exemplo, juntas parafusadas ou regiões de contato, que além de apresentarem possíveis comportamentos não-lineares podem sofrer com modificação estrutural relacionada com a presença de danos. O trabalho de Silva et al. [68] apresenta uma relação de técnicas úteis para ajuste de modelos não-lineares que podem ser bem aplicadas e adaptadas para problemas SHM. O próprio uso de kernels de Kautz-Volterra podem ser usados como função objetivo para ajuste de parâmetros não-lineares concentrados, conforme proposto originalmente em [67].

Com relação ao item (5) a empresa Sulzer S/A demonstrou interesse em implementar o uso de filtros discretos e SPC para monitoramento de condição em algumas bombas hidráulicas que apre-

¹PolyVinylidene Fluoride.

²Como forma direta I, forma direta II, implementações em séries, paralelo, etc.

sentam sérios problemas de diagnóstico apenas com análise convencional usando valores *overall* e análise espectral.

Uma vez implementados e desenvolvidos satisfatoriamente estes tópicos, poderia se obter uma técnica híbrida para se atingir os quatro níveis básicos de um problema SHM. Uma primeira etapa para detectar e localizar o dano, através de um modelo não-linear de Kautz-Volterra com alguma técnica de separação de classes. Em seguida realizar um ajuste de modelos não-lineares com o propósito de quantificar e obter um prognóstico, assumindo como hipótese³ o conhecimento da região onde houve variação estrutural e em quais parâmetros físicos⁴ ela ocorreu.

³Além da hipótese básica de se ter um modelo não-linear perfeitamente ajustado para a condição sem dano.

⁴Com o propósito de se conhecer os parâmetros do ajuste do modelo.

Referências Bibliográficas

- [1] D. E. Adams and R. J. Allemang. Discrete frequency models: a new approach to temporal analysis. *Journal of Vibration and Acoustic*, 123(1):98–103, 2001.
- [2] L. A. Aguirre. *Introdução à Identificação de Sistemas - Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*. Editora UFMG, 2.º edition, 2004.
- [3] R. Babuska, P. J. Van der Veen, and U. Kaymak. Improved covariance estimation for gustafson-kessel clustering. In *IEEE International Conference on Fuzzy System*, pages 1081–1085, 2002.
- [4] E. Bedrosian and S. O. Rice. The output properties of volterra systems driven by harmonic and gaussian inputs. In *IEEE 59*, pages 1688–1707, 1971.
- [5] J. Bezdek. *Pattern Recognition with Fuzzy Objective Function Algorithm*. Plenum Press, 1981.
- [6] J. Bezdek and S. Pal. *Fuzzy Models for Pattern Recognition*. IEEE Press, 1992.
- [7] J. B. Bodeux and J. C. Golinval. Application of armav models to the identification and damage detection of mechanical and civil engineering structures. *Smart Materials and Structures*, 10(3):479–489, 2001.
- [8] A. W. Bowman and A. Azzalini. *Applied Smoothing Techniques for Data Analysis*. Oxford University Press, 1997.
- [9] D. D. Bueno, C. R. Marqui, R. B. Santos, S. Silva, and V. Lopes Junior. False alarms in damage detection approaches. In *IMAC-XXVI: A Conference and Exposition on Structural Dynamics*, 2008.

- [10] D. D. Bueno, S. Silva, C. R. Marques, and V. Lopes Junior. Comparative study of damage-sensitive indexes for structural health monitoring of smart structures. In *19th International Congress of Mechanical Engineering - COBEM*, 2007.
- [11] P. E. Carden and P. Fanning. A vibration based condition monitoring: a review. *Structural Health Monitoring - An International Journal*, 3(4):355–377, 2004.
- [12] H. F. Castro, K. L. Cavalca, and B. D. Mori. Journal bearing orbits fitting with hybrid metaheuristic method. In *18th International Congress of Mechanical Engineering*, 2005.
- [13] F. K. Chang. Structural health monitoring. In *Proceedings of 2nd International Workshop on Structural Health Monitoring*, Standford, CA, USA, 2000.
- [14] A. Chatterjee and N. S. Vyas. Non-linear parameter estimation in multi-degree-of-freedom systems using multi-input volterra series. *Mechanical Systems and Signal Processing*, 18:457–489, 2004.
- [15] M. S. Cho and K. J. Kim. Indirect input identification in multisource environments by principal component analysis. *Mechanical Systems and Signal Processing*, 16(5):873–883, 2002.
- [16] Alex da Rosa. Desenvolvimento de modelos discretos de volterra usando funções de kautz. Master’s thesis, Universidade Estadual de Campinas (UNICAMP) - Faculdade de Engenharia Elétrica e de Computação, 2005.
- [17] Alex da Rosa, R. J. G. B. Campello, and W. C. Amaral. Choice of free parameters in expansions of discrete-time volterra models using kautz functions. *Automatica*, 43:1084–1091, 2007.
- [18] Folha de São Paulo. Queda de ponte sobre rio mississipi mata pelo menos seis pessoas <<http://www1.folha.uol.com.br/folha/mundo/ult94u317>>, Agosto 2007.
- [19] P. M. J. Van den Hof, P. S. C. Heuberger, and J. Bokors. System identification with generalized orthonormal basis functions. *Automatica*, 31(12):1821–1834, 1995.
- [20] P. S. R. Diniz, E. A. B. Silva, and S. Lima Netto. *Digital Signal Processing*. Bookman Company, 1st edition, 2004.

- [21] S. W. Doebling, C. R. Farrar, and M. B. Prime. A summary review of vibration-based damage identification methods. *The Shock and Vibration Digest*, 30(2):91–105, 1998.
- [22] J. F. Doyle. *Wave Propagation in Structures - an FFT-based Spectral Analysis Methodology*. Springer-Verlag, 1998.
- [23] S. J. Dyke, D. Bernal, J. L. Beck, and C. Ventura. An experimental benchmark problem in structural health monitoring. In *3rd International Workshop on Structural Health Monitoring*, 2001.
- [24] C. A. Eduardo. *Fault diagnosis in rotor systems through correlation analysis and artificial neural networks (in portuguese)*. PhD thesis, Faculdade de Engenharia Mecânica - UNICAMP, 2003.
- [25] C. R. Farrar and H. Sohn. Pattern recognition for structural health monitoring. In *Workshop on Mitigation of Earthquake Disaster by Advanced Technologies*, Las Vegas, NY, USA, 2000.
- [26] S. D. Fassois and J. S. Sakellariou. Time-series methods for fault detection and identification in vibrating structures. *Philosophical Transactions of the Royal Society*, 365:411–448, 2007.
- [27] B. F. Feeny and R. Kappagantu. On the physical interpretation of proper orthogonal modes in on the physical interpretation of proper orthogonal modes in vibration. *Journal of Sound and Vibrations*, 211(4):607–616, 1998.
- [28] B. F. Feeny and Y. Liang. Interpreting proper orthogonal modes of randomly excited vibration systems. *Journal of Sound and Vibrations*, 265(5):953–966, 2003.
- [29] M. L. Fugate, H. Sohn, and C. R. Farrar. Unsupervised learning methods for vibration-based damage detection. In *18th International Modal Analysis Conference - IMAC*, 2000.
- [30] M. L. Fugate, H. Sohn, and C. R. Farrar. Vibration-based damage detection using statistical process control. *Mechanical Systems and Signal Processing*, 15(4):702–721, 2001.
- [31] R. M. Furtado and V. Lopes Junior. Damage location in smart structures using low cost impedance measurements. In *XI International Symposium on Dynamics Problems of Mechanics (DINAME)*, 2005.

- [32] R. Ganguli. Noise and outlier removal from jet engine health signals using weighted fir median hybrid filters. *Mechanical Systems and Signal Processing*, 16(6):967–978, 2002.
- [33] D. J. Inman. Smart structures: examples and new problems. In *Proceedings of 16th Brazilian Congress of Mechanical Engineering*. UFU/Uberlândia, 2001.
- [34] D. J. Inman, C. R. Farrar, V. Lopes Junior, and V. Steffen Junior. *Damage Prognosis for Aerospace, Civil and Mechanical Systems*, volume 1. John Wiley Sons, 2005.
- [35] E. A. Johnson, H. F. Lam, L. S. Katafygiotis, and J. L. Beck. A benchmark problem for structural health monitoring and damage detection. In *14th Engineering Mechanics Conference*, 2000.
- [36] J. R. Moura Junior and V. Steffen Junior. Impedance-based health monitoring for aeronautic structures using statistical meta-modeling. *Journal of Intelligent Material Systems and Structures*, 17:1023–1036, 2006.
- [37] V. Lopes Junior, H. H. Müellerslany, F. Brunzel, and D. J. Inman. Damage detection in structures by electrical impedance and optimization technique. volume 89. Kluwer Academic Publishers, 2001.
- [38] V. Lopes Junior, G. Park, H. H. Cudney, and D. J. Inman. Impedance based structural health monitoring with artificial neural networking. *Journal of Intelligent Material Systems and Structures*, 11:206–214, 2000.
- [39] C. H. Keilers and F. K. Chang. Identifying delamination in composite beams using built-in piezoelectrics. *Journal of Intelligent Material Systems and Structures*, 6:649–672, 1995.
- [40] E. Keller and A. Ray. Real-time health monitoring of mechanical structures. *Structural Health Monitoring - An International Journal*, 2(3):191–203, 2003.
- [41] G. Kerschen and J. C. Golinval. Physical interpretation of the proper orthogonal modes using the singular values decomposition. *Journal of Sound and Vibrations*, 249(5):849–865, 2002.
- [42] M. H. Kim. A smart health monitoring system with application to welded structures using piezoceramic and fiber optic transducers. *Journal of Intelligent Material Systems and Structures*, 17:35–44, 2006.

- [43] Y. Lei, A. S. Kiremidjian, K. K. Nair, J. P. Lynch, K. H. Law, T. W. Kenny, E. Carryer, and A. Kottapalli. Statistical damage detection using time series analysis on a structural health monitoring benchmark problem. In *9th International Congress on Applications of Statistical and Probability in Civil Engineering*, 2003.
- [44] L. Ljung. *System Identification: Theory for the User*. Prentice Hall, 2.º edition, 1998.
- [45] Y. Lu and F. Gao. A novel time-domain auto-regressive model for structural damage diagnosis. *Journal of Sound and Vibrations*, 283:1031–1049, 2005.
- [46] J. P. Lynch. Detection of structural cracks using piezoelectric active sensors. In *ASCE Engineering Mechanics Conference - EM2004*, 2004.
- [47] S. G. Mattson and S. M. Pandit. Statistical moments of autoregressive model residuals for damage localisation. *Mechanical Systems and Signal Processing*, 20(3):627–645, 2006.
- [48] G. P. Melo and G. F. Lemos. Fault diagnosis in rotation system using well conditioned state observer. In *22th IMAC - A Conference on Structural Dynamics*, 2004.
- [49] J. S. Mitchell. *Introduction to machinery analysis and monitoring*. PenWell Books, 1993.
- [50] D. C. Montgomery. *Introduction to Statistical Quality Control*. John Wiley Sons, 3.º edition, 1996.
- [51] E. Moulin, J. Assaad, C. Delebarre, and D. Osmont. Lamb waves generation using transducer embedded in a composite plate. In *Proceedings of 12th International Conference on Composite Materials*, Paris, 1999.
- [52] K. K. Nair, A. S. Kiremidjian, and K. H. Law. Time series-based damage detection and localization algorithm to the asce benchmark structure. *Journal of Sound and Vibrations*, 291:349–368, 2006.
- [53] G. H. C. Oliveira and W. C. Amaral. Identificação e controle preditivos de processos não-lineares utilizando séries de volterra e bases de funções ortonormais. In *XIII Congresso Brasileiro de Automática*, Florianópolis-SC-Brasil, 2000.

- [54] G. Park, H. H. Cudney, and D. J. Inman. An integrated health monitoring technique using structural impedance sensors. *Journal of Intelligent Material Systems and Structures*, 11:448–455, 2000.
- [55] G. Park, A. C. Rutherford, H. Sohn, and C. R. Farrar. An outlier analysis framework for impedance-based structural health monitoring. *Journal of Sound and Vibrations*, 286:229–250, 2005.
- [56] G. Park, H. Sohn, C. R. Farrar, and D. J. Inman. Overview of piezoelectric impedance-based health monitoring and path forward. *Shock and Vibration Digest*, 35(6):451–463, 2003.
- [57] P. M. Pawar and R. Ganguli. Genetic fuzzy system for online structural health monitoring of composite helicopter rotor blades. *Mechanical Systems and Signal Processing*, 21:2212–2236, 2007.
- [58] D. M. Peairs. *High Frequency Modeling and Experimental Analysis for Implementation of Impedance-based Structural Health Monitoring*. PhD thesis, Virginia Polytechnic Institute and State University, 2006.
- [59] D. M. Peairs, G. Park, and D. J. Inman. Improving accessibility of the impedance-based structural health monitoring method. *Journal of Intelligent Material Systems and Structures*, 15:129–139, 2004.
- [60] D. M. Peairs, P. A. Tarazaga, and D. J. Inman. A study on the correlation between pzt and mfc resonance peaks and damage detection frequency intervals using the impedance method. In *International Conference of Noise and Vibration Engineering - ISMA 2006*, pages 909–924, 2006.
- [61] J. A. Pereira, W. Heylen, and P. Sas. Model updating and failure detection based on experimental frfs: case study in space frame structure. In *19th International Conference on Noise and Vibration Engineering (ISMA)*, pages 669–681, Leuven, Belgium, 1994.
- [62] J. L. Rose. *Ultrasonic Waves in Solid Media*. Cambridge University Press, New York, 1999.

- [63] W. J. Rugh. *Nonlinear System Theory – The Volterra/Wiener Approach*. The Johns Hopkins University Press, 1991.
- [64] A. C. Rutherford, G. Park, and C. R. Farrar. Non-linear feature identification based on self-sensing impedance measurements for structural health assessment. *Mechanical Systems and Signal Processing*, 21:322–333, 2007.
- [65] J. S. Sakellariou and S. D. Fassois. Nonlinear arx (narx) based identification and fault detection in 2 dof system with cubic stiffness. In *International Conference of Noise and Vibration Engineering - ISMA 2002*, Leuven, Belgium, 2002.
- [66] K. Shin, S. A. Feraday, C. J. Harris, M. J. Brennan, and J. E. Oh. Optimal autoregressive modeling of a measured noisy deterministic signal using singular-value decomposition. *Mechanical Systems and Signal Processing*, 17(2):423–432, 2003.
- [67] S. Silva, S. Cogan, and E. Foltête. Étude sur les méthodes de recalage dans le domaine temporel. Technical report, Centre National d’Études Spatiales (CNES-Toulouse), 2008.
- [68] S. Silva, S. Cogan, E. Foltête, and F. Buffe. Metrics for non-linear model updating in mechanical systems. In *XXVI International Modal Analysis Conference (IMAC)*, 2008.
- [69] S. Silva and M. Dias Junior. Statistical damage detection in a stationary rotor systems through time series analysis. *Latin American Applied Research*, 37(4):243–246, 2007.
- [70] S. Silva, M. Dias Junior, and V. Lopes Junior. Linear prediction techniques for structural damage detection. In *4th National Congress of Mechanical Engineering*, 2006.
- [71] S. Silva, M. Dias Junior, and V. Lopes Junior. Damage detection in a benchmark structure using ar-arx models and statistical pattern recognition. *Journal of the Brazilian Society of Mechanical Science and Engineering*, 29(2):174–184, 2007.
- [72] S. Silva, M. Dias Junior, and V. Lopes Junior. Statistical damage detection through time series analysis on a smart structure. In *19th International Congress of Mechanical Engineering - COBEM*, 2007.

- [73] S. Silva, M. Dias Junior, and V. Lopes Junior. Identification of mechanical systems through kautz filter. *Journal of Vibration and Control*, Aceito para publicação, 2008.
- [74] S. Silva, M. Dias Junior, and V. Lopes Junior. Structural health monitoring in smart structures through time series analysis. *Structural Health Monitoring - An International Journal*, Aceito para publicação, 2008.
- [75] S. Silva, M. Dias Junior, V. Lopes Junior, and M. J. Brennan. Structural damage detection by fuzzy clustering. *Mechanical Systems and Signal Processing*, doi:10.1016/j.ymssp.2008.01.004, 2008.
- [76] S. Silva, V. Lopes Junior, and M. Dias Junior. Detecção de falhas estruturais utilizando controle estatístico de processos. In *4.º Congresso Temático de Dinâmica, Controle e Aplicações*, pages 45–54, 2005.
- [77] H. Sohn, J. J. Czarnecki, and C. R. Farrar. Structural health monitoring using statistical process control. *ASCE Journal of Structural Engineering*, 126(11):1356–1363, 2000.
- [78] H. Sohn and C. R. Farrar. Damage diagnosis using time series analysis of vibration signals. *Smart Materials and Structures*, 10(3):446–451, 2001.
- [79] H. Sohn, C. R. Farrar, F. M. Hemez, D. D. Shunk, D. W. Stinemat, and B. R. Nadler. A review of structural health monitoring literature: 1996-2001. Technical report, Los Alamos National Laboratory, 2003.
- [80] P. Stoica and R. L. Moses. *Introduction to Spectral Analysis*. Prentice-Hall, 1997.
- [81] I. Tawfiq and T. Vinh. Contribution to the extension of modal analysis to non-linear structure using volterra functional series. *Mechanical Systems and Signal Processing*, 17(2):379–407, 2003.
- [82] M. A. Trindade, C. Wolter, and R. Sampaio. Karhunen-loève decomposition of coupled axial/bending vibrations of beams subject to impacts. *Journal of Sound and Vibrations*, 279:1015–1036, 2005.

- [83] K. K. H. Tseng and A. S. K. Naidu. Non-parametric damage detection and characterization using smart piezoceramic material. *Smart Materials and Structures*, 11:317–329, 2002.
- [84] P. Verboven, E. Parloo, P. Guillaume, and M. Van Overmeire. Autonomous structure health monitoring - part i: modal parameter estimation and tracking. *Mechanical Systems and Signal Processing*, 16:637–657, 2002.
- [85] B. Wahlberg. System identification using kautz models. *IEEE Trans. Autom. Control*, 39(1276-1282), 1994.
- [86] W. Wang. An evaluation of some emerging techniques for gear fault detection. *Structural Health Monitoring - An International Journal*, 2(3):225–242, 2003.
- [87] Z. Wei, L. H. Yam, and L. Cheng. Narmax model representation and its application to damage detection for multi-layer composites. *Composite Structures*, 68:109–117, 2005.
- [88] P. H. Wirsching, T. L. Paez, and O. Heith. *Random Vibrations: Theory and Practice*. John Wiley Sons, 1995.
- [89] K. Worden, D. W. Allen, H. Sohn, D. Stinematers, and C. R. Farrar. Extreme values statistics for damage detection in mechanical structures (la 13905-ms). Technical report, Los Alamos National Laboratory, 2002.
- [90] K. Worden and J. M. Dulieu-Barton. An overview of intelligent fault detection in system and structure. *Structural Health Monitoring - An International Journal*, 3(1):85–98, 2004.
- [91] K. Worden, G. Manson, and N. R. J. Fieller. Damage detection using outlier analysis. *Journal of Sound and Vibrations*, 229(3):647–667, 2000.
- [92] K. Worden, G. Manson, and G. R. Tomlinson. A harmonic probing algorithm for the multi input volterra series. *Journal of Sound and Vibration*, 205:67–84, 1997.
- [93] A. N. Zagrai and V. Giurgiutiu. Electro-mechanical impedance method for crack detection in thin plates. *Journal of Intelligent Material Systems and Structures*, 12(709-718), 2001.