

UNIVERSIDADE FEDERAL DE ALAGOAS  
CENTRO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

VICTOR BEZERRA FALCÃO

**APLICAÇÃO DE METODOLOGIAS DE RECONHECIMENTO DE PADRÕES PARA  
DETECÇÃO DE DANO EM VIGAS DE CONCRETO**

Maceió  
2017

VICTOR BEZERRA FALCÃO

**APLICAÇÃO DE METODOLOGIAS DE RECONHECIMENTO DE PADRÕES PARA  
DETECÇÃO DE DANO EM VIGAS DE CONCRETO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil, da Universidade Federal de Alagoas, como parte dos requisitos para a obtenção do título de Mestre em Engenharia de Estruturas.

Orientador: Prof. Dr. Wayne Santos de Assis

Maceió  
2017

**Catálogo na fonte**  
**Universidade Federal de Alagoas**  
**Biblioteca Central**

Bibliotecária Responsável: Janaina Xisto de Barros Lima

F178a Falcão, Victor Bezerra.  
Aplicação de metodologias de reconhecimento de padrões para detecção de dano em vigas de concreto / Victor Bezerra Falcão. – 2018.  
97 f.: il.

Orientador: Wayne Santos de Assis.  
Dissertação (Mestrado em Engenharia Civil: Estruturas) – Universidade Federal de Alagoas. Centro de Tecnologia. Maceió, 2017.

Bibliografia: f. 90-97.

1. Estruturas de concreto – Danos. 2. Reconhecimento padrão – Metodologias.
3. Integridade estrutural – Monitoramento. I. Título.

CDU: 624.012.45



Universidade Federal de Alagoas – UFAL  
Unidade Acadêmica Centro de Tecnologia – CTEC  
Programa de Pós-Graduação em Engenharia Civil – PPGEC



**APLICAÇÃO DE METODOLOGIAS DE RECONHECIMENTO DE PADRÕES PARA  
DETECÇÃO DE DANO EM VIGAS DE CONCRETO**

**VICTOR BEZERRA FALCÃO**

Dissertação submetida à banca examinadora do Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Alagoas e aprovada no dia 04 do mês de dezembro do ano de 2017.

Banca Examinadora:

**Prof. Dr. Wayne Santos de Assis**  
Orientador – PPGEC/UFAL

**Prof. Dr. Flávio Barboza de Lima**  
Avaliador Interno – PPGEC/UFAL

**Prof. Dr. Luiz Eduardo Teixeira Ferreira**  
Avaliador Externo – UFLA

## AGRADECIMENTOS

Agradeço a Deus, que me guia em seu propósito todos os dias e me ajuda a prevalecer diante de todos os desafios.

Agradeço à minha família, que é o laboratório da minha missão, em especial aos meus pais, Luciano e Cláudia, que sempre me apoiaram e me deram uma base firme, com princípios e caráter. Não poderia deixar de mencionar meus avós Numeriano, Lúcia, Waldeci e Penha, que estiveram sempre muito presentes em todo o caminho, com carinho, suprimento, sabedoria e orientações. E também aos meus irmãos Lucas e Heitor.

À minha esposa, Jakeline Falcão, pelo carinho, amor e paciência ao longo destes anos.

Aos meus líderes da Sara Nossa Terra, que me ensinaram a importância de concluir os ciclos. A cada um debaixo da minha cobertura, por serem o combustível para que eu me mantenha em movimento.

Ao meu orientador, professor Wayne Santos de Assis, pela confiança e orientações, estando sempre presente e disponível para que este trabalho fosse concluído.

A todo o corpo docente que compõe o Mestrado de Engenharia Civil (Estruturas e Materiais), pela convivência e por transmitir seus ensinamentos. Em especial aos professores Flávio Barboza de Lima e Eduardo Toledo Lima Junior, que foram muito importantes em momentos significativos durante o curso.

À Fundação de Amparo à Pesquisa do Estado de Alagoas (FAPEAL) pela bolsa fornecida durante o período necessário para a conclusão deste trabalho.

Aos meus amigos Jonas Duarte, Bruna Camerino e Isadora Nogueira, companheiros dos grandes desafios enfrentados nesse período.

A todos os colegas que, de alguma forma, contribuíram com sua companhia e ficaram felizes com as minhas conquistas.

Àqueles que, direta ou indiretamente, ajudaram na elaboração deste trabalho.

## RESUMO

Nas últimas décadas, os sistemas de Monitoramento da Integridade Estrutural (MIE) permanentes têm sido propostos para aumentar a confiabilidade da avaliação da condição estrutural e apoiar o processo de manutenção das pontes. Atuando com a intenção de complementar a análise estrutural de obras-de-arte especiais em serviço, este projeto visa aplicar metodologias de reconhecimento de padrões para identificação de dano em vigas de concreto, tendo em vista a análise da informação proveniente de sistemas de monitoração, permanentes ou temporários, incluindo tecnologia não destrutiva, de modo a futuramente auxiliar no processo de manutenção de pontes e estruturas especiais. Para esse fim, foram aplicados algoritmos de reconhecimento de padrões para identificação dos danos: as *wavelets*, as máquinas de vetores de suporte e o modelo de misturas gaussianas. As vigas apresentavam níveis diferentes de danificação: íntegro, dano de 30% e 60% da altura da viga. Para a análise com as *wavelets* foram utilizadas as funções de Haar e Daubechies, para as máquinas de vetores de suporte foram testadas as funções kernel polinomial e RBF (*Radial Basis Function*) e no modelo de misturas gaussianas foram utilizados três *clusters*. Os três métodos utilizados conseguiram distinguir os diferentes padrões de dano. Utilizando as *wavelets*, a família de Daubechies apresentaram melhor qualidade. Para as máquinas de vetores de suporte, os melhores resultados foram obtidos com a função kernel RBF. Em relação aos modelos de misturas gaussianas, o método também consegue reconhecer a existência de diferentes níveis de dano, ainda que esse reconhecimento não seja completo. Os parâmetros avaliados foram as rigidezes à flexão em função do deslocamento. As conclusões foram obtidas a partir de métodos estatísticos, do LIBSVM e do algoritmo EM (*Expectation Maximization*).

**Palavras-chave:** *Reconhecimento de padrões, dano em estruturas de concreto, monitoração da integridade estrutural.*

## ABSTRACT

In the last decades, permanent Structural Integrity Monitoring (SHM) systems have been proposed to increase the reliability of the structural condition assessment and support the bridge maintenance process. Working with the intention of complementing the structural analysis of engineering structures in service, this project aims to apply methodologies of pattern recognition to identify damage in concrete beams, in order to analyze the information coming from monitoring systems, Permanent or temporary, including non-destructive technology, in order to help in the future the process of maintaining bridges and special structures. For this purpose, we have applied pattern recognition algorithms to identify concrete beam damage: *wavelets*, support vector machines and the gaussian mixtures model. The beams had different damage levels: intact, 30% damage and 60% beam height. For the analysis of the *wavelets*, the functions of Haar and Daubechies were used. For the support vector machines, the polynomial and RBF (Radial Basis Function) functions kernel were tested and three clusters were used in the gaussian mixtures model. The objectives proposed by the work were achieved, that is, the three methods were able to distinguish the different damage patterns. Using the *wavelets*, the Daubechies family presented better quality. For the support vector machines, the best results were obtained with the RBF kernel function. In relation to the Gaussian mixture models, the method also recognizes the existence of different levels of damage, although this recognition is not complete. The evaluated parameters were flexural stiffness as a function of displacement. The conclusions were obtained from statistical methods, the LIBSVM and the EM algorithm (Expectation Maximization).

**Keywords:** *Pattern recognition, concrete structure damage, structural health monitoring.*

## LISTA DE FIGURAS

Figura 2.1 – Noção do elemento de volume representativo (EVR) e escalas da mecânica do dano contínuo. ....	21
Figura 2.2 - Elemento de volume representativo com dano. ....	23
Figura 3.1 – Modos de fissura: (a) modo 1; (b) modo 2; e, (c) modo 3. ....	25
Figura 3.2 – Modos de fratura: (a) modo 1; (b) modo 2; e, (c) modo 3.....	26
Figura 3.3 – Potencial atômico ou curva coesiva de tensão-separação descrevendo a ligação entre dois planos atômicos em um sólido cristalino. ....	29
Figura 3.4 – Formas da curva de amolecimento: (a) função bilinear tipo 1; (b) função linear; (c) função bilinear tipo 2; e, (d) curva de amolecimento real. ....	30
Figura 3.5 – Comportamento tensão-deformação de concreto submetido a tensão uniaxial.....	31
Figura 3.6 – Comportamento tensão-deformação de concreto submetido a tensão uniaxial.....	32
Figura 3.7 – Zona de Processos Inelásticos e Zona de Domínio de $K$ .....	33
Figura 4.1 – Procedimento utilizado para análise de reconhecimentos de padrões de dano.....	36
Figura 4.2 – Processo hierárquico de identificação do dano. ....	39
Figura 4.3 – Processo de reconhecimento de padrões. ....	41
Figura 4.4 – Representação de um senoide e de uma <i>wavelet</i> .....	43
Figura 4.5 – Transformada de Fourier. ....	43
Figura 4.6 – Processo de transformada da <i>wavelet</i> . ....	45
Figura 4.7 – Aplicação do fator escala em senoídes. ....	45
Figura 4.8 – Aplicação do fator escala em <i>wavelets</i> .....	46
Figura 4.9 – Coeficientes da TCW em duas dimensões.....	47
Figura 4.10 – Processo de filtragem do sinal.....	48
Figura 4.11 – Sinal da <i>wavelet</i> Haar.....	49
Figura 4.12 – Alguns sinais das diferentes <i>wavelets</i> Daubechies, de acordo com suas respectivas ordens.....	49

Figura 4.13 – Sinal da <i>wavelet</i> chapéu mexicano. ....	50
Figura 4.14 – Interface da caixa de ferramentas para análise de <i>wavelets</i> .....	52
Figura 4.15 – Definição do melhor plano classificador entre duas classes de dados. ....	55
Figura 4.16 – Interface inicial do WEKA. ....	59
Figura 4.17 – Nuvens de vetores de características de dano, para medição do dano usando a distância Mahalanobis.....	62
Figura 5.1 – Ilustração da vista em perspectiva (a, c) e vista lateral (b, d) dos corpos de prova nas diversas situações de dano.....	66
Figura 5.2 – Ensaio de flexão em quatro pontos, realizado com os corpos de prova dos lotes II e III. ....	67
Figura 5.3 – Aparato experimental para a realização do ensaio de flexão em quatro pontos com posicionamento de relógio comparador para medição dos deslocamentos em função do tempo no centro do vão. ....	67
Figura 5.4 – Resultados médios de força–deslocamento dos corpos de prova do lote II. ....	68
Figura 5.5 – Resultados médios de força–deslocamento dos corpos de prova do lote III. ....	69
Figura 5.6 – Estimativa média da rigidez do lote II para cada situação de dano.....	69
Figura 5.7 – Estimativa média da rigidez do lote III para cada situação de dano.....	70
Figura 5.8 – Interpolação polinomial do 6º grau realizado a partir dos dados de rigidez–deslocamento para o elemento com nível de dano 60%, do lote 2. ....	71
Figura 5.9 – Classificação de dados quaisquer no WEKA. ....	73
Figura 5.10 – Saída de um modelo de classificação qualquer para análise de GMM do WEKA, com 5 <i>clusters</i> . ....	74
Figura 6.1 – Gráficos das interpolações para cada nível de dano, no lote 2: (a) Íntegro; (b) Dano de 30% da altura; e, (c) Dano de 60% da altura da viga. ....	75
Figura 6.2 – Decomposição do registro das rigidezes do lote 2 no estado íntegro em 4 níveis aplicando as <i>wavelets</i> de Haar.....	76
Figura 6.3 – Melhor sinal de baixa frequência para análise de <i>wavelets</i> .....	76
Figura 6.4 – Melhor sinal de baixa frequência para análise de <i>wavelets</i> : (a) Danificado 30%; (b) Danificado 60% da altura da viga.....	77
Figura 6.5 – Melhor sinal de baixa frequência para análise de <i>wavelets</i> : (a) Íntegro; (b) Danificado 30%; (c) Danificado 60% da altura da viga.....	78

Figura 6.6 – Gráficos das interpolações para cada nível de dano, no lote 3: (a) Íntegro; (b) Dano de 30%; e, (c) Dano de 60% da altura da viga. ....	79
Figura 6.7 – Melhor sinal de baixa frequência para análise das <i>wavelets</i> de Haar: (a) Estado íntegro; (b) Danificado 30% da altura; (c) Danificado 60% da altura da viga. ....	79
Figura 6.8 - Melhor sinal de baixa frequência para análise das <i>wavelets</i> de Daubechies: (a) Estado íntegro; (b) Danificado 30% da altura; (c) Danificado 60% da altura. ....	80
Figura 6.9 – Saída do modelo de classificação do WEKA utilizando a função kernel polinomial – Lote 2.....	81
Figura 6.10 – Gráfico EI–deslocamento gerado pelo WEKA na análise pelo LibSVM para a função polinomial – Lote 2. ....	82
Figura 6.11 – Saída do modelo de classificação do WEKA para a função RBF – Lote 2. ....	82
Figura 6.12 – Gráfico EI–deslocamento gerado pelo WEKA na análise pelo LibSVM para a função RBF – Lote 2. ....	83
Figura 6.13 - Saída do modelo de classificação do WEKA, para função polinomial – Lote 3. ....	84
Figura 6.14 – Gráfico EI–deslocamento gerado pelo WEKA na análise pelo LibSVM para a função polinomial – Lote 3. ....	85
Figura 6.15 - Saída do modelo de classificação do WEKA para a função RBF – Lote 3. ....	85
Figura 6.16 – Gráfico EI–deslocamento gerado pelo WEKA na análise pelo LibSVM para a função RBF – Lote 3. ....	86
Figura 6.17 – Resultados obtidos a partir do algoritmo EM, incorporado ao WEKA, para os dados do lote 2.....	86
Figura 6.18 – Gráfico EI–deslocamento gerado pelo WEKA na análise feita pelo algoritmo EM – Lote 2.....	87
Figura 6.19 – Resultados obtidos a partir do algoritmo EM, incorporado ao WEKA, para os dados do lote 3.....	88
Figura 6.20 – Gráfico EI–deslocamento gerado pelo WEKA na análise feita pelo algoritmo EM – Lote 3.....	88

## LISTA DE TABELAS

Tabela 4.1 – Resumo dos kernels mais populares.....	56
Tabela 5.1 - Equações resultantes das interpolações realizadas para os níveis de dano nos lotes 2 e 3.....	71

## LISTA DE ABREVIATURAS E SIGLAS

AASHTO - *American Association of State Highway and Transportation Officials*  
CP - Corpo de prova  
DNIT - Departamento Nacional de Infraestrutura de Transportes  
EM - *Expectation Maximization*  
EUA - Estados Unidos da América  
EVR - Elemento de Volume Representativo  
FEM - Fórum Econômico Mundial  
FHWA - *Federal Highway Administration*  
GMM - *Gaussian Mixture Models*  
ICASSP - Conferência Internacional sobre a Acústica da Fala e Processamento de Sinais  
ICSLP - Conferência Internacional sobre o Processamento de Língua Falada  
KW - Kruskal-Wallis  
LEFM - *Linear Elastic Fracture Mechanics*  
MFF - Modelo de Fissura Fictícia  
MIE - Monitoração da Integridade Estrutural  
RBF - *Radial Basis Function*  
RNA - Redes Neurais Artificiais  
SDI - Sistemas de Detecção de Intrusão  
SGOA - Sistemas de Gestão de Obras de Arte  
SHM - *Structural Health Monitoring*  
SVM - *Support Vector Machine*  
TCW - Transformada Contínua de *Wavelet*  
TDW - Transformada Discreta de *Wavelet*  
UE - União Europeia  
USPS - Serviço Postal Americano  
ZPI - Zona de Processos Inelásticos

## LISTA DE SÍMBOLOS

### SÍMBOLOS ROMANOS

$a$ : aproximação (*wavelets*)

$a/c$ : fator água/cimento

$A-A'$ : Plano de abertura

$b$ : semi-altura de fissura

$c$ : semi-comprimento de fissura

$C$ : semelhança entre *wavelet* e sinal original

$d$ : detalhes (*wavelets*)

$d_{max}$ : diâmetro máximo do agregado

$DE$ : deslocamento das *wavelets*

$E$ : Módulo de elasticidade ou de Young

$f_t$ : tensão de tração uniaxial

$f(t)$ : função dependente do tempo

$FE$ : fator escala (TCW)

$g(x)$ : função *wavelet* qualquer

$G_f$ : Energia de fratura específica

$H_0$ : hipótese nula

$H_1$ : hipótese alternativa

$K$ : região localizada na ponta da fissura

$K_I$ : fator de intensidade de tensão do modo I (modo de abertura)

$K_{II}$ : fator de intensidade de tensão do modo II (modo de abertura por cisalhamento no plano)

$K_{III}$ : fator de intensidade de tensão do modo III (modo de abertura por cisalhamento fora do plano)

$L_{ch}$ : comprimento característico

$n$ : níveis de decomposição das *wavelets*

$p$ : potência da função kernel polinomial

$P$ : carregamento

$r$ : distância entre átomos

$s$ : entropia

$S$ : sinal original (*wavelet*)

$T$ : temperatura absoluta  
 $u(x)$ : função *wavelet* qualquer  
 $u_x, u_y, u_z$ : deslocamentos  
 $w$ : peso (GMM)  
 $W$ : módulo da seção  
 $x, y, z$ : coordenadas do Sistema cartesiano

## SÍMBOLOS DE MATRIZ

$D$ : dano  
 $K$ : matriz positivamente positiva (Teorema de Mercer)  
 $n$ : campo vetorial  
 $S$ : superfície

## SÍMBOLOS GREGOS

$\beta_0$ : parâmetro da função kernel sigmoidal  
 $\beta_1$ : parâmetro da função kernel sigmoidal  
 $\delta$ : delta de Kronecker  
 $\varphi(t)$ : wavelet-mãe  
 $\sigma^2$ : amplitude de função kernel  
 $\sigma_{xx}, \sigma_{yy}, \sigma_{zz}$ : tensões normais  
 $\sigma_{xy}, \sigma_{xz}, \sigma_{yz}$ : tensões cisalhantes  
 $\lambda$ : fator de parametrização (GMM)  
 $\mu$ : média (GMM)  
 $\nu$ : Coeficiente de Poisson  
 $\pi$ : número pi  
 $\theta$ : ângulo  
 $\Sigma$ : covariância (GMM)  
 $\chi^2$ : qui-quadrado (análise estatística)

## NÍVEIS DE ESCALA DO CONCRETO

$n$ : nanoescala ( $10^{-9}$  m)  
 $\mu$ : microescala ( $10^{-6}$  m)  
 $m$ : mesoescala ( $10^{-3}$  m)  
 $M$ : macroescala (contínuo)

# SUMÁRIO

<b>AGRADECIMENTOS</b> .....	<b>6</b>
<b>RESUMO</b> .....	<b>4</b>
<b>ABSTRACT</b> .....	<b>5</b>
<b>LISTA DE FIGURAS</b> .....	<b>6</b>
<b>LISTA DE TABELAS</b> .....	<b>9</b>
<b>LISTA DE ABREVIATURAS E SIGLAS</b> .....	<b>10</b>
<b>LISTA DE SÍMBOLOS</b> .....	<b>11</b>
<b>1 CONSIDERAÇÕES INICIAIS</b> .....	<b>15</b>
1.1 Justificativa .....	16
1.2 Objetivos .....	18
1.3 Organização da dissertação.....	18
<b>2 MECÂNICA DO DANO CONTÍNUO</b> .....	<b>20</b>
2.1 Elemento de volume representativo .....	20
2.2 Definição das variáveis de dano.....	22
<b>3 MECÂNICA DA FRATURA</b> .....	<b>24</b>
3.1 Mecânica da fratura linear elástica .....	26
3.2 Modelo plástico de fissura.....	29
<b>4 MONITORAÇÃO DA INTEGRIDADE ESTRUTURAL</b> .....	<b>34</b>
4.1 Procedimento de um sistema de SHM .....	36
4.2 Reconhecimento de padrões de dano.....	40
4.2.1 Wavelets .....	42
4.2.1.1 Propriedades das <i>wavelets</i> .....	49
4.2.1.2 Análise das <i>wavelets</i> .....	51
4.2.2 Máquinas de vetores de suporte .....	53
4.2.2.1 Implementações disponíveis para SVM .....	58
4.2.2.2 Aplicações cotidianas de SVM .....	59
4.2.3 Modelo de misturas gaussianas .....	60
4.2.3.1 Armazenamento em cluster .....	63

4.2.3.2	Aplicações cotidianas de GMM .....	63
<b>5</b>	<b>METODOLOGIA.....</b>	<b>65</b>
5.1	Trabalho realizado por Carvalho (2015) .....	65
5.2	Wavelets .....	70
5.3	Máquinas de vetores de suporte .....	72
5.4	Modelo de misturas gaussianas .....	73
<b>6</b>	<b>RESULTADOS E ANÁLISES.....</b>	<b>75</b>
6.1	Wavelets .....	75
6.2	Máquinas de vetores de suporte .....	81
6.3	Modelo de misturas gaussianas .....	86
<b>7</b>	<b>CONSIDERAÇÕES FINAIS.....</b>	<b>89</b>
7.1	Sugestões para trabalhos futuros.....	89
	<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>91</b>

## 1 CONSIDERAÇÕES INICIAIS

No decorrer de sua vida útil as estruturas experimentam diversos tipos de carregamentos, os quais associados aos fenômenos de corrosão, ataques químicos e carbonatação, por exemplo, podem produzir diferentes tipos de danos. Desta forma, a capacidade portante da estrutura pode ser reduzida, devido à diminuição das rigidezes dos elementos estruturais.

Os danos podem estar presentes em toda a estrutura, caracterizando o dano global, ou podem estar em pontos específicos, originando o dano local. A ocorrência deste último é mais comum.

A identificação dos danos pode ser feita visualmente ou por meio de técnicas destrutivas e técnicas não destrutivas. Os procedimentos de simples inspeção ou verificação visual são muito utilizados, mas requerem que o profissional analise toda a estrutura e que tenha certa experiência para identificar o dano (CARDOSO, 2005). As técnicas destrutivas podem inutilizar a estrutura, enquanto as não destrutivas avaliam, geralmente, nas proximidades da suspeita de defeitos e examinam a resposta da estrutura (SOARES, 2000).

Para Figueiredo (2010), o processo de implementação de uma estratégia de detecção de danos é abordado como um método de monitoramento estrutural, e neste contexto, o dano pode ser definido como o conjunto de alterações e/ou propriedades geométricas do material, incluindo alterações nas condições de contorno e conectividade do sistema, que afetam negativamente o desempenho atual ou futuro do sistema. Nesta definição, se insere a comparação de estados inicial (denominado de estado não danificado) e final (denominado de estado danificado). Este último ocorre após o desgaste natural da estrutura ou após ser induzida uma alteração de integridade com finalidade experimental.

O monitoramento da integridade de uma estrutura se baseia na utilização de indicadores confiáveis e robustos que permitam detectar, localizar, quantificar e, se possível, prever a ocorrência de danos.

A maioria dos indicadores de danos é baseada na análise no domínio do tempo ou no domínio da frequência dos sinais. Alguns indicadores apresentam problemas de sensibilidade, necessitam de um estado de referência e não apresentam a probabilidade de detectar falsos alarmes, diminuindo sua confiabilidade. Além disso, a identificação dos parâmetros modais é, de certa forma, um procedimento de filtragem, o que pode conduzir a uma perda de informações se comparado à utilização dos sinais brutos. Essa perda de informação pode, portanto, mascarar a variação de pequenas amplitudes (ALVES, 2012). Nesse contexto, é importante empregar técnicas que permitam a utilização de dados brutos de maneira prática e pertinente. A mineração de dados (*Data Mining*) consiste em um conjunto de ferramentas que extraem características escondidas em grandes bases de dados brutos. Geralmente, para chegar em conclusões com a mineração, são utilizados testes estatísticos. (HASTIE *et al.*, 2001).

## 1.1 Justificativa

Na última década, a *Structural Health Monitoring* (SHM) – Monitoração da Integridade Estrutural (MIE) – tem evoluído, especialmente impulsionada pelos avanços tecnológicos registrados nos transdutores, sistemas de aquisição e na informática. De acordo com Figueiredo *et al.* (2013), a SHM é definida como o processo de aplicação de sistemas de monitoração automáticos para medir, em tempo real, as respostas estruturais e para detectar anomalias e/ou danos nas suas fases iniciais. Recentes desenvolvimentos sugerem que, num esforço para otimizar a manutenção de pontes, a SHM deve ser integrada a Sistemas de Gestão de Obras de Arte (SGOA), de forma sistemática. Atualmente, essa integração é amplamente aceita pela comunidade científica, mas poucas aplicações foram realizadas, principalmente pelo elevado custo/benefício destes sistemas.

Além do custo dos sistemas de SHM, atualmente verifica-se que estes sistemas ainda não conseguem dar respostas definitivas acerca da condição estrutural em tempo real. Do ponto de vista técnico, a aplicabilidade da SHM é ainda desafiada por uma série de fatores, especificamente pelas diversas fontes de variabilidade presente nas suas várias etapas, tais como os efeitos da variabilidade operacional e ambiental na

resposta estrutural. Vários estudos indicam que a temperatura e o tráfego, por exemplo, podem causar variabilidade diária nas propriedades modais numa faixa de 5% a 10% e, assim, mascarar as potenciais alterações causadas por dano (BROWNJOHN, 2006; FIGUEIREDO *et al.*, 2013). Com o objetivo de eliminar estes efeitos, ou seja, de separar as variações provocadas por ações de natureza corrente das variações provocadas por dano, nos últimos anos têm-se recorrido a algoritmos de reconhecimento de padrões, isto é, algoritmos de aprendizagem para detecção de dano (FARRAR e WORDEN, 2012; FIGUEIREDO *et al.*, 2009, SOHN *et al.*, 2001). Estes algoritmos operam segundo o princípio de funcionamento do cérebro humano. Mais concretamente, primeiro, estes algoritmos “aprendem” o funcionamento normal da estrutura para, posteriormente, detectarem a presença de comportamentos estatisticamente “anormais” através do reconhecimento de padrões. Estes modelos estatísticos têm vantagem sobre os modelos numéricos estruturais (por exemplo, modelos de elementos finitos), pois os mesmos não dependem da complexidade da estrutura. Adicionalmente, estes algoritmos não estão limitados no tipo de dados de entrada, uma vez que eles podem analisar, em simultâneo, todo o tipo de informação proveniente dos sistemas de monitoração, modelos numéricos de elementos finitos e inspeções visuais. Esta capacidade aumenta a redundância de informação e, conseqüentemente, a probabilidade de detecção de anormalidades (SOHN *et al.*, 2004). Esta vantagem tem-se revelado fundamental para a viabilização dos SHM em aplicações reais de engenharia civil. Além disso, as quantidades de dados, tipicamente observados pelos sistemas de SHM permanentes, são demasiado elevadas para interpretação no seu estado bruto. Portanto, é necessário recorrer a técnicas ou algoritmos de prospecção de dados (*data mining*), que possibilita a extração de informação útil num espaço dimensional reduzido.

Esta dissertação é focada na aplicação de algoritmos que possibilitem reconhecer padrões de danos em vigas de concreto. A identificação e a quantificação destes danos não estão inseridas no escopo deste trabalho. As vigas produzidas são apresentadas na dissertação de Carvalho (2015), e foram criadas com o objetivo de analisar estaticamente seu desempenho quanto a ensaios de flexão, utilizando a rigidez à flexão como parâmetro para verificar indícios da existência do dano através da comparação dos estados íntegro e danificado, e aplicar análise estatística para avaliar a eficiência dos resultados, no que diz respeito à tentativa de formulação de

um parâmetro para detecção de dano. Os dados necessários para essa dissertação são as rigidezes à flexão e os deslocamentos associados.

A fim de embasar os resultados apresentados, um referencial teórico foi apresentado de modo que alcançasse de forma objetiva os temas relacionados à mecânica da fratura, mecânica do dano contínuo, e a detecção do dano estrutural, por meio dos três algoritmos utilizados (*wavelets*, máquinas de vetores de suporte e modelos de misturas gaussianas).

## 1.2 Objetivos

Este trabalho tem por objetivo geral a aplicação de metodologias de reconhecimento de padrões para identificação de dano em vigas de concreto, tendo em vista a análise da informação proveniente de sistemas de monitoração, permanentes ou temporários, incluindo tecnologia não destrutiva, de modo a futuramente auxiliar no processo de manutenção de pontes e estruturas especiais. A fim de alcançar o objetivo proposto foi necessário:

- i. Fazer um levantamento de metodologias de reconhecimento de padrões para identificação de dano estrutural;
- ii. A partir dos resultados obtidos experimentalmente, aplicar metodologias para reconhecimento dos padrões de dano.
- iii. Fazer a distinção entre os diferentes níveis de danificação em vigas de concreto.

## 1.3 Organização da dissertação

O texto da dissertação está dividido em sete capítulos, incluindo este capítulo introdutório.

No capítulo 2 é abordada a temática da mecânica do dano contínuo, com sua definição, diferenciando o dano escalar do tensorial, e de algumas variáveis relevantes. É abordada também a relação com a mecânica da fratura, e sua interferência, de forma prática, nas propriedades dos materiais.

No capítulo 3 é feita uma breve descrição de tópicos relevantes relacionados à mecânica da fratura, como o modelo de mecânica da fratura linear elástica e o modelo plástico para fissuras em metais plásticos e em concretos, baseado no método de fissura fictícia de Hillerborg (HILLERBORG *et al.* 1976).

O capítulo 4 refere-se à monitoração da integridade estrutural, bem como o reconhecimento de padrões, realizados através de três algoritmos: *wavelets*, máquinas de vetores de suporte e modelos de misturas gaussianas. Os aspectos teóricos de cada método são descritos sucintamente a fim de garantir uma compreensão dos resultados obtidos nos capítulos seguintes.

O capítulo 5 apresenta uma descrição detalhada da metodologia utilizada nos *software* para cada algoritmo. A ideia principal deste capítulo é dar a capacidade de utilizar os algoritmos para reconhecimento de padrões de danos, a partir de dados recolhidos experimentalmente.

No capítulo 6 os resultados encontrados, a partir da utilização dos algoritmos, são apresentados. Para as *wavelets* e máquinas de vetores de suporte são utilizadas duas condições diferentes, a fim de avaliar o comportamento dos algoritmos. Para as *wavelets* são utilizadas como funções-mães as *wavelets* de Haar e de Daubechies. Para as máquinas de vetores de suporte são utilizadas as funções kernel polinomial e RBF (*Radial Basis Function*). Para cada aplicação é feita a análise dos resultados, com o intuito de esclarecer se cada algoritmo foi capaz de reconhecer devidamente a presença de padrões.

Finalmente, no Capítulo 7, são tecidas algumas considerações gerais sobre o trabalho desenvolvido, são realçadas as principais conclusões e são também apontadas sugestões para futuros desenvolvimentos.

## 2 MECÂNICA DO DANO CONTÍNUO

Lemaitre e Chaboche (1978) definem dano como o desenvolvimento de cavidades nos processos microscópico, mesoscópico e macroscópico de fratura em materiais, juntamente com a resultante deterioração de suas propriedades mecânicas (LEMAITRE E CHABOCHE, 1978 *apud* MURAKAMI, 2012). A mecânica do dano contínuo é uma teoria mecânica que visa analisar o dano e o processo de fraturamento em materiais a partir do ponto de vista da mecânica do contínuo (MURAKAMI, 2012).

Do ponto de vista da análise dos efeitos de deterioração de materiais sólidos submetidos a ação de natureza mecânica ou térmica, a mecânica do dano contínuo é uma ferramenta essencial. Enquanto a mecânica da fratura lida com as condições de propagação de fissuras macroscópicas, a mecânica do dano contínuo estuda o efeito de microfissuras distribuídas na resposta do material. No caso do concreto, um material no qual a fissuração é o fenômeno dominante no comportamento não-linear, a mecânica do dano é sem dúvida capaz de formular modelos realísticos (PITUBA, 1998).

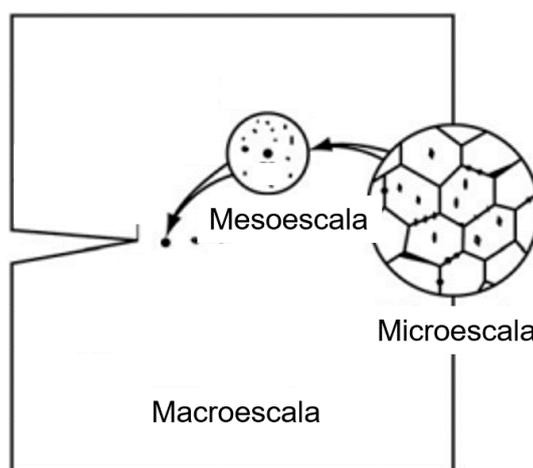
Janson e Hult (1977) diferenciam as duas teorias afirmando que na mecânica do dano contínuo a resistência de uma estrutura carregada é determinada em função da evolução de um campo de defeitos continuamente distribuído, tais como microfissuras ou poros, enquanto que na mecânica da fratura a resistência de uma estrutura carregada é determinada em função da evolução de um defeito em particular, como uma fissura pontiaguda pré-definida, onde o meio em volta da fissura é assumido como mecanicamente intacto.

### 2.1 Elemento de volume representativo

O primeiro trabalho publicado que apresentou o conceito de dano contínuo é de autoria de Kachanov (1958). Nele, o autor trabalhou com o interesse de modelar o efeito da fissuração distribuída na ruptura do tipo frágil observada em metais após um período de deformação lenta. Na engenharia, a mecânica do contínuo introduz um elemento de volume representativo (EVR) por possuir dimensão suficientemente grande de modo que se possa admitir que contenha uma distribuição homogênea das propriedades, sendo ao mesmo tempo pequeno para ser considerado como um ponto

material do contínuo. A Figura 2.1 apresenta o EVR e as escalas relacionadas às condições de estudo do elemento. Do ponto de vista físico, o dano está relacionado às deformações plásticas, e à uma dissipação destas deformações quer na mesoescala ou na microescala. Na primeira situação, o dano é chamado de dano de fadiga de baixo ciclo, quando há repetição de elevados níveis de carga. A segunda situação representa a falha ocorrida em elementos frágeis, onde a cerâmica e o concreto se encaixam (LEMAITRE E DESMORAT, 2005).

Figura 2.1 – Noção do elemento de volume representativo (EVR) e escalas da mecânica do dano contínuo.



Fonte: Adaptado de Murakami, 2012.

Os danos, devido à criação de superfícies livres de descontinuidades, interferem nos valores de inúmeras propriedades: diminuem o módulo de elasticidade, a durabilidade e a densidade, além de promover a redução da intensidade do campo de tensões antes e depois do endurecimento, e aumentam a fluência e a resistência elétrica. Cada uma das variações nestas propriedades é analisada para que a quantificação do dano seja realizada (LEMAITRE E DESMORAT, 2005).

Existem vários modelos constitutivos que incorporam o conceito de dano, alguns deles com especial referência ao concreto. Entre eles pode-se citar: KACHANOV (1984) e MURAKAMI (1981) modelando a deterioração lenta do material (*creep damage*), LEMAITRE & CHABOCHE (1974) na interação dano-fadiga, SIMO & JU (1987) sobre dano em materiais dúcteis, MAZARS (1984) sobre dano em estruturas de concreto armado e LA BORDERIE, PIJAUDIER-CABOT & MAZARS (1991) dano em estruturas

de concreto armado e concreto em fibras sujeitas a carregamento cíclico e FLOREZ-LÓPEZ (1993) tratando do dano em pórticos de concreto armado.

## 2.2 Definição das variáveis de dano

Kachanov (1958) define a quantificação do dano a partir da variável da Equação 1,

$$D = 1 - \psi \quad (1)$$

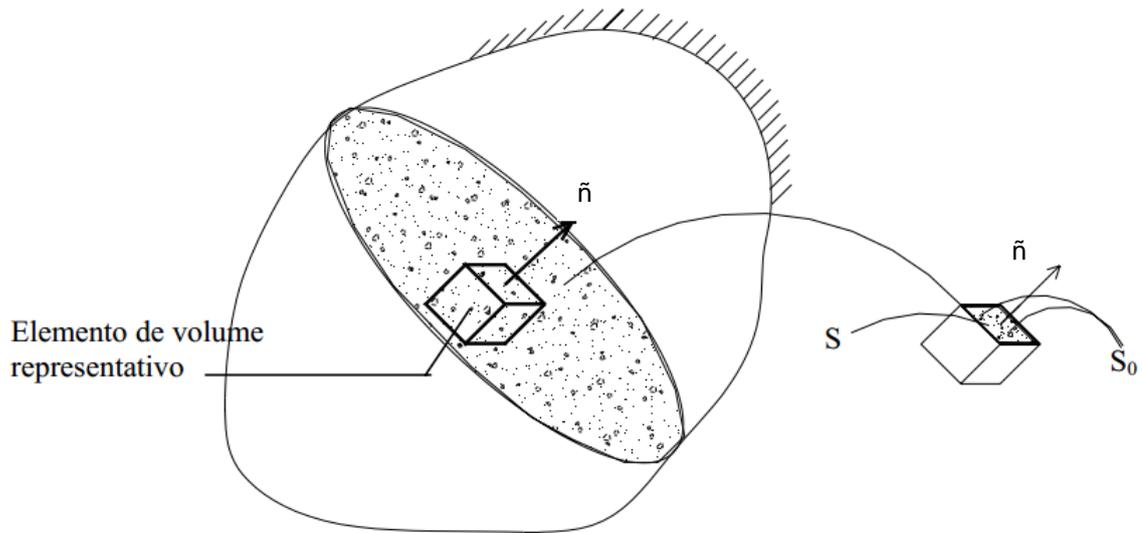
quantidade complementar à variável  $\psi$ , denominada então de continuidade. Para um material sem dano, o valor de  $D$  é zero, enquanto para um estado de completa perda da integridade estrutural,  $D$  corresponde a um. Na literatura, a variável  $D$  é encontrada em natureza escalar (dano isotrópico) e em natureza tensorial (dano anisotrópico). Lemaitre e Desmorat (2005) dizem que o dano escalar pode ser usado como tal para problemas unidimensionais. Se vários mecanismos de dano ocorrem, simultaneamente ou não, cada um deles é representado por uma variável  $D$  diferente.

Pituba (1998) diz que, imaginando-se uma situação em que as microfissuras se distribuam em quaisquer direções, os valores da variável  $D_n$  variam de acordo com a orientação da normal  $\tilde{n}$ . Essa situação configura o dano anisotrópico. O dano isotrópico corresponde, então, a uma situação em que os danos tenham uma distribuição mais ou menos uniforme em qualquer direção, ou seja, independente da orientação da normal  $\tilde{n}$ . Nesse caso, um único valor da variável de dano caracteriza completamente o estado local de deterioração (Equação 2).

$$D = D_n \quad \forall \tilde{n} \quad (2)$$

Seja  $S$  a área de uma das faces do elemento representativo, a qual definida por um plano cujo versor normal tem direção  $\tilde{n}$  (Figura 2.2). Nesta seção, as microfissuras que contribuem para o dano têm formas e orientações quaisquer.

Figura 2.2 - Elemento de volume representativo com dano.



Fonte: Adaptado de Pituba (1998).

No plano da seção considerada, sendo  $\tilde{S}$  a parcela da área total que efetivamente oferece resistência ( $\tilde{S} \leq S$ ), a diferença apresentada na Equação 3 define a área danificada.

$$S_0 = S - \tilde{S} \quad (3)$$

Por definição, LEMAITRE & CHABOCHE (1985) e LEMAITRE (1984), a medida local do dano em qualquer direção pode ser definido pela Equação 4:

$$D_n = \lim_{S \rightarrow 0} \frac{S_0}{S} \quad (4)$$

Os danos são geralmente encontrados no estado anisotrópico, já que o microfissuramento é, em geral, perpendicular ao plano de tensão principal máximo. A superfície de densidade das microfissuras em um plano com a normal  $\tilde{n}$  atua transformando uma superfície maior, em uma menor, porém com área contínua (LEMAITRE E DESMORAT, 2005). Para que haja uma compreensão plena a respeito do dano, torna-se necessário o estudo da mecânica da fratura.

### 3 MECÂNICA DA FRATURA

O entendimento da mecânica da fratura do concreto é um tópico de pesquisa relevante quando se trata da avaliação de dano em estruturas. O concreto, analisado como matéria, bem como os elementos estruturais de concreto, estão sujeitos ao fraturamento em decorrência de inúmeras causas. O carregamento mecânico é uma das mais importantes delas, mas existem também causas físicas, como a variação de umidade, gradientes de temperatura e ataques químicos.

O processo de fratura pode estar associado inicialmente às leis que governam a resistência dos materiais. Para aumentar essa capacidade de resistência do concreto, faz-se uso do aço, posicionado em locais específicos, a fim de elevar os níveis de tensões resistentes. Essa associação aço/concreto apresenta inúmeras vantagens do ponto de vista estrutural. Além disso, a ligação é boa o suficiente para permitir um curto comprimento de ancoragem das armaduras. Mas, mesmo com as boas relações dessa combinação, existem alguns problemas devido à porosidade relativamente elevada do concreto e, muitas vezes uma elevada permeabilidade do cobrimento do concreto em relação ao aço. Isso expõe o concreto a ação de cloretos e outros agentes que são agressivos às armaduras de aço, que causam a corrosão. Como produto da corrosão ocorre o aumento de volume que introduz tensões de tração, provocando fissuração no concreto.

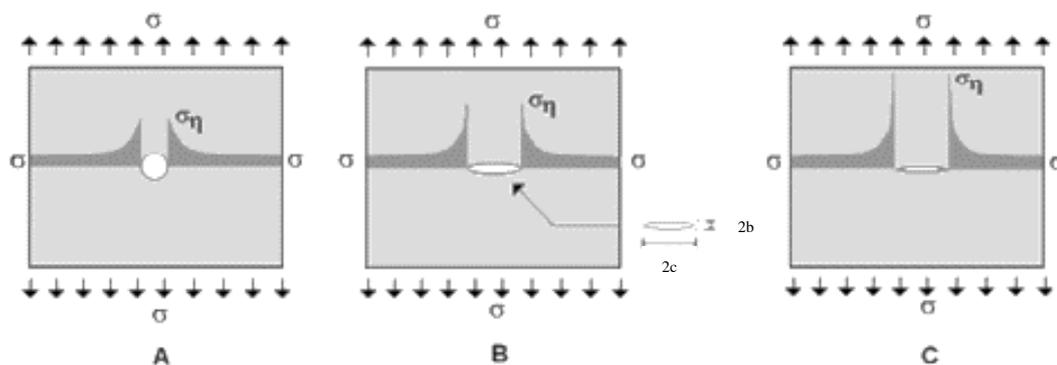
É evidente que existem outros fatores que influenciam na durabilidade das estruturas de concreto, mas a fissuração é a principal responsável pelo processo de deterioração. É bastante apropriada a investigação dos processos de fratura, e identificar as causas para tal, e desenvolver modelos que possam prever o comportamento das fissuras ao longo da vida útil destas estruturas. Desde o início da década de 1970 existem esforços voltados para que sejam criados modelos robustos e confiáveis simulando o processo de fissuração. Atribui-se essa evolução dos modelos à introdução do método dos elementos finitos e outras técnicas de simulação numérica em ciência e engenharia. (VAN MIER, 2013).

Qualquer material, incluindo um material homogêneo como o vidro, contém imperfeições. Estas imperfeições são a fonte de concentrações de tensão, que podem levar à ruptura do material bem abaixo da sua resistência teórica. Concentrações de

tensão em materiais são, por exemplo, causados pela presença de poros, inclusões e interfaces entre as fases distintas de material.

Ferreira (2015) diz que as concentrações de tensões geram rupturas das ligações e nucleações sucessivas de microfissuras, causando a acumulação do dano, que ocorre nos materiais compósitos a partir da perda de coesão entre as diferentes fases do material. No princípio, o processo de danificação é caracterizado pela propagação estável das microfissuras. Por crescimento estável entende-se a necessidade de aumento do carregamento externo para que a fissura volte a propagar. Por outro lado, a acumulação de danos não se dá exclusivamente por razões de ordem mecânica ou geométrica. Outros processos importantes de acumulação de danos são os processos assistidos pelo meio, onde pode-se destacar o processo de corrosão. Na macroescala do elemento estrutural, pequenas regiões que apresentem irregularidades, descontinuidades externas ou internas decorrentes de detalhes mal projetados ou de defeitos de fabricação são regiões potencialmente concentradoras de tensões, as quais podem levar a estrutura à danificação progressiva, à fissuração e ao colapso. A Figura 3.1 apresenta chapas tracionadas com furos de diferentes formatos (circular – Figura 3.1a, e elipsoidal – Figura 3.1b), com a ideia de demonstrar a concentração de tensões nestes elementos. A Figura 3.1c mostra o que acontece em uma situação real, onde  $b$ , o semieixo da elipse formada pela fissuração, é praticamente zero, e ocorre o que se denomina configuração de fissura. Nesse caso, a relação  $c/b$  tende ao infinito e, matematicamente, a tensão também tenderá a crescer infinitamente.

Figura 3.1 – Modos de fissura: (a) modo 1; (b) modo 2; e, (c) modo 3.



Fonte: Adaptado de Ferreira, 2015.

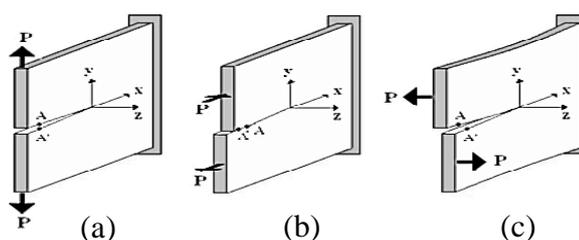
A propagação de fissuras em elementos estruturais ocorre, fundamentalmente, por intensificação de tensões acima da resistência ao fraturamento do material (FERREIRA, 2015). Esta propagação pode ocorrer segundo diferentes regimes. O crescimento estável está relacionado com a carga aplicada. Cessada a carga, a fissura para de propagar. Este tipo é comum em concretos, argamassas, cerâmicas e rochas. No crescimento metaestável a fissura cresce sem que haja, necessariamente, o aumento do carregamento externo e na maioria das vezes, o crescimento da fissura é tanto estável como limitado. Por último, o crescimento instável, é aquele que se verifica uma vez atingida a carga crítica, ou a carga de colapso (encontrado em materiais frágeis).

A seguir, são abordados de forma breve os modelos clássicos de fratura, nomeados como mecânica da fratura linear elástica (*Linear Elastic Fracture Mechanics – LEFM*), por meio dos três modos básicos de fissuras (modo de tração, no plano de cisalhamento, e o modo de fissura fora do plano de cisalhamento, conhecidos como modos I, II e III, respectivamente). É também apresentado o modelo plástico para fissuras em metais plásticos e em concretos, baseado no método de fissura fictícia de Hillerborg, que necessita de um melhor conhecimento do comportamento do concreto no estado fresco. (Hillerborg *et al.* 1976).

### 3.1 Mecânica da fratura linear elástica

Segundo Van Mier (2013), a concentração de tensões em um elemento leva a um dos três modos de fissura, que são conhecidos como sendo os modelos clássicos. Na Figura 3.2 eles são apresentados: o modo de abertura por esforço de tração ou modo 1; o modo de cisalhamento no plano ou modo 2; e, o modo de cisalhamento fora do plano ou modo 3.

Figura 3.2 – Modos de fratura: (a) modo 1; (b) modo 2; e, (c) modo 3.



Fonte: Ferreira, 2015.

Combinando-se os modos de fissura entre si, são gerados os modos-mistos, por exemplo, tensão de tração e cisalhamento podem ser modo 1+2 ou modo 1+3. Na prática da engenharia, o modo mais frequentemente adotado é o modo 1. Os outros são menos utilizados, apesar de terem sua devida importância.

É imprescindível o conhecimento do comportamento detalhado das componentes de tensões e deslocamentos de cada um dos modos de fissura. Tratando-se de uma avaliação linear elástica, parâmetros como coeficiente de Poisson ( $\nu$ ) e módulo de elasticidade longitudinal ( $E$ ) são aliados ao estudo da mecânica da fratura para determinação de tais vetores.

Para o modo 1, as componentes de tensões são representadas pela Equação 5:

$$\begin{Bmatrix} \sigma_{xx} \\ \sigma_{yy} \\ \sigma_{xy} \end{Bmatrix} = \frac{K_I}{\sqrt{2\pi r}} \begin{Bmatrix} \cos \frac{\theta}{2} \left[ 1 - \sin \frac{\theta}{2} \sin \frac{3\theta}{2} \right] \\ \cos \frac{\theta}{2} \left[ 1 + \sin \frac{\theta}{2} \sin \frac{3\theta}{2} \right] \\ \sin \frac{\theta}{2} \cos \frac{\theta}{2} \cos \frac{3\theta}{2} \end{Bmatrix} \quad (5)$$

Sendo  $\sigma_{zz} = 0$  para o estado plano de tensões e como  $\sigma_{zz} = \nu(\sigma_{xx} + \sigma_{yy})$ ,  $\sigma_{xz} = \sigma_{yz} = 0$ , e  $K_I$  é o fator de intensidade de tensão do modo 1. Este fator é definido por Irwin (1958), apresentado na Equação 6, onde:

$$K_I = \sigma_{yy}^{\infty} \sqrt{\pi a} \quad (6)$$

Já as componentes de deslocamentos são representadas pela Equação 7:

$$\begin{Bmatrix} u_{xx} \\ u_{yy} \end{Bmatrix} = \frac{K_I}{2E} \sqrt{\frac{r}{2\pi}} \begin{Bmatrix} (1 + \nu) \left[ (2k - 1) \cos \frac{\theta}{2} - \cos \frac{3\theta}{2} \right] \\ (1 + \nu) \left[ (2k + 1) \sin \frac{\theta}{2} - \sin \frac{3\theta}{2} \right] \end{Bmatrix} \quad (7)$$

Em que:

$$u_{zz} = -\frac{\nu z}{E} (\sigma_{xx} + \sigma_{yy}) \quad (8)$$

$$k = (3 - \nu)/(1 + \nu) \quad (9)$$

para o estado plano de tensões, e  $u_z = 0$  e  $k = 3 - 4\vartheta$  para o estado plano de deformações. No que diz respeito ao modo 2, as componentes de tensões são expressas pela Equação 10:

$$\begin{Bmatrix} \sigma_{xx} \\ \sigma_{yy} \\ \sigma_{xy} \end{Bmatrix} = \frac{K_{II}}{\sqrt{2\pi r}} \begin{Bmatrix} -\sin \frac{\theta}{2} \left[ 2 + \cos \frac{\theta}{2} \cos \frac{3\theta}{2} \right] \\ \sin \frac{\theta}{2} \cos \frac{\theta}{2} \cos \frac{3\theta}{2} \\ \cos \frac{\theta}{2} \left[ 1 - \sin \frac{\theta}{2} \sin \frac{3\theta}{2} \right] \end{Bmatrix} \quad (10)$$

Os valores de  $\sigma_{zz}$ ,  $\sigma_{xz}$ ,  $\sigma_{yz}$  são nulos no estado plano de tensões, como já demonstrado no modo 1. Para o modo 2, as componentes  $u_{xx}$  e  $u_{yy}$ , de deslocamentos, são expressas pela Equação 11, uma vez que  $u_{zz}$  recebe seus respectivos valores de acordo com aquilo que foi mencionado para o modo 1.

$$\begin{Bmatrix} u_{xx} \\ u_{yy} \end{Bmatrix} = \frac{K_{II}}{2E} \sqrt{\frac{r}{2\pi}} \begin{Bmatrix} (1 + \vartheta) \left[ (2k + 3) \sin \frac{\theta}{2} + \sin \frac{3\theta}{2} \right] \\ -(1 + \vartheta) \left[ (2k - 3) \cos \frac{\theta}{2} + \cos \frac{3\theta}{2} \right] \end{Bmatrix} \quad (11)$$

A definição de  $k$  é a mesma do modo 1, porém  $K_{II}$  é definido de forma diferente (Equação 12):

$$K_{II} = \sigma_{xy}^{\infty} \sqrt{\pi a} \quad (12)$$

E, finalmente, o modo 3, que apresenta valores nulos para:  $\sigma_{xx}$ ,  $\sigma_{yy}$ ,  $\sigma_{zz}$ ,  $\sigma_{xy}$ ,  $u_{xx}$ ,  $u_{yy}$ , além de  $\sigma_{xz}$ ,  $\sigma_{yz}$  expressos pela Equação 13,  $u_z$  pela Equação 14, e  $K_{III}$ , pela Equação 15.

$$\begin{Bmatrix} \sigma_{xz} \\ \sigma_{yz} \end{Bmatrix} = \frac{K_{III}}{\sqrt{2\pi r}} \begin{Bmatrix} -\sin \frac{\theta}{2} \\ \cos \frac{\theta}{2} \end{Bmatrix} \quad (13)$$

$$\{u_{zz}\} = \frac{4K_{III}}{E} \sqrt{\frac{r}{2\pi}} \left\{ (1 + \vartheta) \sin \frac{\theta}{2} \right\} \quad (14)$$

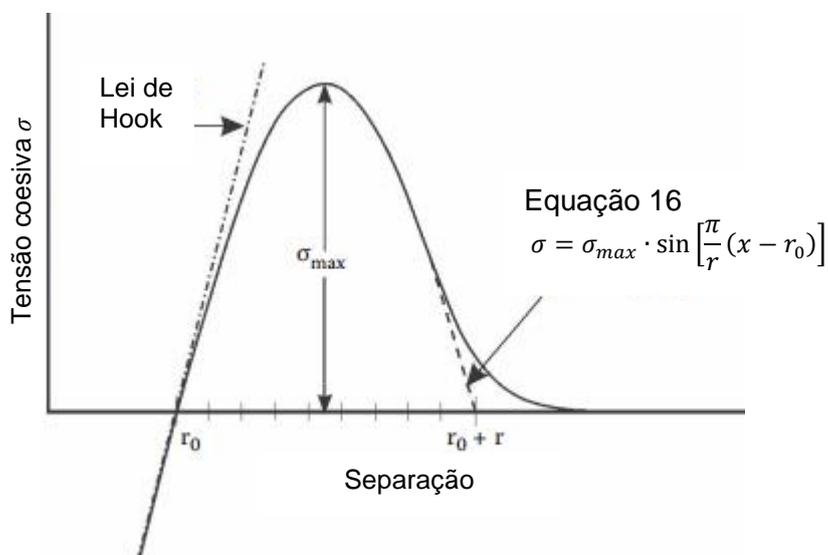
$$K_{III} = \sigma_{yz}^{\infty} \sqrt{\pi a} \quad (15)$$

### 3.2 Modelo plástico de fissura

A aplicabilidade dos conceitos apresentados para as relações elásticas entre tensão e deformação não se aplicam adequadamente em algumas situações. Para sólidos cristalinos se vê a necessidade de incluir um potencial energético para lidar de uma forma realista com os processos de fissuras.

A área abaixo da curva apresentada na Figura 3.3 é a quantidade de energia necessária para separar dois átomos, isto é, quebrar a ligação. O comportamento real do potencial atômico é mostrado como uma linha contínua, enquanto que a aproximação senoidal é mostrada como uma linha tracejada. No ponto em que a curva intercepta o eixo x, a inclinação da curva é igual ao módulo de Young, como é comumente usado na lei de Hooke. Esta energia necessária para quebrar a ligação é, de fato, duas vezes a energia de superfície específica para o sólido sob consideração. Com base na coesão causada por este potencial, Barenblatt (1962) desenvolveu um modelo de fissuração coesiva, que serviu como base para desenvolvimentos posteriores na mecânica da fratura de concretos. As tensões coesivas causadas pelas ligações atômicas agem ao longo do plano da fissura perto da sua ponta. Uma importante hipótese apresentada por Barenblatt é que a zona coesiva deve ser pequena em comparação com o tamanho da fissura.

Figura 3.3 – Potencial atômico ou curva coesiva de tensão-separação descrevendo a ligação entre dois planos atômicos em um sólido cristalino.

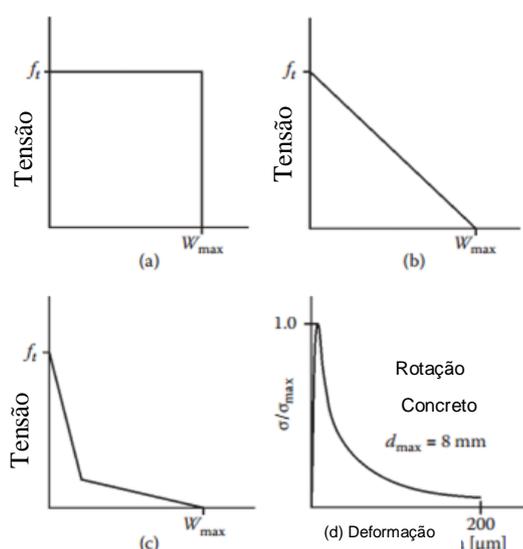


Fonte: Adaptado de Van Mier, 2013.

Hillerborg *et al.* (1976) apresentam o modelo de fissura fictícia (MFF) como sendo uma extensão do modelo plástico de fissura. Ele inclui uma zona de processo semelhante à zona de fissuração plástica, embora a distribuição de tensões não seja uniforme como no modelo de Dugdale (1960), e a máxima tensão mínima era muito menor, isto é, igual à resistência à tração do concreto. As microfissuras estariam presentes na zona de processo, mas as tensões poderiam ainda ser transmitidas. Em Hillerborg *et al.* (1976) e Petersson (1980), o modelo é descrito em detalhe.

A forma da curva de amolecimento é muitas vezes aproximada por meio de funções lineares ou bilineares, como mostrado na Figura 3.4. Os desvios das curvas observadas podem ser muito grandes, se comparados com os obtidos na realidade, como pode ser visto a partir de uma comparação das curvas aproximadas com o resultado da medição da Figura 3.4(d).

Figura 3.4 – Formas da curva de amolecimento: (a) função bilinear tipo 1; (b) função linear; (c) função bilinear tipo 2; e, (d) curva de amolecimento real.



Fonte: Adaptado de Van Mier, 2013.

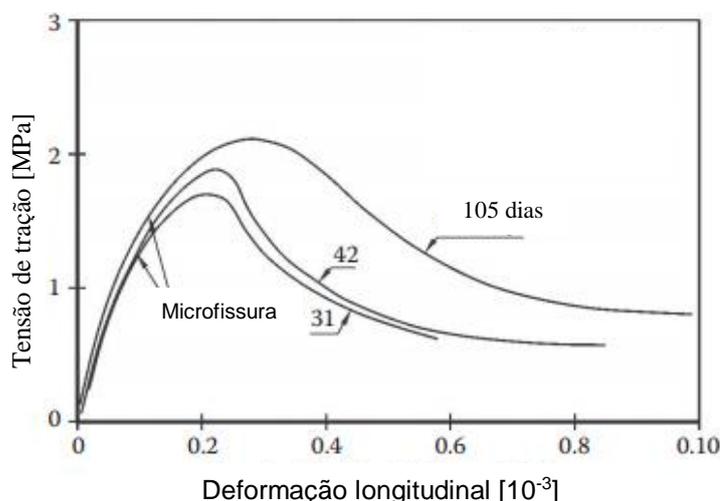
Existem duas quantidades importantes que podem ser derivadas do Modelo de Fissura Fictícia: a energia de fratura específica ( $G_f$ ) e o comprimento característico ( $L_{ch}$ ). Estes parâmetros são utilizados para tentar quantificar a fragilidade do concreto. A energia de fratura específica ( $G_f$ ) é definida como a quantidade de energia necessária para criar uma área de fissura unitária, e equivale à área abaixo da curva

de amolecimento. A curva de amolecimento e, portanto, também a energia de fratura, só podem ser determinadas num teste de tensão uniaxial estável controlado por deslocamento. Uma energia de fratura específica mais elevada significaria um material mais dúctil. O segundo parâmetro, o comprimento característico ( $L_{ch}$ ) do material é definido na Equação 17.

$$L_{ch} = \frac{EG_f}{f_t^2} \quad (17)$$

Segundo Van Mier (2013), o diagrama de deformação de um material e uma estrutura apenas pode ser obtido através do uso de avançadas técnicas de ensaios, que atualmente podem ser feitos com o auxílio de máquinas hidráulicas e máquinas eletromecânicas. Para a determinação dos parâmetros associados à mecânica da fratura, propõe-se usar um ensaio de tensão uniaxial com deslocamento controlado (Figura 3.5). A partir deste ensaio é possível realizar uma análise do comportamento do concreto com os dias. É importante que neste tipo de ensaio as placas devem ser fixadas a fim de evitar rotações e a carga aplicada seja distribuída uniformemente.

Figura 3.5 – Comportamento tensão-deformação de concreto submetido a tensão uniaxial.

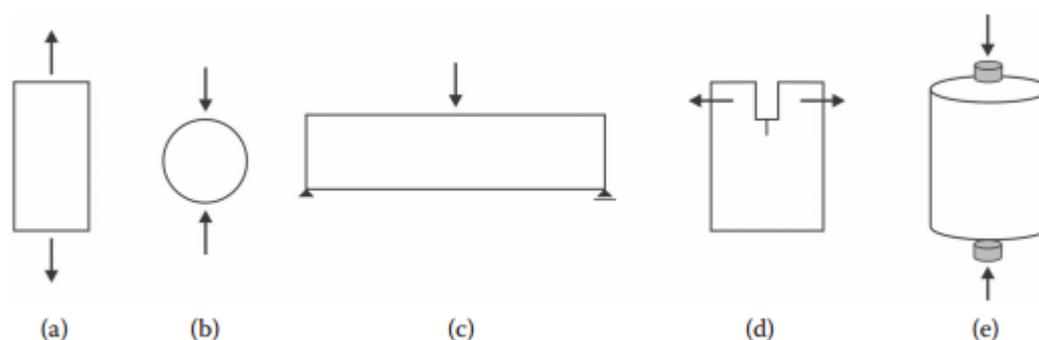


Fonte: Adaptado de Van Mier, 2013.

Porém este ensaio de tensão uniaxial não é tão simples de ser conduzido. Devido às dificuldades encontradas, várias pesquisas preferem medir os parâmetros de MFF utilizando métodos indiretos, incluindo os ensaios de 3 pontos ou 4 pontos (Figura

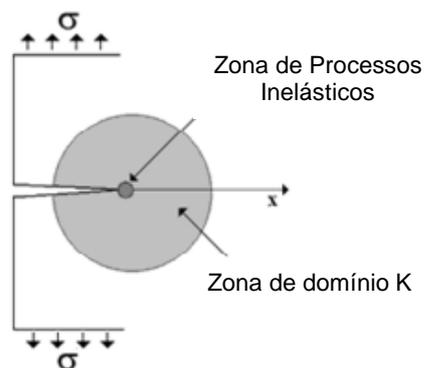
3.6c), o ensaio de cunha (Figura 3.6d, Tschegg *et al.*, 1986 e Linsbauer *et al.*, 1986), o ensaio de Lobo Carneiro (*Brazilian test*) (Figura 3.6b) proposto por Akazawa em 1943 e Carneiro em 1949, apresentados em Nilsson (1961), ou o ensaio de compressão dupla (Figura 3.6e, Chen, 1970). Estes ensaios são preferidos pela uniformidade na distribuição dos carregamentos aplicados e pela facilidade de execução.

Figura 3.6 – Comportamento tensão-deformação de concreto submetido a tensão uniaxial.



Fonte: Van Mier, 2013.

Ferreira (2015) apresenta outros conceitos importantes relacionados às teorias plásticas da mecânica da fratura como a zona de domínio de K, e a zona de processos inelásticos (ZPI). A primeira se trata de uma região circunferencial de maior diâmetro que envolve a ponta da fissura, dentro da qual os campos de tensão e de deformação são descritos e governados pelo fator de intensidade de tensão. Dentro dessa região, e somente nela, a formulação analítica pode ser considerada exata. Em regiões mais externas a esse anel, os desvios são mais significativos em relação à solução exata. O fato deve-se às simplificações de proximidade adotadas ao longo da dedução das equações do tensor de tensão. Quando as tensões na região próxima à ponta de uma fissura excedem o nível da resistência elástica do material, inicia-se, em uma região que envolve essa ponta, a formação da ZPI, conforme ilustrado na Figura 2.8, com a circunferência de menor diâmetro e cor mais escura.

Figura 3.7 – Zona de Processos Inelásticos e Zona de Domínio de  $K$ .

Fonte: Adaptado de Ferreira, 2015.

O entendimento dos tópicos da mecânica do dano contínuo e da mecânica da fratura são fundamentais para que os mecanismos associados a monitoração da integridade estrutural sejam aplicados e entendidos em sua plenitude, e podem ser utilizados para verificar a existência de dano nas estruturas de concreto.

## 4 MONITORAÇÃO DA INTEGRIDADE ESTRUTURAL

A Monitoração da Integridade Estrutural (MIE), internacionalmente conhecida como *Structural Health Monitoring* (SHM), é um campo emergente da Engenharia, que por meio do emprego de transdutores<sup>1</sup> e equipamentos não-destrutivos, aliados à análise das características do sistema estrutural observado, possibilita avaliar de forma periódica ou contínua a integridade e a segurança das estruturas e elementos estruturais monitorados (THAKKAR, 2006). Nos sistemas de monitoração aplicados a estruturas de Engenharia Civil, o acompanhamento do comportamento das estruturas ao longo do tempo é realizado por meio da medição de grandezas como a deformação, a aceleração, o deslocamento linear ou angular, a temperatura, a umidade relativa e a força, entre outras. A partir da devida interpretação dessas informações, é possível determinar o estado da estrutura observada, e estudar, entre outros aspectos, o comportamento reológico e os efeitos estruturais decorrentes da adoção de um determinado processo construtivo (FÉLIX, 2005). Entretanto, apesar dos significativos avanços realizados pela comunidade científica nesse campo, ainda existe uma grande necessidade de aperfeiçoamento de métodos para identificar, localizar e quantificar o dano estrutural, que corresponde a modificações que afetam negativamente o desempenho funcional da estrutura (EN1990, 1990). Desse modo, para a caracterização do dano, torna-se necessária a comparação dos estados inicial (denominado de estado não danificado) e final (denominado de estado danificado) da estrutura ou elemento em estudo.

A identificação do dano em estruturas, bem como o correspondente grau de intensidade, fornece importantes vantagens no projeto e execução de estruturas. Uma vantagem é a capacidade de melhor identificar quando são necessárias intervenções, para que desta forma se possa realizar operações de manutenção em tempo oportuno. Outra capacidade é a de estimar a durabilidade da estrutura, quando esta já foi submetida a determinado nível de dano. Existem diversos métodos de detecção de dano, embora não exista um sistema robusto para tal fim que seja reconhecido como definitivo. Os métodos de identificação de dano podem ser classificados como

---

<sup>1</sup> Um transdutor é um dispositivo eletromecânico que faz corresponder, segundo uma determinada lei ou função de transferência, uma grandeza de saída (sinal eléctrico usualmente na forma de tensão, corrente ou resistência) a partir de uma grandeza de entrada (como por exemplo temperaturas, deslocamentos, forças, velocidades, entre outros) (Campilho, 2000).

métodos locais ou métodos globais. O emprego de métodos locais parte da premissa que a região danificada é previamente conhecida, e a quantificação e extensão do dano são realizadas utilizando-se técnicas experimentais, dentre as quais destacam-se os testes de ultrassom, testes acústicos, métodos de campo magnético, uso de raios x e radar, dentre outros (FAN e QIAO, 2011; MALHOTRA e CARINO, 2004). Uma das principais desvantagens desses métodos está na necessidade de acesso obrigatório de pessoal e/ou equipamentos aos pontos da estrutura mais propícios a falhas, o que nem sempre é possível em virtude das características dos locais a inspecionar, do comprometimento da segurança dos operadores e do custo envolvido (FERREIRA, 2008).

Os métodos globais permitem a identificação de danos a partir da alteração de propriedades globais da estrutura inspecionada, e em geral não apresentam as dificuldades e desvantagens inerentes aos métodos locais. Atualmente, os métodos globais mais usuais empregam a resposta dinâmica da estrutura, com posterior análise de vibrações. A ideia fundamental associada à análise de vibrações refere-se à premissa que as mudanças das propriedades físicas (massa e rigidez, por exemplo) produzidas pela danificação estrutural implicam em mudanças detectáveis nas propriedades modais das estruturas (frequências naturais, formas modais, etc.). Particularmente, as frequências naturais são indicadores sensíveis de integridade estrutural (SALAWU, 1997). Assim, é possível classificar os diversos métodos baseados em análise de vibrações de acordo com a característica dinâmica utilizada para análise, dentre os quais destacam-se o método baseado nas variações de frequência natural, o método da variação das formas modais, o método baseado nas variações das curvaturas das formas modais e o método da flexibilidade dinâmica (CARDEN e FANNING, 2004; DOEBLING, FARRAR e PRIME, 1998; FAN e QIAO, 2011).

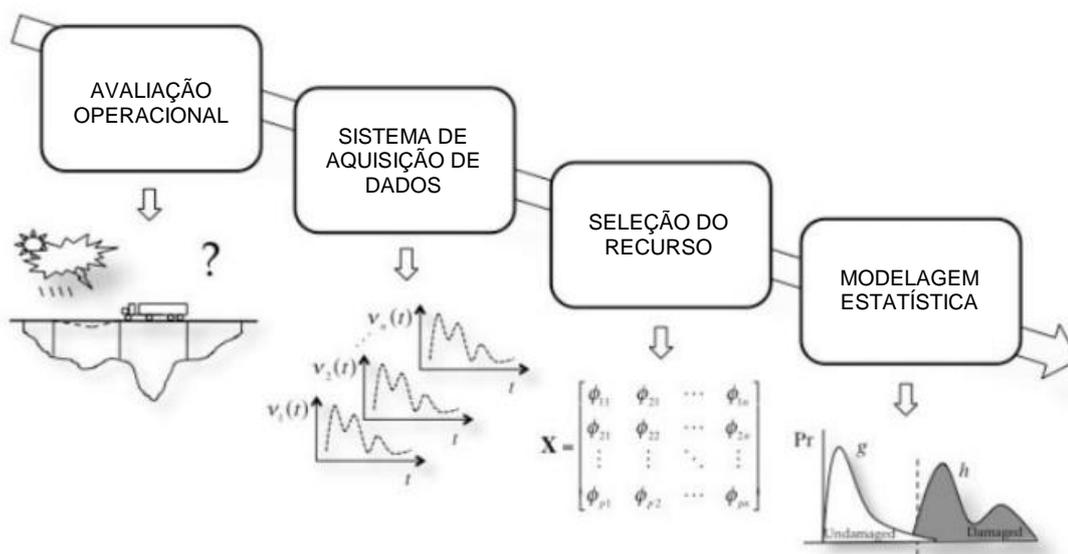
Os métodos globais de identificação de danos que utilizam a resposta estática foram desenvolvidos tendo em vista, principalmente, a avaliação da integridade estrutural em pontes, visto que nestas estruturas é difícil obter mudanças significativas das propriedades modais (CHOI, 2002; PALECHOR, 2013). Os principais métodos estáticos são o método da variação de deslocamentos estáticos e o método da viga conjugada.

No método da variação de deslocamentos estáticos, é realizada uma avaliação do dano a partir da variação da rigidez global da estrutura, que por sua vez está relacionada com a variação dos deslocamentos estáticos. As medidas dos deslocamentos, provocadas pelas cargas estáticas, podem ser obtidas com o peso próprio da estrutura. Este método é muito eficiente na localização de um único dano na estrutura. O método da viga conjugada, por sua vez, consiste em gerar uma viga fictícia com o mesmo comprimento e as mesmas características mecânicas da viga original. Esta viga fictícia será submetida a uma carga fictícia que tem relação com o diagrama de momentos fletores e rigidez à flexão da viga original, aplicando-se posteriormente o método da superposição para determinação dos deslocamentos nas vigas real e fictícia, determinando-se em seguida, por um processo iterativo, a rigidez à flexão das vigas. O dano estrutural corresponderá à redução da rigidez à flexão da viga original (PALECHOR, 2013).

#### 4.1 Procedimento de um sistema de SHM

Pereira (2012) afirma que em geral um sistema de SHM pode ser definido através de quatro procedimentos (Figura 4.1), com a finalidade de fazer análise de reconhecimentos de padrões de dano.

Figura 4.1 – Procedimento utilizado para análise de reconhecimentos de padrões de dano.



Fonte: Adaptado de Pereira, 2012.

#### i. Avaliação operacional

O processo de avaliação operacional tenta fornecer respostas para quatro questões relativas à identificação de dano: a justificativa econômica para realizar o monitoramento de integridade estrutural; a capacidade do sistema identificar os danos e quais casos seriam mais preocupantes; as condições, operacionais e ambientais, em que as funções são monitoradas; e quais as limitações à aquisição de dados no ambiente.

A avaliação começa a definir limitações sobre o que será avaliado e como o monitoramento será realizado. Ela tenta adaptar o processo de identificação de danos para propriedades que são únicas para o sistema que está sendo monitorado e busca explorar as propriedades dos elementos utilizados como referência (condição íntegra), para o dano que se pretende detectar.

#### ii. Sistema de aquisição de dados

Envolve selecionar os tipos de transdutores, número e localização, bem como ocorrerá a aquisição dos dados. Considerações de ordem econômica irão desempenhar um papel importante na tomada de decisões sobre o sistema de aquisição de dados a ser utilizado para o sistema SHM. O intervalo no qual os dados devem ser recolhidos é outra consideração que deve ser abordada. Se o crescimento de fissura é o modo de falha de interesse, pode ser necessário recolher dados em intervalos de tempo relativamente curtos, uma vez que algumas fissuras críticas seriam identificadas.

#### iii. Seleção do algoritmo

A parte do processo SHM que indiscutivelmente recebe a maior atenção na literatura técnica é a identificação de propriedades dos dados que permitem distinguir entre os estados não danificados e danificados da estrutura de interesse (Doebeling *et al.*, 1996; Sohn *et al.*, 2004). Os algoritmos variam consideravelmente na sua complexidade, quanto à compreensão do algoritmo e à sua utilização. O ideal é um conjunto de baixa complexidade que seja altamente sensível à condição da estrutura. Este processo de identificação de propriedades dos dados para distinguir os diferentes estados de

danificação envolve diversas operações matemáticas ou transformações. (SOHN *et al.* 2003).

Segundo Camilo e Silva (2009), a partir da definição dos dados que são utilizados para distinguir os níveis de dano, diversas análises podem ser realizadas. As mais comuns são:

**Classificação:** Visa identificar a qual classe um determinado registro pertence. Nesta tarefa, o modelo analisa o conjunto de dados fornecidos, com cada registro já contendo a indicação à qual classe pertence, a fim de “aprender” como classificar um novo registro (aprendizado supervisionado);

**Regressão:** A regressão é similar à classificação, porém é usada quando os dados são numéricos e não simbólicos. Assim, pode-se estimar o valor de uma determinada variável analisando-se os valores das demais;

**Agrupamento:** A tarefa de agrupamento visa identificar e aproximar os dados com propriedades semelhantes. Um agrupamento (ou *cluster*) é um grupo de registros similares entre si, porém diferentes dos outros registros nos demais agrupamentos. Esta tarefa difere da classificação pois não necessita que os registros sejam previamente categorizados (aprendizado não-supervisionado). Além disso, ela não tem a pretensão de classificar, estimar ou prever o valor de uma variável, ela apenas identifica os grupos de dados similares.

#### iv. Modelagem estatística

O desenvolvimento de um modelo estatístico está relacionado com a execução de algoritmos que operam sobre os dados extraídos para quantificar o estado de dano da estrutura. A relação funcional entre os recursos selecionados e o estado de dano da estrutura é muitas vezes difícil de definir com base em procedimentos de análise de engenharia. Portanto, os modelos estatísticos são derivados utilizando técnicas de aprendizado de máquina. Quando dados de treinamento estão disponíveis, tanto da estrutura intacta como da danificada, algoritmos de aprendizagem podem ser usados. No contexto da SHM, problemas de aprendizagem não supervisionada surgem quando apenas os dados da estrutura intacta estão disponíveis para a formação. Os

resultados obtidos em cada algoritmo são analisados por recursos estatísticos, a fim de concluir o processo de reconhecimento de padrões de dano.

O estado de dano de um sistema pode, em princípio, ser alcançado através de um processo de cinco passos organizados (Figura 4.2) ao longo das linhas da hierarquia, discutido em Rytter (1993).

Figura 4.2 – Processo hierárquico de identificação do dano.



Fonte: Autor.

- a) Verificação de existência: o princípio básico neste ponto é determinar a existência de dano na estrutura. Para tomar decisões em relação à estrutura, é preciso considerar o pior cenário, pois informações sobre a condição real dos materiais, as ações de carga real ou mesmo a vida útil da estrutura são fatores desconhecidos.
- b) Localização: os sistemas de SHM adequados podem fornecer informações sobre a localização do dano, permitindo que se adotem as ações adequadas com antecedência à ruína. Esta detecção precoce de um mau funcionamento estrutural permite uma intervenção rápida com menores custos de manutenção.
- c) Tipo: definir o tipo de dano presente na estrutura auxilia na escolha das melhores soluções, e os sistemas SHM têm o potencial de descobrir essas informações.
- d) Gravidade: a tecnologia de SHM, sendo um sistema de detecção que monitora a resposta da estrutura e notificando que o dano foi detectado, pode otimizar esses sistemas, transformando-os em manutenção baseada nas condições de gravidade do dano encontrado.

- e) Prognóstico: fazer um pequeno investimento em sistemas de SHM no início de um projeto pode trazer economias mais tarde, devido à otimização do projeto e dos materiais, aspectos estes que podem aumentar a vida útil da estrutura. Esse aumento ocorre também para as estruturas em serviço monitoradas.

As respostas a estes cinco passos representam o conhecimento crescente do estado de dano. Quando aplicado em um modo de aprendizagem não supervisionada, modelos estatísticos geralmente podem ser usados para responder a perguntas sobre a existência (e às vezes, mas nem sempre, a localização) de dano. Quando aplicada em um modo de aprendizagem supervisionada e acoplado com modelos analíticos, os procedimentos indicados podem, em teoria, ser usados para determinar o tipo de dano, a extensão dos danos e a vida útil restante da estrutura. Os modelos estatísticos são construídos para minimizar falsos diagnósticos. Diagnósticos falsos caem em duas categorias: a indicação de dano falso-positivo (indicação de danos quando nenhum dano estiver presente) e indicação de dano falso-negativo (sem indicação de danos quando o dano está presente) (PEREIRA, 2012).

## 4.2 Reconhecimento de padrões de dano

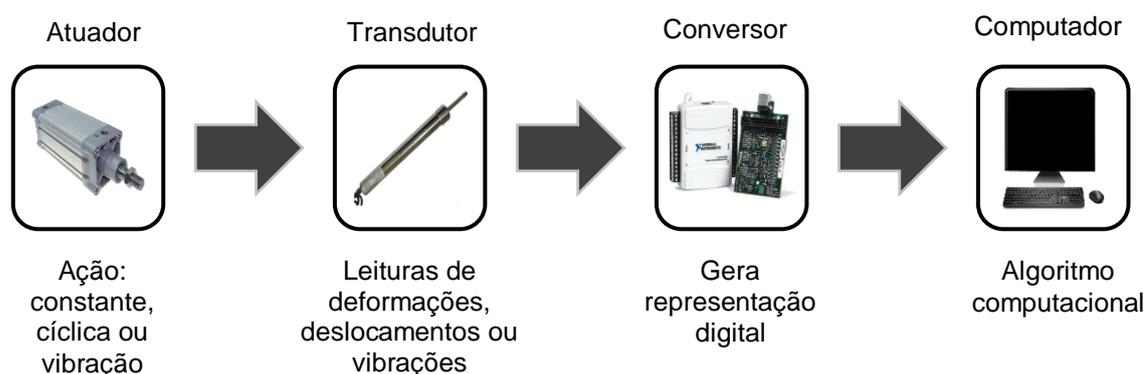
O Reconhecimento de Padrões é uma área da ciência que tem como objetivo a classificação de objetos em um determinado número de categorias ou classes a partir da observação de suas características (THEODORIDIS e KOUTROUMBAS, 2003). Recentemente, vários algoritmos para tratamento estatístico de dados e reconhecimento de padrões têm sido testados e propostos pela comunidade científica em geral, como as transformadas *wavelets*, os modelos de misturas gaussianas (GMM, do inglês: *Gaussian Mixture Models*) e as máquinas de vetores de suporte (SVM, do inglês: *Support Vector Machines*) (FARRAR e WORDEN, 2012; FIGUEIREDO e CROSS, 2013; SOHN et al., 2004; NAIR e KIREMIDJIAN, 2007; PEETERS, MAECK e DE ROECK, 2001; SATPAL et al., 2013).

O problema de reconhecimento de padrões foi formulado na década de 1950. Trata-se de um processo de monitoramento ou leitura de variáveis físicas da estrutura (como o estado de deformações, o estado de tensão etc.) ao longo do tempo, quando uma estrutura é submetida a um estado de carregamento constante ou incremental. Esse

monitoramento é realizado em tempo real e ao longo deste tempo, a estrutura pode inclusive ser submetida a cargas reais de serviço.

Neste processo (Figura 4.3), um atuador provoca uma ação controlada sobre a estrutura. Esta ação pode ser um carregamento cíclico, um carregamento constante, ou uma vibração. A ação atuante faz com que a estrutura apresente deformações, deslocamentos ou vibração (respostas estruturais). Essas respostas são propagadas para o ambiente externo e para as os pontos da estrutura onde os transdutores estão posicionados. A recepção, condicionamento, armazenamento e transmissão dos sinais é realizada pelos sistemas de aquisição. Os sinais são transportados através de sistemas de transmissão até um computador central (Unidade de comando e controle) preparado através de um algoritmo computacional capaz de transformar a resposta da estrutura em informações a respeito dos danos estruturais, que podem ser inerentes tanto às ações a que a estrutura está submetida como ao envelhecimento e degradação, em resultado da operacionalidade e exposição às condições ambientais (FIGUEIREDO, 2006).

Figura 4.3 – Processo de reconhecimento de padrões.



Fonte: Autor.

O trabalho de Figueiredo (2006) compara o funcionamento do SHM ao funcionamento do corpo humano, onde os atuadores seriam os músculos, os transdutores e sistemas de aquisição seriam os órgãos sensoriais, os sistemas de transmissão seriam os nervos sensitivos, a unidade de comando e controle seria o cérebro e os sistemas de instrução seriam os nervos motores. Um sistema composto desses componentes é denominado sistema de monitoração inteligente.

### 4.2.1 Wavelets

A palavra *wavelet* tem como origem a palavra francesa “*Ondulette*”, que significa onda pequena. As *wavelets* foram mencionadas pela primeira vez no apêndice da tese de Haar (1910). Estas *wavelets* ficaram no anonimato por vários anos, até que nos anos 30, vários grupos trabalhando de forma independente pesquisaram a representação de funções usando uma base e variando com a escala. Naquela ocasião, usando como base as *wavelets* de Haar, Paul Levy investigou o movimento Browniano. Ele mostrou que as funções com a base de Haar eram melhores do que as funções com a base de Fourier para estudar os pequenos e complicados detalhes do movimento Browniano.

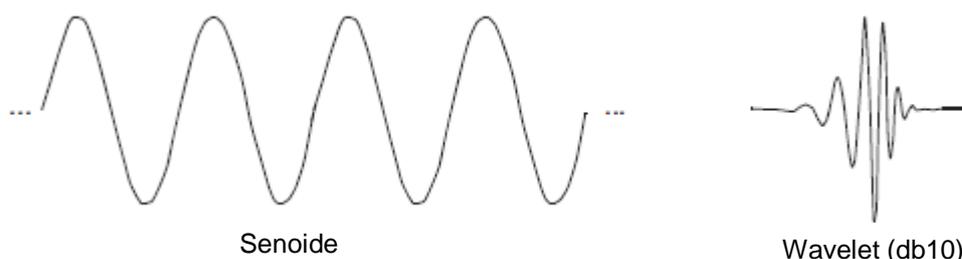
Por um período longo, as *wavelets* de Haar continuaram a ser a única base ortonormal de *wavelets* conhecida. Em 1987, Mallat deu às *wavelets* um grande impulso através de seu trabalho em processamento digital de imagens. Meyer (1989) inspirado nos resultados de Mallat construiu a primeira *wavelet* não trivial (suave). Ao contrário das *wavelets* de Haar, as *wavelets* de Meyer são continuamente diferenciáveis, mas não têm suportes compactos<sup>2</sup>. Em 1990, Ingrid Daubechies usou os trabalhos de Mallat, para construir um conjunto de bases ortonormais de *wavelets* suaves, com suportes compactos. Estes trabalhos são os alicerces das aplicações atuais das *wavelets* (PALECHOR, 2013).

Uma *wavelet* é uma forma de onda de duração limitada, que tem média igual a zero. Comparando uma *wavelet* com uma onda produzida pela função seno, que são a base da análise de Fourier, encontram-se algumas diferenças (Figura 4.4). A primeira delas é que os senoides não têm duração limitada, estendendo-se de menos a mais infinito. Além dessa consideração, eles são suaves e previsíveis, quando as *wavelets* tendem a ser irregulares e assimétricas.

---

<sup>2</sup> Suportes compactos: é o conjunto de pontos onde a função não é nula. Propriedade adequada para representações de características locais.

Figura 4.4 – Representação de um senoide e de uma *wavelet*.



Fonte: Adaptada de Misiti *et al.*, 2002.

A análise de Fourier consiste em dividir um sinal em ondas senoidais de diferentes frequências. Da mesma forma, a análise *wavelet* é a quebra de um sinal em versões deslocadas e escalonadas da *wavelet*-mãe (ou original).

A representação do sinal no domínio da frequência é obtida aplicando a transformada de Fourier (TF) à série original, expressa no domínio do tempo (Figura 4.5). O resultado desta transformação é um conjunto de frequências que caracterizam o sinal original. Em alguns casos a parte mais importante da informação do sinal são suas frequências, em outros, o tempo. Esta transformação pode ser aplicada aos sinais não-estacionários, ou seja, sinais que mudam seus parâmetros ao longo do tempo.

Figura 4.5 – Transformada de Fourier.



Fonte: Adaptado de Misiti *et al.*, 2002.

Em muitas aplicações, é muito importante saber quando ou em que intervalo de tempo as frequências ocorrem. Para essa análise, a TF já não é a mais adequada, salvo se a série for estacionária (os seus parâmetros permanecem constantes ao longo do

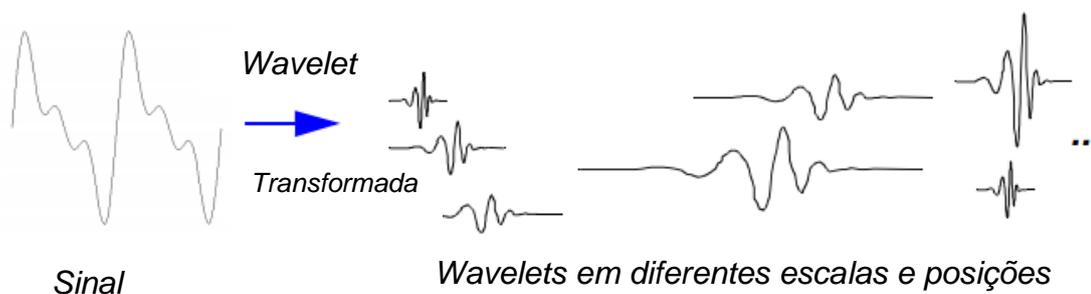
tempo), pois as frequências pelas quais os sinais estacionários estão compostos ocorrem no tempo de existência do sinal. Como alternativa para resolver este problema, surgiu a Transformada por Janelas de Fourier (TPJF) ou Transformada Rápida de Fourier (TRF), que é uma generalização da TF. A sua aplicação permitirá obter a informação do sinal em tempo e frequência. A metodologia da TRF é apresentada por Dimande (2010).

No que diz respeito a forma de análise da *wavelet*, ela pode ser feita de duas formas: contínua e discreta. Segundo Hongnan *et al.* (2008), a principal vantagem da *wavelet* contínua é a sua capacidade de fornecer informação do tempo e escala. Ovanesova (2000) diz que essas diferenças também podem ser apresentadas quanto às suas escalas, garantindo algumas vantagens peculiares a cada forma de análise. Na análise contínua, a escala varia quase continuamente. Quando uma escala é pequena, apenas pequenos detalhes são analisados. Esta é a razão pela qual a análise contínua é muitas vezes mais fácil de ser interpretada. Na análise discreta, a escala é diádica, ou seja, cada coeficiente de nível  $k$  é repetido  $2^k$  vezes. Esta é a razão pela qual a análise discreta garante economia de espaço de codificação e é suficiente para a síntese.

A Transformada Contínua de *Wavelet* (TCW) é definida como a soma sobre todo o tempo (ou espaço) do sinal multiplicado pela escala (Equação 18). Em matemática esta operação é chamada de convolução.

$$C(\text{escala}, \text{posição}) = \int_{-\infty}^{\infty} f(x)\varphi(\text{escala}, \text{posição})dx \quad (18)$$

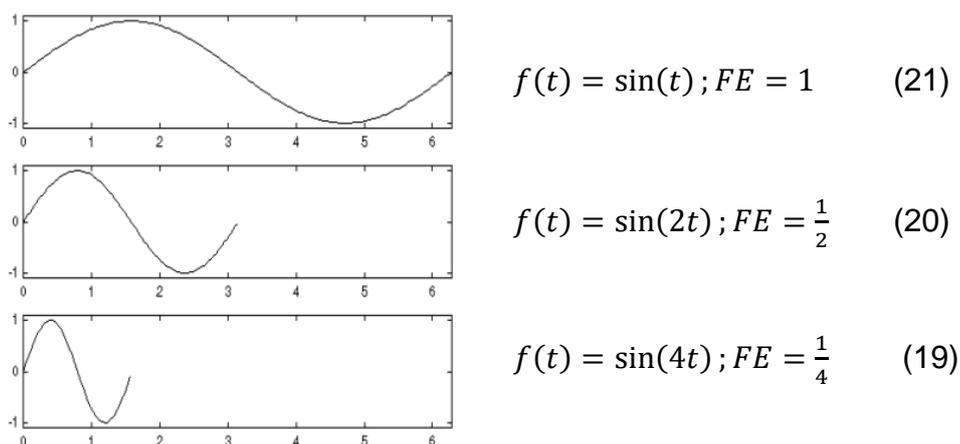
Os resultados da TCW são os coeficientes, que estão em função da escala e da posição. Multiplicando cada coeficiente pela *wavelet* adequadamente dimensionada, produz as *wavelets* constitutivas do sinal original (Figura 4.6).

Figura 4.6 – Processo de transformada da *wavelet*.

Fonte: Adaptado de Misiti *et al.* (2002).

Escalar em uma *wavelet* significa que contraindo ou dilatando. Se os sinais forem senoides, o efeito do fator escala<sup>3</sup> ( $FE$ ) é fácil de visualizar, e é apresentado na Figura 4.7, para a função  $f(t)$ .

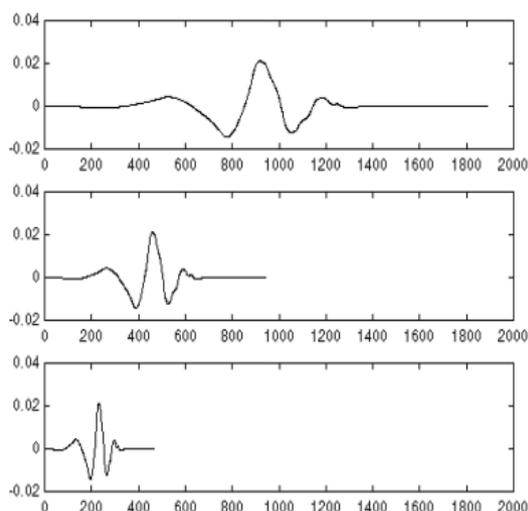
Figura 4.7 – Aplicação do fator escala em senoides.



Fonte: Adaptado de Misiti *et al.* (2002).

O fator escala trabalha exatamente da mesma forma com as *wavelets*. Quanto menor o valor do fator, maior a contração da *wavelet*, como visto na Figura 4.8.

<sup>3</sup> Fator Escala (FE): fator que está relacionado com o quanto a função está contraindo ou dilatando. Quanto maior o valor do fator escala, maior será sua dilatação.

Figura 4.8 – Aplicação do fator escala em *wavelets*.

$$f(t) = \varphi(t); FE = 1 \quad (24)$$

$$f(t) = \varphi(2t); FE = \frac{1}{2} \quad (23)$$

$$f(t) = \varphi(4t); FE = \frac{1}{4} \quad (22)$$

Fonte: Adaptado de Misiti *et al.* (2002).

No que se refere ao deslocamento das *wavelets* significa simplesmente o atraso ou o adiantamento do seu aparecimento. Matematicamente, atrasar  $k$  vezes uma função  $f(t)$  é representá-la por  $f(t-k)$ .

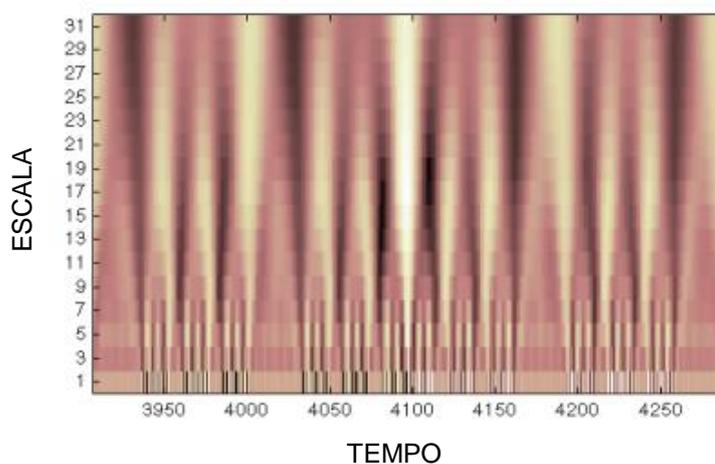
Dimande (2010) diz que a TCW de um sinal é a soma ao longo do sinal multiplicado pelo fator escala  $FE$  e com deslocamento  $DE$ . Este processo produz coeficientes *wavelet*, que são uma função da dimensão e da posição. Os passos para a criação de uma TCW, segundo Misiti *et al.* (2002), são:

- i. Escolher uma *wavelet*-mãe<sup>4</sup> e compará-la a uma seção no início do sinal original.
- ii. Calcular um número  $C$ , que representa a semelhança entre a *wavelet* e o sinal no intervalo analisado. Note-se que os resultados dependem da forma da *wavelet* escolhida.
- iii. O passo seguinte é colocar a *wavelet* para a direita e repetir os passos 1 e 2, até que seja coberto todo o sinal.
- iv. Escalar a *wavelet* no trecho analisado e repetir os passos de 1 a 3.
- v. Repetir os passos 1 a 4 para todas as escalas.

<sup>4</sup> *Wavelet*-mãe: também conhecida como *wavelet* principal, escolhida de acordo com sua semelhança ao sinal original, dando origem a um valor elevado de coeficientes das *wavelets*. O conjunto formado pela *wavelet* principal e as suas versões deslocadas no tempo ou no espaço definem uma família de *wavelet*.

O resultado final são coeficientes produzidos para diferentes escalas. Para a representação dos resultados, o eixo horizontal representa a posição ao longo do sinal (tempo ou espaço), o eixo vertical representa a escala ( $a$ ), e a cor de cada ponto representa a magnitude dos coeficientes *wavelet*. A Figura 4.9 mostra o gráfico dos coeficientes gerados pela TCW-2D.

Figura 4.9 – Coeficientes da TCW em duas dimensões.



Fonte: Adaptado de Misiti *et al.*, 2002.

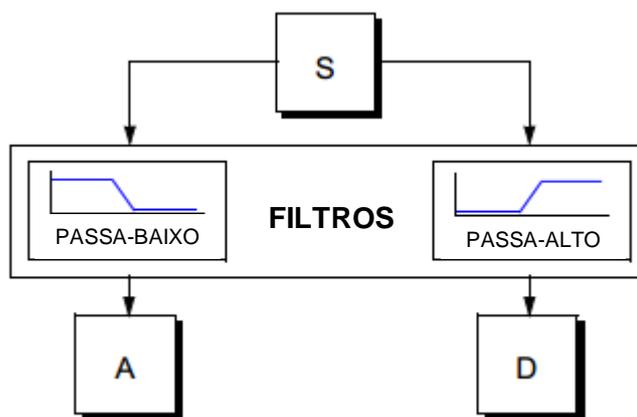
As transformadas *wavelets*, em geral, apresentam-se bastante eficientes na identificação temporal de frequências altas de curta duração e na identificação em frequência de sinais longos de baixas frequências (FILHO *et al.*, 2008). Um dos inconvenientes é que um número muito grande de coeficientes são gerados durante a análise e, além disso, poucas *wavelets* têm uma expressão explícita (OVANESOVA E SUAREZ, 2004).

No que diz respeito à Transformada Discreta de *Wavelet* (TDW), Misiti *et al.* (2002) dizem que é uma maneira eficiente de implementar um esquema usando filtros e um modelo foi desenvolvido em 1988 por Mallat. Este algoritmo de filtragem muito prático produz uma transformada *wavelet* rápida, capaz de gerar rapidamente coeficientes *wavelet*.

Para muitos sinais, os componentes de baixa frequência são as partes mais importantes. É o que dá ao sinal a sua identidade. Os componentes de alta frequência, por outro lado, dão o detalhe. Considere a voz humana: se os componentes de alta frequência forem removidos, a voz soa diferente, mas ainda pode ser entendida. No

entanto, se os componentes de baixa frequência forem removidos, não será possível ouvir adequadamente. É por esta razão que, na análise de *wavelets*, fala-se muitas vezes de aproximações e detalhes. As aproximações (A) são os componentes de alta escala e de baixa frequência do sinal. Os detalhes (D) são os componentes de baixa escala e de alta frequência. O processo de filtragem do sinal, no seu nível mais básico, tem a seguinte aparência (Figura 4.10):

Figura 4.10 – Processo de filtragem do sinal.



Fonte: Adaptado de Misiti *et al.* (2002).

O sinal original, S, passa através de dois filtros complementares. Os filtros passa-baixo removem componentes de alta-frequência do sinal e preservam as variações lentas enquanto que os filtros passa-alto removem os componentes de baixa frequência do sinal e preservam os componentes de alta-frequência (DIMANDE, 2010). O processo de decomposição pode ser iterativo, com aproximações sucessivas sendo decompostas por sua vez, de modo que um sinal é dividido em muitos componentes de baixa resolução. Isso é chamado de árvore de decomposição *wavelet*.

Uma vez que o processo de análise é iterativo, em teoria ele pode ser continuado indefinidamente. Na realidade, a decomposição só pode prosseguir até que os detalhes individuais consistam em uma única amostra. Na prática, seleciona-se um número adequado de níveis com base na Equação 25.

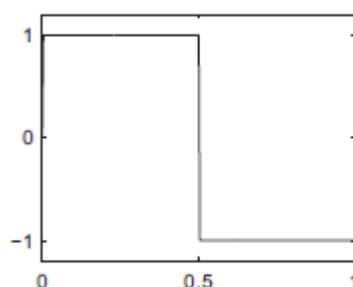
$$n = \log_2(\text{quantidade de amostras}) \quad (25)$$

### 4.2.1.1 Propriedades das *wavelets*

As funções *wavelets* são separadas em famílias: Haar, Daubechies, Biortogonal, Coiflets, Symlets, Morlet, Chapéu Mexicano e Meyer. Em seguida, são apresentadas algumas das principais *wavelets*-mães.

- a) Família *wavelet* Haar: a primeira e mais simples família *wavelet*. É descontínua, e se assemelha à função degrau (Figura 4.11). Representa a *wavelet* Daubechies db1.

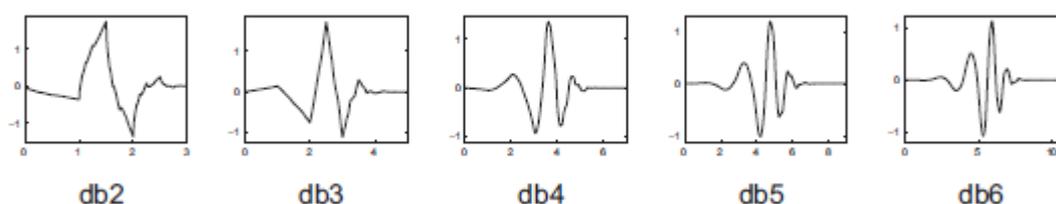
Figura 4.11 – Sinal da *wavelet* Haar.



Fonte: Misiti *et al.* (2002).

- b) Família *wavelet* Daubechies: Ingrid Daubechies criou o que são chamados de *wavelets* ortonormais, tornando possível a análise discreta da transformada *wavelet*. Os nomes das famílias Daubechies são escritos como dbN, onde N é a ordem e db o sobrenome da *wavelet*. Na Figura 4.12 seguem os outros nove membros da família, já que db1 é a família *wavelet* Haar:

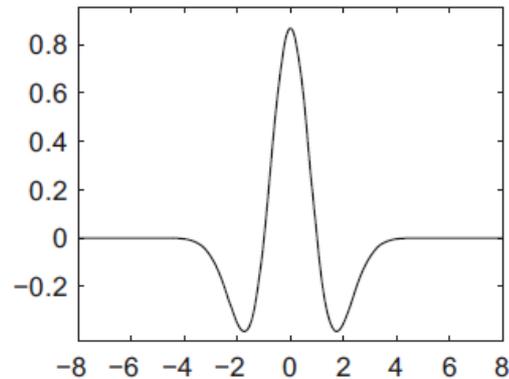
Figura 4.12 – Alguns sinais das diferentes *wavelets* Daubechies, de acordo com suas respectivas ordens.



Fonte: Misiti *et al.* (2002).

- c) Família *wavelet* Chapéu Mexicano: essa *wavelet* (Figura 4.13) não tem nenhuma função de escala e é igual a segunda derivada de uma gaussiana e se assemelha bastante com a forma de ondas sísmicas. Não é possível fazer análise de TDW com a função *wavelet* chapéu mexicano.

Figura 4.13 – Sinal da *wavelet* chapéu mexicano.



Fonte: Misiti *et al.* (2002).

Segundo Estrada (2008), as propriedades mais importantes que uma função *wavelet* precisa para um processo de detecção de dano são:

- a) Ortogonalidade e biortogonalidade: de suma importância para o cálculo dos coeficientes de *wavelet*, porém não encontradas em todas as funções. Define-se a partir do produto interno nulo de duas *wavelets*  $\{u(x)$  e  $g(x)\}$ :

$$\langle u(x), g(x) \rangle = \int_a^b u(x)g^*(x)dx = 0 \quad (26)$$

onde,  $g^*$  é o complexo conjugado de  $g(x)$ .

Palechor (2013) refere-se ao termo biortogonalidade como a ortogonalidade de duas bases entre si, mas que não formam um conjunto ortogonal.

- b) Suporte compacto: é o conjunto de pontos onde a função não é nula. Desta forma, a função *wavelet* não assume o valor zero para intervalos finitos, o que permite representar melhor características locais.
- c) Momentos nulos: determina o grau dos polinômios que podem ser aproximados. Esta propriedade é usada para selecionar a *wavelet*-mãe mais adequada para a detecção de danos.

- d) Regularidade: é o número de vezes que uma função é diferenciável em um ponto  $x_0$ .

De acordo com essas propriedades, a maioria das *wavelets*-mãe conhecidas são classificadas em (OVANESOVA E SUAREZ, 2004):

- i. As funções: Haar, Daubechies de ordem  $n$ , Meyer, Symlets de ordem  $n$  e as Coiflets de ordem  $n$  são exemplos de *wavelets*-mães ortogonais.
- ii. As funções: Haar, Daubechies de ordem  $n$ , Symlets de ordem  $n$  e os Coiflets de ordem  $n$  são *wavelets*-mães tem um suporte compacto.
- iii. As funções: Daubechies de ordem  $n$ , Symlets de ordem  $n$  e as Coiflets de ordem  $n$ , são funções *wavelet*-mães que tem um número arbitrário de momentos nulos;
- iv. As funções: Morlet e Meyer são regulares. Por outro lado, as funções Daubechies de ordem  $n$ , Symlets de ordem  $n$  e as Coiflets de ordem  $n$  são *wavelets*-mãe que apresentam pouca regularidade.

#### 4.2.1.2 Análise das *wavelets*

O *software* Matlab é utilizado para solução de inúmeros problemas relacionados à Engenharia. O programa apresenta várias ferramentas e recursos para facilitar estas resoluções. Uma delas é o *Wavelet Toolbox*, que fornece funções e aplicativos para analisar e sintetizar dados e imagens que exibem o comportamento de diversos elementos. A caixa de ferramentas inclui algoritmos para transformada em *wavelet* contínua, e para análise discreta. Algumas das características-chave são: compactação e reconstrução de sinais e imagens, análise de dados a partir dos bancos de *wavelets*-mães.

O *software* (Figura 4.14) também contém ferramentas gráficas e funções de linha de comando que permitem: examinar e explorar propriedades de *wavelets* individuais e pacotes *wavelet*; examinar estatísticas de sinais e componentes de sinal; realizar uma transformada *wavelet* contínua de um sinal unidimensional; realizar análise discreta e síntese de sinais unidimensionais e bidimensionais; realizar análise de pacotes *wavelet* de sinais unidimensionais e bidimensionais; comprimir e remover o ruído de sinais e imagens.

Figura 4.14 – Interface da caixa de ferramentas para análise de *wavelets*.



Fonte: Autor.

A partir dos coeficientes obtidos com o *Wavelet Toolbox*, faz-se a análise das *wavelets* através de métodos estatísticos que comprovem ou não a relação de distribuições, normais ou não-normais.

Segundo Larson e Farber (2010) um destes métodos é o teste de Kruskal-Wallis (KW), que é um teste não paramétrico utilizado para comparar três ou mais populações. Ele é usado para testar a hipótese nula de que todas as populações possuem funções de distribuição iguais contra a hipótese alternativa de que ao menos duas das populações possuem funções de distribuição diferentes. O teste de Kruskal-Wallis é o análogo ao teste F (FISHER, 1925). Enquanto a análise de variância do teste F depende da hipótese de que todas as populações em confronto são independentes e normalmente distribuídas, o teste de Kruskal-Wallis não coloca nenhuma restrição sobre a comparação quanto à normalidade.

Suponha que os dados provenham de  $k$  amostras aleatórias independentes com tamanhos amostrais  $n_1, n_2, \dots, n_k$  sendo  $N = n_1 + n_2 + \dots + n_k$  o número total de elementos considerados em todas as amostras.

De forma objetiva, os passos para realização deste teste são apresentados a seguir e mais detalhes podem ser vistos em Montgomery e Runger (2003):

- i. Determina-se a hipótese nula de que todos os efeitos são iguais;
- ii. Ordena-se de forma crescente os valores deste novo conjunto de dados e associa-se a cada valor o seu correspondente, tendo cada posto o mesmo sinal do valor que este representa.
- iii. Calcula-se o valor da estatística  $H$ . Em seguida, fixa-se o nível de significância ( $\alpha$ ).
- iv. Encontram-se os valores críticos referentes ao nível de significância fixado. Neste caso, calcula-se os valores  $Q_\alpha$ , de modo que  $P[H > Q_\alpha] = \alpha$  (sob  $H_0$ ).
- v. Se  $H_{obs} > Q_\alpha$  rejeita-se a hipótese nula de que as amostras provêm de populações igualmente distribuídas.
- vi. O p-valor é calculado da seguinte forma:  $P - valor = P[\chi_{k-1}^2 \geq H | H_0]$
- vii. A partir do p-valor encontrado pode-se concluir se a hipótese nula pode ser aceita ou não. Caso o p-valor seja maior que o nível de significância, a hipótese nula é aceita. Caso contrário, se o p-valor for menor, ela é rejeitada. Para o reconhecimento de padrões de danos, rejeitar a hipótese nula ( $H_0$ ) e aceitar a alternativa ( $H_1$ ) significa que o algoritmo das *wavelets* conseguiu distinguir os diferentes níveis de dano.

#### 4.2.2 Máquinas de vetores de suporte

As máquinas de vetores de suporte (*Support Vector Machines* - SVM) constituem uma técnica que tem como base a Teoria de Aprendizado Estatístico (VAPNIK, 1995), a qual vem recebendo grande atenção desde a década de 1990 (HEARST *et al.*, 1998; CRISTIANINI E SHAWE-TAYLOR, 2000). Os resultados da aplicação desta técnica são comparáveis aos obtidos por outros algoritmos de aprendizado, como as Redes Neurais Artificiais (RNA) (HAYKIN, 1999). Elas têm sido utilizadas para tratar o SHM por detecção de danos.

São um conjunto de métodos de aprendizado supervisionado de classificação e regressão. Suas técnicas consistem na definição de um plano de separação entre duas classes, ou seja, de dicotomias, que maximize a distância entre elas, quando se

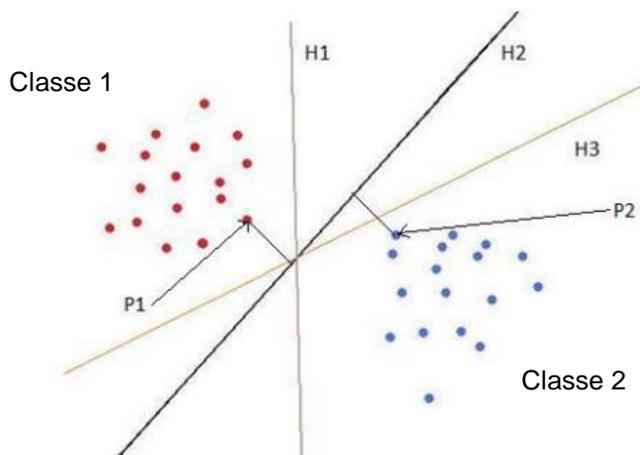
trabalha com um problema de classificação binária. A suposição é que o plano máximo possa oferecer a melhor condição de contorno entre os dois conjuntos de dados (BURGES, 1998).

Uma estratégia de SHM eficaz para uma estrutura envolve a aplicação de métodos globais e locais, como já mencionado em capítulos anteriores. As propriedades extraídas por estes métodos são sensíveis à localização dos transdutores e à localização do dano na estrutura. A presença de ruídos de medição nos dados de vibração representa um desafio para extração de parâmetros estruturais e modais da estrutura. O método de máquinas de vetores de suporte (SVM) aplicado para a detecção de danos em aplicações industriais tem-se revelado bastante promissor na sua capacidade de detectar danos na presença de ruído. As SVM são utilizadas por terem muito boa capacidade de generalização, devido à sua técnica subjacente de maximizar a margem entre 2 classes de dados. O principal desafio da SVM para a detecção de danos em estruturas é a exigência de dados da estrutura danificada durante a fase de treinamento.

As máquinas de vetores de suporte tentam criar um mapa entre as entradas e saídas nos dados de ensaio. Estes dados consistem em pontos de cada classe com a saída esperada. Durante a fase de formação do SVM, o algoritmo localiza o melhor hiperplano que separa os dados do não danificado e a estrutura danificada. O melhor hiperplano, que pode ser linear ou não linear, é aquele que divide as classes de destino com a margem máxima entre eles.

Segundo Sharma (2008), para separar duas classes de dados (Classe 1: vermelho e Classe 2: azul, respectivamente – Figura 4.15) existe um número infinito de planos (H1, H2, H3 etc.) que podem ser desenhados entre os 2 conjuntos de pontos. O melhor plano de divisão é aquele que irá maximizar a distância entre os pontos mais próximos em ambos os lados desse plano. Para o plano H2, os pontos mais próximos em ambos os lados são P1 e P2. Deve notar-se que para um plano diferente H1 ou H3 os pontos das duas classes mais próximas deles podem ser diferentes de P1 e P2. Na Figura 30, H2 é o melhor plano divisor porque a sua distância dos pontos mais próximos de ambos os lados (P1 e P2) é o máximo possível. O classificador H2 está equidistante dos dois pontos P1 e P2.

Figura 4.15 – Definição do melhor plano classificador entre duas classes de dados.



Fonte: Adaptado de SHARMA, 2008.

Estas classes são dados obtidos da estrutura íntegra e da estrutura danificada. Os planos H2 e H3 são chamados de margens e são paralelos e equidistantes do plano H1. Eles passam pelos pontos mais próximos em ambas as classes. Os pontos mais próximos parecem estar apoiando as margens para fora e, portanto, são chamados de vetores de suporte. A configuração selecionada é chamada de Máquina de Vetor de Suporte. O objetivo é estimar uma função usando os exemplos de treinamento, e aplicá-la nos exemplos de teste, para que sejam classificados corretamente.

Esta classificação é realizada pelas funções kernel. As funções kernel têm a finalidade de projetar os vetores de características de entrada em um espaço de características de alta dimensão para classificação de problemas que se encontram em espaços não linearmente separáveis. Isso é feito porque à medida que se aumenta o espaço da dimensão do problema, aumenta também a probabilidade desse problema se tornar linearmente separável em relação a um espaço de baixa dimensão. Entretanto, para obter uma boa distribuição para esse tipo de problema é necessário um conjunto de treinamento com um elevado número de instâncias (GONÇALVES, 2010). Pode-se chamar uma função de Kernel se ela satisfaz as condições estabelecidas pelo Teorema de Mercer. Este teorema diz que uma função é dita de kernel, se a matriz K é positivamente definida, onde K é a matriz resultante do produto interno dos dados de entrada. Uma matriz é positivamente definida se seus autovalores são maiores que

zero. As funções de kernel que satisfazem as condições do Teorema de Mercer, são chamadas de kernels de Mercer (SMOLA *et al.*, 1999). Algumas das funções kernels mais utilizadas estão descritas na Tabela 4.1.

Tabela 4.1 - Resumo dos kernels mais populares.

Tipo de Kernel	Função K	Tipo do Classificador
Polinomial	$[(x_i \cdot x_j) + 1]^p$	Máquina de aprendizagem polinomial
Gaussiano (ou <i>Radial Basis Function</i> - RBF)	$\exp\left(-\frac{\ x_i - x_j\ ^2}{2\sigma^2}\right)$	Rede RBF
Sigmoidal	$\tanh(\beta_0 \langle x_i \cdot x_j \rangle) + \beta_1$	<i>Perceptron</i> de duas camadas

Fonte: HAYKIN, 1999.

Haykin (1999) relata que na função polinomial a potência  $p$  é previamente especificada pelo usuário, de acordo com o número de classes. Na RBF a amplitude  $\sigma^2$ , comum a todos os kernels, é especificada pelo usuário. Já no *Perceptron* de duas camadas o teorema de Mercer é satisfeito apenas para alguns valores de  $\beta_0$  e  $\beta_1$ .

Algumas escolhas devem ser feitas para obtenção de uma SVM, como a função kernel, os parâmetros da função, além da definição do algoritmo para determinação do hiperplano ótimo (LORENA E CARVALHO, 2003).

De acordo com Lorena e Carvalho (2003), as SVM podem ser classificadas como: SVM com margens rígidas, SVM lineares com margens suaves, SVM não lineares e SVM para várias classes. A seguir apresenta-se um breve resumo a respeito de cada um dos tipos.

i. SVM com margens rígidas:

Considera-se a forma mais simples de SVM, utilizada na geração de classificadores para conjuntos de treinamento linearmente separáveis.

Um conjunto linearmente separável é composto por exemplos que podem ser separados por pelo menos um hiperplano. Como mencionado na introdução do tópico

anterior, o melhor hiperplano é aquele em que a margem de separação entre as classes presentes nos dados é maximizada.

O classificador apresentado, porém, não é suficiente quando confrontado com bases de dados mais gerais, podendo se orientar por ruídos presentes nos dados.

#### ii. SVM lineares com margens suaves

Em situações reais é difícil encontrar aplicações cujos conjuntos sejam linearmente separáveis. Isso se deve a diversos fatores, entre eles a presença de ruídos nos dados ou a própria natureza do problema, que pode ser não-linear.

As SVM lineares com margens rígidas são adaptadas para lidar com conjuntos de treinamento não linearmente separáveis. Para isso, é admitida a ocorrência de alguns erros de classificação para o conjunto de treinamento, por meio da introdução de variáveis de relaxamento. Essas modificações fazem parte de um processo usualmente denominado “suavização de margens” (CORTES E VAPNIK, 1995). Apesar de ser melhor que o primeiro tipo, este ainda é limitado. Existem situações em que é necessária a utilização de decisões não lineares.

#### iii. SVM não lineares

Os classificadores lineares apresentados anteriormente são simples, entretanto sua aplicação é limitada. Vários são os casos em que não é possível definir o hiperplano satisfatório.

As SVM lineares podem ser generalizadas de forma a satisfazer um maior número de situações. O artifício de levar os dados de treinamento para um espaço de maior dimensão é utilizado. Incorpora-se a esse tipo de SVM o conceito de funções Kernel, que permitem o acesso a espaços complexos (em alguns casos infinitos) de forma simplificada.

#### iv. SVM para várias classes

Embora as SVM sejam originalmente produzidas para geração de classificadores binários, alguns artifícios permitem que estas sejam aplicadas a problemas multiclases, em que o número de classes é maior que dois.

Duas abordagens usuais para tal são a decomposição “um-contra-todos” e “todos-contra-todos”. Sendo  $k$  o número de classes, no primeiro caso produz-se  $k$  classificadores, cada um separando uma classe  $i$  das  $k - 1$  restantes. A classe de um novo padrão é dada pelo índice da SVM que produz a maior saída. No caso da decomposição “todos-contra-todos”, são produzidos classificadores para separação de cada classe  $i$  de outra  $j$ , em que  $i, j = 1, \dots, k$ ; com,  $i \neq j$ . Neste caso, a saída de um padrão é dada por um voto de maioria entre as SVM. Cada uma dessas alternativas tem vantagens e desvantagens, as quais foram brevemente discutidas neste capítulo. Uma comparação mais detalhada dos métodos decomposicionais<sup>5</sup> é apresentada em (HSU E LIN, 2002).

#### 4.2.2.1 Implementações disponíveis para SVM

Existem inúmeras implementações possíveis de SVM disponíveis. Vários algoritmos podem ser encontrados em Smola e Schölkopf (2000). Algumas das principais ferramentas são brevemente descritas a seguir:

i. SMO:

Essa ferramenta deve ser utilizada em plataforma Unix/Linux, desenvolvida por Ge (2001) em C++. Como Kernel, estão disponíveis as funções Linear e Gaussiana. Esta implementação lida com problemas binários e multiclases.

ii. SVM<sup>light</sup>:

Pode ser utilizada em problemas de classificação, binários ou multiclases, e de regressão. Permite a utilização de vários tipos de função Kernel: Linear, Polinomial, Gaussiano, Sigmoidal e de funções definidas pelo usuário. Para Windows NT, Unix, Linux e Powermac. Usa ferramenta de programação quadrática para resolução dos problemas de otimização, distribuída juntamente com o *software*. Desenvolvida por Joachims (1998).

---

<sup>5</sup> Métodos decomposicionais: técnica de mapeamento perceptual que mede apenas a impressão ou avaliação geral de um objeto e então tenta derivar posições espaciais em um espaço multidimensional que reflitam tais percepções (Hair *et al.*, 2009).

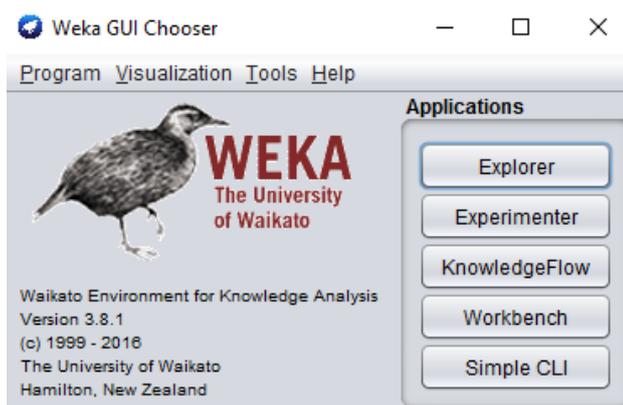
iii. SVM *toolbox* para Matlab:

Ferramenta para Matlab (SCHWAIGHOFER, 2002) baseado no SVM<sup>light</sup>. Pode ser utilizado em problemas de classificação binária ou multiclases. Pode ser facilmente modificado e requer a utilização de um pacote de otimização, que pode ser o fornecido pelo próprio Matlab.

iv. LIBSVM:

O pacote LIBSVM foi desenvolvido em 2000 e funciona como uma biblioteca para máquinas de vetores suporte. É disponibilizado gratuitamente e atualmente é um dos *software* SVM mais utilizados. O uso do LIBSVM envolve basicamente dois passos: primeiro, treinar a base de dados para obter o modelo, e, segundo, usar um modelo para apresentar informações acerca da base de dados testada. O LIBSVM pode ser utilizado por diversos *software*, mas é com frequência encontrado no WEKA. O WEKA é um produto da Universidade de Waikato (Nova Zelândia) e foi implementado pela primeira vez em sua forma moderna em 1997 (IBM, 2017).

Figura 4.16 – Interface inicial do WEKA.



Fonte: Autor.

#### 4.2.2.2 Aplicações cotidianas de SVM

As SVM vêm sendo aplicadas com sucesso a diversos problemas computacionais (HEARST *et al.*, 1998; SMOLA *et al.*, 1999b; MULLER *et al.*, 2001). Logo abaixo será apresentada de forma sucinta uma explicação sobre algumas das principais aplicações de SVM, além do reconhecimento de padrões:

i. Visão computacional

Uma das principais aplicações é a identificação de faces humanas em imagens. Fernandez e Viennet (1999) aplicaram SVM com Kernel do tipo RBF na realização desta tarefa. Em Hearst *et al.* (1998) também é descrita uma aplicação de SVM ao problema de detecção de faces em imagens.

ii. Reconhecimento de dígitos

Esta aplicação consiste em reconhecer um número a partir de dígitos manuscritos. Diversos trabalhos deste tipo foram conduzidos utilizando a base do Serviço Postal Americano (USPS) (SCHAPIRE *et al.*, 1997; DECOSTE E SCHÖLKOPF, 2001; LECUN *et al.*, 1995).

iii. Bioinformática

Por Bioinformática entende-se a aplicação de técnicas computacionais, envolvendo desde o armazenamento de informações à análise das mesmas, no gerenciamento de informações biológicas (BALDI E BRUNAK, 1998). Os dados neste domínio em geral são volumosos e complexos, o que torna o uso das SVM adequadas. São exemplos: identificação de genes, estrutura de proteínas e análise de expressão gênica.

#### 4.2.3 Modelo de misturas gaussianas

O Modelo de Misturas Gaussianas (*Gaussian Mixtures Models* – GMM) é um tipo de ferramenta de probabilidade e estatística para caracterizar incertezas (BANFIELD E RAFTERY, 1993). Pode ser aplicado ao problema de modelagem de distribuições arbitrárias por decomposição de uma distribuição não gaussiana em uma combinação de número finito de componentes gaussianos (distribuição gaussiana) baseada na aprendizagem não supervisionada sem qualquer conhecimento prévio. Portanto, alguns estudos iniciais começaram a introduzir o GMM no campo do SHM para modelar a incerteza e a não-linearidade dos sinais do transdutor em condições variáveis no tempo.

O GMM é uma soma de funções gaussianas parametrizadas, que contém um vetor de média ( $\mu_i$ ), e uma matriz de covariância ( $\Sigma_i$ ). Cada componente de densidade

gaussiana possui um peso ( $w$ ), resultando numa soma ponderada (HUI *et al.*, 2013; HOSSEIN-KHANI *et al.*, 2011).

Um modelo de misturas gaussianas é parametrizado pelos vetores de média, matriz de covariância e os pesos das misturas de cada uma das  $M$  componentes. Em conjunto esses parâmetros são representados com a seguinte notação, conforme Equação (27).

$$\lambda = \{w_i, \mu_i, \Sigma_i\}, \text{ no qual } i = 1, 2, \dots, M \quad (27)$$

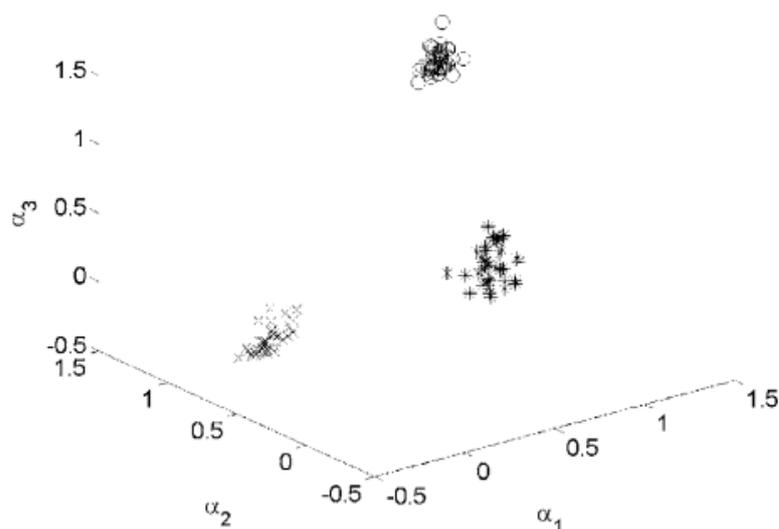
Dependendo do problema, os parâmetros de  $\lambda$  podem sofrer variações. Uma delas é a variação sobre a matriz de covariância, que pode ser utilizada em sua forma completa, ou apenas os elementos da diagonal principal. Outro parâmetro do GMM é a quantidade de componentes gaussianas. As componentes podem compartilhar a mesma matriz de covariância. A configuração do modelo deve basear-se na quantidade de dados disponíveis para a estimativa dos parâmetros e como o modelo será utilizado (DOUGLAS *et al.*, 2000; e DEMPSTER *et al.*, 1977).

Tschöpe *et al.* (2009) relataram a validação do uso de GMM para classificar o grau de dano de uma estrutura tipo placa. Banerjee *et al.* (2010) utilizaram GMM para estimar diferentes comprimentos de fissuras de um elemento compósito reparado em forma de placa. A condição variável no tempo, de mudanças bruscas de temperatura, foi considerada na validação deste método, mas é uma situação simples. Qiu *et al.* (2014) propuseram um método de atualização GMM on-line para monitorar um dano progressivo. Hastie *et al.* (2001) afirmam que os GMM são frequentemente usados como algoritmos de agrupamento em classificação de padrões. Os estudos acima mencionados usaram o GMM construído usando o método tradicional de *Expectation Maximization* (EM).

Nair e Kiremidjian (2007), apresentam de forma detalhada como o algoritmo da EM é utilizado. Segundo os autores, a premissa principal do algoritmo proposto é que há uma migração de nuvens de vetores de características de dano incorrido para a estrutura. O dano é identificado através do número de misturas em um conjunto de dados particular. Se houver mais do que uma mistura de um conjunto de dados, então

existe uma alta probabilidade de danos (Figura 4.16). Em seguida, a medição de danos é obtida usando a distância de Mahalanobis entre o centróide de distribuição da mistura sob questão em relação à mistura de referência (estrutura não-danificada).

Figura 4.17 – Nuvens de vetores de características de dano, para medição do dano usando a distância Mahalanobis.



Fonte: Nair e Kiremidjian, 2007.

A distância de Mahalanobis é uma métrica frequentemente utilizada na análise multivariada para determinar a separação de duas distribuições. Mais especificamente, a métrica utilizada, é definida como a razão entre  $\Delta(\mu_{sem\ dano}, \mu_{dano}; \Sigma_{sem\ dano})$  e  $(\mu_{sem\ dano}, 0; \Sigma_{sem\ dano})$  onde  $\Sigma_{sem\ dano}$  é a matriz de covariância do conjunto de dados sem dano,  $\mu_{sem\ dano}$ ,  $\mu_{dano}$ , são as médias dos conjuntos de dados sem dano e danificado, respectivamente. Estes valores são obtidos após modelagem de vetores de GMM a partir do algoritmo EM. Matematicamente, a distância de Mahalanobis é definida na Equação 28 (MARDIA *et al.*, 2003).

$$DM = \sqrt{\frac{(\mu_{sem\ dano} - \mu_{dano})^T \Sigma_{sem\ dano}^{-1} (\mu_{sem\ dano} - \mu_{dano})}{(\mu_{sem\ dano})^T \Sigma_{sem\ dano}^{-1} (\mu_{sem\ dano})}} \quad (28)$$

#### 4.2.3.1 Armazenamento em cluster

Para discriminar o dano em um conjunto de dados, o número de grupos ou misturas tem de ser determinado (TIBSHIRANI *et al.*, 2001). O armazenamento em cluster permite que um usuário faça grupos para determinar padrões a partir dos dados. É possível criar um número específico de grupos, dependendo de suas necessidades de avaliação. Um benefício decisivo do armazenamento em cluster sobre a classificação é que cada atributo no conjunto de dados será usado para analisar os dados. Uma desvantagem de usar o armazenamento em cluster é que o usuário necessita saber de antemão quantos grupos gostaria de criar.

No entanto, para o usuário intermediário, o armazenamento em cluster pode ser o método de avaliação de dados mais útil que pode ser usado. A matemática subjacente a esse método é relativamente complexa, por isso, aproveita-se todas as vantagens do WEKA.

#### 4.2.3.2 Aplicações cotidianas de GMM

Além do reconhecimento de padrões, são inúmeras as aplicações dos Modelos de Misturas Gaussianas, dentre elas:

- i. Aplicação de misturas gaussianas na classificação de tráfego (ZAVALA *et al.*, 2002):

Com o propósito de uma gestão de rede eficiente, a classificação correta do tráfego torna-se parte essencial dos Sistemas de Detecção de Intrusão (SDI). Utilizada para detectar padrões de ataques de negação de serviço ou identificar o uso indevido dos recursos de rede, por parte de algum usuário, uso que de alguma forma contraria os termos de serviços dos operadores. Existem na literatura inúmeras técnicas que abordam o tema classificação de tráfego, desde métodos tradicionais baseados nos números das portas de serviços, métodos baseados em assinaturas ou padrões dos conteúdos dos pacotes, métodos baseados em anomalias do volume do tráfego gerado pelas aplicações, até métodos estatísticos e de aprendizagem de máquinas.

ii. Verificação de padrões vocais (REYNOLDS *et al.*, 2000):

Nos últimos anos, os modelos de mistura gaussiana tornaram-se a abordagem dominante para a modelagem em aplicações de reconhecimento de alto-falantes independentes do texto. Isto é evidenciado pelos numerosos artigos de vários sites de investigação publicados nas principais conferências de fala, tais como a Conferência Internacional sobre a Acústica da Fala e Processamento de Sinais (ICASSP), a Conferência Europeia sobre Comunicação e Tecnologia da Fala (*Eurospeech*) e a Conferência Internacional sobre o Processamento de Língua Falada (ICSLP). Um GMM é usado em aplicações de reconhecimento de alto-falante como um modelo probabilístico genérico para densidades multivariadas capazes de representar densidades arbitrárias, o que o torna adequado para aplicações independentes de texto sem restrições. O uso de GMM para a identificação de falantes de texto independente foi descrito pela primeira vez em Rose e Reynolds (1990). Uma extensão dos sistemas para verificação de alto-falantes foi descrita e avaliada em vários corpos de fala disponíveis, publicados em Reynolds (1995, 1996).

iii. Monitoramento estrutural sem fio e sistema de apoio à decisão (KIREMIDJIAN, 2011):

Os atuais sistemas utilizados na SHM ainda contam com transdutores e comunicação de dados com fio. Tais sistemas são limitados pela capacidade do sistema de aquisição de dados, que tipicamente tem vários canais, muitas vezes requerendo múltiplos sistemas de aquisição de dados para um maior número de implantação de transdutores. Transdutores estruturais sem fio para aplicações de engenharia estrutural foram introduzidos por Straser e Kiremidjian (1998), com a instalação de cinco acelerômetros, que se comunicavam com um computador. Após isso, vários outros trabalhos foram desenvolvidos como os de Lynch *et al.* (2004), e Wang *et al.* (2006). Os principais componentes do sistema incluem uma unidade de detecção sem fios, uma rede de comunicação sem fios e um sistema de apoio à decisão que controla o sistema de detecção e fornece informações aos utilizadores. Vários algoritmos foram incorporados na unidade de detecção. Estes incluem controle de unidade e de diagnóstico de danos. Os algoritmos de diagnóstico de danos utilizaram métodos estatísticos de reconhecimento de padrões.

## 5 METODOLOGIA

A metodologia associada a este trabalho contempla, em sua totalidade, a aplicação de algoritmos fundamentais para o reconhecimento de padrões de danos em estruturas de concreto a partir das *wavelets*, máquinas de vetores de suporte e modelo de misturas gaussianas, utilizando os resultados experimentalmente obtidos por Carvalho (2015), para o reconhecimento de padrões de dano. Este trabalho não tem como objetivo a determinação da localização ou a quantificação do dano estrutural.

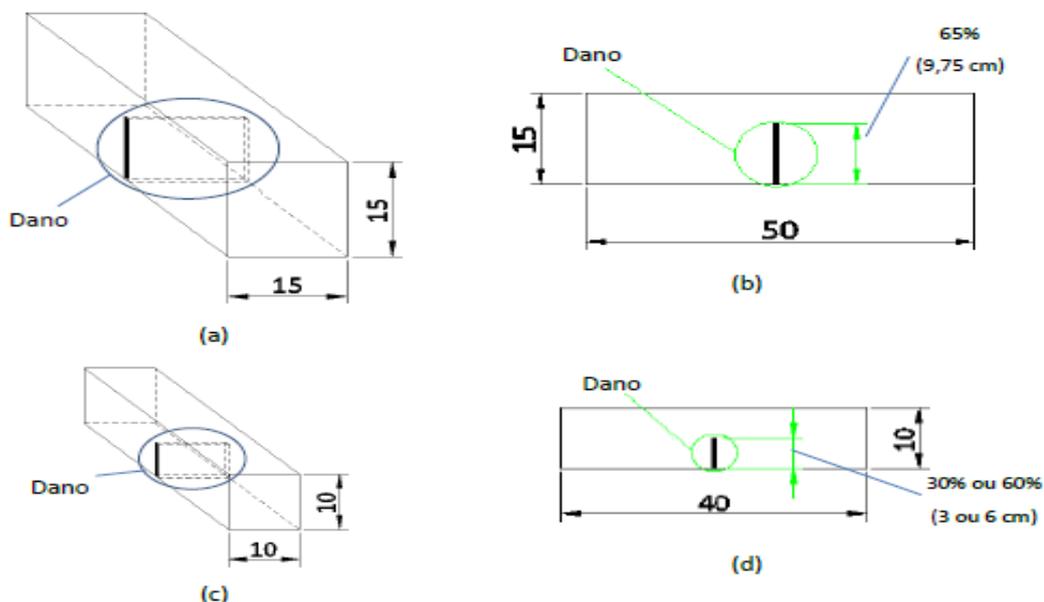
### 5.1 Trabalho realizado por Carvalho (2015)

O trabalho proposto por Carvalho (2015), buscou apresentar resultados para constatar efeitos da existência ou não de danos em corpos de prova (CP) de vigas de concreto simples e também concreto reforçado com fibras. Corpos de prova íntegros foram utilizados, neles não há introdução de dano antes dos ensaios, e por isso, são ensaiados com a mesma integridade e forma que apresentam no processo de desforma. Esta condição é aqui denominada de condição não danificada (CP-ND). Para os CPs danificados, o dano é caracterizado com um entalhe introduzido por uma retífica. O entalhe apresenta 5 mm de espessura e tem direção perpendicular ao eixo da viga, e no sentido que parte da face inferior até uma certa altura da viga. Estes CPs danificados recebem a classificação de corpos de prova em condição danificada (CP-CD). Este dano é quantificado de maneira que o entalhe corresponde à penetração do disco da retífica em 65% (9,75 cm) da altura do CP nas duas faces laterais do CP (Figura 5.1 a e b). O outro CP do lote permanece sem dano. De acordo com o que foi realizado por Carvalho (2015), cada lote foi definido com o nível de dano introduzido e com o tipo de concreto que o compõe.

No caso dos lotes II e III, foram moldados, para cada lote, 10 CPs de concreto sem fibras e a introdução do dano foi realizada para 6 CPs de cada lote (CP-CD). Os 4 CPs restantes de cada lote permanecem sem a introdução de dano (CP-ND). Para esses lotes, foi realizada uma diversificação do estado de dano para os CP-CD, sendo que 3 CP-CD (que serão denominados de CP-CD-30) de cada lote foram danificados de maneira que o entalhe corresponde à penetração do disco da retífica em 30% (3 cm) da altura (Figura 5.1 c e d).

A simulação numérica do dano nesse caso recaiu inteiramente nas propriedades geométricas, ou seja, com a redução da inércia e a área da seção.

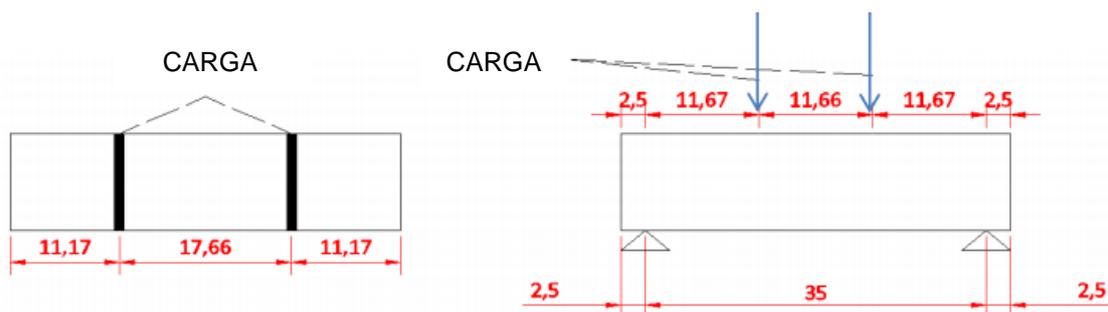
Figura 5.1 – Ilustração da vista em perspectiva (a, c) e vista lateral (b, d) dos corpos de prova nas diversas situações de dano.



Fonte: Carvalho, 2015.

De acordo com o ensaio proposto pela NBR 8522 (2008) foi realizado a determinação do módulo estático de elasticidade à compressão  $e$ , de acordo com a NBR 5739 (2007), foi determinada a resistência à compressão axial. As resistências à compressão axial ( $f_{ck}$ ) encontradas foram 23,36 MPa e 19,96 MPa, e para o módulo de elasticidade ( $E$ ) 23,09 GPa e 19,19 GPa, respectivamente para os lotes II e III. Foram realizados para o lote I, ensaio de flexão em três pontos, que consiste no posicionamento da viga na condição bi-apoiada e na aplicação de uma carga incremental concentrada no meio do vão até a ruína da viga, conforme realizado por Carvalho (2015). Para os lotes II e III, foi realizado o ensaio de flexão em quatro pontos (duas cargas concentradas a mesma distância dos apoios e viga simplesmente apoiada), previsto pela NBR 12142 (2010), representado pela Figura 5.2.

Figura 5.2 – Ensaio de flexão em quatro pontos, realizado com os corpos de prova dos lotes II e III.



Fonte: Carvalho, 2015.

A estimativa de rigidez para esta etapa é realizada através da aferição da medida do deslocamento, em tempo real. O deslocamento foi medido também no centro do vão da viga, não por meio das informações do equipamento de aplicação de carga, mas sim através de um relógio comparador analógico posicionado abaixo da viga e no centro do vão, conforme ilustra a Figura 5.3.

Figura 5.3 – Aparato experimental para a realização do ensaio de flexão em quatro pontos com posicionamento de relógio comparador para medição dos deslocamentos em função do tempo no centro do vão.

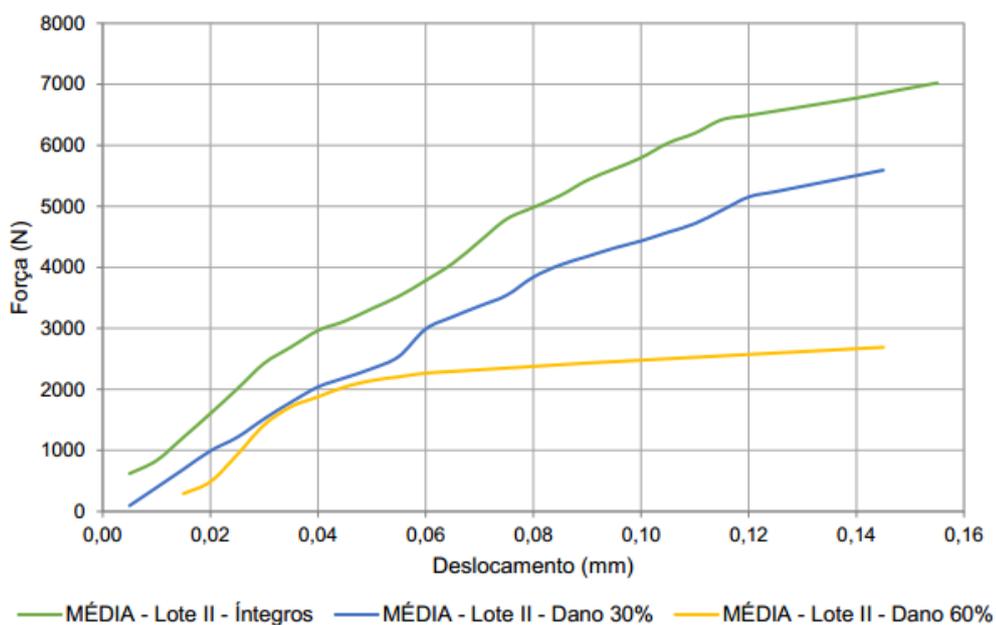


Fonte: Carvalho, 2015.

Um resumo dos resultados das curvas de Força - Deslocamento encontradas são mostrados na Figura 5.4 e Figura 5.5, para os Lotes II e III, respectivamente. As curvas médias foram geradas a partir dos dados experimentais dos corpos de prova. Foram

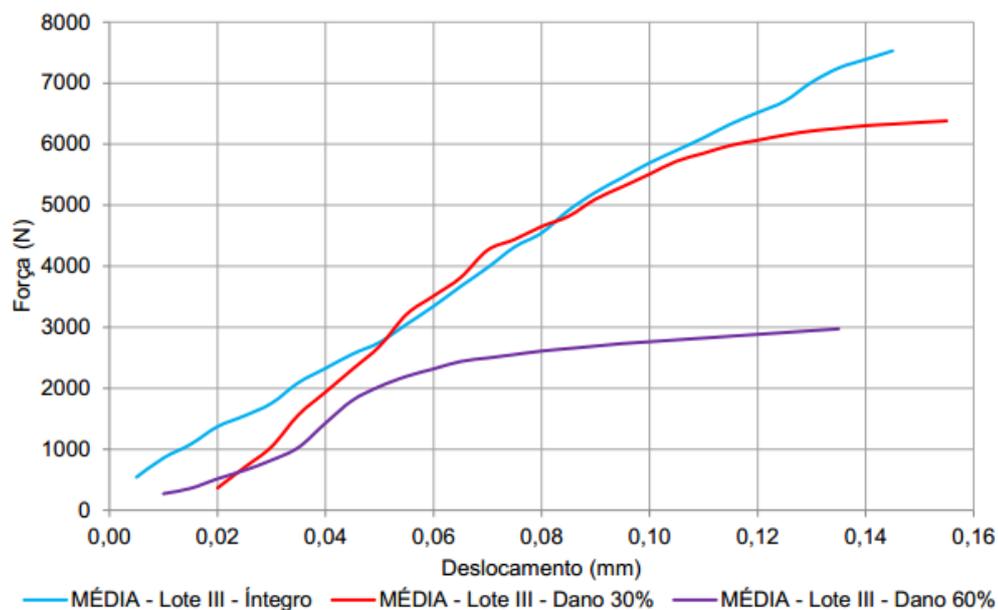
definidos valores para o deslocamento e então, os valores de força correspondentes para cada instante de deslocamento foram pareados. Nos valores de deslocamento que não possuíam valores de força correspondente, foi realizada uma interpolação entre as forças anterior e posterior, garantindo que a média fosse gerada com contribuição de todos os corpos de prova do mesmo lote e condição de dano. O último ponto da curva média não tem qualquer relação com o valor de ruptura dos dados experimentais. A curva média é finalizada quando o valor de força de qualquer um dos corpos de prova começava a decair, devido a ruptura. Portanto, em alguns corpos de prova, os valores de ruptura foram maiores que os mostrados na curva média, mas em nenhum corpo de prova este valor foi menor. Esta descrição se aplica para as curvas e força–deslocamento a seguir e para as curvas de rigidez–deslocamento mostradas posteriormente.

Figura 5.4 – Resultados médios de força–deslocamento dos corpos de prova do lote II.



Fonte: Adaptado de Carvalho (2015).

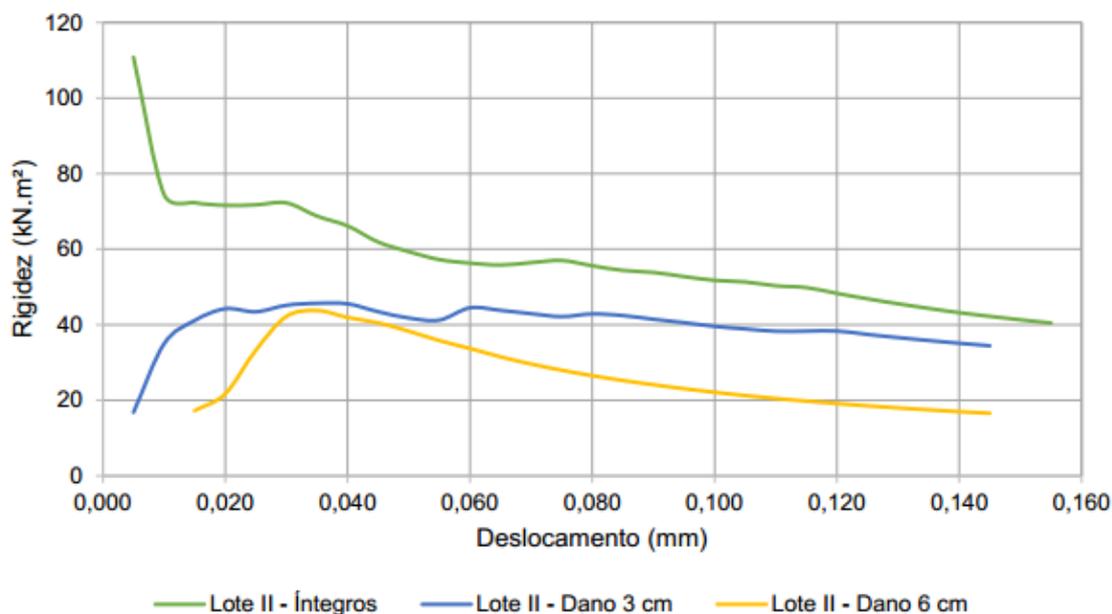
Figura 5.5 – Resultados médios de força–deslocamento dos corpos de prova do lote III.



Fonte: Adaptado de Carvalho (2015).

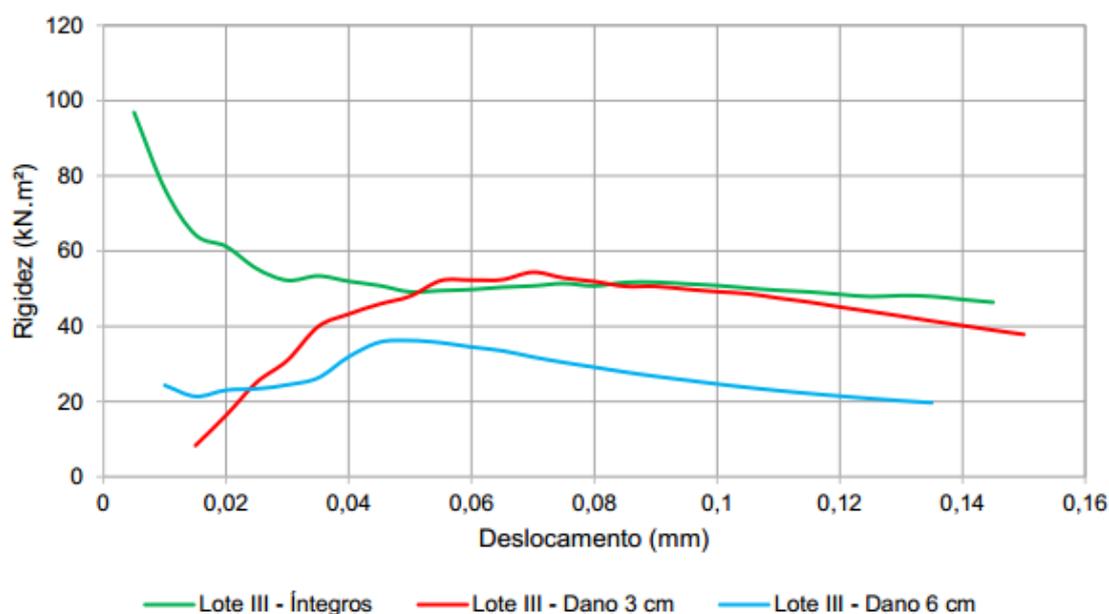
A estimativa da rigidez é realizada através do uso de uma equação que relaciona a curvatura da viga, o vão total da viga e o momento atuante na região entre os dois carregamentos. Nas Figuras 5.6 e 5.7 são apresentadas as médias das estimativas de rigidez em função do deslocamento para cada lote.

Figura 5.6 – Estimativa média da rigidez do lote II para cada situação de dano.



Fonte: Adaptado de Carvalho (2015).

Figura 5.7 – Estimativa média da rigidez do lote III para cada situação de dano.



Fonte: Adaptado de Carvalho (2015).

Com a aplicação de testes estatísticos, Carvalho (2015) chega à conclusão de que o método empregado para realizar a detecção de dano através das variações na rigidez se mostrou eficaz.

Os dados de rigidez–deslocamento serão utilizados em cada um dos algoritmos, que terão suas metodologias de aplicação descritas nos tópicos seguintes.

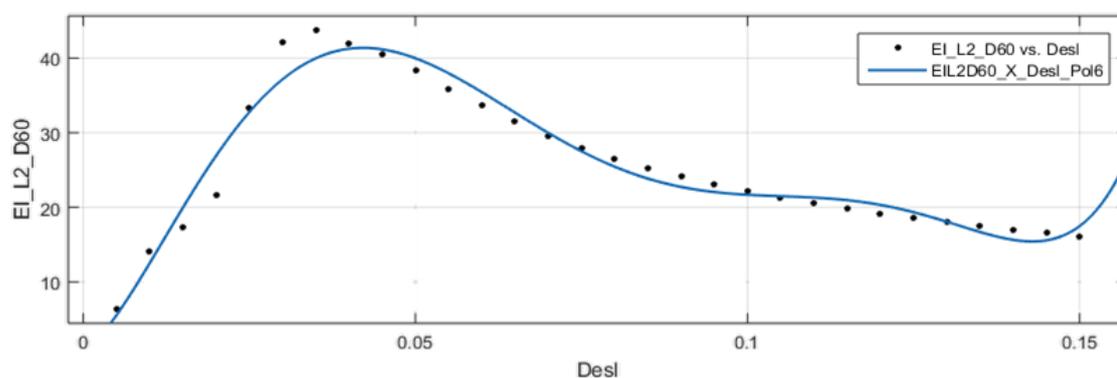
## 5.2 Wavelets

As transformadas *wavelets*, como foi visto no referencial teórico, podem ser contínuas ou discretas. Levando-se em consideração o objetivo geral deste trabalho, o reconhecimento de padrões de dano estrutural, em Ovanesova e Suárez (2004), e Reda-Taha, et al. (2004), resultados satisfatórios são encontrados utilizando *wavelets* discretas. Além da praticidade e objetividade encontrada na análise a partir do Wavelet Toolbox, que dá a condição de gerar os coeficientes de forma mais precisa e de fácil tratamento. Em virtude desses fatores, optou-se pela Transformada Discreta de *Wavelet*.

O *software* requer uma função para projetar uma nova *wavelet* adaptada a um determinado padrão. Estas funções serão geradas a partir da análise de rigidez–deslocamento, do trabalho desenvolvido por Carvalho (2015).

Para serem utilizadas no *software*, os dados precisam ser transformados em sinais. Para isso, faz-se necessária a aproximação de uma linha de tendência. A escolha dessa linha de tendência leva em consideração o coeficiente de determinação ( $R^2$ ) e a facilidade em trabalhar com os coeficientes de cada equação. A melhor curva para cada nível de dano (exemplo na Figura 5.8), nos dois lotes, foi a Polinomial de 6º grau. As equações são apresentadas na Tabela 5.1.

Figura 5.8 – Interpolação polinomial do 6º grau realizado a partir dos dados de rigidez-deslocamento para o elemento com nível de dano 60%, do lote 2.



Fonte: Autor.

Tabela 5.1 – Equações resultantes das interpolações realizadas para os níveis de dano nos lotes 2 e 3.

Lote	Nível de dano	Equação	$R^2$
2	Íntegro	$f_1(x) = -9,47 * 10^7 x^6 + 5,932 * 10^7 x^5 - 1,422 * 10^7 x^4 + 1,629 * 10^6 x^3 - 8,966 * 10^4 x^2 + 1813x + 62,24$	0,988
2	30%	$f_2(x) = -4,022 * 10^8 x^6 + 2,069 * 10^8 x^5 - 4,177 * 10^7 x^4 + 4,182 * 10^6 x^3 - 2,161 * 10^5 x^2 + 5321x - 3,116$	0,960
2	60%	$f_3(x) = 4,542 * 10^8 x^6 - 2,132 * 10^8 x^5 + 3,708 * 10^7 x^4 - 2,811 * 10^6 x^3 + 7,296 * 10^5 x^2 + 726,1x + 0,426$	0,960
3	Íntegro	$f_4(x) = 3,161 * 10^8 x^6 - 1,61 * 10^8 x^5 + 3,296 * 10^7 x^4 - 3,473 * 10^6 x^3 + 1,987 * 10^5 x^2 - 5851x + 120$	0,988
3	30%	$f_5(x) = 2,443 * 10^7 x^6 - 1,272 * 10^7 x^5 + 2,062 * 10^6 x^4 - 7160x^3 - 3,181 * 10^4 x^2 + 3016x - 30,65$	0,996
3	60%	$f_6(x) = 4,688 * 10^8 x^6 - 2,419 * 10^8 x^5 + 4,888 * 10^7 x^4 - 4,817 * 10^6 x^3 + 2,313 * 10^5 x^2 - 4615x + 52,32$	0,968

Fonte: Autor.

Após a criação das variáveis correspondentes às equações, faz-se necessária a escolha da *wavelet*-mãe. Em trabalhos que utilizam a transformada *wavelet*, especificamente em reconhecimento de padrões, normalmente a escolha da função *wavelet* é arbitrária (Argoud *et al.*, 2004).

Ao realizar a análise, os níveis de decomposição do registro de rigidezes em termos de componentes de baixa-frequência ( $a_n$ ) e de alta-frequência ( $d_n$ ) são apresentados de acordo com o nível da *wavelet* ( $n$ ) (Equação 19).

O melhor sinal a ser escolhido está relacionado ao comportamento do ensaio a ser executado ou à natureza do problema. Para situações onde as variações sejam suaves, como a da temperatura ao longo de um determinado período, por exemplo, o ideal é que sejam utilizados os sinais de baixa frequência, que apresente o comportamento mais suave possível, geralmente encontrados nos primeiros níveis. Caso a escolha da *wavelet* mãe seja escolhida de forma adequada, os resultados gerados chegam a ser semelhantes aos dados de origem.

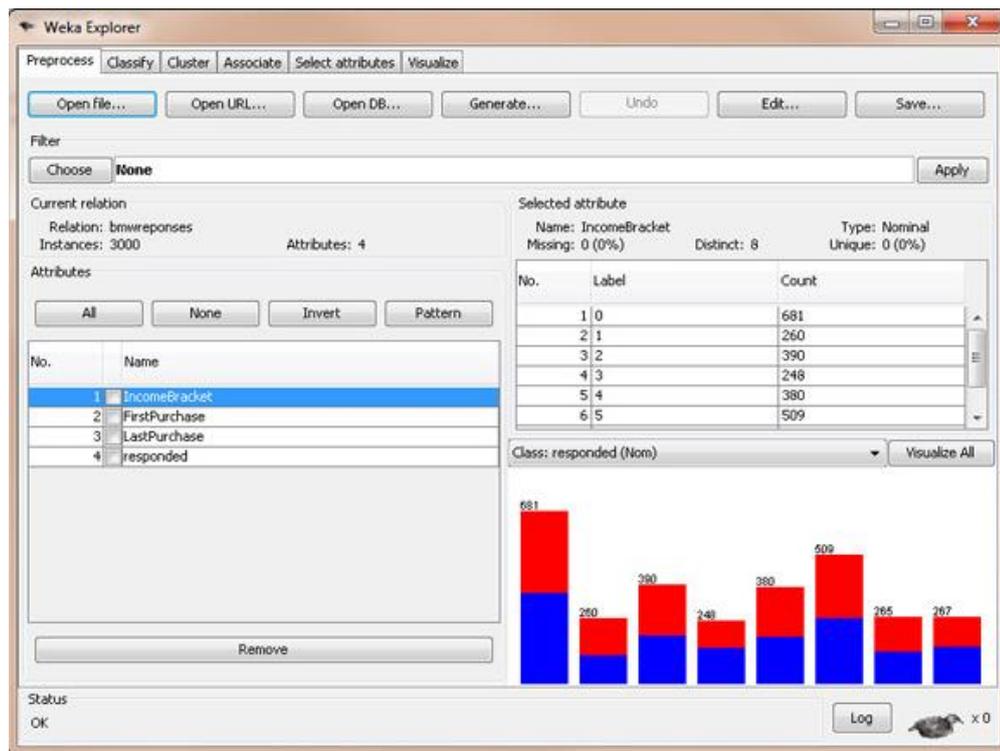
A fim de concluir as avaliações, aplica-se o Teste de Kruskal-Wallis, segundo o procedimento apresentado anteriormente, por meio do aplicativo *Action Stat* (Estatcamp, 2017).

### **5.3 Máquinas de vetores de suporte**

Para a construção de classificadores de máquinas de vetores de suporte (SVM), foi utilizada a ferramenta LIBSVM, no WEKA, e esta construção pode ser feita com duas ou mais classes. Uma SVM classifica dados encontrando o melhor hiperplano que separa todos os pontos de dados de uma classe daqueles de outra classe.

Para isso, é necessário carregar o banco de dados obtidos e definir quais as variáveis que serão utilizadas para a classificação. A tela após este procedimento se assemelha à apresentada na Figura 5.9. Posteriormente, seleciona-se o classificador (LIBSVM) a ser utilizado, responsável pela geração dos resultados, apresentados no capítulo 6.

Figura 5.9 – Classificação de dados quaisquer no WEKA.



Fonte: IBM, 2017.

## 5.4 Modelo de misturas gaussianas

A metodologia para construir classificadores via GMM a partir de *clusters* é semelhante à usada em máquinas de vetores de suporte, utilizando o WEKA. Com o carregamento dos dados ao *software*, o *clusterer* (EM – *Expectation Maximization*) é escolhido, assim como a quantidade de *clusters* para cada situação. Executando-se o WEKA, a saída deve parecer com a Figura 5.10, de acordo com a quantidade de *clusters* definida. A análise feita com os resultados deste tópico será apresentada no capítulo 6.

Figura 5.10 – Saída de um modelo de classificação qualquer para análise de GMM do WEKA, com 5 clusters.

Attribute	Full Data (100)	Cluster#				
		0 (26)	1 (27)	2 (5)	3 (14)	4 (28)
Dealership	0.6	0.9615	0.6667	1	0.8571	0
Showroom	0.72	0.6923	0.6667	0	0.5714	1
ComputerSearch	0.43	0.6538	0	1	0.8571	0.3214
M5	0.53	0.4615	0.963	1	0.7143	0
3Series	0.55	0.3846	0.4444	0.8	0.0714	1
Z4	0.45	0.5385	0	0.8	0.5714	0.6786
Financing	0.61	0.4615	0.6296	0.8	1	0.5
Purchase	0.39	0	0.5185	0.4	1	0.3214

#### Clustered Instances

0	26 ( 26%)
1	27 ( 27%)
2	5 ( 5%)
3	14 ( 14%)
4	28 ( 28%)

Fonte: IBM, 2017.

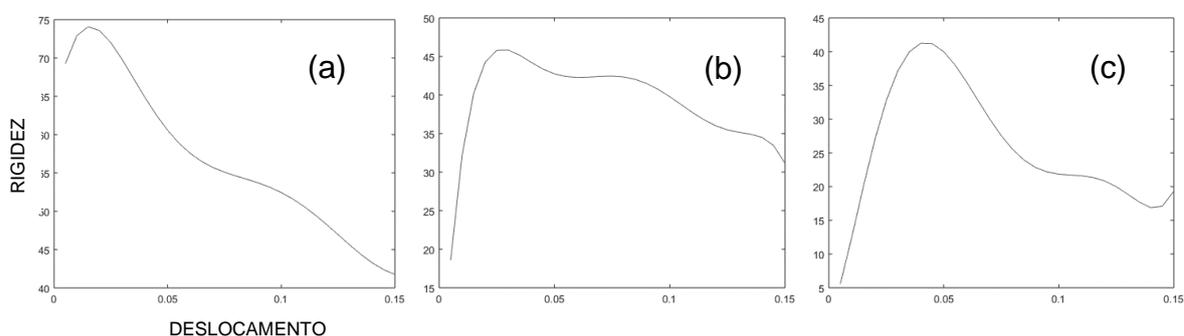
## 6 RESULTADOS E ANÁLISES

Como resultado deste projeto, serão aplicados os algoritmos para reconhecimento de padrões para identificação de dano estrutural, contribuindo para uma avaliação mais confiável da condição estrutural. Os desenvolvimentos oriundos deste projeto, uma vez inseridos em uma plataforma de SHM apropriada, constituirão ferramentas que irão auxiliar na análise da informação proveniente dos sistemas de monitoração, contribuindo assim no processo de manutenção de pontes e estruturas especiais. Nesta etapa do trabalho, serão apresentados resultados relacionados às *Wavelets*, Máquinas de Vetores de Suporte e Modelos de Misturas Gaussianas.

### 6.1 Wavelets

Seguindo o procedimento apresentado no item 5.2, foram obtidos os resultados para a análise por meio das *wavelets*. Os lotes 2 e 3 serão apresentados separadamente, de acordo com cada nível de dano (íntegro, dano de 30% e de 60% da altura da viga). A Figura 6.1 apresenta os gráficos gerados pelas interpolações realizadas a partir dos dados de rigidez - deslocamento experimentais para o lote 2.

Figura 6.1 – Gráficos das interpolações para cada nível de dano, no lote 2: (a) Íntegro; (b) Dano de 30% da altura; e, (c) Dano de 60% da altura da viga.

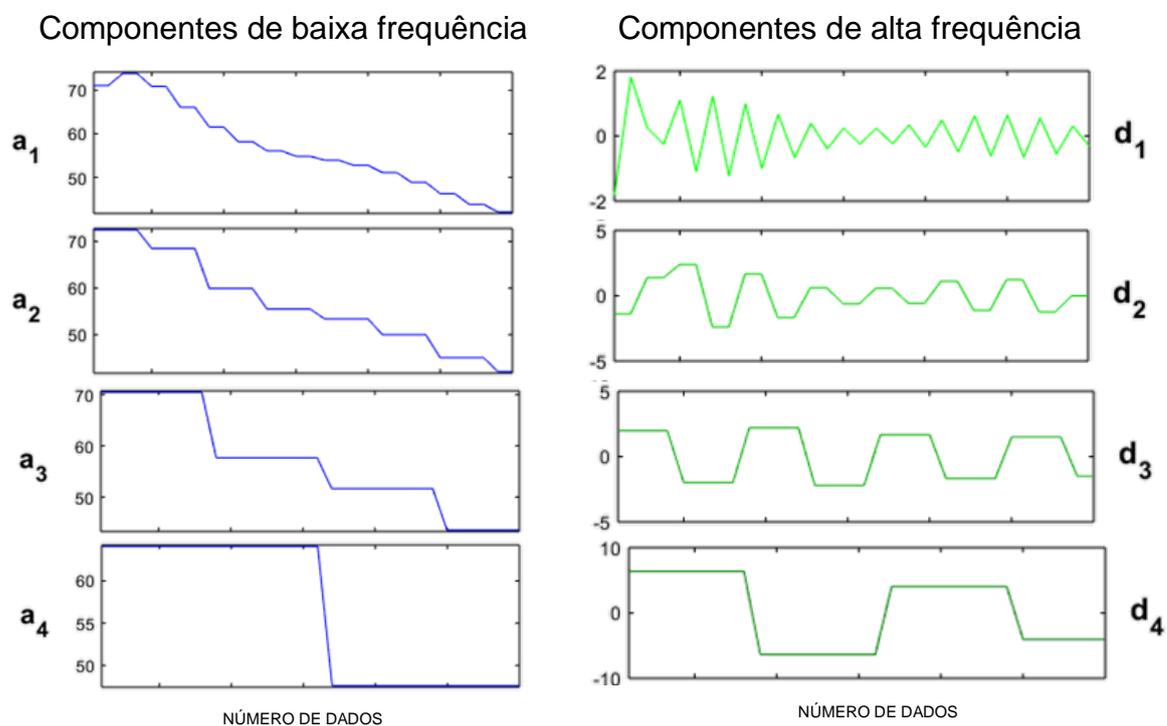


Fonte: Autor.

A partir dos dados das equações e interpolações, realizou-se a análise de *wavelets*. Para reconhecimento de padrões, as *wavelets* comumente utilizadas são a de Haar (ARGOUD *et al*, 2004), e a de Daubechies (OVANESOVA E SUÁREZ, 2004, e REDATAHA, *et al.*, 2004). A Figura 6.2 apresenta a decomposição em sinais de baixa e alta frequência, em 4 níveis, para o estado íntegro, a partir dos dados experimentais incorporados ao *Toolbox*, para a *wavelet*. Vale salientar que essa quantidade de níveis

é a mesma para os dois lotes, e está presente tanto na situação não-danificada como na danificada (30% e 60% da altura da viga).

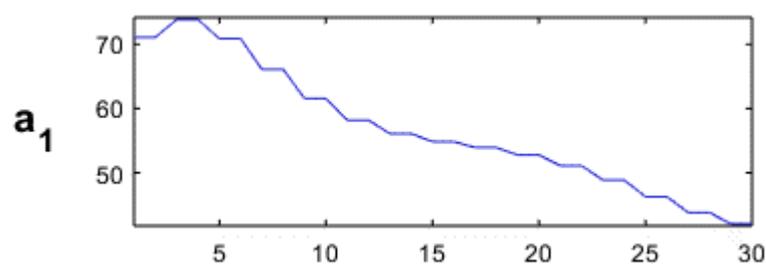
Figura 6.2 – Decomposição do registro das rigidezes do lote 2 no estado íntegro em 4 níveis aplicando as *wavelets* de Haar.



Fonte: Autor.

Como explicado na metodologia, o melhor sinal é o de baixa frequência, e por apresentar melhor suavidade, o  $a_1$  (Figura 6.3) foi escolhido.

Figura 6.3 – Melhor sinal de baixa frequência para análise de *wavelets*.

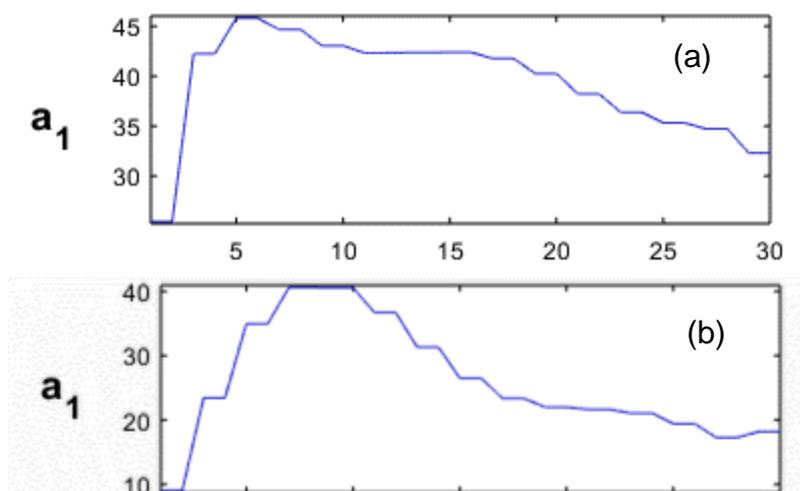


Fonte: Autor.

De semelhante modo ao apresentado para o estado íntegro, repetem-se os procedimentos para os elementos danificados (30% e 60% da altura da viga), e mais

objetivamente, os melhores componentes de baixa frequência para ambos, são apresentados na Figura 6.4.

Figura 6.4 – Melhor sinal de baixa frequência para análise de *wavelets*: (a) Danificado 30%; (b) Danificado 60% da altura da viga.



Fonte: Autor.

Os dados de  $a_1$  para cada situação foram exportados pelo Matlab. A fim de verificar se é possível identificar padrões diferentes nos dados gerados a partir das *wavelets*, aplicou-se o Teste de Kruskal-Wallis. Utilizando os dados de  $a_1$ , a ideia é validar ou não a hipótese nula  $H_0$ , de que os gráficos são iguais, e consequentemente, os padrões de dano não podem ser diferenciados. Testou-se para o nível de significância de 5%, a hipótese de igualdade dos três níveis de dano, e a Tabela 6.1 apresenta o resultado.

Tabela 6.1 – Resultados do Teste de Kruskal-Wallis para os dados do lote 2, a partir das *wavelets* de Haar.

FATORES COMPARADOS	KRUSKAL-WALLIS QUI-QUADRADO	P-VALOR GERAL	P-VALOR (DOIS A DOIS)	DIFERENÇA
DANO 30% - DANO 60%	68,23	1,55E-15	0	SIM
DANO 30% - ÍNTEGRO			0	SIM
DANO 60% - ÍNTEGRO			0	SIM

Fonte: Autor.

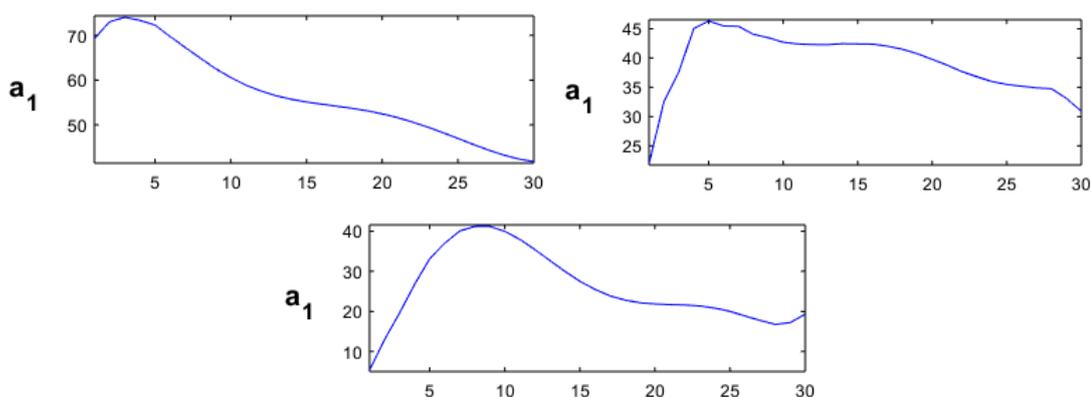
Como o p-valor geral é menor que 0,05, a hipótese nula ( $H_0$ ) é rejeitada, ou seja, os três gráficos são diferentes entre si. Quando comparados dois a dois, também se nota um p-valor menor que 0,05, rejeitando, desta forma, qualquer possibilidade de que

haja alguma relação entre eles. O algoritmo a partir das *wavelets* conseguiu reconhecer a diferença entre os três padrões de dano, ou seja, consegue reconhecer diferentes padrões de dano.

A fim de comparar resultados de *wavelets*-mães diferentes, fez-se uma análise com as *wavelets* de Daubechies para o lote 2, e em seguida para o lote 3.

Para o lote 2, visualmente estes resultados foram melhores do que os das *wavelets* de Haar. Para os três níveis de dano foram utilizadas as *wavelets* de Daubechies nível 4. Os melhores sinais de baixa frequência com as *wavelets* Daubechies são apresentados na Figura 6.5. Estes sinais se assemelham com os resultados das interpolações.

Figura 6.5 – Melhor sinal de baixa frequência para análise de *wavelets*: (a) Íntegro; (b) Danificado 30%; (c) Danificado 60% da altura da viga.



Fonte: Autor.

Os dados de  $a_1$  para cada situação foram exportados pelo Matlab. Aplicando-se o Teste de Kruskal-Wallis, pode-se obter os p-valores apresentados na Tabela 6.2.

Tabela 6.2 – Resultados do Teste de Kruskal-Wallis para os dados do lote 2, a partir das *wavelets* de Daubechies.

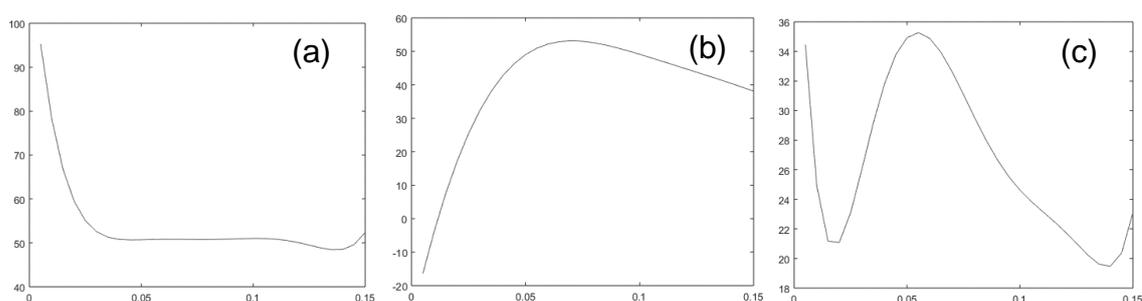
FATORES COMPARADOS	KRUSKAL-WALLIS QUI-QUADRADO	P-VALOR	P-VALOR (DOIS A DOIS)	DIFERENÇA
DANO 30% - DANO 60%	67,84	1,85E-15	0	SIM
DANO 30% - ÍNTEGRO			0	SIM
DANO 60% - ÍNTEGRO			0	SIM

Fonte: Autor.

Como os p-valores são menores que o nível de significância estabelecido, pode-se concluir que há diferença entre os três padrões de dano, ou seja, o método também consegue reconhecer padrões diferentes de dano, quando se utiliza *wavelet* de Daubechies para o lote 2.

A seguir são apresentados os resultados obtidos para o lote 3, alcançados de modo semelhante ao que foi visto para o lote 2. A Figura 6.6 apresenta os resultados das interpolações, realizadas a partir dos dados experimentais de Carvalho (2015).

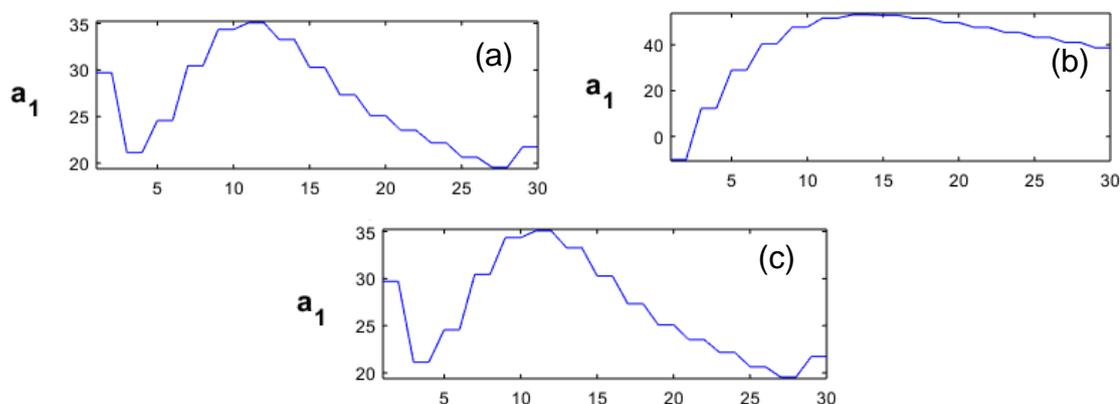
Figura 6.6 – Gráficos das interpolações para cada nível de dano, no lote 3: (a) Íntegro; (b) Dano de 30%; e, (c) Dano de 60% da altura da viga.



Fonte: Autor.

De forma mais objetiva, apresentam-se na Figura 6.7 os sinais  $a_1$  para o estado íntegro, danificado 30% e 60% da altura da viga, respectivamente.

Figura 6.7 – Melhor sinal de baixa frequência para análise das *wavelets* de Haar: (a) Estado íntegro; (b) Danificado 30% da altura; (c) Danificado 60% da altura da viga.



Fonte: Autor.

Os dados de  $a_1$  para cada situação foram exportados pelo Matlab. De modo semelhante ao que foi realizado para o lote 2, aplicou-se o Teste de Kruskal-Wallis

com os dados de  $a_1$ , com a ideia de validar ou não a hipótese nula  $H_0$ , de que os gráficos são iguais. Também se testou para o nível de 5%, a hipótese de igualdade dos três ensaios, e o resultado é apresentado na Tabela 6.3.

Tabela 6.3 – Resultados do Teste de Kruskal-Wallis para os dados do lote 3, a partir das *wavelets* de Haar.

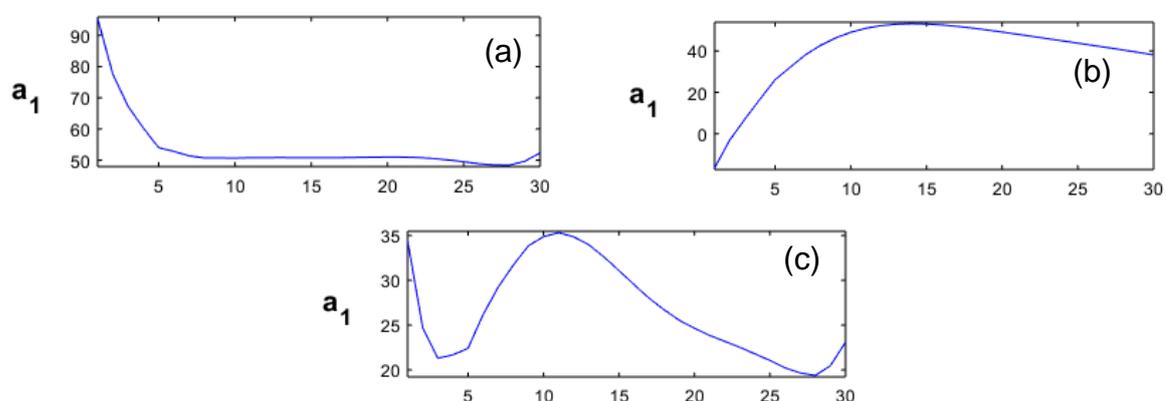
FATORES COMPARADOS	KRUSKAL-WALLIS QUI-QUADRADO	P-VALOR	P-VALOR (DOIS A DOIS)	DIFERENÇA
DANO 30% - DANO 60%	52,018	5,06E-12	0	SIM
DANO 30% - ÍNTEGRO			0,000004	SIM
DANO 60% - ÍNTEGRO			0	SIM

Fonte: Autor.

Como o p-valor geral é menor que 0,05, rejeitamos a hipótese nula, ou seja, os três gráficos são diferentes entre si. Quando comparados dois a dois, também se nota um p-valor menor que 0,05, rejeitando também a hipótese nula.

A análise via *wavelet* de Daubechies também foi realizada para o lote 3, resultando os sinais  $a_1$  apresentados na Figura 6.8.

Figura 6.8 - Melhor sinal de baixa frequência para análise das *wavelets* de Daubechies: (a) Estado íntegro; (b) Danificado 30% da altura; (c) Danificado 60% da altura.



Fonte: Autor.

Os dados de  $a_1$ , para cada situação da análise das *wavelets* de Daubechies, foram exportados pelo Matlab. Aplicando-se o Teste de Kruskal-Wallis, foram obtidos os valores expressos na Tabela 6.4.

Tabela 6.4 – Resultados do Teste de Kruskal-Wallis para os dados do lote 3, a partir das *wavelets* de Daubechies.

FATORES COMPARADOS	KRUSKAL-WALLIS QUI-QUADRADO	P-VALOR	P-VALOR (DOIS A DOIS)	DIFERENÇA
DANO 30% - DANO 60%	52,30	4,39E-12	0	SIM
DANO 30% - ÍNTEGRO			0	SIM
DANO 60% - ÍNTEGRO			0	SIM

Fonte: Autor.

A tabela acima comprova a capacidade das *wavelets* conseguirem reconhecer os padrões diferentes de dano, quando se utiliza *wavelet* de Daubechies para o lote 3.

## 6.2 Máquinas de vetores de suporte

Pelo WEKA, os dados do lote 2 foram analisados considerando as seguintes funções kernel, fornecidas pelo programa: polinomial e *radial basis* (RBF). A seguir será apresentado o resultado de cada análise.

Dos números apresentados na Figura 6.9, os mais importantes são os próximos a *Correctly Classified Instances* (33,33%) e às *Incorrectly Classified Instances* (66,67%), números que mostram que o método de Máquinas de Vetores de Suporte (SVM), utilizando a função polinomial não consegue fazer o reconhecimento de diferentes padrões de dano de forma adequada. Em *Confusion Matrix*, os números de falsos-positivos e falsos-negativos são mostrados, indicando que nos estados íntegro e dano de 30%, os valores não são confiáveis, pois se apresentam na parte de cima da diagonal principal da matriz, indicando falsos-positivos. Apenas para o estado de dano de 60% a função polinomial fez o reconhecimento de forma correta. A Figura 6.10 apresenta os resultados obtidos para a função polinomial de modo ilustrativo, onde os ícones em formato de quadrados indicam as amostras que foram classificadas incorretamente, enquanto que os ícones em formato de “X” indicam o contrário, as amostras classificadas corretamente.

Figura 6.9 – Saída do modelo de classificação do WEKA utilizando a função kernel polinomial – Lote 2.

```

=== Summary ===

Correctly Classified Instances      30      33.3333 %
Incorrectly Classified Instances    60      66.6667 %
Kappa statistic                    0
Mean absolute error                0.4444
Root mean squared error            0.6667
Relative absolute error            100 %
Root relative squared error        141.4214 %
Total Number of Instances          90

=== Detailed Accuracy By Class ===

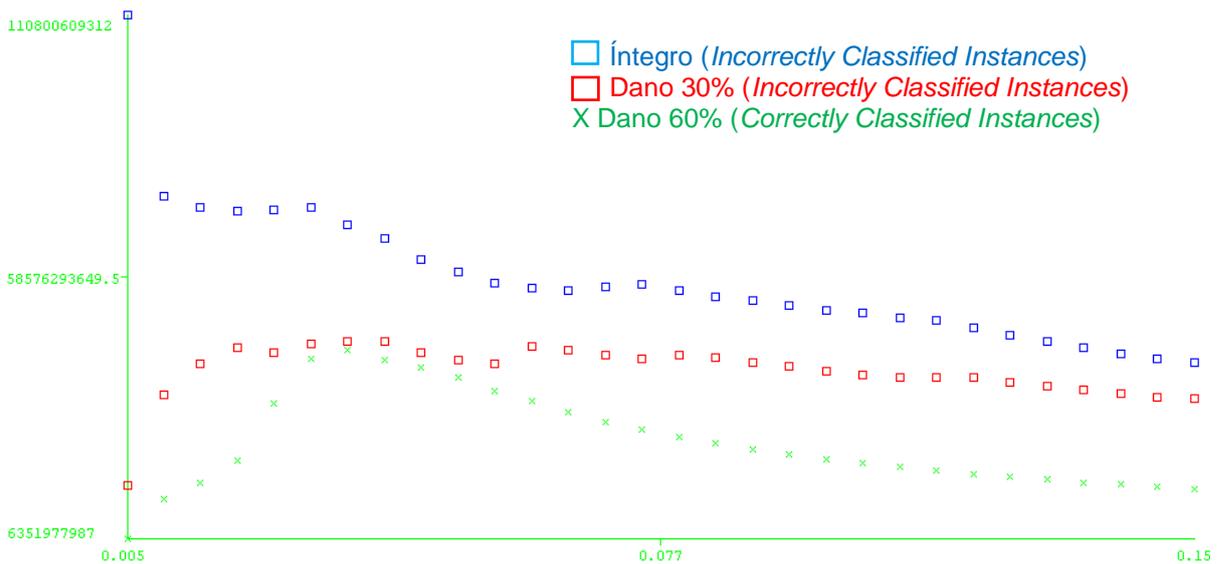
          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC  ROC Area  PRC Area  Class
          0,000   0,000   0,000     0,000   0,000     0,000  0,500    0,333    integro
          0,000   0,000   0,000     0,000   0,000     0,000  0,500    0,333    d30
          1,000   1,000   0,333     1,000   0,500     0,000  0,500    0,333    d60
Weighted Avg.   0,333   0,333   0,111     0,333   0,167     0,000  0,500    0,333

=== Confusion Matrix ===

 a  b  c  <-- classified as
 0  0 30 | a = integro
 0  0 30 | b = d30
 0  0 30 | c = d60
    
```

Fonte: Autor.

Figura 6.10 – Gráfico EI-deslocamento gerado pelo WEKA na análise pelo LibSVM para a função polinomial – Lote 2.



Fonte: Autor.

Quando as mesmas amostras foram testadas utilizando a função kernel RBF, os resultados foram diferentes. Eles são apresentados na Figura 6.11.

Figura 6.11 – Saída do modelo de classificação do WEKA para a função RBF – Lote 2.

```

=== Summary ===

Correctly Classified Instances      90      100 %
Incorrectly Classified Instances    0       0 %
Kappa statistic                    1
Mean absolute error                 0
Root mean squared error            0
Relative absolute error             0 %
Root relative squared error        0 %
Total Number of Instances          90

=== Detailed Accuracy By Class ===

      TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
      1,000    0,000    1,000     1,000    1,000     1,000    1,000    1,000    integro
      1,000    0,000    1,000     1,000    1,000     1,000    1,000    1,000    d30
      1,000    0,000    1,000     1,000    1,000     1,000    1,000    1,000    d60
Weighted Avg.    1,000    0,000    1,000     1,000    1,000     1,000    1,000    1,000

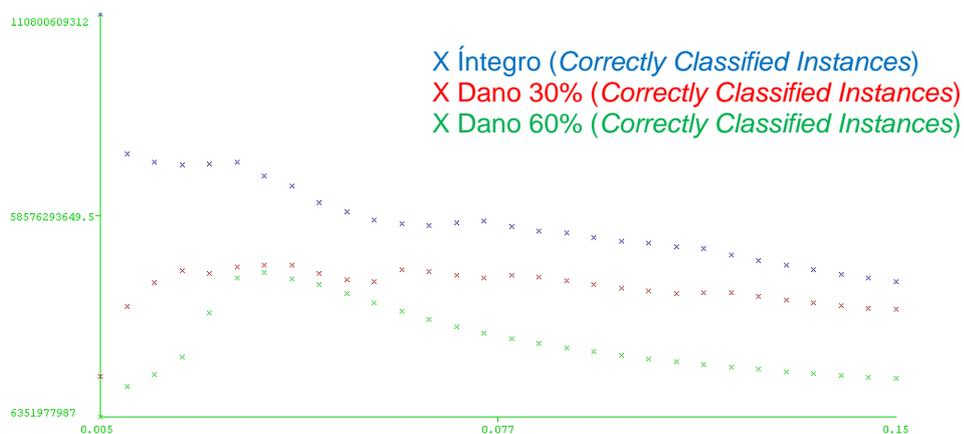
=== Confusion Matrix ===
  a  b  c  <-- classified as
 30  0  0 | a = integro
 0 30  0 | b = d30
 0  0 30 | c = d60

```

Fonte: Autor.

Os números próximos a *Correctly Classified Instances* são 100% e a *Incorrectly Classified Instances* são 0%, números que mostram que o método de máquinas de vetores de suporte, por meio do WEKA, consegue fazer o reconhecimento de diferentes padrões de dano. Em *Confusion Matrix*, os números de falsos-positivos e falsos-negativos são mostrados, que para este caso, são nulos, descartando as hipóteses de possíveis erros nas detecções do dano. A Figura 6.12 apresenta os resultados obtidos pelo WEKA de modo ilustrativo.

Figura 6.12 – Gráfico EI–deslocamento gerado pelo WEKA na análise pelo LibSVM para a função RBF – Lote 2.



Fonte: Autor.

O lote 3 foi avaliado da mesma forma para a função polinomial e RBF. A Figura 6.13 apresenta os resultados para a polinomial.

Figura 6.13 - Saída do modelo de classificação do WEKA, para função polinomial – Lote 3.

```

=== Summary ===

Correctly Classified Instances      26      28.8889 %
Incorrectly Classified Instances    64      71.1111 %
Kappa statistic                     0
Mean absolute error                 0.4741
Root mean squared error             0.6885
Relative absolute error             107.4756 %
Root relative squared error        146.6301 %
Total Number of Instances          90

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
          0,000   0,000   0,000     0,000   0,000     0,000   0,500    0,322    integro
          0,000   0,000   0,000     0,000   0,000     0,000   0,500    0,389     d30
          1,000   1,000   0,289     1,000   0,448     0,000   0,500    0,289     d60
Weighted Avg.   0,289   0,289   0,083     0,289   0,130     0,000   0,500    0,339

=== Confusion Matrix ===

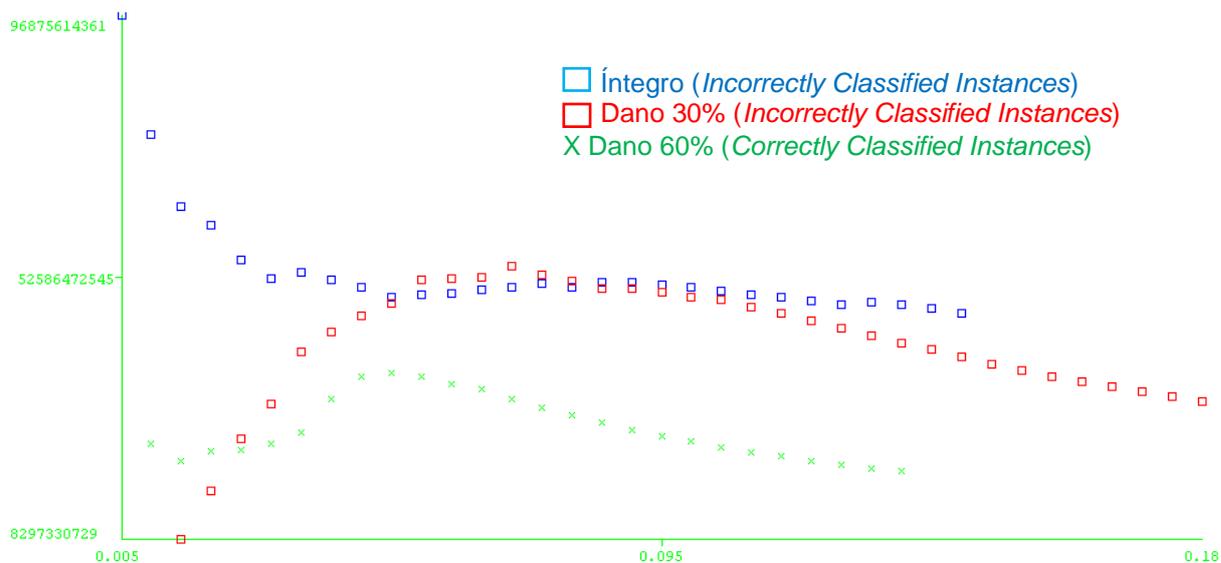
  a  b  c  <-- classified as
  0  0 29 | a = integro
  0  0 35 | b = d30
  0  0 26 | c = d60

```

Fonte: Autor.

Mais uma vez o resultado de 28,89% em *Correctly Classified Instances*, e os falsos-positivos presentes em *Confusion Matrix*, comprovam que utilizar a função polinomial para este trabalho não é adequado. A Figura 6.14 apresenta os resultados obtidos pelo WEKA de modo ilustrativo.

Figura 6.14 – Gráfico EI–deslocamento gerado pelo WEKA na análise pelo LibSVM para a função polinomial – Lote 3.



Fonte: Autor.

Quando as mesmas amostras do lote 3 foram testadas utilizando a função kernel RBF, os resultados foram diferentes. Eles são apresentados na Figura 6.15.

Figura 6.15 - Saída do modelo de classificação do WEKA para a função RBF – Lote 3.

```

=== Summary ===

Correctly Classified Instances      90
Incorrectly Classified Instances    0
Kappa statistic                     1
Mean absolute error                 0
Root mean squared error             0
Relative absolute error             0 %
Root relative squared error         0 %
Total Number of Instances          90

=== Detailed Accuracy By Class ===

      TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
      1,000    0,000    1,000     1,000    1,000     1,000    1,000     1,000    integro
      1,000    0,000    1,000     1,000    1,000     1,000    1,000     1,000    d30
      1,000    0,000    1,000     1,000    1,000     1,000    1,000     1,000    d60
Weighted Avg.    1,000    0,000    1,000     1,000    1,000     1,000    1,000     1,000

=== Confusion Matrix ===

  a  b  c  <-- classified as
29  0  0  | a = integro
 0 35  0  | b = d30
 0  0 26  | c = d60

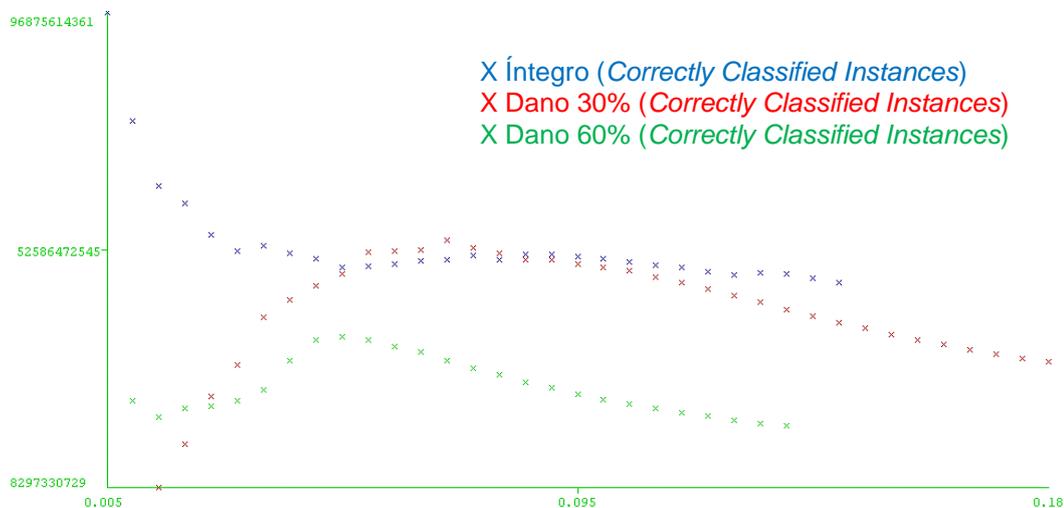
```

Fonte: Autor.

Semelhante ao que foi encontrado para o lote 2, a classificação pode ser feita integralmente, onde o resultado de 100% em "*Correctly Classified Instances*" significa que os três resultados são diferentes entre si, sem apresentar falsos-positivos ou

falsos-negativos. A Figura 6.16 apresenta os resultados obtidos pelo WEKA de modo ilustrativo.

Figura 6.16 – Gráfico EI–deslocamento gerado pelo WEKA na análise pelo LibSVM para a função RBF – Lote 3.



Fonte: Autor.

### 6.3 Modelo de misturas gaussianas

Com o WEKA, as análises dos dados dos lotes 2 e 3 foram feitas com a quantidade de *clusters* que melhor representasse a quantidade de níveis de danificação (íntegro, dano de 30% e de 60% da altura da viga), desta forma, foram escolhidos 3 *clusters* nos dois casos. Os resultados obtidos para o lote 2 são apresentados na Figura 6.17.

Figura 6.17 – Resultados obtidos a partir do algoritmo EM, incorporado ao WEKA, para os dados do lote 2.

Attribute	Cluster		
	0 (0.28)	1 (0.41)	2 (0.31)
<b>Tipo</b>			
integro	1.0051	3.8372	28.1576
d30	2.1917	29.5968	1.2116
d60	25.046	6.744	1.2101
[total]	28.2428	40.1779	30.5793
<b>Deslocamento</b>			
mean	0.0833	0.0786	0.0707
std. dev.	0.046	0.043	0.0401
<b>EI</b>			
mean	21744423283.7958	40682457193.4337	59361549833.3198
std. dev.	6597148100.4063	3428666418.801	13621131462.1362

Clustered Instances

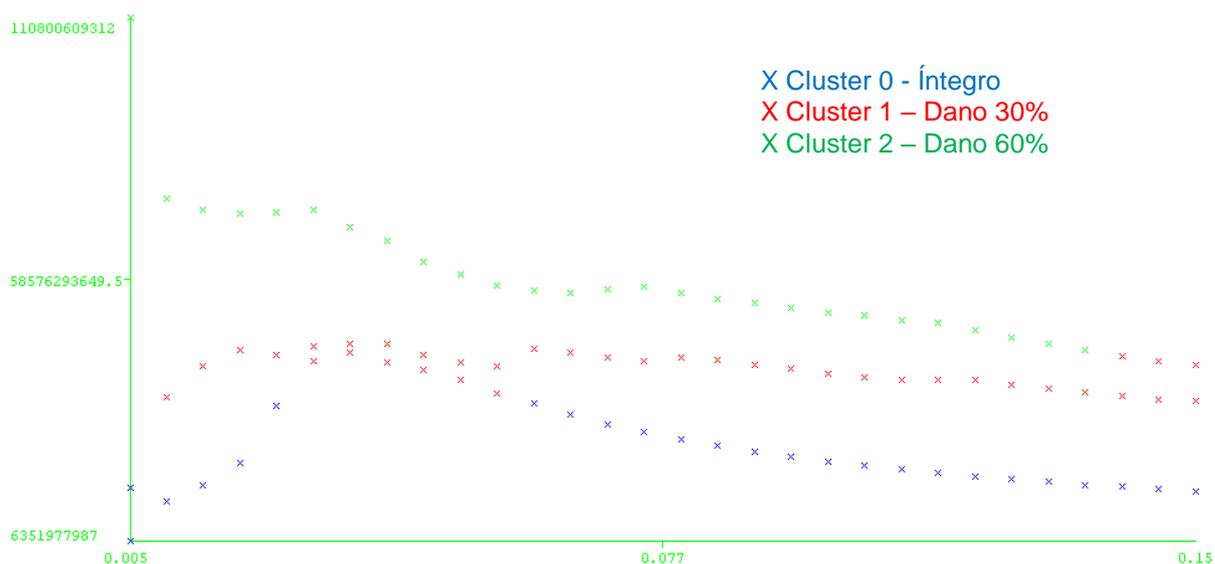
0	25 ( 28%)
1	38 ( 42%)
2	27 ( 30%)

Log likelihood: -23.61318

Fonte: Autor.

Os resultados gerados dizem o quanto cada *cluster* conseguiu ou não identificar grupos distintos. A situação ideal seria que cada *cluster* identificasse um padrão de dano. De acordo com a Figura 6.17, o *cluster 0* deveria identificar os CP's íntegros, enquanto que o *cluster 1* identificaria os CP's com 30% de dano da altura da viga, e o *cluster 2* os CP's com 60% de dano. Mas na realidade essa distinção não foi feita adequadamente (100%). Isso é comprovado pela tabela *Clustered Instances*, que apresenta quantidades de amostras para o *cluster 1* maior do que a quantidade de dados para este grupo, que seriam apenas 30. Essa diferença pode ser melhor percebida na Figura 6.18, que apresenta o *cluster 2* (em vermelho) agrupando dados que deveriam ser dos outros *clusters*. Porém, esta diferença é relativamente pequena, já que de alguma forma três níveis diferentes de danos puderam ser reconhecidos.

Figura 6.18 – Gráfico EI–deslocamento gerado pelo WEKA na análise feita pelo algoritmo EM – Lote 2.



Fonte: Autor.

Já os resultados para o lote 3 são apresentados na Figura 6.19. Diferente do que aconteceu para o lote 2, os clusters aplicados ao lote 3 conseguiram distinguir corretamente (100%) os três níveis distintos de danificação. A diferença é comprovada pela quantidade de amostras para cada nível, apresentadas na tabela *Clustered Instances*, que permanece de acordo com o banco de dados do trabalho. A Figura 6.20 também faz essa comprovação, já que mesmo se cruzando os gráficos conseguem permanecer sem misturar as cores.

Figura 6.19 – Resultados obtidos a partir do algoritmo EM, incorporado ao WEKA, para os dados do lote 3.

Attribute	Cluster		
	0 (0.32)	1 (0.39)	2 (0.29)
<b>Tipo</b>			
integro	30	1	1
d30	1	36	1
d60	1	1	27
[total]	32	38	29
<b>Deslocamento</b>			
mean	0.075	0.1	0.0725
std. dev.	0.0426	0.0512	0.0382
<b>EI</b>			
mean	53617956446.3793	41295469386.4571	26837739896.9231
std. dev.	10268341385.0965	10560455910.7504	5291230283.3529

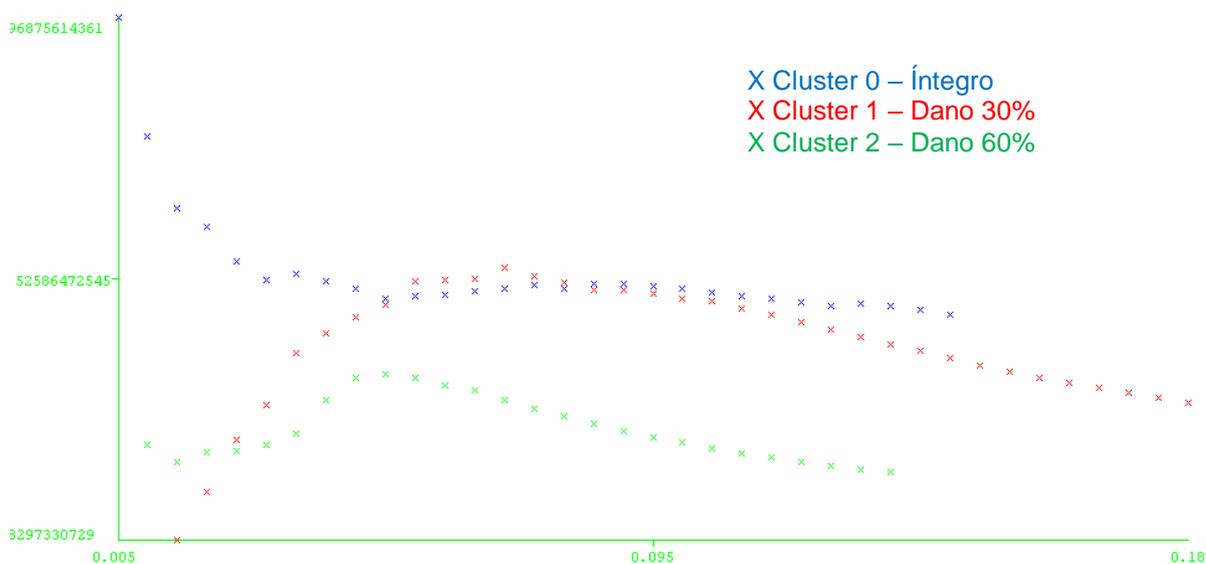
  

Clustered Instances		
0	29	( 32%)
1	35	( 39%)
2	26	( 29%)

Log likelihood: -23.68566

Fonte: Autor.

Figura 6.20 – Gráfico EI–deslocamento gerado pelo WEKA na análise feita pelo algoritmo EM – Lote 3.



Fonte: Autor.

## 7 CONSIDERAÇÕES FINAIS

Neste trabalho foi realizada a aplicação de algoritmos utilizados na classificação e regressão de dados, que há alguns anos vêm ganhando espaço na análise de ensaios relacionados à Engenharia de Estruturas. Os algoritmos utilizados foram as *wavelets*, as máquinas de vetores de suporte e o modelo de misturas gaussianas, para reconhecimento de padrões de danos em estruturas de concreto. Os dados analisados foram obtidos no trabalho desenvolvido por Carvalho (2015).

No que diz respeito à análise feita com as *wavelets*, os melhores resultados foram encontrados utilizando as *wavelets*-mães de Haar e de Daubechies. Por meio do teste estatístico de Kruskal-Wallis, constatou-se que houve o reconhecimento dos diferentes níveis de dano (íntegro, 30% e 60% da altura da viga) para cada uma delas. Utilizando as máquinas de vetores de suporte (*Support Vector Machine* – SVM) também foi possível encontrar resultados significativos do ponto de vista de reconhecimento de diferentes padrões de danificação das vigas ensaiadas. O método, aplicado por meio do algoritmo LibSVM incorporado ao programa WEKA, conseguiu distinguir com 100% de eficiência quando utilizada a função kernel RBF (*Radial Basis Function*). O mesmo nível de eficiência não foi encontrado quando foi utilizada a função kernel polinomial, com apenas 33,33%.

Em relação ao algoritmo de modelos de misturas gaussianas (*Gaussian Mixture Model* – GMM), conclui-se que o método também consegue reconhecer a existência de diferentes níveis de dano, ainda que esse reconhecimento não seja completo. Mas, se utilizado em uma situação onde o conhecimento prévio do dano não seja possível, o método conseguirá concluir que existe diferença nesses níveis de danificação.

A etapa por vencida refere-se à validação de um modelo. Assim, as dispersões encontradas, são naturais às exclusões de procedimentos, em análises futuras.

### 7.1 Sugestões para trabalhos futuros

Sugere-se o uso dos algoritmos utilizados no trabalho (*wavelets*, máquinas de vetores de suporte e modelos de misturas gaussianas) no reconhecimento de padrões de diferentes níveis de dano, em diferentes dimensões e formas de seções transversais

em vigas de concreto. É possível a modificação do tipo de concreto (concreto reforçado com fibras, por exemplo) para que essa análise seja feita.

Como cada um dos algoritmos têm uma vasta quantidade de conteúdo, sugere-se que individualmente cada um deles seja estudado. Nas *wavelets*, por exemplo, pode-se estudar a influência das diferentes funções-mães. Na máquina de vetores de suporte, pode-se fazer a verificação com diferentes funções kernel. E no modelo de misturas gaussianas, a análise pode ser feita com outro algoritmo diferente do EM (*Expectation Maximization*).

De modo mais aprofundado, sugere-se a implementação e desenvolvimento de metodologias próprias, a partir dos conceitos matemáticos próprios de cada assunto.

## REFERÊNCIAS BIBLIOGRÁFICAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **ABNT NBR 5739**: Concreto: Ensaio de compressão de corpos de prova cilíndricos. Rio de Janeiro, 2007.

\_\_\_\_\_. **ABNT NBR 8522**: Concreto: Determinação do módulo estático de elasticidade à compressão. Rio de Janeiro, 2008.

\_\_\_\_\_. **ABNT NBR 12142**: Concreto – Determinação da resistência à tração na flexão de corpos de prova prismáticos, 2010.

AKAZAWA, H. J. **Jpn. Civ. Eng. Inst.**, 1943.

ALVES, V., N. **Estudo de novas estratégias para identificação de danos estruturais a partir de dados vibracionais**. Dissertação de mestrado, Universidade Federal de Ouro Preto, Minas Gerais, 2012.

ARGOUD, F. I. M.; AZEVEDO, F. M.; NETO, J., M. **Estudo comparativo entre funções *wavelet* e suas diferentes aplicabilidades em reconhecimento de padrões epileptogênicos em eletroencefalograma**. Revista Brasileira de Engenharia Biomédica, v. 20, n. 2-3, p. 49-59, 2004.

BARENBLATT, G.I. **The mathematical theory of equilibrium of cracks in brittle fracture**. Adv. Appl. Mech., 7: 55–129, 1962.

BANERJEE, S.; QING, X.; BEARD, S.; CHANG, F.K. **Prediction of Progressive Damage State at the Hot Spots Using Statistical Estimation**. J. Intell. Mater. Syst. Struct., 595–605, 2010.

BANFIELD, J.; RAFTERY, A. **Model-based Gaussian and Non Gaussian Clustering**. Biometrics, 49, 803–821, 1993.

BROWNJOHN, J. M. **Structural Health Monitoring of Civil Infrastructure**. Phil. Trans. R. Soc. A, 365, 589-622, 2006.

BURGES CHRISTOPHER J. C. **A Tutorial on Support Vector Machines for Pattern Recognition, Data Mining and Knowledge Discovery**, 2, pp. 121-167, 1998.

CAMILO, C. O., SILVA, J. C. **Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas**. Technical Report. Instituto de Informática. Universidade Federal de Goiás, 2009.

CAMPILHO, A. **Instrumentação Electrónica: Métodos e Técnicas de Medição**. 2. ed. Porto: Faculdade de Engenharia da Universidade do Porto, 2000. p. 562.

CARDOSO, C., G. **Identificação de danos em estruturas de viga por meio das suas propriedades dinâmicas**. Dissertação de mestrado, Universidade de Brasília, 2005.

CARVALHO, P. P. M. **Estudo Teórico-Experimental do Dano em Vigas de Concreto**. Dissertação de mestrado, Universidade Federal de Alagoas, Maceió, 2015.

CHEN, W.F. **Double-punch test for tensile strength of concrete**. ACI Mater.J., 67(2): 993–995, 1970.

CORTES, C., VAPNIK, V. N. **Support vector networks**. Machine Learning, 20:273–296, 1995.

CEB-FIP MODEL CODE 1990. **Design code**. London: Thomas Telford Services Ltd., Comité Euro-International du Béton, 1993.

CRISTIANINI, N. AND SHAW-TAYLOR, J. **An Introduction to Support Vector Machines and other kernel-based learning methods**. Cambridge University Press, 2000.

DAUBECHIES, I. **The wavelet transform time-frequency localization and signal analysis**. IEEE Trans. Inform. Theory, vol. 36 n<sup>o</sup>. 5 pp. 961-1005, 1990.

DECOSTE, D.; SCHÖLKOPF, B. **Training invariant support vector machines**. Machine Learning, 46:161–190, 2001.

DEMPSTER, A. P.; LAIRD, N. M.; RUBIN, D. B. **Maximum likelihood from incomplete data via the EM algorithm**. Journal of the Royal Statistical Society, v. 39, n. 1, p. 1-38, 1977.

DIMANDE, A. O. **Análise experimental de pontes durante a construção e em serviço**. Tese de doutorado. Universidade do Porto, Portugal, 2010.

DOEBLING, S.; FARRAR, C.; PRIME, M. E SHEVITZ, D. **Damage identification and health monitoring on structural and mechanical systems form changes in their vibration characteristics: a literature review**, Relatório técnico, Los Alamos National Laboratory, Estados Unidos, 1996.

DOUGLAS, A. R.; THOMAS, F. Q.; ROBERT, B. D. **Speaker verification using adapted gaussian mixture models**. Digital Signal Processing, v. 10, p. 19-41, 2000.

DUGDALE, D.S. **Yielding of sheets containing slits**. J. Mech. Phys. Sol. 8: 100–108, 1960.

ESTATCAMP. Estatcamp – Empresa de consultoria de estatística e desenvolvedora do Action Stat, 2017. <https://www.estatcamp.com.br/empresa/action-stat>. Acesso em 10 de setembro de 2017.

FARRAR, C.R.; WORDEN, K. **Structural Health Monitoring: A Machine Learning Perspective**. John Wiley & Sons, 2012.

FERNANDEZ, R. AND VIENNET, E. **Face identification using support vector machines**. In Proceedings of the European Symposium on Artificial Neural Networks (ESANN99), pages 195–200, Brussels. D.-Facto Press, 1999.

FERREIRA, L. E. T. **Elementos de mecânica da fratura aplicada à engenharia estrutural: Aspectos analíticos, computacionais e experimentais.** Águas da Prata, SP. Edição do autor, 2015.

FIGUEIREDO, E., PARK, G., FIGUEIRAS, J., FARRAR, C., & WORDEN, K. **Structural Health Monitoring Algorithm Comparisons using Standard Data Sets.** Los Alamos National Laboratory Report, 2009.

FIGUEIREDO, E. J. F. **Damage Identification in Civil Engineering Infrastructure under Operational and Environmental Conditions.** 196 f. Tese (Doutorado em Engenharia Civil), Universidade do Porto, Porto, 2010.

FIGUEIREDO, E.; MOLDOVAN, I.; MARQUES, M. B. **Condition Assessment of Bridges: Past, Present and Future. A Complementary Approach.** Universidade Católica Editora, 2013.

FILHO, L. A. C. M. A., ROITMAN, N., MAGLUTA, C. **Identificação de Carregamentos e Estruturas em Operação Através de Transformadas Wavelet.** In: Xxix Cilamce - Iberian Latin American Congress On Computational Methods In Engineering, Alagoas, 2008.

FISHER, R.A. (1925). **Statistical Methods for Research Workers.** Oliver & Boyd, Edinburgh.

GE, X. (2001). **Sequential minimal optimization for svm.** <http://datalab.uci.edu/people/xge/svm/>.

GONÇALVES, A. R. (2010). **Máquinas de Vetores suporte.** Notas de aula. Universidade Estadual de Campinas. São Paulo.

GUTIERREZ, C. E. C. (2002). **Eliminação do ruído por encolhimento de wavelets.** Dissertação de Mestrado, Pontifícia Universidade de Católica de Rio de Janeiro.

HASTIE, T., TIBSHIRANI, R., FREIDMAN, J. (2001). **Elements of Statistical Learning: Data Mining, Inference and Prediction,** 1st ed., Springer Verlag, NY.

HAYKIN, S. (1999). **Neural Networks - A Comprehensive Foundation.** Prentice-Hall, New Jersey, 2 edition.

HAIR, J. F., TATHAM, R. L., ANDERSON, R. E., BLACK, W., BABIN, B. J. **Análise multivariada de dados.** 5. ed. Porto Alegre: Bookman, 2005.

HEARST, M. A., SCHOLKOPF, B., DUMAIS, S., OSUNA, E., PLATT, J. (1998). **Trends and controversies - support vector machines.** IEEE Intelligent Systems, 13(4):18–28.

HILLERBORG, A., MODEÉR, M., PETERSON, P. E. (1976). **Analysis of crack formation and crack growth in concrete by means of fracture mechanics and finite elements.** Cem. Conc. Res., 6: 773–782.

HONGNAN, L., TINGHUA, Y., MING, G., LINSHENG, H. (2008). **Evaluation of earthquake induced structural damages by wavelet transform**. Journal of Progress in Natural Science, Volume 19, Pages 461-470.

HOSSEIN-KHANI, J., SOLTANIAN-ZADEH, H., KAMAREI, M., STAADT, O. **Ball detection with the aim of corner event detection in soccer video**. In: PARALLEL AND DISTRIBUTED PROCESSING WITH APPLICATIONS WORKSHOPS (ISPAW), 2011. Ninth IEEE International Symposium on, p. 147 - 152.

HSU, C., W., LIN, C., J. (2002). **A simple decomposition method for support vector machines**, Machine Learning, vol. 46, pp. 291–314.

HUI, Z.; WU, Q. M. J.; NGUYEN, T. M. **Image segmentation by a robust modified gaussian mixture model**. In: ICASSP, 2013. p. 1478-1482.

IBM (2017). IBM developer works Brasil. <https://www.ibm.com/developerworks/br/opensource/library/os-weka1/>. Acesso em 16/02/2017.

IRWIN, G.R. (1958). **Fracture**. In S. Flugge (Ed.), Handbuch der Physik, Berlin: SpringerVerlag, vol. 6, 551–590.

JANSON, J.; HULT, J. (1977). **Fracture mechanics and damage mechanics a combined approach**. Journal de Mécanique Appliquée, v. 1, n. 1, pp. 69-84.

JOACHIMS, T. (1998). **Making large-scale support vector machine learning practical**. In **Advances in Kernel Methods: Support Vector Machines**, Schölkopf, B., Burges, C., and Smola, A. (editors), MIT Press.

KACHANOV, L. M. (1958). **Time of the rupture process of non-linear solid mechanics**. Otd. Tech. Nauk., v. 8, pp. 28-31.

KACHANOV, L. M. (1984). **On brittle fracture of a thin plastic interlayer in creep conditions**. In: DVORAK, G.; SHIELD, R., ed. Mechanics of Material Behavior. Amsterdam, Elsevier.

KIREMIDJIAN, A., S.; KIREMIDJIAN, G.; SARABANDI, P. (2011). **A wireless structural monitoring system with embedded damage algorithms and decision support system**. Structure and Infrastructure Engineering. Vol. 7, No. 12, December 2011, 881–894.

LA BORDERIE, C.; MAZARS, J.; PIJAUDIER-CABOT, G (1991). **Response of plain and reinforced concrete structures iunder cyclic loadings**. Cachan, France, Laboratoire de Mécanique et Technologie, Rapport Interne, n. 123.

LARSON, R., FARBER, B. (2010). **Elementary statistics**. 4ed. São Paulo: Pearson Prentice Hall.

LECUN, Y. A., JACKEL, L. D., BOTTOU, L., BRUNOT, A., CORTES, C., DENKER, J. S., DRUCKER, H., GUYON, I., MULLER, E., SMOLENSKY, I., ACKINGER, E., SIMARD, P. Y., AND VAPNIK, V. N. (1995). **Comparison of learning algorithms for handwritten digit recognition.** In FoulgemanSoulié, F. and Gallinari, P., editors, Proceedings of the International Conference on Artificial Neural Networks (ICANN'95), volume 2, pages 53–60, Nanterre, France.

LEMAITRE, J. (1984). **How to use damage mechanics.** Nucl. Eng. Des., v. 80, pp. 233.

LEMAITRE, J.; CHABOCHE, J. L. (1974). **A non-linear model of creep-fatigue damage cumulation and interaction.** In: IUTAM Symp. of Mechanics of Viscoelastic Media and Bodies, Gothenburg. Proc. Springer.

LEMAITRE, J., CHABOCHE, J.L. (1978). **Aspect phénoménologique de la rupture par endommagement.** Journal de Mécanique Appliquée 2:317–365.

LEMAITRE, J., DESMORAT, R. (2005). **Engineering Damage Mechanics - Ductile, Creep, Fatigue and Brittle Failures.** Ed. Springer.

LINSBAUER, H.N., TSCHEGG, E.K. (1986). **Fracture energy determination of concrete with cube-shaped specimens.** Zement und Beton, 31: 38–42.

LORENA, A. C.; CARVALHO, A. C. P. L. de. (2003) **Introdução às Máquinas de Vetores Suporte.** São Carlos - SP, Abril 2003.

LYNCH, J.P.; WANG, Y.; LU, K. C.; HOU, T. C.; LOH, C., H. (2006). **Post-seismic damage assessment of steel structures instrumented with self-interrogating wireless sensors.** In: Proceedings of the 8th national conference on earthquake engineering (8NCEE). [CD-ROM]. 18, 22 August 2006, San Francisco. Oakland, CA: Earthquake Engineering Research Institute.

MALLAT, S. (1987). **A compact multiresolution representation: the wavelet model.** in Proc. IEEE Workshop Comput. Vision, Miami, FL.

MARDIA, K. V., KENT, J. T., AND BIBBY, J. M., (2003). **Multivariate Analysis,** Academic, London.

MAZARS, J. (1984). **Application de la mécanique de l'endommagement au comportement non linéaire et à la rupture du béton de structure.** Thèse de Doctorat d'État, Université Paris 6.

MEYER, Y. (1989). **Wavelets: Time-Frequency Methods and Phase Space,** eds. J.-M. Combes, A. Grossmann, & P. Tchamitchian (Berlin, Heidelberg: Springer), 21.

MISITI, M., MISITI, Y., OPPENHEIM, G., POGGI, J. M. (2002). **Wavelet toolbox.** Math Works. Inc., Natick, Massachusetts.

MISITI, M., MISITI, Y., OPPENHEIM, G., POGGI, J.-M. (2003), **Les ondelettes et leurs applications,** Hermes.

MONTGOMERY, D. C.; RUNGER, G. C. (2003) **Applied Statistics and Probability for Engineers**. 3<sup>o</sup> ed. Arizona State University, John Wiley & Sons, Inc.

MULLER, K. R.; MIKA, S.; RATSCH, G.; TSUDA, K.; SCHÖLKOPF, B. (2001). **An introduction to kernel-based learning algorithms**. IEEE Transactions on Neural Networks, 12(2):181–201.

MURAKAMI, S. (1981). **Effect on cavity distribution in constitutive equations of creep and creep damage**. In: EUROMECH Colloque on Damage Mechanics, Cachan, France.

MURAKAMI, S. (2012). **Continuum Damage Mechanics: A Continuum Mechanics Approach to the Analysis of Damage and Fracture**. Springer Science.

NAIR, K. K., KIREMIDJIAN, A. D. (2007). **Time Series Based Structural Damage Detection Algorithm Using Gaussian Mixtures Modeling**. Journal of Dynamic Systems, Measurement, and Control. 129, 285-293.

NILSSON, S. (1961). **The tensile strength of concrete determined by splitting tests on cubes**. RILEM Bull., 2(11): 63–67.

OVANESOVA, A. V. (2000). **Application of wavelet to crack detection in frame structures**. Tese de Doutorado da Universidade do Porto Rico, 235p.

OVANESOVA, A. V., SUÁREZ L. E. (2004). **Applications of wavelet transforms to damage detection in frame structures**. Journal Engineering Structures, Volume 26, Pages 39-49

PEETERS, B., MAECK, J., & DE ROECK, G. (2001). **Vibration-based Damage Detection in Civil Engineering: Excitation Sources and Temperature Effects**. Smart Materials and Structures, 10, 518-527.

PEREIRA, J., T., M., N. (2012). **Applicability of the Statistical Pattern Recognition Paradigm for Structural Health Monitoring of Bridges**. Dissertação de mestrado, Universidade Católica Portuguesa - Faculdade de Engenharia.

PETERSSON, P.E. (1980). **Fracture energy of concrete: Method of determination**, Cem. Conc. Res., 10: 78–89.

PITUBA, J. J. C. (1998). **Estudo e aplicação de modelos constitutivos para o concreto fundamentados na mecânica do dano contínuo**. Dissertação de mestrado, Universidade de São Paulo.

QIU, L.; YUAN, S.; CHANG, F.K.; BAO, Q.; MEI, H.F. (2014). **On-line Updating Gaussian Mixture Model for Aircraft Wing Spar Damage Evaluation under Time-Varying Boundary Condition**. Smart Mater. Struct., 23.

REDA-TAHA, M.; NOURELDIN, A.; ROSS, T. **A Fuzzy-aided Damage Recognition for Intelligent Structural Health Monitoring**, In: Boller, C., Staszewski, W.J.,

Proceedings of the 2nd European Workshop on Structural Health Monitoring, Munich, Germany, 2004.

REYNOLDS, D. A., (1995). **Speaker identification and verification using Gaussian mixture speaker models**, Speech Commun. 17, 91–108.

REYNOLDS, D. A., (1996). **Automatic speaker recognition using Gaussian mixture speaker models**, Lincoln Lab. J. 8, 173–192.

REYNOLDS, D. A., QUATIERI, T., F., DUNN, R., B., (2000). **Speaker Verification Using Adapted Gaussian Mixture Models**. M.I.T. Lincoln Laboratory, 244 Wood St., Lexington, Massachusetts 02420. Digital Signal Processing 10, 19–41.

ROSE, R. C., REYNOLDS, D. A. (1990). **Text-independent speaker identification using automatic acoustic segmentation**. In Proceedings of the International Conference on Acoustics, Speech, and Signal Processing, pp. 293–296.

RYTTER, A. (1993). **Vibrational Based Inspection of Civil Engineering Structures**. 196p. Tese (Doutorado em Engenharia de Estruturas) – Department of Building and Structural Engineering, University of Aalborg, Dinamarca.

SATPAL, S. B., KHANDARE, Y., GUHA, A., BANERJEE, S. (2013). **Structural health monitoring of a cantilever beam using support vector machine**. International Journal of Advanced Structural Engineering, 5:2, 1-7.

SCHWAIGHOFER, A. (2002). **SVM toolbox for Matlab**. <http://www.cis.tugraz.at/igi/aschwaig/software.html>.

SCHAPIRE, R., FREUND, Y., BARLETT, P., AND LEE, W. S. (1997). **Boosting the margin: a new explanation for the effectiveness of voting methods**. In Jr., D. H. F., editor, Proceedings of the International Conference on Machine Learning (ICML97), pages 322–330. Morgan Kaufmann.

SHARMA, S. (2008). **Application of Support Vector Machines for Damage Detection in Structures**. Dissertação de mestrado, Worcester Polytechnic Institute, EUA.

SIMO, J. C., JU, J. W. (1987). **Strain and stress based continuum damage models j. formulation**. Int. J. Solids & Structures, v. 23, pp. 821-840.

SMOLA, A. J., BARLETT, P., SCHÖLKOPF, B., AND SCHUURMANS, D. (1999). **Introduction to Large Margin Classifiers**, chapter 1, pages 1–28.

SMOLA, A., SCHÖLKOPF, B. (2000). **Kernel machines homepage**. [www.kernel-machines.org](http://www.kernel-machines.org).

SOARES, M., E., G. (2000). **Localização e quantificação de danos em estruturas por meio das suas características dinâmicas**. Dissertação de mestrado, Universidade de Brasília.

SOHN, H., FARRAR, C., HUNTER, N., & WORDEN, K. (2001). **Applying the LANL Statistical Pattern Recognition Paradigm for Structural Health Monitoring to Data from a Surface-effect Fast Patrol Boat**. Los Alamos National Laboratory Report: LA-13761-MS.

SOHN, H., FARRAR, C. R., HEMEZ, F. M., SHUNK, D. D., STINEMATES, D. W., NADLER, B. R. (2004). **A Review of Structural Health Monitoring Literature from 1996-2001**. Los Alamos National Laboratory: LA-13976-MS.

STRASER, E.G., KIREMIDJIAN, A.S. (1998). **Modular wireless damage monitoring system for structures**. Technical Report No. 128. John A. Blume Earthquake Engineering Center, Department of Civil and Environmental Engineering, Stanford University, Stanford, CA.

TIBSHIRANI, R., WALTHER, G., HASTIE, T., (2001). **Estimating the Number of Clusters in a Dataset via the Gap Statistic**. J. R. Stat. Soc. Ser. B (Methodology), 63(2), pp. 411–423.

TSCHEGG, E.K., LINSBAUER, H.N. (1986). **Prüfeinrichtung zur Ermittlung von Bruchmechanische Kennwerten (Testing procedure for determination of fracture mechanics parameters)**. Patentschrift No. A-233/86, Österreichisches Patentamt (in German).

TSCHOPE, C., WOLFF, M. (2009) **Statistical Classifiers for Structural Health Monitoring**. IEEE Sens. J., 1567–1576.

VAPNIK, V. N. (1995). **The Nature of Statistical Learning Theory**. Springer-Verlag.

VAN MIER, J. G. M. (2013). **Concrete Fracture, a multiscale approach**. CRC Press.

WANG, Y., LYNCH, J.P., AND LAW, K.H., (2006). **Wireless sensing, actuation and control with applications to civil structures**. In: I.F.C. Smith, ed. Intelligent Computing in Engineering and Architecture. Berlin, Germany: Springer.

ZAVALA, Y.; STÊNICO, J. W. G; LING, L., L. (2002). **Aplicação de Misturas Gaussianas na Classificação de Tráfego**. Universidade Estadual de Campinas.