UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Faculdade de Engenharia de Ilha Solteira
Departamento de Engenharia Mecânica
DEM/FEIS-UNESP

UTILIZAÇÃO DE TÉCNICAS NÃO DESTRUTIVAS NA IDENTIFICAÇÃO DE FALHAS ESTRUTURAIS E AVALIAÇÃO DOS EFEITOS DO AMORTECIMENTO NO PROCESSO DE AJUSTE DE MODELOS

João Antonio Pereira

1210001245

Tese apresentada à Faculdade de Engenharia de Ilha Solteira – FEIS/UNESP para obtenção do título de Livre Docente na disciplina Medições de Grandezas Mecânicas junto ao Departamento de Engenharia Mecânica

ILHA SOLTEIRA - SP
Dezembro - 2000

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Faculdade de Engenharia de Ilha Solteira
Departamento de Engenharia Mecânica
DEM/FEIS-UNESP

UTILIZAÇÃO DE TÉCNICAS NÃO DESTRUTIVAS NA IDENTIFICAÇÃO DE FALHAS ESTRUTURAIS E AVALIAÇÃO DOS EFEITOS DO AMORTECIMENTO NO PROCESSO DE AJUSTE DE MODELOS

João Antonio Pereira

1210001245

Proc. 040/2001-NRD 124/01
UNESP - "CAMPUS DE ILHA SOLTEIRA"
SERVIÇO TÉC. DE BIBLIOTECA E DOCUMENTAÇÃO
DATA DE CHEGADA 02/10/01 | DATA DE TOMBO 30/10/01
Aiza | Te. 1245
AQUISIÇÃO Doação autor R$ 10,00 | CLASSIFICAÇÃO

30500001 ENGENHARIA MECÂNICA

Tese apresentada à Faculdade de Engenharia de Ilha Solteira – FEIS/UNESP para obtenção do título de Livre Docente na disciplina Medições de Grandezas Mecânicas junto ao Departamento de Engenharia Mecânica

ILHA SOLTEIRA - SP

Dezembro - 2000

BCpIS - FEIS - UNESP

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Faculdade de Engenharia de Ilha Solteira
Departamento de Engenharia Mecânica
DEM/FEIS-UNESP

UTILIZAÇÃO DE TÉCNICAS NÃO DESTRUTIVAS NA IDENTIFICAÇÃO DE FALHAS ESTRUTURAIS E AVALIAÇÃO DOS EFEITOS DO AMORTECIMENTO NO PROCESSO DE AJUSTE DE MODELOS

João Antonio Pereira

1210001245

Proc. 040/2001-NPD 124/01
UNESP - "CAMPUS DE ILHA SOLTEIRA"
SERVIÇO TÉC. DE BIBLIOTECA E DOCUMENTAÇÃO
DATA DE CHEGADA 02/10/01 | DATA DE TOMBO 30/10/01
aiza | Te. 1245
AQUISIÇÃO doação autor R$ 10,00 | CATALOGAÇÃO

30500001 ENGENHARIA MECÂNICA

Tese apresentada à Faculdade de Engenharia de Ilha Solteira – FEIS/UNESP para obtenção do título de Livre Docente na disciplina Medições de Grandezas Mecânicas junto ao Departamento de Engenharia Mecânica

ILHA SOLTEIRA - SP

Dezembro - 2000

BCpIS - FEIS - UNESP

RESUMO

Este trabalho apresenta parte dos resultados das atividades técnico-científicas realizadas pelo docente nos últimos cinco anos nas áreas de identificação de falhas com base em vibrações e ajuste de modelos. A idéia do uso da mudança das propriedades de vibração para avaliação das condições de operação de sistemas mecânicos é bastante intuitiva. As mudanças observadas nessas propriedades ou nos parâmetros de vibrações estimadas a partir das variáveis medidas seriam utilizadas como indicação da ocorrência de falha. Neste trabalho são discutidas técnicas e alternativas para identificar e quantificar tais variações visando a definição de ferramentas Não Destrutivas de Avaliação de Falhas. É proposto a utilização de dados espectrais obtidos pela Transformada de Fourier e dados obtidos pela Transformada Wavelet para a definição de padrões falhas e posteriormente, Redes Neurais Artificiais (RNAs) são utilizadas para a identificação e reconhecimento desses padrões. Adicionalmente são discutidas também técnicas de ajuste de modelos, tanto para a geração de modelos de diagnósticos, como para a definição de padrões de comportamento do modelo intacto e do modelo com falha. Esses padrões são utilizados para geracao dos dados de treinamento das RNAs. Os princípios básicos que nortearam as atividades desenvolvidas são detalhadamente discutidos em cada capítulo e os fundamentos teóricos utilizados na formulação e solução dos problemas são apresentados de forma sintética. A potencialidade e as limitações das várias técnicas e propostas pesquisadas, tanto na área de identificação de falhas, como de ajuste de modelos são apresentados e discutidas nos artigos anexos. Neste texto são enumeradas apenas algumas conclusões de caracter geral extraídas dos artigos apresentados. E finalmente, são discutidos alguns aspectos a serem considerados em trabalhos futuros.

BCpIS - FEIS - UNESP

ABSTRACT

This work presents part of the results of the technical-scientific activities developed by the author in the last five years in the areas of damage detection based on vibrations measurements and finite element model updating. The idea of the use of changes in the vibration properties for evaluation of the conditions of operation of mechanical systems is quite intuitive. The changes observed in those properties or in the parameters estimated from the vibrations monitoring would be used as indication of the occurrence of damage. In this work techniques and alternatives are discussed to identify and to quantify such variations aiming at defining of Non Destructive Evaluation tools (NDE). It proposes the use of spectral data obtained by the Fourier Transform and data obtained by Wavelet for the definition of patterns recognition and later on, it uses Artificial Neural Networks (ANNs) for the identification and recognition of those patterns. Additionally, is also discussed model updating techniques for the generation of diagnostic models as well as for the definition of patterns which will be used for the training of the neural network. The basic principle that driven the developed activities are discussed thoroughly in each chapter and the theoretical fundaments used in the formulation and solution of the problems, they are presented in a synthetic way. The potentiality and limitations of some techniques and proposes investigated as in the area of damage detection as the model updating they are discussed in the enclosed papers. In this text just some general conclusions, extracted from the presented work are enumerated. And finally, it discusses some aspects they would be considered in future works.

BCDIS - FEIS - UNESP

AGRADECIMENTOS . . .

. . . Aos professores e amigos do Departamento de Engenharia Mecânica da UNESP - Ilha Solteira Antônio E. Turra e Vicente Lopes Jr., co-autores de parte dos artigos que compõe este trabalho, pela contribuição efetiva para o desenvolvimento das minhas atividades técnico-científicas ao longo dos últimos anos;

. . . aos alunos e amigos do Curso de Graduação e Pós-graduação do DEM/FEIS-UNESP Adriano, Alex, Daniela, Edimilson, Edson e Silmara co-autores em alguns dos artigos apresentados no texto;

. . . aos parceiros e amigos da Gehard-Mercator-Universität Duisburg, Al., Professor H. H. Müller-Slany e seu assistente, Eng. F. Bruzel pelo desenvolvimento de atividades conjuntas, incluindo alguns artigos publicados em co-autoria. Gostaria de registrar também um especial agradecimento ao professor Hans I. Weber da PUC-Rio que, além de co-autor de vários dos trabalhos aqui mostrados, tem sido o grande incentivador do grupo de Dinâmica do DEM/FEIS-UNESP;

. . . ao Departamento de Engenharia Mecânica da Faculdade de Engenharia de Ilha Solteira, especialmente à Área de Mecânica dos Sólidos pelo apoio incondicional;

. . . à todas as pessoas que direta ou indiretamente contribuíram para a realização deste trabalho.

BCoIS - FEIS - UNESP

ÍNDICE

CAPÍTULO 1 – INTRODUÇÃO 1

CAPÍTULO 2 - LOCALIZAÇÃO DE FALHAS COM BASE NO AJUSTE DE MODELO 4

2.1 - INTRODUÇÃO 4

2.2 - AJUSTE DE MODELOS COM BASE NAS FRF(S) 5

2.3 - AJUSTE DE MODELOS POR PROCESSOS DE OTIMIZAÇÃO MULTI-CRITÉRIO 11

2.4 - ALGORÍTMO DE DETECÇÃO DE FALHA 14

2.5 - RESULTADOS 16

CAPÍTULO 3 - LOCALIZAÇÃO DE FALHAS UTILIZANDO REDES NEURAIS 17

3.1 - INTRODUÇÃO 17

3.2 - ANÁLISE DE SINAIS 18

3.2.1 - Análise de Sinais Estacionários 18

3.3 - ANÁLISE DE SINAIS NÃO-ESTACIONÁRIOS 22

3.3.1 - Transformada de Fourier com Janela 22

3.4 - TRANSFORMADA WAVELET 24

3.4.1 - Famílias Wavelets 25

3.4.2 - Conceito de Escala 26

3.4.3 - Relação de Incerteza de Heisenberg 27

3.4.4 - Transformada Wavelet Contínua 29

3.4.5 - Transformada Wavelet Discreta 30

3.5 - REDES NERUAIS 34

3.5.1 - Redes Neruais Artificiais 36

3.5.2 - Neurônio Artificial 38

3.5.3 - Redes Neurais de Simples Camada 40

3.5.4 - Redes Neurais Multi-Camadas 41

3.5.5 - Treinamento das Redes Neurais 42

3.5.6 - Regra Delta 43

3.6 - RESULTADOS 45

BCpIS - FEIS - UNESP

CAPÍTULO 4 - AJUSTE DE MODELOS USANDO FRF(s) AMORTECIDAS 46

4.1 - INTRODUÇÃO 46

4.2 - AMORTECIMENTO EM DINÂMICA ESTRUTURAL 47

4.2.1 - Modelos de Amortecimento Proporcional 49

4.2.2 - Construção da Matriz de Amortecimento 51

4.2.3 - Amortecimento Não proporcional 53

4.3 - AMORTECIMENTO NO AJUSTE DE MODELOS 56

4.3.1 - Correção de Parâmetros 56

4.3.2 - Análise de Sensibilidade 59

4.3.2 - Ajuste para o amortecimento Não Proporcional 61

4.4 - RESULTADOS 63

CAPÍTULO 5 - CONCLUSÃO 64

ANEXO 66

Capítulo 1 -

INTRODUÇÃO

A idéia do uso da mudança das propriedades de vibração para avaliação das condições de operação de sistemas mecânicos é bastante intuitiva e pode ser perfeitamente interpretada como uma variante do diagnóstico médico para a avaliação do estado de saúde de um paciente. Neste caso, o paciente seria uma máquina ou um equipamento qualquer submetido às suas condições de operação e as mesmas premissas usadas no caso do diagnóstico médico são aplicadas para avaliação do estado de funcionamento do equipamento. O sistema é monitorado através de medições das variáveis de interesse. As mudanças observadas nessas variáveis ou nas propriedades de vibrações estimadas a partir dessas variáveis são usadas como indicação da ocorrência de dano (falha) no sistema. Portanto, a identificação de falhas com base em medidas de vibrações pode ser interpretado como um problema de reconhecimento de padrões, tanto para o sistema intacto, como para os vários padrões definidos para cada condição de falha.

Uma das grandes dificuldades encontradas nesse caso é a definição adequada dos padrões de falha a partir das variáveis monitoradas, que podem ser por exemplo as respostas do sistema. Na maioria dos casos, a resposta medida poderá conter milhares de informações (dados) que devem ser "separados" de forma adequada, ressaltando as informações essenciais para caracterização do estado de falha do sistema e eliminando as demais. Por exemplo, uma função de resposta de vibração pode ser medida com centenas ou mesmo milhares de pontos sendo que muitos destes contêm informações redundantes ou representam informações espúrias (ruído). Portanto, faz-se necessário um pré-processamento das informações brutas obtidas no monitoramento, visando identificar algumas características que levam à definição de padrões representativos, contendo apenas as informações relevantes para expressar o real estado de funcionamento do sistema.

unesp

A principal meta neste caso é evitar as conseqüências de uma falha imprevisível visto que a ocorrência de falha é uma condição bastante provável durante a operação de um sistema. A identificação de falhas no estágio inicial permite minimizar os custos e, principalmente, aumentar a segurança e confiabilidade nos sistemas.

As falhas estruturais em máquinas e equipamentos ocorrem devido a vários fatores tais como excesso de carga, desgaste, corrosão, fadiga, afrouxamento de uniões aparafusadas, trincas, condições de operação precárias ou mesmo a combinação de vários desses fatores. Independente da origem, na grande maioria dos casos, falhas estruturais provocam variações nos parâmetros espaciais do modelo tais como redução da rigidez estrutural, redução de massa e aumento do amortecimento alterando, consequentemente, o comportamento do modelo. Essas mudanças nos parâmetros espaciais irão refletir diretamente nos parâmetros dinâmicos do modelo, funções de resposta, freqüências de ressonância, razão de amortecimento e modos próprios. Portanto, as propriedades dinâmicas podem ser usadas para avaliar o estado de falha da estrutura. O uso de técnicas Não-destrutivas para o monitoramento e identificação de falha estrutural baseado em medidas de vibrações utilizam este fato para avaliar o estado de funcionamento do equipamento.

A literatura corrente apresenta uma vasta gama de método de detecção e localização de falhas com base na condição de vibração do sistema. Os diferentes tipos de falhas juntamente com os algorítmos utilizados para identificar sua ocorrência e efeitos provocados no sistema levam a diferentes classificações e categorias de métodos de identificação de falhas, métodos diretos, métodos inversos, métodos baseados em modelos (Model Based), identificação linear e não linear.

Entretanto, uma classificação sistemática dos tipos de falhas e métodos de identificação nos parece difícil dada a diversidade da origem e das conseqüências destas, bem como dos objetivos da identificação. Estes podem ser apenas para determinarem se existe falha no sistema ou uma avaliação mais ampla que envolve, inclusive, a predição do tempo de vida que o equipamento poderá operar em condições segura. Dentre as diversas classificações dos métodos de identificação, a que nos parece mais abrangente é a divisão dos métodos em quatro níveis englobando os vários aspectos da manutenção dos sistemas mecânicos. O nível 1 determina a existência de falha na estrutura, o nível 2 engloba o anterior

cm 1 2 3 4 5 6 7 8 unesp 12 13 14 15 16 17 18

mais a localização geométrica da falha, o nível 3 engloba o anterior mais a quantificação da intensidade da falha e finalmente o nível 4 que engloba o anterior juntamente com a predição da vida útil da estrutura.

Neste trabalho são discutidas várias técnicas entretanto as mesmas estão restritas basicamente aos níveis 1, 2 e 3. O nível 4 demanda a utilização de métodos e algoritmos de identificação consolidados e, mais ainda, a sua aplicação envolve o desenvolvimento de uma metodologia específica para cada caso em particular. Essa será uma etapa seguinte, a ser desenvolvida a partir da consolidação das várias propostas discutidas e apresentadas neste trabalho. Um outro tópico abordado neste trabalho é a utilização de técnicas de ajuste na área de modelagem de estruturas mecânicas visando a obtenção de modelos analíticos-numéricos representativos a partir de dados de testes experimentais. O trabalho pode ser dividido sem perda de generalidade em duas partes, uma primeira etapa voltada para o detecção e localização de falhas com base em medidas de vibrações e uma segunda etapa que versará sobre a inclusão dos efeitos de amortecimento no processo de ajuste de modelos com base nas FRF(s). Em ambos os casos, os conceitos e o desenvolvimento teórico de cada método são apresentados de forma sintética e os resultados obtidos, principal parte deste trabalho, estão nos 15 artigos técnicos anexos.

Esses artigos são apresentados na forma original que foram publicados ou encaminhados para publicação. Deve-se salientar que os mesmos foram desenvolvidos em cooperação com professores e alunos do curso de graduação e pós-graduação do Departamento e Engenharia Mecânica da UNESP - Ilha Solteira e instituições parceiras, PUC-Rio e Gehard-Mercator-Universität Duisburg, Alemanha. Essa interação permitiu o docente estabelecer uma relação frutífera tanto com os alunos e professores da FEIS/UNESP como os professores das demais instituições, ampliando os seus conhecimento através de novos contatos e visitas técnicas-científicas em outras instituições.

cm 1 2 3 4 5 6 7 8 unesp 12 13 14 15 16 17 18

Capítulo 2 -

LOCALIZAÇÃO DE FALHAS COM BASE NO AJUSTE DE MODELO

2.1 - INTRODUÇÃO

Os métodos de ajuste de modelo, no sentido mais convencional, tem sido usados para melhorar a qualidade dos resultados do modelo numérico-analítico tendo como meta os resultados obtidos em testes experimentais. O processo compara o modelo experimental com o modelo analítico através da correlação dos parâmetros modais, e quando a concordância não é satisfatória, o modelo analítico é corrigido com base nos dados experimentais. Os algoritmos de ajuste procuram identificar, com base nos dados medidos, variações dos parâmetros espaciais do modelo analítico que minimizam a diferença entre os modelos analítico e experimental. Neste contexto, a aplicação do conceito de atualização de modelo para a investigação da integridade dos componentes estruturais de sistemas mecânicos mostra-se bastante atraente, visto que a identificação das variações dos parâmetros necessários para minimizar a diferença entre os modelos podem levar a uma avaliação das condições de falha do sistema.

Comparando os dados do modelo intacto com os dados do modelo em operação, a integridade dos componentes do sistema pode ser avaliada identificando os parâmetros responsáveis por eventuais mudanças no comportamento do modelo. Os danos estruturais introduzem mudanças no comportamento da estrutura e essas mudanças podem ser observadas através da deterioração da correlação inicial dos modelos. Consequentemente, o acompanhamento da correlação dos modelos poderá fornecer indicações da existência de mudanças nos parâmetros estruturais do sistema. A estimativa da mudança dos parâmetros necessária para ajustar o modelo analítico intacto em relação ao modelo experimental

unesp

danificado permite caracterizar o estado de deterioração da estrutura, incluindo, em alguns casos, uma avaliação quantitativa do dano.

Uma revisão detalhada das técnicas de ajuste de modelos existente e das atividades de pesquisa correntes na área, indicam várias possibilidades de utilização destas técnicas para o desenvolvimento de ferramentas Não Destrutivas de Avaliação de Falha (NDAF). Entretanto, a aplicabilidade das técnicas de ajuste de modelos para a identificação de falhas ainda é insipiente e está restrita praticamente a testes de laboratórios. Objetivando conhecer melhor as limitações e potencialidades destas técnicas, o autor vem estudando duas possibilidade de aplicação de ajuste de modelos para a identificação de falhas. Uma abordagem utilizando ajuste de modelos com base nas FRF(s) medidas e outra baseada em um processo hierárquico de otimização.

Em ambos os casos, a metodologia proposta é fundamentada no ajuste dos próprios parâmetros físicos e geométricos do modelo, a combinação do uso de **parâmetros físicos e/ou geométricos** diretamente como **parâmetros de atualização** e a facilidade na definição dos **parâmetros de atualização em nível de elementos ou macro regiões** conferem à proposta uma característica importante com relação a interpretação física da falha. Aliado a isto, tem se o fato das funções de resposta serem medidas diretas e de fácil monitoramento o que torna a metodologia bastante atraente. A seguir são apresentados os conceitos básicos envolvidos nos dois processos. Os resultados obtidos foram discutidos e apresentados na forma de artigos (anexo).

2.2 - AJUSTE DE MODELOS COM BASE NAS FRF(S)

Nesta proposta o ajuste é discutido em termos das FRF(s), os algorítmos são iterativos sendo que a variações dos parâmetros de atualização são calculadas com base na sensibilidade das matrizes de rigidez e massa do modelo. Para modelos compatíveis, o método expressa a diferença entre o modelo analítico e o experimental através de um vetor balanço de força, derivado a partir da equação dinâmica (sem amortecimento) do modelo.

$$\left([K]-(\omega_k)^2[M]\right)\{X(\omega_k)\}=\{F(\omega_k)\} \qquad (2.1)$$

unesp

A discrepância entre os modelos analítico e experimental é expressa diretamente através da diferença entre a força de excitação atuando no modelo analítico e a força atuando no modelo experimental. Neste caso, o vetor erro é definido como sendo a diferença entre a força de excitação experimental $\{F^X\}$ e a força analítica $\{F^A\}$ necessária para produzir uma resposta analítica $\{X^A\}$ idêntica à resposta experimental $\{X^X\}$, ou seja $\{X^X\} = \{X^A\}$.

$$\{\varepsilon\} = \{F^X\} - \{F^A\} \tag{2.2}$$

Reescrevendo a expressão acima em termos da matriz de rigidez dinâmica $[Z]$, matriz de receptância $[H]$ e substituindo a resposta analítica $\{X^A\}$ pela experimental $\{X^X\}_j$, define-se o vetor erro a partir das variáveis do modelo analítico e dos parâmetros medidos diretamente no sistema.

$$\{\varepsilon\} = \{I\}_j - [Z^A]\{H^X\}_j \tag{2.3}$$

onde: $\{H^X\}_j$ - j-ésima coluna da matriz de FRF(s);
$\{I\}_j$ - vetor nulo, exceto para a j-ésima componente, que é igual a 1.

Neste caso, o resíduo $\{\varepsilon\}$ que descreve a discrepância dos modelos pode ser interpretada como um função da matriz de rigidez dinâmica $[Z^A]$, que contém as informações dos $\{p\}$ - parâmetros físicos e geométricos do modelo analítico e da receptância $\{H^X\}_j$ medida.

$$\{\varepsilon\} = f\left([Z^A(\{p\})], \{H^X\}\right) \tag{2.4}$$

Para uma perfeita correlação entre os modelos o vetor resíduo deve ser nulo. No entanto, em situações práticas, os dados analíticos e experimentais não satisfazem a equação (2.4) pois os modelos não são perfeitamente correlacionados ou seja, $\{\varepsilon\} \neq \{0\}$. As técnicas de ajuste de modelos de forma genérica, buscam identificar eventuais correções dos parâmetros $\{p\}$ que minimizam a diferença entre os modelos. Portanto, neste caso, a solução do problema consiste em identificar n_p mudanças de parâmetros as quais tornam a diferença entre os dados dos modelos próxima de zero.



$$\{\varepsilon\} = f\left(\left[Z^A\left(p_1 + \Delta p_1, p_2 + \Delta p_2, \quad \ldots \quad , p_{np} + \Delta p_{np}\right)\right], \left\{H^X\right\} \right) \cong \{0\} \qquad (2.5)$$

Em geral, os critérios usados para comparar os modelos levam a um conjunto de equações não lineares em relação aos parâmetros selecionados para atualização, $\{p^u\}$, os chamados parâmetros de ajuste. Dependendo do tipo de parâmetros selecionados, a solução das equações torna-se muito complexa ou pode não existir. A linearização destas equações, para a maioria dos sistemas físicos, é uma suposição válida nas faixas de freqüências de interesse para análises de vibração. Assim, um solução aproximada para o problema pode ser estudada linearizando-se a equação do resíduo (expansão de Taylor) em relação aos parâmetros de atualização $\{p^u\}$. A equação linearizada, após algumas manipulações algébricas convenientes é dada pela expressão (2.6).

$$\{\tilde{\varepsilon}(\omega_k)\} = \sum_{i=1}^{np} \left(\left[H_k^A\right]^0 \frac{\partial\left[Z_k^A(p)\right]}{\partial p_i} p_i \left\{H_k^X\right\}_j \frac{\Delta p}{p_i} \right) + \left\{H_k^X\right\}_j - \left\{H_k^A\right\}_j^0 \qquad (2.6)$$

onde: $\{\tilde{\varepsilon}(\omega_k)\} = \left[H_k^A\right]^0 \left\{\varepsilon^{lin}(\omega_k)\right\}$;

$\left[H_k^A\right] = \left(\left[Z_k^A\left(p^0\right)\right]\right)^{-1}$;

$\left\{\varepsilon^{lin}(\omega_k)\right\}$ - resíduo linearizado;

p_i^0 - valor inicial dos parâmetros de atualização;

ω_k - freqüência de ajuste;

np - número de parâmetros de atualização.

A correção do modelo analítico é feita minimizando a diferença entre os dados dos modelos (analítico e experimental) diretamente em relação aos próprios parâmetros físico e geométricos do modelo ao invés dos coeficientes das matrizes de rigidez e massa. Isto torna claro e simples a interpretação física da variação dos parâmetros ajustados durante o processo, levando à identificação da falha. O conjunto dos possíveis parâmetros de atualização é definido em função das características do tipo de elemento finito utilizado na modelagem. A tabela 2.1 mostra alguns tipos de elementos e respectivos parâmetros $\{p\}$ necessários para a definição do elemento, esses parâmetros são definidos como os possíveis parâmetros de ajuste.

A seleção dos parâmetros a serem ajustados, dentre o conjunto dos possíveis parâmetros de atualização, é feita pelo usuário em nível de elemento ou macro região do modelo. Estes parâmetros, para algumas classes de elementos, são funções lineares em relação as matrizes de rigidez e massa, e a sensibilidade da matriz de rigidez dinâmica em relação a eles pode ser explicitada analiticamente. Para uma formulação mais geral, incluindo diferente tipos de elementos, a formulação explícita torna-se complexa ou pode não ser possível em alguns casos. Portanto, a sensibilidade dos elementos ou regiões em relação aos parâmetros é avaliada numericamente.

Tabela 2.1: Típicos de Elementos Finitos e Respectivos Parâmetros

Tipo de elemento finito	**Matriz de massa**	**Matriz de rigidez**
Barra	A, ρ	E, A
Viga	A, I_p	A, E, I_x, I_y, I_z, ν
placa	t, ρ	E, t, ν
Massa	m_x , m_y, m_z,	
Mola		k_x, k_y, k_z,

Os parâmetros de ajuste $\{p^u\}$ podem estar relacionados diretamente com os próprios elementos ou macro regiões do modelo. A sensibilidade do modelo com relação à variação de um parâmetro p_i é calculada a partir da variação da matriz do elemento (ou região) ao qual o parâmetro esta associado em relação à matriz do modelo. Isso pode ser interpretado como sendo uma variação local o que facilitaria sua associação com os parâmetros físicos do modelo.

Um outro aspecto importante a ser observado é que a correção dos parâmetros durante o processo de atualização não afeta a conectividade dos elementos e a matriz de conexão permanece inalterada, ou seja, as matrizes atualizadas mantêm as mesmas formas originais. Ao final do processo de ajuste as matrizes de massa e rigidez mantêm a conectividade, propriedades de simetria, esparcialidade, etc.. Portanto, o sucesso do ajuste baseado na atualização elemento por elemento pode responder, através da comparação do modelo original

com o modelo ajustado, duas questões fundamentais dos métodos de localização de falhas, i.e., quais são as discrepâncias entre os modelos e onde as mesmas estão localizadas.

CORREÇÃO DE PARÂMETROS

As equações de ajuste são obtidas utilizando a aproximação dos mínimos quadrados para a solução da equação do resíduo (2.6). Para uma freqüência de atualização ω_k, a minimização da equação do resíduo leva a um conjunto de *n* equações de ajuste em relação aos n_p parâmetros selecionados. Em termos da matriz de rigidez dinâmica e matriz de receptância tem-se:

$$\sum_{i=1}^{np}\left(\left[H_k^A\right]^t \frac{\partial\left[Z_k^A\{p\}\right]}{\partial p_i}\left\{H_k^X\right\}_j \Delta p_i\right)=\left\{\Delta H_k\right\}_j \tag{2.7}$$

$$\begin{bmatrix} & & \\ \{S_k\}_1 & \cdots & \{S_k\}_{np} \\ & & \end{bmatrix}\begin{Bmatrix} \Delta p_1 \\ \vdots \\ \Delta p_{np} \end{Bmatrix}=\begin{Bmatrix} \Delta h_{k,1} \\ \vdots \\ \Delta h_{k,n} \end{Bmatrix}_j \tag{2.8}$$

onde:
$$\{S_k\}_i=\left[H_k^A\right]\frac{\partial\left[Z_k^A\{p\}\right]}{\partial p_i}\left\{H_k^X\right\}$$

$$\Delta p_i = p_i - p_i^0$$

$$\left\{\Delta H_k\right\}_j=\left\{H_k^A\right\}_j^0-\left\{H_k^X\right\}_j$$

Em uma forma mais compacta,

$$\left[S_k\right]\left\{\Delta p\right\}=\left\{\Delta H_k\right\}_j \tag{2.9}$$

A equação (2.9) é válida para o ponto de freqüência de atualização ω_k, em aplicações práticas, o que ocorre geralmente é a seleção de um conjunto de pontos de freqüência e a equação é avaliada para cada ponto de freqüência selecionado. Isto define um conjunto

simultâneo de equações de ajuste, sendo que as freqüências de ajuste devem ser selecionadas de forma à prover uma matriz de receptância de referência, contendo de uma forma balanceada, todas as informações relevantes contidas na matriz de receptância medida na faixa de freqüência de análise. No entanto, a seleção de um conjunto ótimo de freqüência de ajuste não obedece um critério sistemático de seleção como discutido nos artigos apresentados. O conjunto de equações de atualização para um conjunto de n_k freqüência é dado pela expressão (2.10)

$$\left[S \right] \{\Delta p\} = \left\{ \Delta H \right\}_j \tag{2.10}$$

onde: $[S]^T = \left[\left[S_1 \right] \quad \left[S_2 \right] \quad \ldots \left[S_k \right] \quad \ldots \quad \left[S_{nk} \right] \right]$

$\{\Delta H\}_j^T = \left\{ \left\{ \Delta H_1 \right\}_j \quad \left\{ \Delta H_2 \right\}_j \quad \ldots \quad \left\{ \Delta H_k \right\}_j \quad \ldots \quad \left\{ \Delta H_{nk} \right\}_j \right\}$

$\{\Delta p\}^T = \left\{ \Delta p_1 \; \Delta p_2 \quad \ldots \quad \Delta p_{np} \right\}$

n_k - número de freqüências de atualização.

A expressão (2.10) representa um sistema superdeterminado de n_s equações, onde o número de linhas de [S] é n_k vezes a ordem n do modelo, i.e., $n_s = (n_x n_k)$ e o número de colunas é igual ao número de parâmetros de atualização n_p . Problemas numéricos são esperados na solução deste sistema de equações uma vez que a matriz [S] pode ser rank deficiente, tornando o produto $[S]^T[S]$ singular. Esses problemas são reduzidos utilizando o teorema da decomposição de valores singulares (SVD), que ajuda filtrar eventuais singularidades, inclusive quantificar a noção de rank deficiente da matriz. A sensibilidade da solução do problema de mínimos quadrados é examinada pelo condicionamento da matriz [S]. Para a norma *2-norm,* o número de condição de [S] é definido por

$$\kappa(S) = \frac{\sigma_1(S)}{\sigma_r(S)} \tag{2.11}$$

onde: $\sigma_1(S)$, $\sigma_r(S)$ - maior e menor valor singular de [S];

r - rank de [S].

Valores elevados de $\kappa(S)$ significam um mal condicionamento da matriz [S]. O teste do condicionamento da matriz de referência busca a definição de um conjunto ótimo de pontos de freqüência, visto que o condicionamento da matriz esta diretamente relacionado com as freqüências de ajuste selecionadas.

2.3 - AJUSTE DE MODELOS POR PROCESSOS DE OTIMIZAÇÃO MULTI-CRITÉRIO

A identificação de falha do sistema, neste caso, é obtida a partir de um modelo de diagnóstico gerado através de um processo de otimização com restrições, cuja solução é dada por uma estratégia de escalonização hierárquica. A geração do modelo de diagnóstico busca representar o modelo inicial do sistema por um modelo reduzido equivalente capaz de descrever adequadamente as suas principais características estáticas e dinâmicas. Este novo modelo, equivalente ao modelo original, será utilizado para a avaliação das condições de funcionamento do sistema. O modelo adaptado deve ser um modelo estrutural, substancialmente reduzido, e ao mesmo tempo acurado, i.e., o modelo adaptado deve apresentar as propriedades dinâmicas do sistema original com um alto nível de acurácia na faixa de freqüência de interesse.

A vantagem desta técnica é que ela permite ajustar as propriedades do modelo em relação às propriedades medidas no sistema real com um alto grau de precisão. O processo de adaptação utilizado na geração do modelo de diagnóstico é formulado em termos de um problema de otimização multi-critério e as variáveis de projeto são definidas a partir da solução do problema. Os componentes da função objetiva são expressões de erros formulados em termos das propriedades físicas do sistema original *S* e do modelo de diagnóstico *D,* ou seja, do modelo equivalente.

As variáveis de projeto para o modelo de diagnóstico $\mathbf{x} = \{x_1, \ldots . x_n\}^T$ são definidas a partir das propriedades do modelo original. No caso de elementos de viga, os componentes do vetor das variáveis de projeto são a massa dos elementos, as coordenadas dos nós e a rigidez de cada elemento. Os componentes da função objetiva $\boldsymbol{f}(\mathbf{x})$ são expressões de erro $\varepsilon_i(\mathbf{x})$, definidas a partir da diferença entre as propriedades físicas do modelo de diagnóstico $p_i^{\mathrm{D}}(\mathbf{x})$ e

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

do sistema real $\boldsymbol{p}_i^S(\mathbf{x})$. Esses componentes são minimizados em relação as variáveis de projeto.

As expressões erro para as *nv*-variáveis de projeto são definidas pelas expressoes (2.12) a (2.14).

$$\varepsilon_i(\mathbf{x}) = \sum_{j=1}^{m} \left| 1 - \frac{p_j^D(x)}{p_j^S} \right|, \qquad i = 1, ..., 4 \tag{2.12}$$

$$\varepsilon_5(\mathbf{x}) = \sum_{j=1}^{nm} \left(1 - \frac{\{\phi\}_j^D(x)^T \{\phi\}_j^S}{\left|\{\phi\}_j^D(x)^T\right| \left|\{\phi\}_j^S\right|} \right) \tag{2.13}$$

$$\varepsilon_6(\mathbf{x}) = \sum_{i=1}^{k} \sum_{j=1}^{nv} \left| H_j^S - H_j^D(\omega_i, x) \right|, \tag{2.14}$$

onde: *nm* – número de modos;

nv – número de variáveis de projeto;

k – número de pontos de freqüência.

A equação (2.12) descreve o erro a partir da massa total, posição do centro de massa dos elementos, tensor de inércia dos elementos e frequências naturais. Devido as características de não linearidade do problema é utilizado uma estratégia de solução hierárquica escalonada para o problema. Os elementos da função objetiva são separados em quatro diferentes grupos e resolvido inicialmente para o grupo 1. Uma vez calculado os parâmetros que minimizam o problema, a solução obtida é imposta como restrição e o problema e resolvido para o segundo grupo e assim sucessivamente.

$$\boldsymbol{f}(\mathbf{x}^D) \Rightarrow \mathbf{s}\left(\boldsymbol{f}\left\{\varepsilon\left(x^D\right)\right\}\right) = \begin{Bmatrix} s_1\left[\varepsilon_1\left(x^D\right), \varepsilon_2\left(x^D\right)\varepsilon_3\left(x^D\right)\right] \\ s_2\left[\varepsilon_4\left(x^D\right)\right] \\ s_3\left[\varepsilon_5\left(x^D\right)\right] \\ s_4\left[\varepsilon_6\left(x^D\right)\right] \end{Bmatrix} \tag{2.15}$$

unesp

A solução do problema agora é calculada em quatro diferentes etapas utilizando o algorítmo de otimização SQP incluído na *NAG library*. Os parâmetros de projetos do modelo de diagnóstico são adaptadas em relação as propriedades do modelo real seguindo a estratégia mostrada abaixo. Cada parâmetro pode variar no intervalo definido por x_L e x_U.

1 passo: ajuste da massa

$$\min_{x \in \Sigma} \; s_1\left\{\boldsymbol{f}\left(\varepsilon_1\left(x^D\right), \varepsilon_2\left(x^D\right), \varepsilon_3\left(x^D\right)\right)\right\}$$

$$s_1\left\{\boldsymbol{f}\left(\varepsilon_1\left(x^D\right), \varepsilon_2\left(x^D\right), \varepsilon_3\left(x^D\right)\right)\right\} = \sum_{i=1}^{3} \varepsilon_i$$

$$\Sigma := \left\{x^D \in \Re^n \,\middle|\, x_L \le x^D \le x_U\right\}$$

2 passo: ajuste das freqüências de interesse

$$\min_{x \in \Sigma} \left\langle s_2\left\{\boldsymbol{f}\left(\varepsilon_4\left(x^D\right)\right)\right\} \,\middle|\, h(x^D) = 0\right\rangle$$

$$s_2\left\{\boldsymbol{f}\left(\varepsilon_4\left(x^D\right)\right)\right\} = \sum_{j=1}^{nm} \varepsilon_4\left(\omega_j\right)$$

$$\Sigma := \begin{Bmatrix} \left\{x^D \in \Re^n \,\middle|\, x_L \le x^D \le x_U\right\} \\ h_1(x^D) = \varepsilon_1\left(x^D\right) - \Delta = 0 \\ h_2(x^D) = \varepsilon_2\left(x^D\right) - \Delta = 0 \\ h_3(x^D) = \varepsilon_3\left(x^D\right) - \Delta = 0 \end{Bmatrix}$$

3 passo: ajuste dos modos de interesse

$$\min_{x \in \Sigma} \left\langle s_3\left\{\boldsymbol{f}\left(\varepsilon_5\left(x^D\right)\right)\right\} \,\middle|\, h(x^D) = 0\right\rangle$$

$$s_3\left\{\boldsymbol{f}\left(\varepsilon_5\left(x^D\right)\right)\right\} = \sum_{j=1}^{nm} \varepsilon_5\left(\{\phi\}_j\right)$$

$$\sum := \begin{Bmatrix} \{x^D \in \Re^n \mid x_L \le x^D \le x_U\} \\ h_1(x^D) = \varepsilon_1(x^D) - \Delta = 0 \\ h_2(x^D) = \varepsilon_2(x^D) - \Delta = 0 \\ h_3(x^D) = \varepsilon_3(x^D) - \Delta = 0 \\ h_4(x^D) = \varepsilon_4(\omega_1) - \Delta = 0 \\ \vdots \\ h_{k+3}(x^D) = \varepsilon_4(\omega_k) - \Delta = 0 \end{Bmatrix}$$

4 passo: ajuste das FRF(s)

$$\min_{x \in \sum} \left\langle s_4\left\{f\left(\varepsilon_6\left(x^D\right)\right)\right\} \mid h(x^D) = 0 \right\rangle$$

$$s_4\left\{f\left(\varepsilon_6\left(x^D\right)\right)\right\} = \sum_{i=1}^{k}\sum_{j=1}^{nv}\left|H_j^S - H_j^D(\omega_i, x)\right|,$$

$$\sum := \begin{Bmatrix} \{x^D \in \Re^n \mid x_L \le x^D \le x_U\} \\ h_1(x^D) = \varepsilon_1(x^D) - \Delta = 0 \\ h_2(x^D) = \varepsilon_2(x^D) - \Delta = 0 \\ h_3(x^D) = \varepsilon_3(x^D) - \Delta = 0 \\ h_4(x^D) = \varepsilon_4(\omega_1) - \Delta = 0 \\ \vdots \\ h_{k+3}(x^D) = \varepsilon_4(\omega_k) - \Delta = 0 \end{Bmatrix}$$

As propriedades ajustadas em cada passo são fixadas para os próximos passos através de condições adicionais de restrições (equations of equality) e o processo é resolvido novamente.

2.4 - Algorítmo de Detecção de Falha

Dois algorítmos similares baseados na variação dos parâmetros ajustados, na diferença das freqüências e na correlação dos modos (MAC-valores) são propostos. Ambos assumem que uma **falha estrutural** leva à uma **redução dos valores das propriedades físicas e ou**

geométricas (área seccional, momento de inércia, massa etc.) na **região com falha**. Na primeira proposta, chamada análise elemento por elemento, o algoritmo compara, de forma iterativa, os parâmetros ajustados de cada elemento com os parâmetros do modelo original. Aqueles elementos que apresentam um redução dos valores dos parâmetros atualizados são elementos provavelmente avariados. Consequentemente, os elementos caracterizados por uma redução acentuada do valor dos parâmetros de atualização são classificados como os prováveis elementos com falha. Aqueles elementos cujos parâmetros aumentam durante o processo de atualização são tratados como elementos sem falha.

Se o processo de atualização não é satisfatório, i.e., grandes diferenças entre as freqüências de ressonância e baixos valores dos MAC-valores os elementos não danificados (elementos cujos parâmetros de atualização aumentaram) são removidos do conjunto de parâmetros de atualização inicial, e o processo é repetido para um novo conjunto de parâmetros. Neste caso, o processo atualiza apenas os parâmetros dos prováveis elementos danificados, buscando obter uma correlação satisfatória entre os modelos, ou seja, diferença relativa entre as freqüências suficientemente pequenas e MAC-valores próximos da unidade. No caso onde a correlação dos modelos continua não satisfatória, mesmo após a atualização do modelo, significa que a metodologia não conseguiu localizar a contento a região com falha.

Na segunda aproximação, a estrutura é subdividida em grupos de elementos ou macro-regiões, e os grupos de elementos são atualizados independentemente. Neste caso, os parâmetros ajustados das macro regiões são comparados com os parâmetros originais, buscando identificar as possíveis macro regiões danificadas. Definido as possíveis macro regiões, à análise elemento por elemento é aplicada visando identificar o componente danificado naquela região. O diagrama da figura 2.1 mostra uma visão geral do algoritmo utilizados tanto no processo de ajuste com base nas FRF(s), como para o problema de otimização.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

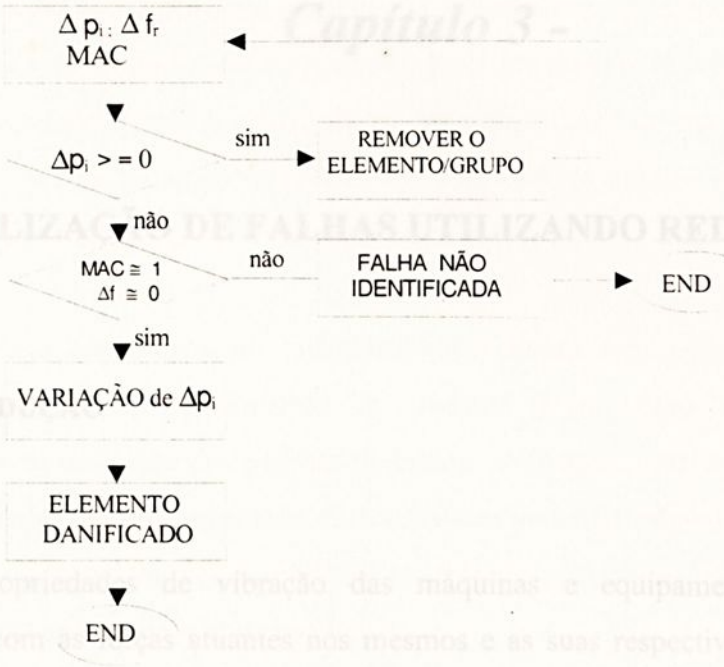


Figura 2.1: Diagrama de blocos da proposta de localização de falha.

Um aspecto importante a ser destacado na metodologia é como se dá a seleção dos parâmetros de ajuste dos elementos (macro regiões) e a sua reavaliação durante o processo. O algoritmo compara automaticamente os parâmetros de ajuste com os parâmetros originais e redefine, para cada iteração, um novo conjunto de parâmetros de ajuste contendo apenas aqueles parâmetros que apresentaram uma redução do valor da variável de projeto. Isto melhora a localização de eventuais falhas estruturais do modelo, pois apenas os prováveis parâmetros danificados são atualizados na iteração seguinte e evitando modificações de possíveis áreas ou parâmetros livres de erros.

2.5 - RESULTADOS

Os resultados objetos desse capítulo são mostrados em anexo, artigos P1, P2, P4, P6, P7 e P10. Esses artigos anexos foram reproduzidos na forma original como publicados ou submetidos para publicação.

Capítulo 3 -

LOCALIZAÇÃO DE FALHAS UTILIZANDO REDES NEURAIS

3.1 - INTRODUÇÃO

As propriedades de vibração das máquinas e equipamentos estão associadas, diretamente, com as forças atuantes nos mesmos e as suas respectivas propriedades físicas, sendo que qualquer mudança nas propriedades físicas (massa, rigidez e amortecimento) irá refletir imediatamente nos sinais de vibração. O monitoramento e o acompanhamento da variação desses sinais pode ser usado para avaliar as condições de funcionamento das máquinas e equipamentos. Entretanto, a natureza dos sinais é bastante complexa e existem diferentes classes de sinais, cujo interpretação e processamento adequado depende de algumas características específicas pertinentes à cada classe. Consequentemente, o estudo das técnicas de processamento e análise de sinais são tópicos fundamentais para a interpretação correta do problema quando se deseja proceder a identificação de falhas com base em medidas de vibração.

Alguns métodos processamento são mais adequados para o tratamento de uma determinada classe de sinais, visto que eles podem evidenciar melhor determinadas características específicas de interesse no problema. Neste caso, a escolha pode levar a uma avaliação no domínio do tempo (nível RMS do sinal), domínio da freqüência (componentes espectrais), relações tempo-freqüência (relação tempo-escala na análise wavelet) e outras. Independentemente desta escolha, os sistemas de diagnóstico com base em medidas de vibração, conforme discutido anteriormente, são interpretados basicamente como um problema de reconhecimento de padrões. Portanto, inicialmente é necessário a definição prévia de padrões de comparação, os quais são obtidos através de conhecimentos anteriores (dados da literatura técnica) ou da realização de ensaios referente as várias condições de falhas de interesse. A utilização de testes experimentais para definir os padrões de comparação



permite a extração de diferentes parâmetros e informações do modelo, entretanto, a escolha dos parâmetros a serem monitorados nem sempre é imediata pois certos parâmetros são mais sensíveis a uma dada condição (localização, severidade, etc.) do que a outra. Isso demanda uma avaliação previa de quais parâmetros e métodos de analise são indicados para uma particular condição de falha.

O trabalho, em andamento, busca responder algumas das questões acima, avaliando a utilização de diferentes parâmetros do sistema bem como diferentes técnicas de processamento na definição dos padrões de falhaa. A identificação da falha é feita através da utilização de redes neurais cujas suas características inerentes relacionadas com a capacidade de reconhecimento de padrões e robustez em relação a variações nos dados de entrada são bastante atraentes para este tipo de problema.

A seguir é apresentado, resumidamente, alguns formas convencionais de tratamento dos sinais usadas na definição de padrões de falhas avaliados pelas ferramentas NDAF propostas e/ou em desenvolvimento pelo autor. Adicionalmente, é apresentado uma discussão mais detalhada a respeito do tratamento de sinais não estacionários envolvendo a transformada wavelet. Diferentes ferramentas e estratégias foram discutidas, utilização de redes neurais treinadas com dados de freqüência, utilização de rede neurais associadas com técnicas de ajuste, wavelet junto com redes neurais e, finalmente, métodos utilizando elementos PZT.

3.2 - Análise de Sinais

A interação do homem com o universo, em várias situações, pode ser caracterizada por algumas funções específicas, por exemplo, cada ponto do espaço, em um determinado valor de tempo, pode ser associado a uma variação de uma grandeza física. Na área técnica essas funções relacionando as várias grandezas físicas são interpretadas como sinais. Neste contexto, os sinais temporais podem ser classificados, inicialmente, em estacionários e não-estacionários. No primeiro caso, o sinal não sofre alterações ao longo do tempo, ou seja, as suas propriedades estatísticas não mudam. No segundo caso, as propriedades estatísticas do sinal mudam significativamente num dado intervalo de tempo, isto é, o sinal (ou parte dele) não apresenta um padrão de repetição e é considerado como um sinal não-estacionário.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

3.2.1 - Análise de Sinais Estacionários

Para muito sinais cujo conteúdo de freqüência é suficientemente rico em informações a respeito do comportamento do sistema a análise espectral é extremamente útil, por exemplo, um sinal de áudio em que conhecendo-se as freqüências pode se definir o que se ouve de sons graves e agudos. Portanto, o sinal neste caso pode ser caracterizado por suas frequências. O ponto de partida para o entendimento das características de freqüência dos sinais é dado pela a análise das funções periódicas. A série de Fourier representa adequadamente esta classe de funções.

Seja uma função harmônica $x(t)=A\ sin(2\pi\omega t)$, para $\omega=2\pi/\tau$, $\tau>0$, A>0. O parâmetro A mede a amplitude do sinal e o parâmetro ω indica quantos ciclos completos existem em um dado intervalo de tempo T, fig. 3.1. Esse número está diretamente relacionado com o número de oscilações da função na unidade de tempo (período τ), ou seja, a freqüência da função. As figuras (3.1.b) e (3.1.c) mostram o gráfico de uma função periódica $x(t)$ para diferentes valores de ω.

Uma função periódica $x(t)= x(t+\tau)$, pode ser expressa como uma série infinita formada pelas suas componentes harmônicas, eq. (3.1).

$$x(t) = a_0 + \sum_{k=1}^{\infty}\left(a_k\ cos\ \frac{2\pi kt}{\tau} + b_k\ sen\ \frac{2\pi kt}{\tau} \right) \tag{3.1}$$

sendo a_0, a_k e b_k constantes denominadas coeficientes de Fourier, dadas por:

$$a_0 = \frac{1}{\tau}\int_{-\tau/2}^{\tau/2} x(t)dt \tag{3.2}$$

$$a_k = \frac{2}{\tau}\int_{-T/2}^{T/2} x(t)cos\frac{2\pi kt}{\tau}dt; k = 1,2,\ldots\ldots,n, \tag{3.3}$$

$$b_k = \frac{2}{\tau}\int_{\tau/2}^{\tau/2} x(t)sen\frac{2\pi kt}{\tau}dt; k = 1,2,\ldots\ldots,n, \tag{3.4}$$

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

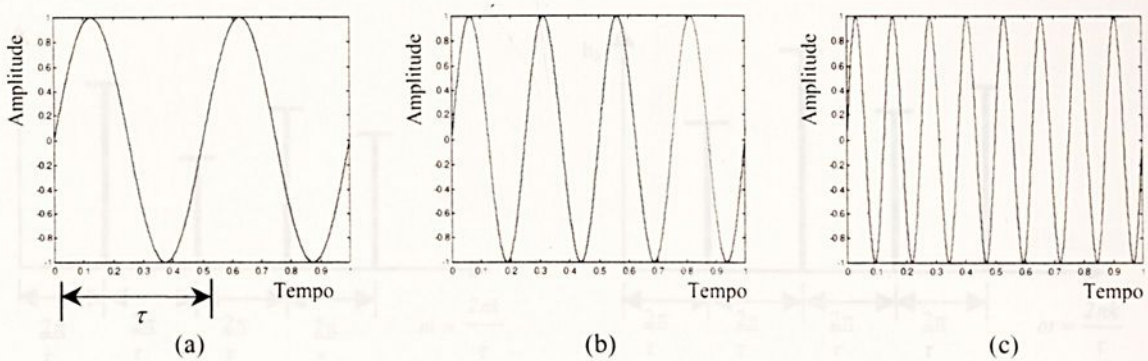


Figura 3.1: Funções periódicas

A decomposição dos sinais em termos desses coeficientes pode fornecer várias informações a respeito das suas componentes de freqüências. As condições matemáticas para convergência da Eq. (3.1) são atendidas na maioria dos problemas de engenharia, entretanto uma importante restrição deve ser feita quando a função *x(t)* é descontinua, neste caso a série gera um valor médio de *x(t)* na descontinuidade. Supõe-se que a posição do eixo da variável tempo, Fig. 3.1, seja ajustada para que o valor médio de *x(t)* seja zero. Então, de acordo com a Eq. (3.2), o coeficiente a_0 será zero. Para sinais periódicos os coeficientes remanescentes a_k e b_k e seus valores podem ser ilustrados graficamente como mostra a Fig. (3.2). O eixo horizontal representa as componentes de freqüências e a localização dos respectivos coeficientes ω_k,

$$\omega_k = \frac{2\pi k}{\tau}, \tag{3.5}$$

que fornecem o valor da freqüência de cada harmônico que compõe o sinal. Os espaçamentos entre as freqüências dos harmônicos é dado pela diferença entre dois harmônicos consecutivos.

$$\Delta\omega = \frac{2\pi}{\tau} \tag{3.6}$$

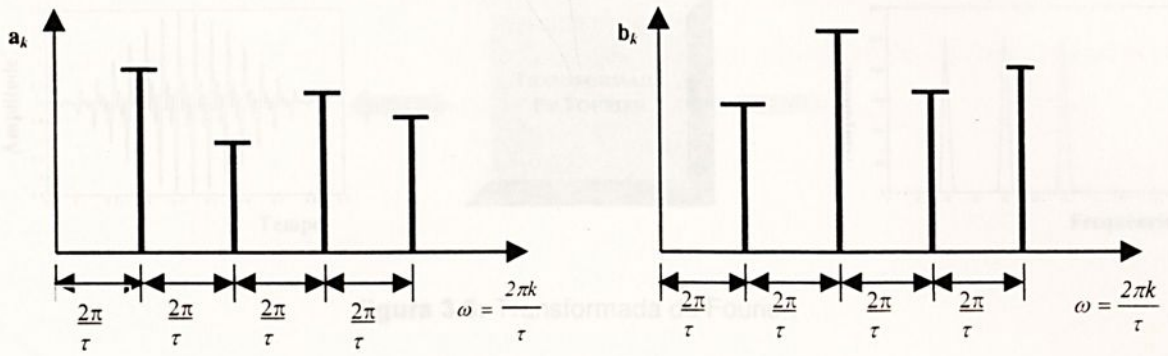


Figura 3.2: Representação gráfica dos coeficientes de Fourier.

Uma outra classe de sinal de suma importância neste contexto é a dos sinais transientes. Observando a equação (3.6), nota-se que um aumento do período τ leva a uma diminuição do espaçamento $\Delta\omega$ entre os harmônicos do sinal e vice e versa. Portanto, para $\tau \to \infty$, os espaçamentos entre as raias não vai existir e elas estarão unidas, assim *x(t)* não mais representa um fenômeno periódico e não pode ser analisado em termos das componentes de freqüências discretas. Neste caso, as equações (3.2) a (3.4) são redefinidas a partir de novos parâmetros, levando à funções continuas em freqüência e a análise das componentes de freqüência do sinal é feita pela chamada transformada de Fourier.

As Equações (3.7) e (3.8) formam o par de transformada de Fourier na forma complexa que permitem a transformação do sinal temporal *x(t)* para o domínio de freqüência e vice-versa, conforme esquematizado na Figura 3.3.

$$X(\omega) = \int_{-\infty}^{+\infty} x(t) e^{-i2\pi\omega t} dt \qquad (3.7)$$

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} X(\omega) e^{i2\pi\omega t} d\omega \qquad (3.8)$$



Figura 3.3: Transformada de Fourier.

3.3 - ANÁLISE DE SINAIS NÃO-ESTACIONÁRIOS

As técnicas de análise espectral tradicionais, com base na transformada de Fourier ou filtros digitais, fornece uma descrição melhor de sinais estacionários e pseudo-estacionários. Infelizmente, estas técnicas enfrentam algumas limitações quando os sinais a serem analisados são não-estacionários, isto é, sinais com propriedades espectrais variando no tempo. Em tais casos, a solução seria calcular um espectro instantâneo para cada índice temporal do sinal. As ferramentas que trabalham dessa forma são chamadas de técnicas de análise tempo-freqüência, as quais serão discutidas a seguir.

3.3.1 - Transformada de Fourier com Janela

A transformada de Fourier, discutida anteriormente, não se mostra adequada para a classe de sinais não-estacionários, ou seja, existem variações temporais no sinal (eventos transitórios) que não serão observadas pela transformada. Assim, Gabor, (1946) tentando corrigir esta limitação, propõe uma adaptação da TF para analisar somente uma pequena seção do sinal no tempo (janelamento do sinal). Essa adaptação é conhecida como transformada de Fourier com janela (*Short time Fourier transform* - STFT). A idéia é dividir o sinal não-estacionário em segmentos e assumir as hipóteses de estacionariedade para cada segmento do sinal e calcular a transformada de Fourier para este segmento. A divisão é feita por meio de uma janela $g(t-b)$, na qual b representa a posição da janela e, portanto, a localização temporal para o correspondente espectro, Fig. 3.4. A série de espectros, cada um relacionado a um índice temporal, forma a representação tempo-freqüência do sinal. Note que

o comprimento, a forma da janela e também as suas translações são fixadas em valores escolhidos antes de se iniciar a análise. Portanto, a STFT oferece uma resolução fixa no tempo e na freqüência, seu cálculo é definido a partir da transformada de Fourier de um sinal janelado para as várias posições *b* da janela,

$$S_b = \int_{-\infty}^{+\infty} x(t) g^*(t-b) e^{-j2\pi(t-b)} dt \qquad (3.9)$$

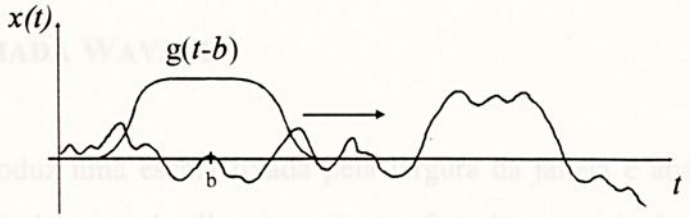


Figura 3.4: Transformada de Fourier com Janela "*Short Time Fourier Transform*"

Devido a natureza da STFT, i.e., a representação tempo-frequência fornece um reticulado uniforme, ou seja, as células de informações que formam o domínio tempo-frequência são uniformes, fig. 3.5. Isso implica em uma limitação na acurácia das informações obtidas, pois a mesma é determinada pelo tamanho da janela. A vantagem entretanto é que uma vez escolhida o tamanho de uma particular janela, esta é a mesma para todas as freqüências.

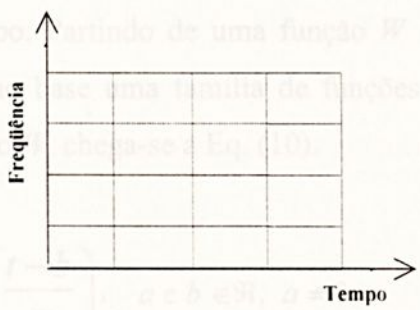


Figura 3.5: Domínio de Tempo-Freqüência (STFT).

Os resultados obtidos com o uso da STFT têm se mostrado muito bons, entretanto, muitos sinais requerem um enfoque mais flexível, ou seja, que o tamanho da janela possa variar, visando uma avaliação mais acurada de uma determinada característica que poderia ser obtida através de uma escala mais refinada no domínio do tempo ou da freqüência. A transformada Wavelet apresenta essas característica, ela é mais flexível em relação à representação tempo-frequência e, diferentemente da STFT, as células de informações podem variar para fornecer dados com maior acurácia no tempo ou na frequência.

3.4 - TRANSFORMADA WAVELET

A STFT introduz uma escala fixada pela largura da janela e analisa o sinal a partir desta escala. Se o sinal possui detalhes importantes fora dessa escala, haverá problemas para a avaliação destes detalhes. Portanto, para STFT visualizar melhor esses detalhes o tamanho da janela terá que ser alterado para um novo valor o qual será fixo ao longo de todo o sinal. As conseqüências dessa escolha serão uma melhor visualização de algumas características no domínio do tempo e um empobrecimento no domínio da freqüência ou vice-versa. Isso acontece devido ao princípio da incerteza que descreve a impossibilidade de se obter simultaneamente localizações acuradas no domínio do tempo e da frequência.

Uma forma de evitar a limitação causada pela escala fixa da STFT, seria definir uma transformada em que a escala possa variar. A largura da função de modulação define a escala e portanto, neste caso deve ser utilizada uma função de modulação que não tenha escala fixa e que seja localizada no tempo. Partindo de uma função W (*Wavelet* mãe) como função de modulação, e tomando como base uma família de funções geradas a partir da variação da escala e da posição da função W, chega-se a Eq. (10).

$$W_{(a,b)}(t) = \frac{1}{\sqrt{a}} W\left(\frac{t-b}{a}\right), \quad a \text{ e } b \in \Re,\ a \neq 0 \tag{3.10}$$

unesp

A modulação da função W pelo fator $1/\sqrt{a}$, faz com que sua amplitude aumente quando a escala a diminui e vice-versa. Em termos de freqüência, quando a diminui $W_{(a,b)}$ possui alta freqüência e vice-versa, para um aumento de a a freqüência diminui, Fig. 3.6.

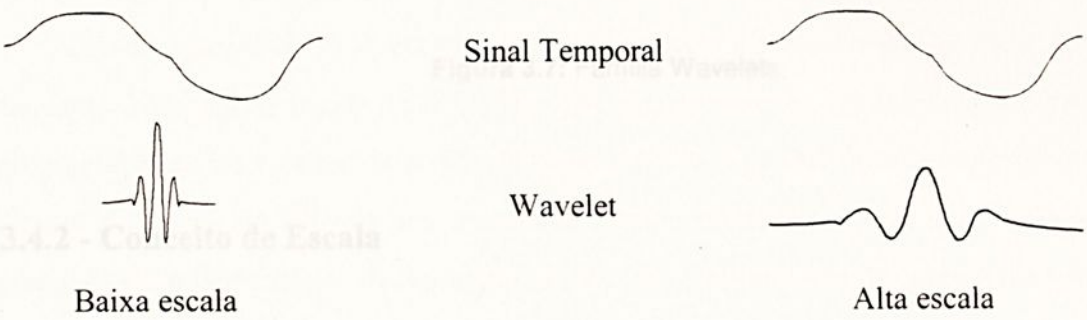


Figura 3.6: Relação entre Freqüência e Escala

3.4.1 - Famílias Wavelets

As famílias Wavelets mais conhecidas Daubechies, Morlet e Meyer são mostradas na Figura 3.7. As Wavelets da família Daubechies tem sido bastante utilizadas por ter um suporte compacto e também devido a sua assimetria, a qual favorece a visualização de alguns detalhes como efeitos transientes, variações de frequência no período de amostragem e outros. Esta primeira fase do trabalho discute as Wavelets da família Daubechies, elas foram escolhidas devido as suas propriedades mencionadas anteriormente bem como a sua aceitação na comunidade.

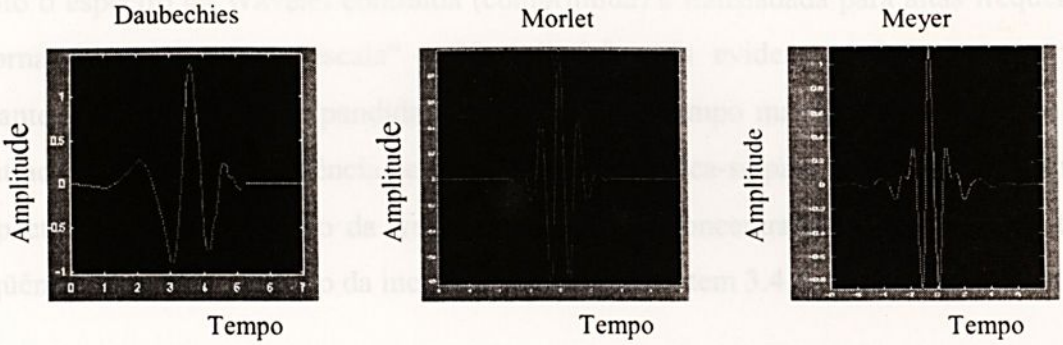


Figura 3.7: Família Wavelets.

3.4.2 - Conceito de Escala

Para estabelecer uma conexão clara entre "escala" e "freqüência" é adequado observar as Wavelets inicialmente no domínio da freqüência, Fig. 3.8. O espectro da Wavelet corresponde a um filtro passa banda centrado na freqüência f_0, dada pelo inverso do período da Wavelet, e a largura de banda depende de quantos períodos (oscilações) estão incluso na Wavelet, ou seja, o comprimento da Wavelet.

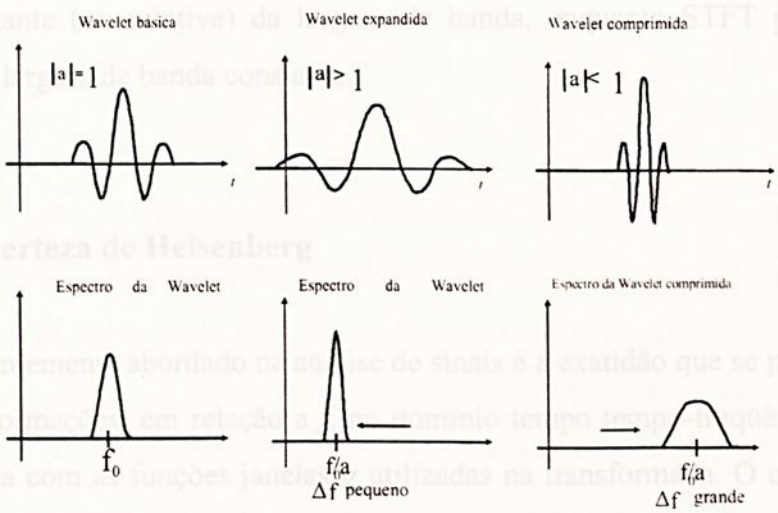


Figura 3.8: Influência do parâmetro escala *a* em uma Wavelet básica

A escala no domínio do tempo corresponde a uma translação no domínio da freqüência. O espectro da Wavelet dilatada (expandida) é transladada para baixas freqüências,

enquanto o espectro da Wavelet contraída (comprimida) é transladada para altas freqüências. Isso torna a relação entre "escala" e "freqüência" mais evidente. Outra característica importante é que a Wavelet expandida é mais ampla no tempo mas exibe um espectro mais concentrado em torno da freqüência central. O inverso aplica-se para a Wavelet comprimida, seu espectro é amplo em torno da freqüência central e concentrado no tempo. Este fato é conseqüência direta do princípio da incerteza, discutido no item 3.4.3.

A duração Δt da Wavelet no domínio do tempo é proporcional ao fator de escalar a, enquanto a largura de banda do filtro Wavelet, Δf, no domínio da freqüência é inversamente proporcional ao fator de escala a. Como conseqüência, o produto entre a duração temporal e a largura de banda do filtro é uma constante ($\Delta t \Delta f = constante$), sendo que ela pode assumir qualquer valor dependendo da definição de Δt e Δf. Definindo-se Δt como a duração RMS da Wavelet e Δf como largura de banda RMS do filtro Wavelet, então o produto é sempre $\geq 1/4\pi$. Isto é chamado a relação de incerteza de Heisenberg, a qual também se aplica para a STFT.

A conclusão é que a TW favorece a resolução temporal quando são analisados componentes de alta freqüência e oferece vantagens na resolução de freqüência quando são analisados componentes de baixa freqüência comparada com a STFT. Essa oferece resolução constante no domínio do tempo e em freqüência. Assim, a TW conduz à análise a partir de uma porcentagem constante (ou relativa) da largura de banda, enquanto STFT permite a análise apenas para uma largura de banda constante.

3.4.3 - Relação de Incerteza de Heisenberg

Um ponto freqüentemente abordado na análise de sinais é a exatidão que se pode obter para localização das informações, em relação a f, no domínio tempo tempo-freqüência. Esta exatidão está relacionada com as funções janelas g utilizadas na transformada. O que rege a exatidão na localização das informações da transformada no domínio tempo-freqüência é a relação de incerteza de Heizenberg. De maneira sucinta, esse princípio afirma que não se pode obter simultaneamente localizações acuradas no domínio do tempo e da freqüência. A idéia desse princípio é simples, para medir freqüências deve-se observar o sinal por um período de

tempo definido e quanto mais exatidão se deseja na medida da freqüência, maior deve ser o período observado.

A relação de incerteza é conhecida como o produto *BT* (largura de banda x tempo), que deve ser maior que a unidade para se ter os resultados desejados na análise. Para análise utilizando FFT "*Fast Fourier Transform*", uma versão muito prática e geral do produto *BT* é obtido considerando $\Delta fT=1$, sendo Δf o espaçamento da FFT e T é a duração do registro. Esta relação é independente da escolha da função de ponderação. Definindo-se Δt como a duração RMS da Wavelet e Δf como largura de banda RMS do filtro Wavelet, então o produto é sempre $\geq 1/4\pi$. Isto é a chamada relação de incerteza de Heisenberg, a qual também se aplica para a STFT.

A versão fundamental da relação de incerteza utiliza o desvio padrão, dado pelas expressões da energia do sinal.

$$\Delta t_{RMS} = \left(\frac{1}{E_g} \int_{-\infty}^{+\infty} (t - t_0)^2 |g(t)|^2 \, dt \right)^{\frac{1}{2}} \tag{3.11}$$

$$\Delta f_{RMS} = \left(\frac{1}{E_g} \int_{-\infty}^{+\infty} (f - f_0)^2 |G(f)|^2 \, df \right)^{\frac{1}{2}} \tag{3.12}$$

As equações (3.11) e (3.12) determinam a localização no domínio (f,t) e é representada por elipses de dimensões $\Delta t \Delta f$. Essas elipses são chamadas de células de informação. Pelo princípio da incerteza, a área dessa célula é $\geq 1/4\pi$. O fator de normalização E na equação é a energia da função janela. A função de ponderação escolhida é da forma Gaussiana para ambas as transformadas: TW e STFT. Neste caso alcança-se a relação da incerteza, cujo produto é igual a $1/4\pi$. Isto pode ser visualizado pelas elipses de Heisenberg. Para STFT, a elipse tem uma forma constante, enquanto que para TW o comprimento da largura de freqüência é proporcional a freqüência na qual ela está localizada. Assim, a STFT oferece uma resolução constante no tempo e em freqüência, Fig. 3.9, enquanto que a TW oferece uma melhor resolução no tempo e em freqüência, Fig. 3.10.

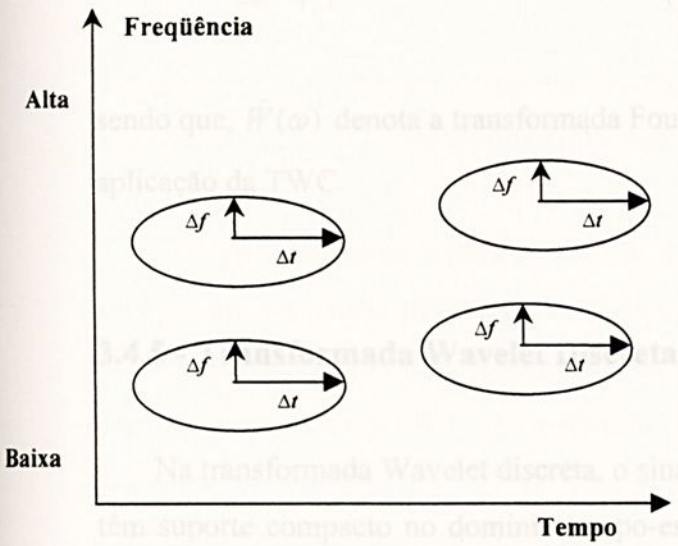


Figura 3.9: Elipse de Heisenberg para STFT

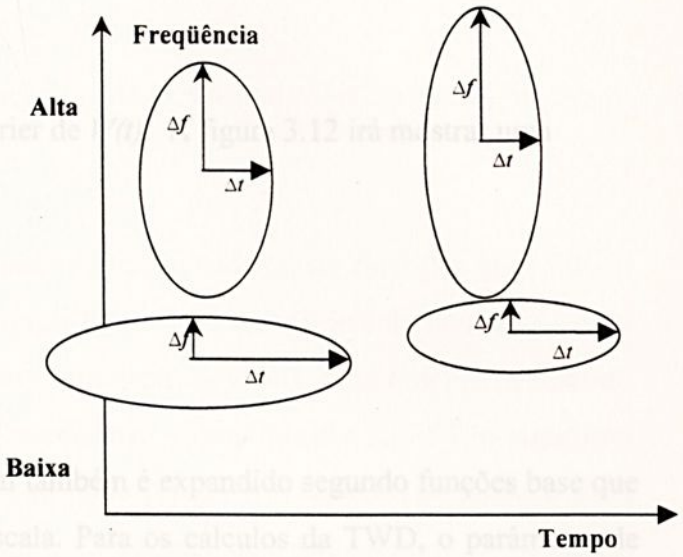


Figura 3.10: Elipse de Heisenberg para TW

3.4.4 - Transformada Wavelet Contínua

A Transformada Wavelet Contínua (TWC), de maneira similar a transformada de Fourier com janela (STFT), é definida utilizando o conjunto de funções base $W_{(a,b)}$ como função moduladora de f, Eq. (3.13).

$$TW_{(a,b)} = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) W\left(\frac{t-b}{a} dt\right), \tag{3.13}$$

e sua transformada inversa é dada pela Eq. (3.14).

$$f(t) = \frac{1}{C_W} \iint_{\Re} TW_{(a,b)} W_{(a,b)} da db \tag{3.14}$$

Para que existam as condições de operações da transformada direta/inversa, a *Wavelet* mãe deve satisfazer a condição de admissibilidade dada por

$$C_W \int_{-\infty}^{+\infty} \frac{\left|\hat{W}(\omega)\right|^2}{|\omega|} d\omega < \infty, \qquad (3.15)$$

sendo que, $\hat{W}(\omega)$ denota a transformada Fourier de *W(t)*. A figura 3.12 irá mostrar uma aplicação da TWC.

3.4.5 - Transformada Wavelet Discreta

Na transformada Wavelet discreta, o sinal também é expandido segundo funções base que têm suporte compacto no domínio tempo-escala. Para os cálculos da TWD, o parâmetro de dilatação *a* e o parâmetro de translação *b* devem ser discretizados. A mais comum discretização é a diádica (potência de dois), ou seja, o parâmetro *a* é substituído por 2^{-j} e *b* por $k2^{-j}$. Uma das funções utilizadas na expansão do sinal neste caso é a função escala, que é expressa por (3.16)

$$\phi_{(j,k)}(t) = 2^{-j/2}\phi\left(2^{-j}t - k\right) \qquad (3.16)$$

e a outra, denominada função Wavelet é definida a partir da função escala, eq. (3.17).

$$\psi_{(j,k)}(t) = 2^{-j/2}\psi\left(2^{j}t - k\right) \qquad (3.17)$$

A construção das funções representadas pelas Eq. (3.16) e Eq. (3.17) devem respeitar as propriedades de conservação de área, acurácia e ortogonalidade. Uma vez atendido essas condições, o sinal pode ser decomposto em termos da função escala e Wavelet.

$$f(t) = \sum_{k=-\infty}^{\infty} a_k \phi(x-k) \sum_{j=0}^{\infty} \sum_{k=-\infty}^{\infty} a_{(2^j+k)} \psi_{(j,k)}(t) \qquad (3.18)$$

onde: $a_0 = \int_0^1 f(t)\phi(t)dt$;

$$a_{2^j+k} = 2^j \int_0^1 f(t)\psi_{(j,k)}dt .$$

O coeficiente a_0 representa a amplitude da função escala e os demais coeficientes a_1, a_2, a_3, ... representam as amplitudes da função Wavelet.

O processamento numérico da TW desenvolvido por Mallat no final dos anos 80's é feito por um algorítmo semelhante ao algorítmo da FFT. Esse algorítmo é de fato um método clássico, conhecido por toda comunidade de processamento de sinais, sendo inclusive referido algumas vezes como a FWT (*Fast Wavelet Transform*). Como no caso da FFT, o algorítmo decompõe ou sintetiza um sinal de uma maneira muito eficiente e rápida, separando o sinal original em várias componentes. Parte destas componentes são responsáveis pelas baixas freqüências (a-aproximações) e as outras pelas altas freqüências (d-detalhes). A figura 3.11 mostra esquematicamente a decomposição do sinal nas componentes de baixa (*a's*) e de alta (*d's*) freqüência.

A figura 3.12 mostra esquematicamente a aplicação da TF, TWC e TWD para um sinal simples formado por uma senoide de 20 Hz e um impulso. O sinal é amostrado com 1024 pontos (T=0.8 s) e o impulso ocorre na posição 600 (0,5 s) após o início da amostragem. A TF mostra claramente a freqüência do sinal mas não consegue observar os efeitos transientes. A TW, em ambos os casos, permite uma estimativa da freqüência (refinar a escala) além de fornecer as informações a respeito da ocorrência de efeitos transiente.

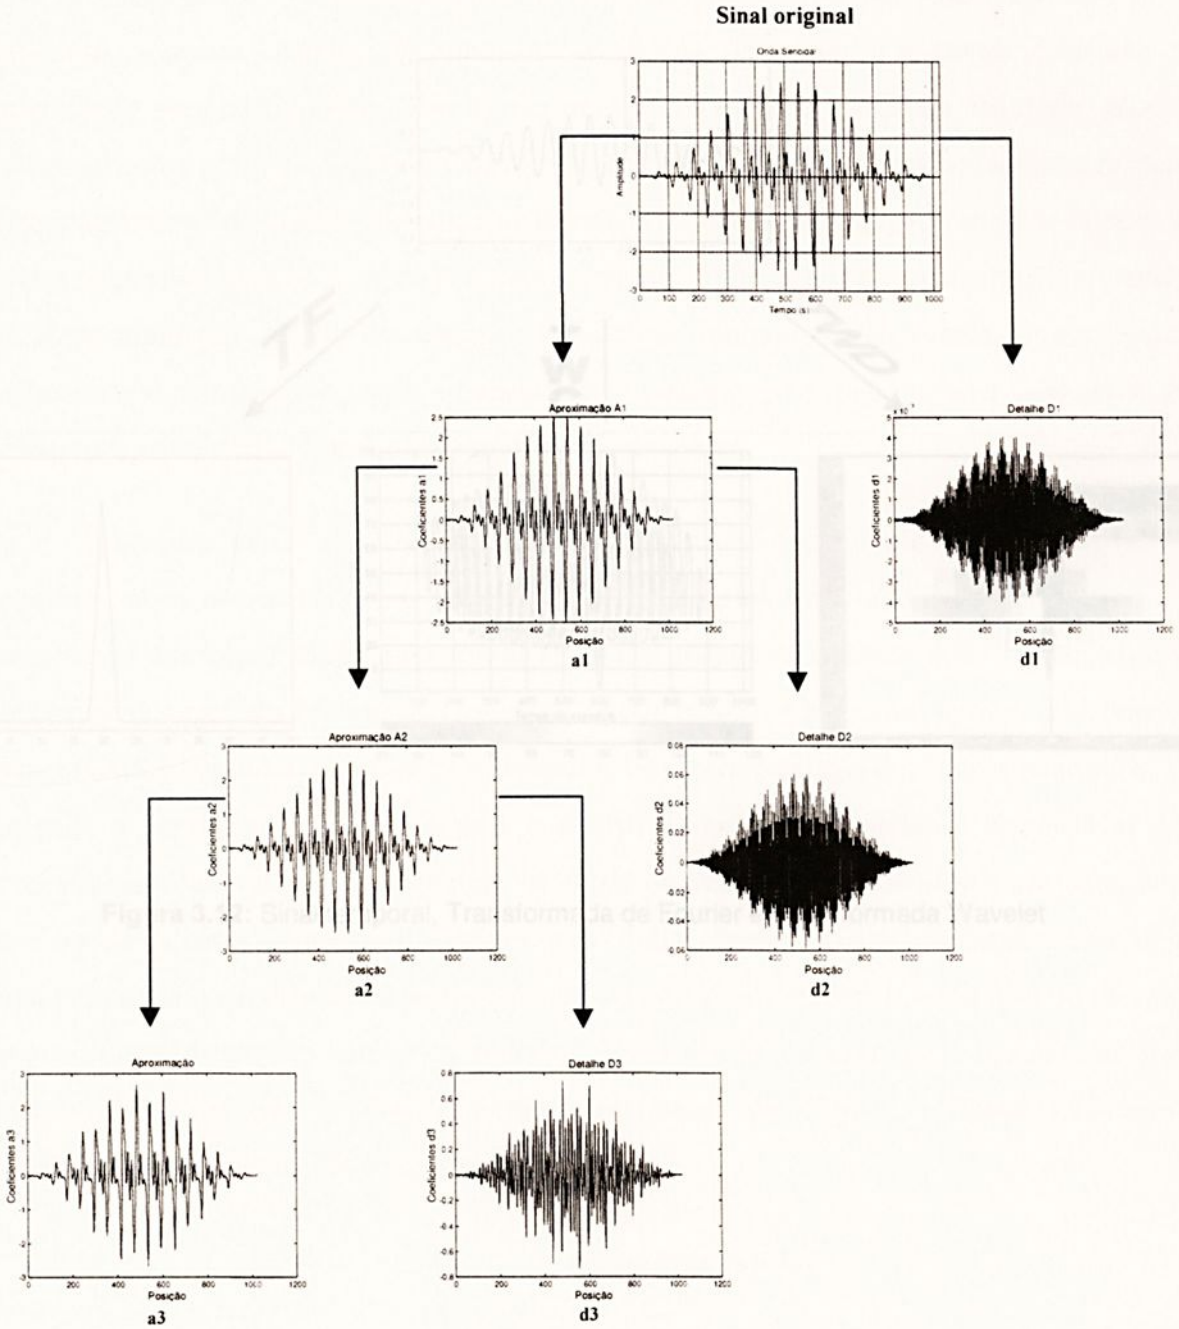


Figura 3.11: Decomposição em Detalhes e Aproximações

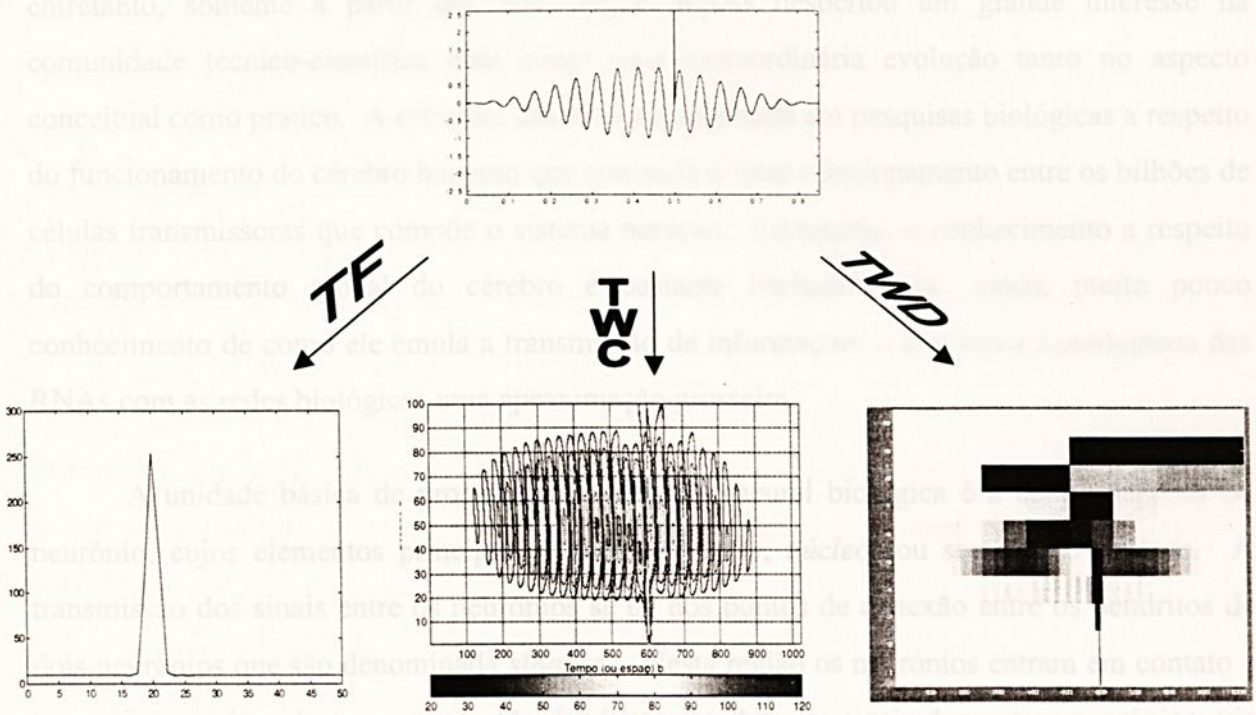


Figura 3.12: Sinal temporal, Transformada de Fourier e Transformada Wavelet

3.5 - REDES NERUAIS

As Redes Neurais Artificiais (RNAs) surgiram inicialmente por volta da década de 60 entretanto, somente a partir dos anos 80 as RNAs despertou um grande interesse na comunidade técnico-científica bem como uma extraordinária evolução tanto no aspecto conceitual como prático. A estrutura das RNAs é inspirada em pesquisas biológicas a respeito do funcionamento do cérebro humano que comanda o inter-relacionamento entre os bilhões de células transmissoras que compõe o sistema nervoso. Entretanto, o conhecimento a respeito do comportamento global do cérebro é bastante limitado e há, ainda, muito pouco conhecimento de como ele emula a transmissão de informações o que torna a associacoa das RNAs com as redes biológicas uma aproximação grosseira.

A unidade básica de processamento da rede neural biológica é a célula nervosa ou neurônio, cujos elementos principais são os *dendritos*, *núcleo* (ou soma) e o *axiônio*. A transmissão dos sinais entre os neurônios se dá nos pontos de conexão entre os dendritos de dois neurônios que são denominada *sinapses*. Nesta região os neurônios entram em contato e transmitem os impulsos nervosos. Os *dendritos* recolhem os sinais dos outros neurônios, via sinapses, e conduzem estes sinais para o núcleo da célula. O núcleo é responsável pelo processamento que ocorre no neurônio, os sinais provenientes dos *dendritos* são somados e caso o total da soma ultrapasse um determinado limite (threshold) a célula dispara e envia um sinal pelo *axônio* em direção as outras células. Alguns sinais tendem inibir o disparo da célula enquanto outros têm um caráter excitatório. Estas são as características básicas das redes neurais biológicas que inspiraram o desenvolvimento das RNAs, a figura 3.13 mostra esquematicamente uma célula nervosa.

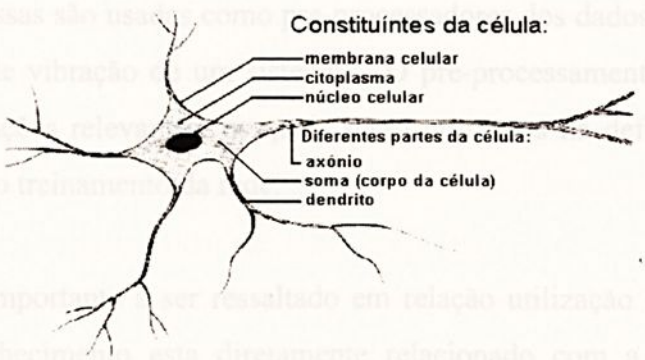


Figura 3.13: Esquema Simplificado de uma Célula Neural

As Redes Neurais Artificias, de forma geral, podem ser entendidas como concepções e técnicas computacionais, baseadas em modelos matemáticos inspirados em modelos biológicos, para a codificação e processamento de informações. Assim como no modelo biológico, as RNAs são compostas de elementos chamados neurônios que buscam realizar de maneira similar a maior parte das funções elementares do neurônio biológico. Estes elementos são organizados de forma que o seu funcionamento, grosseiramente falando, possa ser comparado com o funcionamento do cérebro. Neste caso, a rede neural exibe um número surpreendente de características similares as características cerebrais. Por exemplo, o aprendizado a partir de experiências, generalização de conhecimentos prévios para reconhecer uma nova característica abstrata a partir de entradas de dados até então desconhecidos e outros. Uma outra característica importante das RNAs é que elas podem adaptar seus procedimentos em resposta ao meio, se auto ajustam e produzem respostas consistentes. Entretanto, a atual "inteligencia" exibida pelas mais sofisticadas redes é ainda muito limitada e o entusiasmo quanto a sua semelhança funcional com o cérebro deve ser ajustada à realidade.

O campo de aplicação das RNAs é bastante amplo, e uma das funções que elas executam com bastante habilidade é o reconhecimento de padrões, superando em muitos casos os métodos mais tradicionais. Esta capacidade vai diretamente ao encontro dos requisitos desejados nas ferramentas não destrutivas para identificação de falhas ou seja, habilidade para reconhecimento de padrões de comportamento da estrutura com defeito, em comparação com o comportamento da estrutura sem defeito (intacta). As RNAs, neste caso, são designadas para classificar os padrões de entrada do sistema em classes pré-definidas ou criar categorias de grupos padrões de acordo com as suas similaridades e posteriormente identificá-los. Entretanto, a definição de padrões não é simples e envolve, na maioria das vezes, a utilização de outras técnicas. Essas são usadas como pre-processadores dos dados brutos referentes, por exemplo, ao estado de vibração de um sistema. O pré-processamento busca evidenciar os parâmetros e informações relevantes, os quais serão utilizados na definição dos padrões de comparação usados no treinamento da rede.

Um aspecto importante a ser ressaltado em relação utilização das redes é que a sua capacidade de reconhecimento esta diretamente relacionado com a qualidade dos dados utilizados no treinamento e com o sucesso da etapa de treinamento em si. O treinamento é

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

uma etapa crucial que esta ligada com a definição de uma estrutura ótima da rede, que não é imediata, pois não existem padrões pré-definidos que incondicionalmente apresentam resultados satisfatórios. Os resultados, de forma geral, são casos dependentes.

Os métodos utilizados como pré-processadores para a extração dos dados usados no treinamento assim como a definição da estrutura da rede demandam uma avaliação específica caso a caso. Diferentes estratégias têm sido discutidas pelo autor, tanto relacionadas com a definição da estrutura da rede, como com os métodos de pré-processamentos das informações a serem utilizadas no treinamento. Parte dos resultados obtidos são discutidos e apresentados nos artigos anexos, a seguir será discutido os conceitos básicos das RNAs.

3.5.1 - Redes Neruais Artificiais

As RNAs têm sido desenvolvidas em uma grande variedade de configurações, apesar desta aparente diversidade, os padrões das redes têm vários aspectos em comuns. As RNAs são inspiradas biologicamente e as pesquisas a respeito de configurações de rede e algorítmos são conduzidas, geralmente, pensando no funcionamento e organização do cérebro. Entretanto, essa correspondência termina nesse ponto pois o conhecimento a respeito do funcionamento do cérebro ainda é muito limitado.

A unidade básica de uma rede neural biológica é a célula nervosa, ou neurônios cujos componentes principais são os *dendritos*, o soma ou *núcleo* e o *axônio*. As ligações entre neurônios são chamadas de *sinapses*. Os dendritos recolhem os sinais provenientes de outros neurônios, via sinapses, e conduzem estes sinais para o núcleo do neurônio. O núcleo é responsável pelo processamento que ocorre no neurônio. Os sinais provenientes dos dendritos são somados e caso o total ultrapasse um determinado limiar, a célula dispara e envia um sinal pelo axônio em direção as outras células. Alguns sinais tendem a inibir o disparo da célula, enquanto outros tem caráter excitatório. Estas são as características mais elementares das redes neurais biológicas e são repetidas nas redes artificiais.

As RNAs geralmente são definidas por um conjunto de camadas de elementos (neurônios) arranjados de forma a reproduzir uma estrutura similar à biológica. Essas

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

camadas são classificados como camada de entrada[1], camadas intermediárias e camada de saída, Fig. 3.14. As redes com um conjunto de neurônios arranjados em uma única camada são denominados RNAs de simples camadas e as RNAs com mais de uma camada são denominadas de multi-camadas.

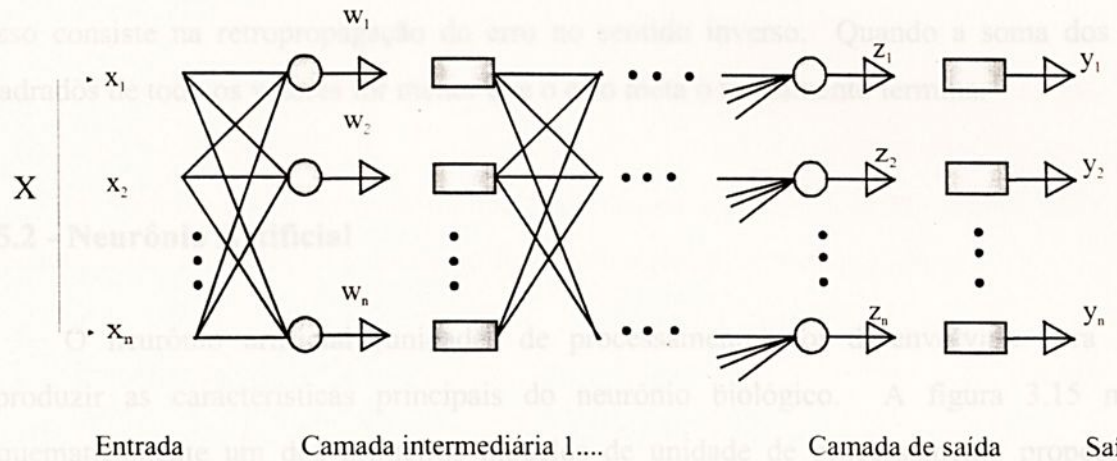


Figura 3.14: Esboço de uma rede neural multi-camadas.

Cada neurônio, em uma camada, é ligado a todos os neurônios da camada seguinte e essas ligações são responsáveis pela transmissão de informações de um neurônio para o próximo. Os dados de entrada $\{X\}$ são ponderados pelos coeficientes $\{W\}$ e passados para a primeira camada intermediária. Os neurônios desta camada são ativados e produzem as saídas, as quais têm como base a somatória dos pesos dos valores passados a elas pela função de ativação. Da mesma forma, a primeira camada intermediária passa os valores à segunda camada (se ela existir) e, assim, sucessivamente. No final, os valores são passados para a camada de saída que reproduz as saídas da rede. As saídas da rede são repetidamente comparadas com as saídas desejadas e a cada iteração os pesos de conexão são ajustados na direção das saídas desejadas. Este processo é denominado "treinamento" ou "aprendizado" da rede, cujos pesos de interconexão entre as camadas são ajustados buscando a saída correta.

Um dos algorítmos mais utilizados no treinamento das redes neurais de multi-camadas é o *Back-Propagation*. Neste caso, os vetores de entrada e os correspondentes vetores de

[1] **Camada de entrada:** alguns autores não a classificam como camada, pois não possue neurônios com capacidade de processamento, portanto não é computada no total de camadas de uma RNA.

saída pré-definidos são usados para o treinamento da rede até ela poder aproximar uma função, associando os vetores de entrada com os vetores específicos de saída, ou classificando vetores de entrada em um modo apropriado já definido. Inicialmente um padrão {X} é apresentado à rede que irá produzir uma saída {Y} e em seguida, determina-se o erro da saída calculada que é dado pela diferença entre o valor desejado e a saída calculada. O próximo passo consiste na retropropagação do erro no sentido inverso. Quando a soma dos erros quadrados de todo os vetores for menor que o erro meta o treinamento termina.

3.5.2 - Neurônio Artificial

O neurônio artificial (unidades de processamento) foi desenvolvido para tentar reproduzir as características principais do neurônio biológico. A figura 3.15 mostra esquematicamente um dos primeiros modelos de unidade de processamento proposto por McCulloch e Pitts no início dos anos quarenta.

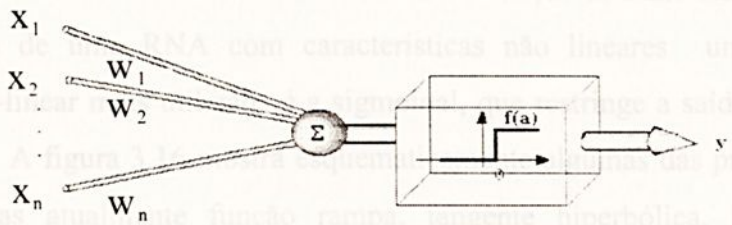


Figura 3.15: Neurônio artificial projetado por McCulloch-Pitts

Esta unidade de processamento pode ser dividida em duas partes. A primeira parte engloba as conexões de entrada da unidade. Em essência, um conjunto de entradas são aplicados sendo que cada uma dessas entradas representa a saída de um outro neurônio. Cada entrada é multiplicada por um peso correspondente, análogo ao comprimento sináptico, e todos os pesos de entrada são, então, somados em um determinado nível de ação do neurônio. Apesar da diversidade de padrões das redes, esta é a configuração base da unidade de processamento de todas as RNAs. Um grupo de entradas (x_1, x_2,..., x_n) é aplicado ao neurônio artificial e essas entradas, vetor {X}, correspondem aos sinais dentro da sinapse de um neurônio biológico. Cada sinal é multiplicado por um peso associado (w_1, w_2,..., w_n) e é

aplicado em um bloco, denominado soma Σ. Cada peso corresponde ao comprimento de uma simples conexão sináptica biológica (o grupo de pesos é referido coletivamente como um vetor *W*). O bloco soma que corresponde simbolicamente à célula biológica, adiciona algebricamente todos os pesos de entrada, produzindo uma saída denominada *NET*. Isto pode ser descrito em notação vetorial pela expressao (3.19).

$$NET = \{X\}^t \{W\} \tag{3.19}$$

A segunda parte do neurônio artificial recebe a saída do bloco soma (*NET*), que é processado por uma função de ativação *F* que produzirá a saída do neurônio .

$$Y = F(NET), \tag{3.20}$$

A função *F* pode ser uma função linear simples, uma função "*threshold*" ou uma função mais complexa, capaz de simular características de transferência não-lineares do neurônio biológico. No neurônio de McCulloch-Pitts a função de transferência consiste de um degrau. No caso de uma RNA com características não lineares uma das funções de transferência não-linear mais utilizada é a sigmoidal, que restringe a saída do neurônio entre os valores 0 e 1. A figura 3.16 mostra esquematicamente algumas das principais funções de ativação utilizadas atualmente função rampa, tangente hiperbólica, logística, degrau e gaussiana.

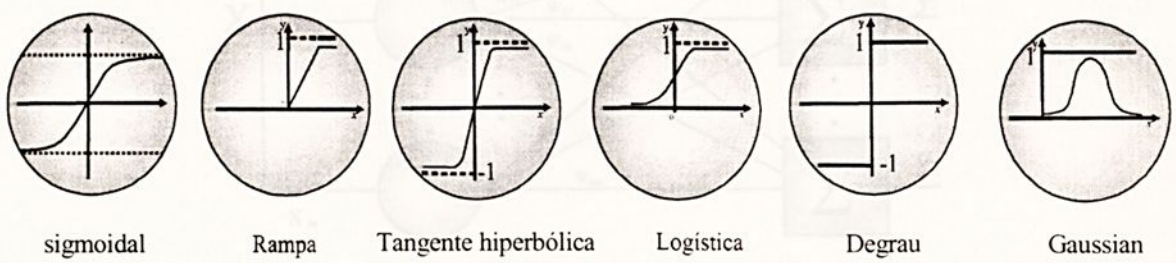


Figura 3.16: Funções de transferência.

3.5.3 - Redes Neurais de Simples Camadas

Um simples neurônio pode representar modelos simples, por exemplo, um modelo de detecção de força, entretanto, o poder da computação neural vem da comunicação dos vários neurônios na rede. A rede mais simples é composta por um grupo de neurônios arranjados em uma camada como mostra o lado direito da figura 3.17. Nota-se que os círculos do lado esquerdo da figura servem somente para distribuir as entradas. Eles não realizam computação e, consequentemente, não constitui uma camada. Por essa razão, são mostrados como círculos para distingui-los dos neurônios de computação, que serão mostrados como quadrados. O conjunto de entradas {X} tem cada um dos seus elementos conectados a um dos neurônios ponderados por coeficiente w e cada neurônio emite uma soma ponderada das entradas para rede.

As redes artificiais atuais, tal como as biológicas, têm muitas das conexões apagadas entretanto, por razões de generalidade, todas serão mantidas neste caso. É conveniente considerar os pesos como elementos $w_{i,j}$ de uma matriz W. As dimensões da matriz são *m* linhas por *n* colunas, sendo que *i*= 1, 2, ...*m* são as entradas e *j*=1, 2,.....*n* são os neurônios. Por exemplo, o peso conectando a 2^{a} entrada com o 1^{o} neurônio seria $w_{2,1}$ e o valor NET calculado para cada saída seria dado pelo produto {X} por {W}.

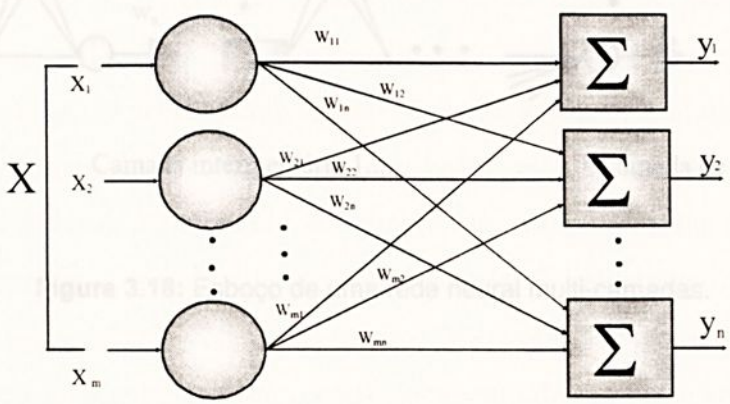


Figura 3.17: Rede Neural com uma camada.

3.5.4 - Rede Neurais Artificiais Multi-Camadas

Em geral, as redes multicamadas são mais complexas e oferecem maior capacidade computacional. Apresentam arquitetura nas mais variadas configurações, e o arranjo dos neurônios nas várias camadas busca, de forma geral, representar a estrutura de certas partes do cérebro. Portanto, as redes de multi-camadas são providas de capacidade computacional além daquelas das redes de simples camadas, e algorítmos mais elaborados têm sido desenvolvidos para o treinamento das mesmas.

As redes de multi-camadas podem ser vistas como um grupo de camadas simples em cascata. A saída de uma camada provém as informações para a entrada da camada subsequente, conforme esquematizado na Figura 3.18. Entretanto, a utilização de redes multi-camadas não aumenta necessariamente a capacidade computacional em relação a rede de simples camada a menos que se utilize uma função de transferência não-linear entre as camadas.

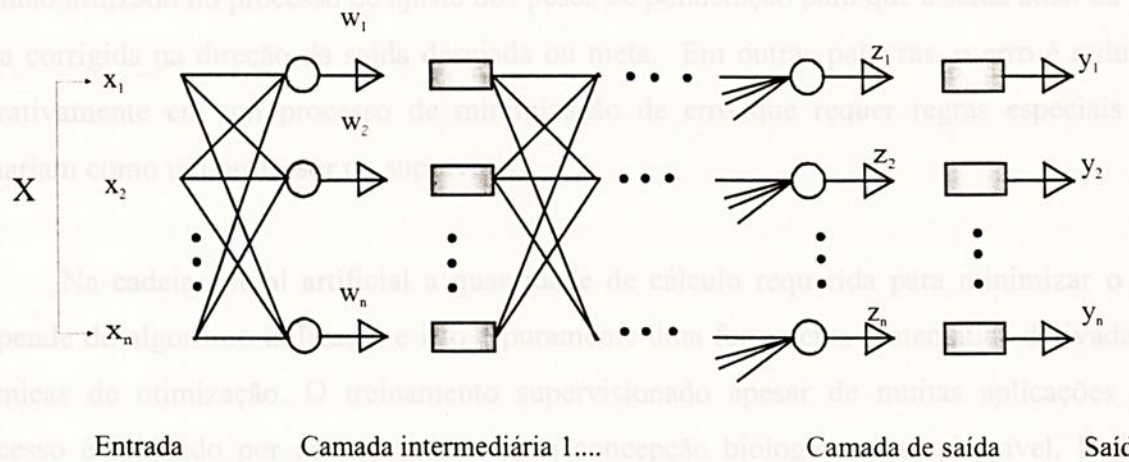


Figura 3.18: Esboço de uma rede neural multi-camadas.

A capacidade de representação de uma rede com mais de uma camada de neurônio pode ser entendida como uma combinação das capacidades de representação de cada rede individualmente. Esta combinação dependerá dos pesos associados as conexões entre a primeira e última camada, bem como da função de transferência dos neurônios nas camadas.

3.5.5 - Treinamento das Redes Neurais

O treinamento das RNAs consiste na determinação dos valores dos coeficientes de ponderação que levam um grupo de entradas à produzir a saída desejada. O treinamento é executado seqüencialmente aplicando os vetores de entrada de acordo com um procedimento pré-determinado e estimando os valores do ajuste dos pesos. Para um treinamento satisfatório, os pesos convergem gradualmente para determinados valores, de forma que o vetor de entrada seja capaz de produzir a saída desejada. Os métodos de treinamento de uma rede neural podem ser separados na categoria de aprendizado supervisionado e aprendizado não supervisionado.

O aprendizado supervisionado consiste em apresentar à rede neural uma série de dados de entrada e as respectivas saídas esperadas. Um estímulo de entrada é aplicado e durante o processo de treinamento a rede reage e responde com uma saída que é comparada com o sinal de saída desejado. Se a saída atual diferenciar da saída desejada é gerado um sinal de erro que é então utilizado no processo de ajuste dos pesos de ponderação para que a saída atual da rede seja corrigida na direção da saída desejada ou meta. Em outras palavras, o erro é reduzido iterativamente em um processo de minimização de erro que requer regras especiais que atuariam como um professor ou supervisor.

Na cadeia neural artificial a quantidade de cálculo requerida para minimizar o erro depende do algoritmo utilizado, e isto é puramente uma ferramenta matemática derivada das técnicas de otimização. O treinamento supervisionado apesar de muitas aplicações com sucesso é criticado por não apresentar uma concepção biologicamente plausível. É difícil conceber um mecanismo de treinamento do cérebro que compara saídas reais com as saídas desejadas, realimentando o processo de correções da rede. O treinamento não-supervisionado é mais plausível, neste sentido, ele se assemelha ao modelo de entendimento do sistema biológico. Esse treinamento não requer o estabelecimento de um vetor alvo para as saídas e, consequentemente, também não requer comparações com saídas pré-determinadas, utiliza apenas um vetor de entrada.

Neste caso, o algoritmo de treinamento modifica os pesos da rede para produzir vetores de saída consistentes. O processo de treinamento, por essa razão, extrai as

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

propriedades estatísticas do conjunto de dados de treinamento e agrupa os vetores similares em classes. Aplicando um vetor de uma dada classe, esta entrada produzirá um vetor de saída específico mas não existe como determinar, a priori, qual padrão de saída específico será produzido para essa classe de vetor de entrada. Consequentemente, as saídas da rede devem, geralmente, ser transformadas em formas compreensíveis durante o processo de treinamento.

Em contraste com a aprendizagem supervisionada, a aprendizagem não-supervisionada não requer um professor, isto é, não há alvo de saída. Ainda que a aprendizagem não supervisionada não requeira um professor, ela requer princípios gerais para determinar como organizar os grupos. O agrupamento pode ser baseado em forma, cor, consistência material ou sob alguma outra propriedade do objeto. Portanto, se os princípios gerais forem dados e os tipos de características que devem ser usadas para o agrupamento dos objetos não forem dados o treinamento pode ou não ser bem sucedido.

3.5.6 - Regra Delta

Muitos dos algorítmos de treinamento atuais têm usado a concepção de *Hebb* que estabelece que a força sináptica (peso de ponderação) entre uma célula A e B é modificada segundo o grau de atividade correlata entre a quantidade que entra e a que sai. Nesse modelo a ponderação (pesos) é incrementada se ambos, a origem e o neurônio de destino forem ativados. Usando muitas vezes estes caminhos, a rede é fortalecida e o fenomenal hábito de aprender pela repetição direta é explicado. A rede incrementa os pesos de acordo com o produto do nível de excitação da origem e dos neurônio de destino.

A regra delta foi a principal inovação introduzida por *Widrow* para o treinamento de redes do tipo ADALINE, que são composta por uma unidade de processamento com função de transferência linear, por isso o nome ADALINE (ADAPTIVE LINEAR ELEMENT). Este modelo foi posteriormente estendido para o caso de redes multi-camadas as denominadas MADALINE. Em seguida, a regra delta foi adaptada para outros tipos de redes neurais, formando a base de um dos tipos de redes mais empregado atualmente, as redes multi-camadas com retro-propagação do erro (*Back-Propagation*).



A regra delta para uma rede neural formada por uma camada de neurônios e com função de transferência linear tem aplicação bastante restrita devido a uma série de limitações. Entretanto, desenvolvimentos subsequentes levaram a aplicação da regra delta nas redes com múltiplas camadas de neurônios e função de transferência não linear. Diferentemente do perceptron que checa se a saída da rede é correta ou incorreta, na regra delta tem-se um erro em que a saída atual da rede é comparada com a saída desejada, *d*. A diferença básica do algorítmo de treinamento da rede ADALINE em relação as que utilizam valores de saída binários é que esta utiliza uma saída contínua. Isso permite a introdução do termo δ,

$$\delta = (d\text{-}y), \tag{3.21}$$

Para o caso em que $\delta = 0$ a saída da rede é correta e não é necessário cálculos adicionais, para $\delta > 0$ e $\delta < 0$ a saída é incorreta. No primeiro caso, adiciona-se cada valor de entrada nos correspondentes pesos e no segundo, os valores de entrada são subtraídos dos pesos. Em qualquer caso, o algorítmo é satisfeito se δ é multiplicado pelo valor de cada entrada x_i e este produto é adicionado ao peso correspondente. Generalizando esse procedimento pode se definir uma "taxa de aprendizagem" representada pelo coeficiente γ que multiplica o produto δx_i. Isso permite o controle do tamanho médio da mudança dos pesos,

$$\Delta = \gamma\ \delta x_i \tag{2.22}$$

$$w_i(n+1) = w_i(n) + \Delta_i \tag{3.23}$$

onde: Δ_i - correção associada com a *i-ésima* entrada x_i;

$w_i(n+1)$ - valor de ponderação *i* após o ajuste;

$w_i(n)$ - o valor de ponderação *i* antes do ajuste.

A regra delta modifica os pesos a partir das informações das entradas desejadas e das saídas calculadas.

3.6 - RESULTADOS

Os resultados objetos desse capítulo são mostrados em anexo, artigos P1, P5, P6, P9, P10, P11, P13 e P14. Os artigos P1 e P10 discutem o uso de técnicas de ajuste de modelos na geração de dados de treinamento para a rede e os artigos P5 e P11 discutem a utilização de wavelets como ferramentas de pré-processamento. O artigo P14 discute a introdução de componentes pzt na modelagem de elementos finitos (elementos do tipo viga) e posteriormente utiliza os dados no treinamento da rede visando a detecção de falhas a partir medida de impedância elétrica. Todos artigos anexos foram reproduzidos na forma original como publicados ou submetidos para publicação.

unesp

Capítulo 4 -

AJUSTE DE MODELOS USANDO FRF(S) AMORTECIDAS

4.1 - INTRODUÇÃO

Os efeitos do amortecimento nas estruturas e componentes mecânicos estão sempre presentes nos projetos de engenharia e a sua modelagem é bastante complexa. Esses efeitos são facilmente observados na natureza, qualquer estrutura em vibração livre apresenta um decaimento na amplitude do seu movimento com o passar do tempo, até que, em um certo instante, a estrutura alcança o estado de repouso. Do ponto vista da dinâmica estrutural, a energia contida em um sistema é constante e apenas a presença de mecanismos não conservativos pode explicar estas perdas. Estes mecanismos se originam normalmente a partir das forças de amortecimento que podem surgir de diversas fontes tais como fricção entre duas superfícies deslizantes, resistência de um fluido, amortecimento elétrico, fricção interna devido a imperfeições na elasticidade do material e outros.

A maioria das análises de engenharia utilizando o método dos elementos finitos estuda o comportamento do modelo em termos das matrizes de massa e de rigidez, e o amortecimento é ignorado completamente ou utiliza-se alguma forma de amortecimento proporcional. Já os dados provenientes de testes experimentais são valores complexos na maioria das vezes devido ao mecanismo de dissipação de energia.

Como o objetivo do ajuste é obter um modelo analítico representativo, a introdução de algum mecanismo que leve em conta na modelagem os efeitos de amortecimento faz-se necessário. Entretanto, a identificação da matriz de amortecimento ainda não apresenta o mesmo grau de confiabilidade obtido na identificação das matrizes de massa e rigidez o que evidencia ainda mais a necessidade do ajuste quando se deseja computar o amortecimento no modelo de elementos finitos.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Os efeitos do amortecimento no ajuste se evidenciam já na comparação inicial dos modelos, pois a presença de modos complexos no modelo experimental pode levar a uma inconsistência na comparação direta dos modos. Algumas técnicas de ajuste têm sido estendidas para incluir alguma forma de identificação do amortecimento no entanto, a maioria dos métodos de ajuste requerem o uso de modos experimentais reais. Para tanto, é necessário uma conversão dos modos complexos em modos reais o que pode introduzir erros no modelo, dificuldade ainda mais o ajuste. A proposta deste capítulo é discutir a introdução dos efeitos do amortecimento em processos de ajuste e mostrar como incluir o amortecimento no processo de ajuste discutido no capítulo 2.

4.2. - O AMORTECIMENTO EM DINÂMICA ESTRUTURAL

A modelagem estrutural é uma formulação utilizada para estudar o comportamento dos sistemas físicos em termos de um modelo matemático. Uma descrição detalhada da geometria e o conhecimento das propriedades de materiais de um sistema, geralmente, são suficientes para uma representação acurada das suas propriedades de inércia e rigidez. Entretanto, a modelagem prática das forças de amortecimento é carente de entendimento e é bem menos explorada do que a modelagem das forças de rigidez e inércia.

Embora a distribuição do amortecimento possa ser prevista em algumas situações, existem vários casos práticos em que a sua distribuição é bastante complexa, apresentando inclusive certas regiões cujos valores do amortecimento são maiores do que as outras (juntas, por exemplo). Quando isto acontece, é muito difícil prever qual mecanismo de amortecimento irá reger o comportamento do modelo, aumentando ainda mais as dificuldades para se encontrar uma boa quantificação do modelo de amortecimento inicial. Estudos de alguns mecanismos de amortecimento baseados em suposições teóricas e testes experimentais mostram que os modelos teóricos de amortecimento podem ser separados em lineares e não lineares. As forças de amortecimento lineares são invariantes no tempo e são representadas por coeficientes constantes de proporcionalidade ao deslocamento ou à velocidade, ou a ambos. As forças de amortecimento não lineares variam com o tempo (por ex., fricção de Coulomb) e levam, consequentemente, a equações do movimento com coeficientes dependentes do tempo, o que torna a solução do problema mais complexa.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Para o caso de amortecimento linear, a equação diferencial do movimento com coeficientes constantes para um sistema com n graus de liberdade, sujeito a uma excitação externa $f(t)$, pode ser expressa pela eq. (4.1).

$$[M]\{\ddot{u}(t)\}+[C]\{\dot{u}(t)\}+[K]\{u(t)\}=f(t) \tag{4.1}$$

Na modelagem estrutural, um modelo padrão de amortecimento conveniente utilizado é o amortecimento viscoso, representado pela matriz amortecimento de viscoso $[C]$, o qual é proporcional à velocidade. O mecanismo de amortecimento viscoso pode ser melhor entendido a partir do conhecimento do amortecedor convencional. Este tipo de aproximação é freqüentemente aplicada para sistemas com concentração local de amortecimento em certas regiões (juntas, pontos de conexão entre estruturas adjacentes, componentes específicas de um amortecedor, etc.). Entretanto, em várias situações práticas esta aproximação não apresenta resultados satisfatórios.

Um outro modelo de amortecimento bastante conhecido é o histerético que é utilizado para representar o amortecimento que surge internamente no material ou a partir da fricção do material. Nesta situação podem ser encontradas forças de fricção que são praticamente independentes da velocidade. Portanto, o modelo de amortecimento histerético fornece, neste caso, uma descrição mais realística das forças de amortecimento atuantes do que o amortecimento viscoso.

Os métodos de identificação de paramentos utilizados na modelagem experimental permitem uma estimativa razoável dos efeitos de amortecimento se as respostas forem medidas corretamente. Já na modelagem analítica, muito embora as matrizes de massa e rigidez $[M]$ e $[K]$ possam ser modeladas com uma boa acurácia (elementos finitos), a representação das propriedades de amortecimento definidas pela matriz $[C]$ é bastante limitada. O conhecimento a respeito da distribuição e da magnitude do amortecimento ainda é extremamente escasso e a análise por elementos finitos está freqüentemente confinada a representação de um modelo não amortecido. Isso pode levar a uma modelagem deficiente em várias situações, o que claramente justifica a inclusão do amortecimento na modelagem, principalmente, quando se deseja uma maior representatividade da modelo, que é exatamente a proposta das técnicas de ajuste de modelos.



4.2.1 - Modelos de Amortecimento Proporcional

O amortecimento proporcional é bastante utilizado para representar o mecanismo de amortecimento presente em sistemas que possuem uma distribuição uniforme das suas propriedades. O meio mais simples de formular a matriz de amortecimento neste caso é fazê-la proporcional a matriz de massa ou a matriz de rigidez. Deste modo, a matriz de amortecimento é dada por,

$$[C] = \alpha [M] \tag{4.2.a}$$

$$[C] = \beta [K] \tag{4.2.b}$$

sendo que as constantes de proporcionalidade α e β tem unidades de sec^{-1} e sec, respectivamente. Em (4.2), a primeira equação representa o chamado amortecimento proporcional a matriz de massa e a segunda representa o amortecimento proporcional a matriz de rigidez do sistema. O comportamento do amortecimento em ambos os casos pode ser estudado utilizando as propriedades de ortogonalidade dos modos para calcular o valor do amortecimento modal generalizado, c_r, para cada caso.

$$c_r = \alpha \{\phi_r\}^T [M] \{\phi_r\} \tag{4.3.a}$$

$$c_r = \beta \{\phi_r\}^T [K] \{\phi_r\} \tag{4.3.b}$$

Combinando a equação do amortecimento modal com o amortecimento viscoso para um sistema de um grau de liberdade ($c = 2\zeta\omega_r m$) pode se definir a razão de amortecimento em termos das constantes de proporcionalidade.

$$2\omega_r m_r \zeta_r = \alpha m_r \quad \text{ou} \quad \zeta_r = \frac{\alpha}{2\omega_r} \tag{4.4.a}$$

$$2\omega_r m_r \zeta_r = \beta k_r \quad \text{ou} \quad \zeta_r = \frac{\beta \omega_r}{2} \tag{4.4.b}$$

onde: k_r rigidez modal;
m_r massa modal.

Estas expressões mostram que para o amortecimento proporcional a massa, a razão de amortecimento é inversamente proporcional a freqüência enquanto que o amortecimento proporcional a rigidez é diretamente proporcional a freqüência. Nesta consideração é importante notar que a resposta dinâmica geralmente incluirá contribuições de todos os N modos mesmo que apenas um número limitado deles sejam incluídos nas equações desacopladas do movimento. Desta maneira, nenhum destes tipos de matrizes de amortecimento são adequadas para o uso em um sistema com múltiplos graus de liberdade pois os modos significativos ocupam uma ampla faixa de freqüência. As amplitudes relativas dos diferentes modos neste caso serão seriamente distorcidos por razões de amortecimento inadequadas.

Se a hipótese do amortecimento proporcional é empregada, pode-se conseguir melhores resultados combinando as matrizes de massa e rigidez, eq. (4.2.a) e (4.2.b), como uma soma.

$$[C] = \alpha[M] + \beta[K] \tag{4.6}$$

Este tipo de amortecimento é o chamado de amortecimento de Rayleigh. Por analogia, com as equações (4.3) e (4.4), o amortecimento de Rayleigh também pode ser expresso por uma relação entre a razão de amortecimento e a freqüência.

$$\zeta_r = \frac{\alpha}{2\omega_r} + \frac{\beta\omega_r}{2} \tag{4.7}$$

A figura 4.1 mostra graficamente a relação entre a razão de amortecimento e a freqüência para o amortecimento proporcional a massa, proporcional a rigidez e o amortecimento combinado.

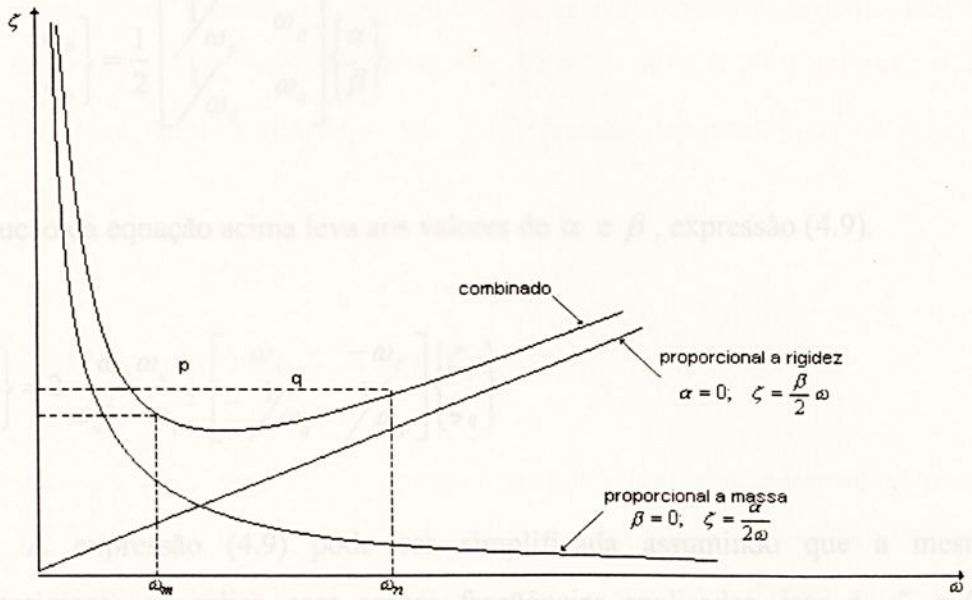


Figura 4.1: Relação entre razão de amortecimento e freqüência para o amortecimento de Rayleigh (Penzie e Clough, 1993)

O modelo do amortecimento proporcional tem encontrado grande aplicação e apresenta bons resultados para muitos problemas práticos. Isto é verdade especialmente para a determinação experimental dos fatores de amortecimento modal onde o amortecimento proporcional tem sua base teórica. Entretanto, deve-se notar que nem todas estruturas estão sujeitas a este tipo de distribuição, o que leva a se pensar em outro tipo de amortecimento não proporcional, como será discutido no item 4.2.3.

4.2.2 - Construção das Matrizes de Amortecimento

No amortecimento viscoso, as constantes α e β (amortecimento de Rayleigh) podem ser avaliados pela solução de um par de equações simultâneas definidas a partir das razões de amortecimento ζ_p e ζ_q associados a duas freqüências específicas conhecidas ω_p e ω_q, referentes aos modos p e q. Escrevendo a equação (4.7) para cada frequência específica e efetuando algumas manipulações algébricas, chega-se a expressão matricial utilizada para o cálculo das constantes α e β.

$$\begin{Bmatrix} \zeta_p \\ \zeta_q \end{Bmatrix} = \frac{1}{2} \begin{bmatrix} 1/\omega_p & \omega_p \\ 1/\omega_q & \omega_q \end{bmatrix} \begin{Bmatrix} \alpha \\ \beta \end{Bmatrix} \tag{4.8}$$

A solução da equação acima leva aos valores de α e β, expressão (4.9).

$$\begin{Bmatrix} \alpha \\ \beta \end{Bmatrix} = 2\frac{\omega_p \omega_q}{\omega_q^{\,2} - \omega_p^{\,2}} \begin{bmatrix} \omega_q & -\omega_p \\ -1/\omega_q & 1/\omega_p \end{bmatrix} \begin{Bmatrix} \zeta_p \\ \zeta_q \end{Bmatrix} \tag{4.9}$$

A expressão (4.9) pode ser simplificada assumindo que a mesma razão de amortecimento se aplica para ambas freqüências analisadas, isto é, $\zeta_p = \zeta_q = \zeta$. Esta aproximação é feita devido as dificuldades na obtenção de informações a respeito da variação da razão de amortecimento com a freqüência. Neste caso, os fatores de proporcionalidade são dados pela versão simplificada da eq. (4.9).

$$\begin{Bmatrix} \alpha \\ \beta \end{Bmatrix} = \frac{2\zeta}{\omega_p + \omega_q} \begin{Bmatrix} \omega_p \omega_q \\ 1_n \end{Bmatrix} \tag{4.10}$$

Quando este procedimento é aplicado para o cálculo da matriz de amortecimento proporcional, recomenda-se que ω_p seja geralmente tomado como a freqüência fundamental do sistema de múltiplos graus de liberdade e que ω_q seja tomado entre as freqüências mais altas dos modos que contribuem de maneira significante com a resposta dinâmica. Isso garante a obtenção da razão de amortecimento para estes dois modos, isto é $\zeta_1 = \zeta_q = \zeta$. Os modos com freqüência entre estas duas freqüências especificadas terão valores de razão de amortecimento mais baixo enquanto todos os modos com freqüências mais altas que ω_q terão razões de amortecimento que aumentam acima de ζ_q monotonicamente com a freqüência como pode ser observado na figura 4.1. O resultado final desta situação é que as respostas dos modos com freqüências muito altas são efetivamente eliminados pela sua alta razão de amortecimento.

Uma outra maneira de se determinar as constantes de proporcionalidade é, tendo determinado ω_r e ζ_r experimentalmente, para os modos de interesse, utilizar mínimos quadrados para resolver o sistema que será formado substituindo-se os valores na equação (4.7).

4.2.3 - Amortecimento Não proporcional

As matrizes de amortecimento proporcional são adequadas para modelar o comportamento de uma grande parte dos sistemas estruturais, especificamente aqueles em que o amortecimento é distribuído em todo o modelo. Entretanto, existem várias situações em que este mecanismo não se aplica, por exemplo, estruturas feitas de mais de um tipo de material. Os diferentes tipos de materiais podem produzir diferenças drásticas nos mecanismos de perda de energia em cada região da estrutura e a distribuição das forças de amortecimento não é mais similar à distribuição das forças inerciais ou elásticas, em outras palavras, o amortecimento resultante será não proporcional.

Uma forma de representar o amortecimento neste caso seria utilizar procedimentos similares à aqueles discutidos anteriormente na montagem das matrizes de amortecimento proporcional para construir a matriz de amortecimento não proporcional. O amortecimento de cada região seria estudado separadamente através da formulação proporcional e posteriormente, a matriz de amortecimento do sistema seria construída a partir da combinação do amortecimento dessas regiões. O procedimento é explicado esquematicamente na figura (4.2), que retrata uma estrutura composta por dois materiais distintos concreto e aço.

As matrizes de massa e rigidez do sistema são mostradas qualitativamente na figura (4.3), as contribuições da estrutura de aço estão posicionadas no canto superior esquerdo da matriz e a contribuição da estrutura de concreto no canto inferior direito. As contribuições associadas com os graus de liberdade comuns na interface entre as duas estruturas incluem contribuições de ambas, estrutura de aço e de concreto. A matriz de amortecimento combinando os dois efeitos é determinada por um processo de construção similar ao mostrado na figura 4.3.a e b. A derivação das sub-matrizes de amortecimento para as subestruturas de

aço e concreto, em princípio, poderiam ser avaliadas por qualquer um dos procedimentos para o determinação das matrizes de amortecimento proporcional descritos anteriormente.

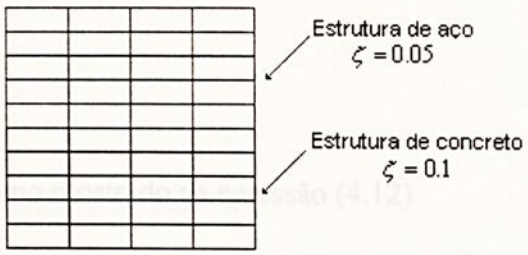


Figura 4.2: Estrutura combinada: aço e concreto

a) matriz de rigidez

$$[K] = \begin{bmatrix} \text{estrutura de aço} \\ [K_a] \\ \\ \text{estrutura de concreto} \\ [K_c] \end{bmatrix}$$

b) matriz de massa

$$[M] = \begin{bmatrix} \text{estrutura de aço} \\ [M_a] \\ \\ \text{estrutura de concreto} \\ [M_c] \end{bmatrix}$$

c) matriz de amortecimento

$$[C] = \begin{bmatrix} \text{estrutura de aço} \\ [C_a] \\ \\ \text{estrutura de concreto} \\ [C_c] \end{bmatrix}$$

Figura 4.3: Construção das matrizes das propriedades do sistema combinado

cm 1 2 3 4 5 6 7 unesp 11 12 13 14 15 16 17 18

Uma proposta que esta sendo estudada pelo autor é a utilização do amortecimento de Rayleigh. As sub-matrizes de amortecimento para as estruturas de aço e de concreto serão então dadas respectivamente por (equação 4.6),

$$[C_a] = \alpha [M_a] + \beta [K_a] \tag{4.11.a}$$

$$[C_c] = \alpha [M_c] + \beta [K_c] \tag{4.11.b}$$

As constantes α e β são avaliadas como mostrado na epressão (4.12)

$$\begin{Bmatrix} \alpha \\ \beta \end{Bmatrix} = \frac{2\zeta}{\omega_p + \omega_q} \begin{Bmatrix} \omega_p \omega_q \\ 1_p \end{Bmatrix} \tag{4.12}$$

Os valores destas constantes dependem das freqüências ω_p e ω_q a serem usadas. Essas são determinadas pela solução do problema de autovalor do sistema combinado isto é, usando as matrizes combinadas de massa e rigidez, $[M]$ e $[K]$. Como foi mencionado anteriormente, é recomendado que ω seja tomada como a freqüência do primeiro modo do sistema combinado com a maior freqüência na faixa de interesse. A matriz de amortecimento não proporcional para o sistema combinado é obtida finalmente, pela construção mostrada na figura 4.3.c.

Usando esta matriz de amortecimento na equação de movimento (4.1) e transformando o sistema para coordenadas normais através da pré e pós-multiplicação da equação pela matriz modal calculada para o sistema combinado, obtém-se as equações do movimento na forma modal.

$$\left[m \right]\{\ddot{q}(t)\} + \left[c \right]\{\dot{q}(t)\} + \left[k \right]\{q(t)\} = \Im \tag{4.13}$$

onde: $\Im = [\Phi]^T f(t)$.

As matrizes $\left[m \right]$ e $\left[k \right]$ são diagonais e contêm os componentes da massa e rigidez modal e o vetor $\Im$ é o carregamento padrão em coordenadas modais. As matrizes de massa e

rigidez são todas desacopladas (diagonais) entretanto, a matriz de amortecimento em coordenadas modais mantém o acoplamento (não diagonal).

$$[c]=[\Phi]^T[C][\Phi]=\begin{bmatrix} C_{11} & C_{12} & C_{13} & \cdots \\ C_{21} & C_{22} & C_{23} & \cdots \\ C_{31} & C_{32} & C_{33} & \cdots \\ \vdots & \vdots & \vdots & \vdots \end{bmatrix} \tag{4.14}$$

A solução do problema da resposta dinâmica do sistema acoplado pode ser obtida utilizando o método da integração passo a passo. Uma solução aproximada pode ser obtida ignorando-se os coeficientes de acoplamentos fora da diagonal principal da matriz de amortecimento modal e então resolver as equações desacopladas como uma típica análise por superposição modal.

4.3 - AMORTECIMENTO NO AJUSTE DE MODELOS

Tomando-se como base a formulação do amortecimento discutida anteriormente, esta etapa discuti a implementação do ajuste de modelos levando em conta os efeitos do amortecimento presente nas FRF(s) experimentais. A formulação básica apresentada no capítulo 2 é redefinida para que os efeitos e o caráter complexo das FRF(s) sejam incluídos no processo de ajuste. O mecanismo de amortecimento utilizado, nesta fase inicial, é baseado no modelo do amortecimento proporcional às matrizes de massa e rigidez do modelo de elementos finitos.

4.3.1 - Correção de Parâmetros

A formulação detalhada para se chegar as equações de ajuste serão omitida, o enfoque maior será voltado para as considerações a respeito da montagem das equações de ajuste e do cálculo dos parâmetros de atualização a partir da introdução da matriz de amortecimento. A equação do resíduo discutida no capítulo 2 (linearizada) é redefinida, introduzindo o efeito do amortecimento na matriz de rigidez dinâmica do modelo analítico.

$$\left\{\varepsilon^{lin}(\omega_k)\right\} = \left[Z_k^A(p^o)\right]\left\{H_k^X\right\}_j + \sum_{i=1}^{np}\left(\frac{\partial\left[Z_k^A(p)\right]}{\partial p_i}\Delta p_i\left\{H_k^X\right\}_j\right) - \{1\}_j \qquad (4.15)$$

onde: $[Z_A] = [K_A] + i\omega[C_A] - \omega^2[M_A]$

$[C_A]$ matriz de amortecimento.

Para uma freqüência de ajuste ω_k, a minimização do resíduo das forças atuando no modelo leva ao sistema de equações de ajuste, em termos da matriz de rigidez dinâmica analítica e dos valores experimentais da receptância.

$$\sum_{i=1}^{np}\left(\left[H_k^A\right]^0\frac{\partial\left[Z_k^A\{p\}\right]}{\partial p_i}\left\{H_k^X\right\}_j\Delta p_i\right) = \left\{H_k^X\right\}_j - \left\{H_k^A\right\}_j^0 \qquad (4.16)$$

Para um número *np* de parâmetros desconhecidos (parâmetros de ajuste) e *j* pontos de excitação a equação (4.16) pode ser escrita na forma matricial.

$$\begin{bmatrix} \left[H_k^A\right]^0\frac{\partial\left[Z_k^A\right]}{\partial p_1}\left\{H_k^X\right\}_1 & \left[H_k^A\right]^0\frac{\partial\left[Z_k^A\right]}{\partial p_2}\left\{H_k^X\right\}_1 & \cdots & \left[H_k^A\right]^0\frac{\partial\left[Z_k^A\right]}{\partial p_{np}}\left\{H_k^X\right\}_1 \\ \left[H_k^A\right]^0\frac{\partial\left[Z_k^A\right]}{\partial p_1}\left\{H_k^X\right\}_2 & \left[H_k^A\right]^0\frac{\partial\left[Z_k^A\right]}{\partial p_2}\left\{H_k^X\right\}_2 & \cdots & \left[H_k^A\right]^0\frac{\partial\left[Z_k^A\right]}{\partial p_{np}}\left\{H_k^X\right\}_2 \\ \vdots & \vdots & \vdots & \\ \left[H_k^A\right]^0\frac{\partial\left[Z_k^A\right]}{\partial p_1}\left\{H_k^X\right\}_j & \left[H_k^A\right]^0\frac{\partial\left[Z_k^A\right]}{\partial p_2}\left\{H_k^X\right\}_j & \cdots & \left[H_k^A\right]^0\frac{\partial\left[Z_k^A\right]}{\partial p_{np}}\left\{H_k^X\right\}_1 \end{bmatrix}\begin{Bmatrix}\Delta p_1\\ \Delta p_2\\ \vdots\\ \vdots\\ \Delta p_{np}\end{Bmatrix} = \begin{Bmatrix}\left\{H_k^X\right\}_1 - \left\{H_k^A\right\}_1^0\\ \left\{H_k^X\right\}_2 - \left\{H_k^{AX}\right\}_2^0\\ \vdots\\ \left\{H_k^X\right\}_j - \left\{H_k^A\right\}_j^0\end{Bmatrix} \qquad (4.17)$$

Ou em uma notação mais compacta:

$$[S_k]\{\Delta p\} = \{\Delta H_k\} \qquad (4.18)$$

A equação (4.18) é definida inicialmente para a freqüência de ajuste ω_k. Para um conjunto de pontos de freqüência, o que ocorre geralmente em aplicações práticas, a equação deve ser reavaliada para cada ponto de freqüência selecionado. Isto define um conjunto simultâneo de equações de atualização para todas as freqüências ajuste.

Esse conjunto de freqüências de ajuste deve ser selecionado de forma a prover uma matriz de receptância de referência contendo, de uma forma balanceada, todas as informações relevantes contidas na matriz de receptância medida na faixa de freqüência em análise. Entretanto, a seleção de um conjunto ótimo de freqüências de ajuste não obedece um critério sistemático de seleção.

Para uma freqüência de ajuste ω_k, a sensibilidade em relação ao p é calculada numericamente pela expressao (4.19).

$$\frac{\partial[Z]}{\partial p_k} \cong \frac{[Z(p_k + \Delta p_k)] - [Z(p_k)]}{\Delta p_k} = \frac{[\Delta Z]}{\Delta p_k} \tag{4.19}$$

Em termos das matrizes de massa, rigidez e amortecimento,

$$[\Delta K] = [K(p_k + \Delta p_k)] - [K(p_k)] \tag{4.20}$$

$$[\Delta M] = [M(p_k + \Delta p_k)] - [M(p_k)] \tag{4.21}$$

$$[\Delta C] = [C(p_k + \Delta p_k)] - [C(p_k)] \tag{4.22}$$

As variações das matrizes de massa e rigidez, devido a perturbação no parâmetro p para o r-ésimo elemento ou uma macro-região são estimadas iterativamente pelas expressões (4.23) e (4.24), respectivamente:

$$[K(p_k + \Delta p_k)] = \overline{\sum_{e \; R=1}^{neR}} [K(p_k)]^{e \; R} - [K(p_k)]^r + [K(p_k + \Delta p_k)]^r \tag{4.23}$$

$$[M(p_k + \Delta p_k)] = \overline{\sum_{e \; R=1}^{neR}} [M(p_k)]^{e \; R} - [M(p_k)]^r + [M(p_k + \Delta p_k)]^r \tag{4.24}$$

onde: $\overline{\Sigma}$ soma (elementos finitos) das matrizes dos elementos/macro-regiões;

e/R elemento ou macro região;

j *j-ésimo* elemento ou região;

k *k-ésimo* parâmetro

neR número de elementos ou macro regiões;

Se a matriz de amortecimento é calculada com base no modelo de amortecimento proporcional, equação(4.6), a variação da matriz de amortecimento é proporcional as matrizes de massa e rigidez:

$$[C(p_k + \Delta p_k)] = \alpha[M(p_k + \Delta p_k)] + \beta[K(p_k + \Delta p_k)] \tag{4.25}$$

Onde as constantes α e β são extraídas a partir das razões de amortecimento modal e das freqüências naturais experimentais utilizando a equação (4.6). A substituição dos parâmetros modais na equação (4.6) leva a um sistema de equações em α e β que posteriormente é resolvida através do método de mínimos quadrados.

4.3.2 - Análise de Sensibilidade

O sucesso do ajuste do modelo depende além da escolha dos pontos de freqüências (ver seção 2.2) da seleção dos parâmetros a serem ajustados. A seleção de parâmetros incorretos ou parâmetros pouco sensíveis poderá dificultar a solução do problema, levando a instabilidade numérica ou mesmo forçando o processo corrigir regiões que com pouca influência no comportamento do modelo. O conhecimento prévio dos componentes ou regiões do modelo em que os parâmetros são mais sensíveis à pequenas variações pode melhor o ajuste, visto que serão corrigidos apenas os parâmetros que têm uma maior influência no comportamento do modelo. A seleção deste parâmetros pode ser feita a partir do cálculo da sensibilidade do modelo.

Basicamente, a sensibilidade de uma quantidade modal em relação a um parâmetro p é calculada como a variação de primeira ordem desta quantidade em relação a uma pequena variação deste parâmetro. A sensibilidade das freqüências características do modelo em relação a um parâmetro $\{p\}$ é estimada por meio da seguinte expressão (4.26).

$$(-\lambda[M] + [K])\{X\} = \{0\} \tag{4.26}$$

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Para o r-ésimo modo tem-se:

$$[K]\{\psi\}_r - \lambda_r[M]\{\psi\}_r = 0 \tag{4.27}$$

Derivando a Expressão (4.27) com relação ao p-ésimo parâmetro, tem-se:

$$[K]'\{\psi\}_r + [K]\{\psi\}'_r - \lambda_r[M]\{\psi\}_r - \lambda_r[M]'\{\psi\}_r - \lambda_r[M]\{\psi\}'_r = 0 \tag{4.28}$$

onde: $(\,)'$, $\{\,\}'$ e $[\,]'$ são derivadas de primeira ordem.

Pré-multiplicando a expressão (4.28) por $\{\psi\}_s^T$, e aplicando as propriedades de ortogonalidade das matrizes de massa e rigidez, esta pode ser rearranjada em função das suas derivadas de primeira ordem.

$$\{\psi\}_s^T[K]'\{\psi\}_r - \lambda_r'\{\psi\}_s^T[M]\{\psi\}_r - \lambda_r\{\psi\}_s^T[M]'\{\psi\}_r + \{\psi\}_r'^T([k]\{\psi\}_s - \lambda_r[M]\{\psi\}_s) = 0 \tag{4.29}$$

A sensibilidade de primeira ordem do r-ésimo autovalor λ_r em relação a um parâmetro $\{p\}$ é dada por:

$$\frac{\partial\lambda_r}{\partial p} = \{\psi\}_r^T\frac{\partial[K]}{\partial p}\{\psi\}_r - \lambda_r\{\psi\}_r^T\frac{\partial[M]}{\partial p}\{\psi\}_r \tag{4.30}$$

onde: $\{\psi\}_r^T$ - autovetor
$[M]$ - matriz de massa
$[K]$ - matriz de rigidez

A sensibilidade de primeira ordem do r-ésimo vetor modal em relação a um parâmetro é também derivada por meio de expressão (4.29), entretanto esta analise não foi implementa nos trabalhos mostrados em anexos.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

4.3.3 - Ajuste para o amortecimento Não Proporcional

Para estruturas que apresentam concentrações locais de amortecimento em alguns pontos específicos, como por exemplo, juntas, soldas, estruturas compostas por diferentes tipos de materiais e outros, a hipótese do amortecimento proporcional pode levar a resultados incorretos.

Uma forma de lidar com o amortecimento não proporcional é assumir que o amortecimento é proporcional em nível elementar ou em regiões. Isso permite considerar variações do amortecimento nas diversas partes da estrutura. Neste caso, a descrição do amortecimento pode ser obtida assumindo-se uma combinação linear das matrizes de massa e rigidez em termos locais. Para o *i*-ésimo elemento ou macro-regiao o amortecimento pode ser estimado em termos locais pela equacao (4.31).

$$\left[C_i^{e/R}\right] = \alpha_i \left[K_i^{e/R}\right] + \beta_i \left[M_i^{e/R}\right] \tag{4.31}$$

Neste caso, existirão dois eventuais parâmetros de ajuste associados com cada elemento ou região *i* da estrutura. Isto aumentará o número de incógnitas do problema e, provavelmente, o benefício da descrição mais refinada do amortecimento pode ser perdida em alguns casos. Entretanto, usando a equação (4.31) e dividindo a estrutura em ***neR*** elementos finitos ou macro regiões, obtém-se:

$$[C] = \sum_{i=1}^{neR} \alpha_i \left[K_i^{e/R}\right] + \beta_i \left[M_i^{e/R}\right] \tag{4.32}$$

Os coeficientes α_i e β_i são inicialmente estimados e então corrigidos por um procedimento de ajuste adequado para cada elemento ou macro região. As principais dificuldades são a estimativa inicial da matriz $[C]$ e o significado físico dos parâmetros de amortecimento. Para uma aproximação inicial, a estrutura é assumida homogênea e isotrópica, e aplica-se a equação (4.6).

$$[C] = \alpha[M] + \beta[K]$$

BCpIS - FEIS - UNESP

$[M]$ e $[K]$ são as matrizes globais de massa e rigidez. Uma saída para o problema é determinar α e β a partir das razões de amortecimento experimentais, assumindo-se o comportamento de um sistema de um grau de liberdade nas proximidades da ressonância. Utilizando-se a equação (4.6) tem-se

$$\zeta_r = \frac{\alpha \omega_r^{\,2} + \beta}{2\omega_r}, \quad r = 1, \ldots, N$$

Os termos ζ_r e ω_r são as razões de amortecimento e as freqüências naturais obtidas experimentalmente. Os valores de α e β podem ser determinados pela solução da equação (4.7) utilizando o mínimos quadrados, e usados como estimativa inicial na equação (4.6). As matrizes de amortecimento dos elementos poder ser ainda construídas baseadas em outros modelos de amortecimento. Isto é feito de maneira análoga aos procedimentos para a determinação das matrizes locais de amortecimento viscoso. A seguir serão apresentados algumas destas possíveis hipóteses.

Amortecimento Modal

A hipótese do amortecimento modal define a matriz de amortecimento viscoso como sendo

$$[C] = \sum_{r=1}^{N} 2\omega_r \zeta_r \{\phi_X\}_r \{\phi_X\}_r^T \tag{4.33}$$

$\{\phi_X\}_r$ é o *r-ésimo* modo normalizado em relação a massa. Os coeficientes ζ_r são inicialmente estimados pelas razões de amortecimento e então corrigidos pelo processo de ajuste. Neste caso, há a adição de apenas um parâmetro de ajuste por cada elemento ou macro-região.

Amortecimento Estrutural

A matriz de Amortecimento estrutural $[D]$, pode ser definida pela equação:

$$\left[D_i^{e/R}\right] = \eta_i \left[K_i^{e/R}\right] \tag{4.34}$$

ou por

$$[D] = \sum_{i=1}^{N} \eta_i \left[K_i^{e/R}\right] \tag{4.35}$$

Como uma primeira aproximação, pode-se assumir que todos os η_i são iguais ao valor da soma ponderada, eq. (4.36).

$$\eta = \frac{2}{m} \sum_{r=1}^{m} \zeta_r \tag{4.36}$$

Devido a inclusão do amortecimento, tanto proporcional quanto não proporcional, na rotina de ajuste e ao caráter complexo das FRF(s) medidas, a equação (4.18) assume a forma complexa e pode ser discutida em termos da parte real e imaginária,

$$\begin{bmatrix} \mathrm{Re}(S) \\ \mathrm{Im}(S) \end{bmatrix} \{\Delta p\} = \begin{Bmatrix} \mathrm{Re}\left(\Delta H^k\right) \\ \mathrm{Im}\left(\Delta H^k\right) \end{Bmatrix} \tag{4.37}$$

A equação (4.37) é resolvida utilizando o método da decomposição do valor singular (SVD) e a variação dos parâmetros $\{\Delta p\}$, é utilizada para obter, de forma iterativa, uma estimativa do ajuste das matrizes de massa e rigidez do modelo de elementos finitos. O uso do teorema da decomposição do valor singular (SVD) no cálculo da solução do sistema ajuda a filtrar singularidades e permite, inclusive, quantificar a noção da deficiência do *rank* da matriz.

4.4 - RESULTADOS

Os resultados objetos desse capítulo são mostrados em anexo, artigos P3, P8, P12 e P15. Os artigos P3, P8 e P12 discutem o uso da análise de sensibilidade na definição dos parâmetros de ajuste do modelo.

Capítulo 5 -

CONCLUSÃO

Este trabalho apresenta parte dos resultados das atividades técnico-científicas realizadas pelo docente nos últimos cinco anos nas áreas de ajuste de modelos e identificação de falhas com base em vibrações. Os princípios básicos que nortearam as atividades desenvolvidas são amplamente discutidos em cada capítulo já os fundamentos teóricos utilizados na formulação e solução dos problemas são apresentados de forma sintética.

A potencialidade e limitações das várias técnicas e propostas pesquisadas, tanto na área de identificação de falhas, como de ajuste de modelos foram discutidos nos vários artigos apresentados. Neste texto serão enumeradas apenas algumas conclusões de caracter geral extraídas dos vários trabalhos apresentados. O autor é da opinião que as técnicas de ajuste de modelos são ferramentas extremamente importantes que têm despertado o interesse, principalmente, da comunidade de dinâmica, haja visto as últimas chamadas de vários congressos da área. Entretanto, a utilização destas técnicas como ferramentas Não-Destrutivas de Avaliação de Falhas carece de uma reavaliação, visto que a sua real aplicabilidade nesta área ainda é incerta. As várias propostas estudadas, apesar dos resultados satisfatórios, não se mostraram viável para aplicações práticas e se restringiram a testes de laboratórios. As técnicas discutidas no capítulo 3 são mais promissoras para a área de monitoramento e identificação de falhas a partir de medidas de sinais de vibração. A utilização de rede neurais, apesar da dependência que esta apresenta em relação a outras técnicas de pré-processamento, apresentam grande potencialidade de sucesso em aplicações práticas. Já para problemas de modelagem, as técnicas de ajuste de modelos se adaptam aos requisitos de projeto e têm um grande potencial, principalmente, naqueles componentes em que a modelagem por elementos finitos é deficiente como conexões, juntas e outros. A introdução dos efeitos de amortecimento na formulação do ajuste de modelos com a opção de correções dos parâmetros de amortecimento representa um grande avanço na área visto que o conhecimento prático dos mecanismo de amortecimento ainda é muito limitado. A utilização

unesp

de amortecimento não proporcional no ajuste poderá fornecer informações mais próximas do modelo real, inclusive, melhorar a modelagem de problemas envolvendo efeitos de juntas, estruturas com mais de um tipo de material cujos efeitos de amortecimento se comportam de forma distinta.

ETAPAS FUTURAS

Vários pontos merecem destaque para a continuidade deste trabalho tanto nas áreas de ajuste, como de identificação de falhas. Na área de identificação de falhas utilizando redes neurais existem dois aspectos importantes a serem melhor estudados. O primeiro esta diretamente relacionado com a melhoria da performance da rede, definição de uma estrutura ótima, estudar os problemas de convergência e aumento da velocidade de treinamento. Isso é muito importante para os casos de utilização *on line* da rede. O outro aspecto envolve o estudo e a definição de técnicas adequadas de pré-processamento (técnicas de redução) dos dados brutos para a geração dos padrões de treinamento da rede. Estas devem ser capazes de evidenciar os parâmetros e informações relevantes e transforma-los em um conjunto reduzido de dados contento apenas as informações suficientes para caracterizar comportamento do sistema de maneira correta. E finalmente, a partir dos conceitos e experiência adquirida com a implementação dos vários métodos discutidos neste trabalho propor a implementação do nível 4 que engloba os níveis anteriores juntamente com a predição do tempo de vida útil com base nas condições de funcionamento atuais da estrutura. Na área de ajuste de modelos um dos principais pontos a ser tratados é a verificação da aplicabilidade das técnicas de ajuste utilizando amortecimento não proporcional em situações práticas.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

ANEXO

P1



03 - 07 MARCH 1997

HOTEL DO FRADE

ANGRA DOS REIS - RIO DE JANEIRO - BRAZIL

SPONSORED BY

ABCM

Associação Brasileira de Ciências Mecânicas
Brazilian Society of Mechanical Sciences

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

AUTOMATION IN FAULT DETECTION USING NEURAL NETWORKS AND MODEL UPDATING

Lopes Jr., Vicente
Pereira, João Antonio
Fac.de Engenharia de Ilha Solteira -UNESP
Cx. Postal. 31 - Cep. 15385-000
Ilha Solteira- SP - Brasil

Weber, Hans Ingo
Fac. Eng. Mecânica de Campinas - UNICAMP
Cx. Postal 6051 - Cep. 13083-970
Cidade Universitaria - Campinas - SP - Brasil

EXTENDED ABSTRACT

Introduction

Non-Destructive Evaluation (NDE) tools using vibration measurement are gaining more and more importance in the context of operation condition monitoring and failure diagnosis of machines and equipments. They use the changes of the structural dynamic properties of the system, provoked by changes of the structural parameters occurred due to the damage, to evaluate the health condition and damage detection of the systems. The relative success and the potentiality demonstrated by these tools, mainly, those based on model updating techniques has shown that they are promising tools for damage detection purpose (Pereira, 1994; Hemez, 1993; Zimmerman, 1995). However, for purpose of monitoring, model updating based tools are still far to be consolidated. The recent literature has been shown some attempts to use permanently working monitoring systems, based on natural excitation source actuating in the structure, to evaluate its health condition (Rohrmann & Rucker, 1994) but the results are still limited.

Neural networks have recently been emerged as a promising tool for pattern recognition and can be applied for monitoring and fault detection in machine and equipment. In his case, neural networks may be designed to classify input patterns in pre-defined classes or to create categories of group patterns according to their similarity. One important feature of neural nets is their ability to model process and systems from actual data, and to respond in real time to the changes in the state of the system, provided by continuos sensor inputs. Other important characteristic, it is their inherent ability to operate on noisy, incomplete or sparse data and to model process from actual system parameters (Uhl, 1994). Hence this technique should facilitate fault identification in real time, providing a good NDE tool based on measured vibration data. Nevertheless, attempts to use neural networks have faced difficulties to generate reliable information to train the net. It demands a wide range of experimental tests to cover the whole possibility of damages which makes its use prohibitive.

This work presents an alternative propose that intents to exploit the capability of model updating techniques associated with neural network to investigate the state of operation and health condition of the system. In this case, the set of information used to feed the neural net during the training phase is generated from a very reliable updated finite element model, defined by using the concepts of model updating. The finite element model is initially adjusted and validated in terms of the dynamic measured data of the real system and later used to create the set of information of the system through a simulation of different types of damage conditions.

Methodology

Neural networks are made by a number of processing elements which are connected to form layers of neurons. Each neuron is a simple mathematical processing unit that when are interconnected, produces a complex structure and once trained, it can provide the ability to execute some tasks. The learning of the net is by examples. The pattern recognition of the damage signal, frequency response functions, used to feed the training of the net is provided by the reliable numerical model. The scheme of proposed diagnosis system is shown in figure 1.

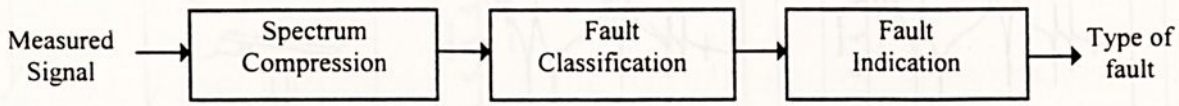


Figure 1: Scheme of the proposed diagnosis system

The first step in the diagnosis procedure consists in compression of the spectrum size for a reduced number of points. Two methods have been applied in this paper. In the first method the maximum amplitude is select and this point is used to construct a new signature. The second method searches the maximum points in the original signal for each frequency range early specified, i.e., around of the natural frequencies,and it is considered a range of 2.5% for each maximum point.

Frame Structure

To demonstrate the applicability of the propose, a laboratory spatial frame structure is investigated. An experimental modal analysis and a finite element model of the structure were carried out and compared aiming to define a representative numerical model able to predict the real behaviour of the structure. The comparison of modal parameters from both models shows a deviation of the predicted data from the experimental one, table 1 and figure 3.a. The spatial parameters of the finite element model, elements evolved into the welding connections, were updated successfully updated using a FRF based model updating procedure (Pereira, 1996) and, the correlation of the models was improved satisfactory, table 1. Figure 3.b shows the FRF in the drive point for the experimental test and the new reliable finite element model. Defined the reliable model, the network was trained to recognise damage in various regions (elements) of the structure.

Table 1: Experimental, Analytical and Updated models correlation

Experimental model		Analytical model		Updating model		Initial correlation		Final correlation (iteration 5)	
mode	freq. [Hz]	mode	freq. [Hz]	mode	freq. [Hz]	Δf [%]	MAC-val.	Δf [%]	MAC-val.
1	17.06	1	17.26	1	16.98	1.17	0.994	-0.43	0.995
2	22.10	2	25.30	2	22.38	14.47	0.991	1.26	0.991
3	42.44	3	43.86	3	42.73	3.34	0.990	0.68	0.990
4	97.54	4	102.06	4	97.04	5.71	0.978	-0.02	0.985
5	112.86	5	121.63	5	112.91	8.73	0.975	0.66	0.974
6	142.36	6	144.93	6	141.60	2.73	0.834	-0.53	0.881
7	153.83	7	155.03	7	153.71	0.78	0.954	-0.07	0.953
8	171.13	8	176.21	8	172.56	2.96	0.978	0.83	0.982

unesp

To simulate a real damage it was introduced a cut in a bar of the structure, see figure 02, and the procedure was used to recognise the damage. Table 2 shows the results for four damaged elements. The damage of element 21 is introduced in the real structure and the damage of elements 10, 25 and 28 were simulated numerically.

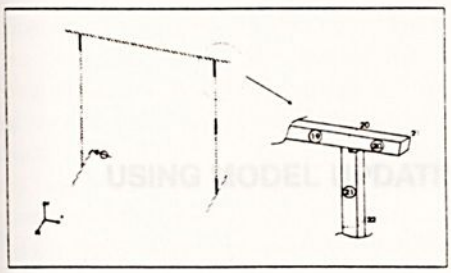
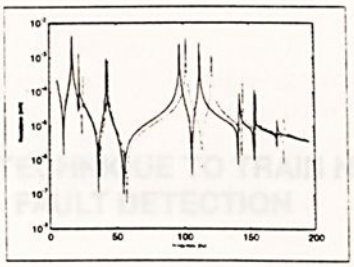
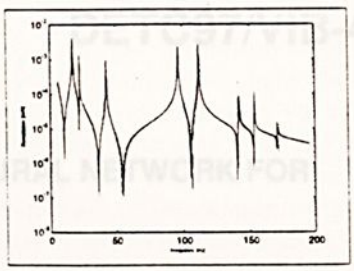


Figure 2: Frame structure - Detail of the cut bar



(a) before updating



(b) after updating

Figure 3: Experimental (full line) and analytical (dashed line) receptances (point 1, x-direction)

Table 2. Results obtained to compressed data

	undamaged	damage element 10	damage element 21	damage element 25	damage element 28
One point at the frequency peak	**9.5367e-006**	0.5691	0.2902	0.1903	0.4672
	0.0092	**8.6109e-006**	0.0244	0.0043	0.0063
	0.0558	1.8012e-004	**8.9917e-006**	0.0012	0.0208
	1.2064	0.9937	0.6471	**9.1820e-006**	1.1166
	1.0306	0.3374	0.2341	0.9504	**9.4408e-006**
Frequency band 2.5 %	**7.6229e-006**	0.0148	0.0196	0.5430	0.4652
	0.0789	**6.6129e-006**	7.1048e-004	2.0485	0.0242
	0.0383	0.0581	**8.5513e-006**	0.0045	0.5015
	0.5625	0.4271	0.4018	**9.4771e-006**	0.3311
	0.0700	0.4103	0.6801	1.2634	**9.9018e-006**

Discussion

The paper discusses the use of neural network, supported by a finite element model updating procedure in the training of the nets, for structural fault classification. Compressed data, considering one point at the frequency peak or a frequency range around of the frequency peak provided sufficient information to training the network. The criterion to define the optimum architecture of the net is not yet well defined since it does not comply with a systematic definition. However, the results seem to be better when the neurons number in the hidden layer is increase. The preliminary results show that the proposed methodology can be applied to classify an unknown signal in patterns beforehand fixed.

Proceedings of DETEC'97:
1997 ASME Design Technical Conferences
September 14-17, 1997, Sacramento, California

DETC97/VIB-4233

USING MODEL UPDATING TECHNIQUE TO TRAIN NEURAL NETWORK FOR FAULT DETECTION

Vicente Lopes Jr.
João Antonio Pereira
Dep. de Eng. Mecanica -UNESP, Ilha Solteira
Ilha Solteira, São Paulo 15385-000 - Brasil
e-mail: vicente@feis.unesp.br

Hans Ingo Weber
Fac. de Eng. Mecânica de Campinas - UNICAMP
Campinas, São Paulo 13083-970 - Brasil
e-mail: hans@mec.puc-rio.br

ABSTRACT

Vibration monitoring and fault detection of components in manufacturing plants involve a detailed analysis of a collection of vibration data in order to establish a correlation among changes of the measured data and the corresponding fault. This work presents an alternative proposal which intent is to exploit the capability of model updating techniques associated to neural networks to reduce the amount of measured data. The updating procedure supplies a reliable model that permits to simulate any damage condition, which allows to establish a direct correlation between the deviation of the response and the corresponding fault. The learning of the net is performed using a compressed spectrum signal created for each specific type of fault. Different fault conditions for a frame structure are evaluated using simulated data and finally, the capability of the proposal is demonstrated using experimental data.

KEYWORDS: Neural network; Predictive maintenance; Fault classification; Model updating

INTRODUCTION

Non-Destructive Evaluation (NDE) tools based on vibration measurement are gaining more and more importance in the context of operation condition monitoring and fault detection of machines and equipments. In a more conventional sense, they compare the monitored vibration level of the system, usually the response function, with a standard vibration level (undamaged system) aiming to identify changes in the actual system. Recent literature correlates some types of vibration signals with typical faults of the system trying to identify eventual faults in an early stage. Analysis of tendency, for example, is a well known technique that compares the vibration spectrum of each machine with a reference spectrum and evaluates the vibration magnitude changes of each spectrum at specified time intervals. However, in these classical pattern recognition techniques, a significant part of the analysis consists in the pre-processing and separation of the measured data in sets of data related with each kind of fault.

The establishment of a reliable relation among these sets of data and the different kinds of faults is regarded as the main problem in these techniques. Usually, this is performed by maintenance personal, monitoring and recording transducer signals and analysts that search the operating condition of the machine to detect incipient faults. Therefore, there is considerable motivation to design a robust system, that automatically performs this type of analysis in real time and in a reproducible manner.

Neural networks have recently emerged as a good tool for pattern recognition turning it in an promising tool for monitoring and fault classification of machines and equipments. In this case, the neural networks should be designed to classify the input patterns in pre-defined classes or to create categories of group patterns according to their similarity. An important feature of the neural networks, in this context, is their inherent ability to operate on noisy, incomplete or sparse data and to model process from actual system parameters (Uhl, 1994). The neural network will respond in real time to the changes in the system state, provided by continuous sensor inputs. Hence this technique should facilitate fault identification in real time, providing a good NDE tool based on measured vibration data. Nevertheless, several attempts to use neural networks faced difficulties to generate reliable information to train the net. It demands a wide range of experimental tests in the damaged system to

Copyright © 1997 by ASME

cover the whole possibility of damages which makes, its use prohibitive.

This work presents an alternative proposal to exploit the capability of neural network associating it with model updating technique to investigate the state of operation and health condition of the system. In this case, the set of information used to feed the neural net during the training phase is generated from a very reliable updated finite element model, created by using techniques of model updating (Larson, 1992; Lammens, 1994; Pereira, 1996). The finite element model is initially adjusted and validated in terms of the dynamic measured data of the real system and later used for simulations of different types of damage conditions, training the network.

The proposed approach is addressed to fault detection on the frequency analysis domain, but its application is similar for others kind of signal. In the frequency spectrum, the low level signal are not masked out by the presence of high level signal by using a log scale. Generally, each machine defect produces a set of vibration components that allows the recognition of different faults. In this case there are many others parameters that can be measured to evaluate the operation condition of a machine such as pressure, temperature, sound, oil particles, etc.

METHODOLOGY

An Artificial Neural Network (ANN) associated with a Model Updating Procedure (MUP) has been used to operate the monitoring and failure diagnosis of machines and equipments. The network is designed to classify the input patterns of the model in pre-defined classes of inputs or to create categories of group patterns according to their similarity. The updating approach is used to define a representative mathematical model of the system that permits to generate the various damage conditions necessary for the training of the network. So, the methodology leads to diagnose of the system in real time, facilitating identification of faults in the operating system.

The ANN comprises a set of neurons interconnected and organized in layers (Lippmann, 1987; Narenda,1990). It is made up of a given number of layers, where each one has a specified number of neurons. The interconnections are only among neurons of adjacent layers, and each node (neuron) belonging to a layer is connected to all neurons of the adjacent layers. All neurons connected directly to the inputs of the network belong to the same input layer. These neurons do not have offset. The neurons that furnish the network outputs also belong to a single layer, called the output layer. Other neurons are organized in one or more hidden layers. The number of neurons for input and output layers depends on a specific application. The choice of the number of layers and its dimension is based on preliminary tests, and the definition of an optimal choice is still under investigation among artificial intelligence researches (Bernieri, 1994, Worden and Tomlinson, 1994, Yuedong and Du, 1996).

The ANN learns by example and it is forced to furnish the desired outputs on the inputs supplied to it. This is carried out through learning algorithms, which suitably modify both the interconnection weight and the offset values (section 2.1). Once learning is completed, the neural network is supposed to respond like the system for the expected kind of inputs.

The classification and identification of the vibration signal generated from the improved finite element model is separated in three stages: I - separation of the vibration signals in signals of components operating normally and signals of components operating with fault; II - compression of the signals; III - classification of the compressed patterns using a backpropagation algorithm. The compression is an important issue in this methodology because it transforms a large set of data in an equivalent reduced set of data containing the same information, which decreases significantly the training time (Lopes Jr. and Turra, 1996).

Neural Network

An Artificial Neural Network (ANN) is made by a number of processing elements which are connected to form layers of neurons. Each neuron is a simple mathematical processing unit that, when it is interconnected, produces a complex structure with different architectures, that can be trained to recognize changes of the system. It is common to specify the architecture of the network by referring to the number of hidden layers; layers that are neither inputs nor outputs. Different sizes and topologies for the network were initially investigated in order to define the used network structure. Figure 1 shows the architecture used, it has one hidden layer with 500 neurons for an output layers with 11 neurons. Initially, various test were performed with networks of different sizes and topologies to define the used network structure. The training is performed such that outputs are a combination of 0 and 1 for each state of operation of the machine. For the intact structure, all neurons of the output layer are equal one.

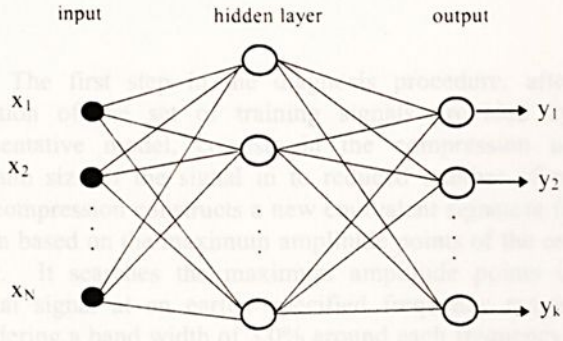


Figure 1: Architecture of the neural network with one hidden layer

Copyright © 1997 by ASME

The input x's are weighted by $W^h_{j,i}$ and by the bias b^h_j, and the result feed the hidden layer. The output of the j^{th} hidden unit can be described by:

$$y^h_j = F_1\left(b^h_j + \sum_{i=1}^{N} W^h_{i,j}.x_i \right) \qquad (1)$$

where the superscript (h) means that the quantities pertain to the hidden unit and $\mathbf{F}_1(\,.\,)$ is a sigmoid nonlinear function. The output of the net is biased and weighted by sum of the hidden layer outputs:

$$y_l = F_2\left(b^o_l + \sum_{j=1}^{H} W^o_{j,l}.y^h_j \right) \qquad l = 1, 2, \ldots, k \qquad (2)$$

the superscript (o) refers to the output unit, H is the number of units in the hidden layer and $\mathbf{F}_2(\,.\,)$ is a linear activation transfer function. The net is trained starting with a random set of weights and biases and calculating the output for every input set. Then, the error E is computed from the output layer backwards, which has historically been called the backpropagated error, and the learning algorithm the backpropagation. Details of this algorithm can be found in several publications (Hecht and Nielsen, 1990; Wasserman, 1989; Hush and Horne, 1993).

$$E = \text{sumsqr}(\{T\} - \{y\}) \qquad (3)$$

where sumsqr is the sum of squared of the elements and T is the desired output. The error E is formulated as a function of the weights and biases and then, the minimization is performed by means of the usual steepest algorithm. The error E is denoted by $\{\alpha_j\}$, where the index j taking on as many values as there are weights and biases. When the parameter α_j changes by $\delta\alpha_j$, the error E changes by

$$\delta E = \frac{\partial}{\partial \alpha_j}(E)\,\delta\alpha_j \qquad (4)$$

where $\frac{\delta}{\delta\alpha_j}(E)$ is evaluated using the current values of the parameter. To ensure that changes in α_j results in a decrease in E, it selects

$$\delta\alpha_j = -\eta \frac{\partial}{\partial\alpha_j}(E) \qquad (5)$$

where η is a positive constant. The parameter η determines how large a step is made in the direction of the steepest descent and therefore how quickly the optimum parameters are obtained. For this reason η is called the learning coefficient.

The training of the network uses a set of inputs for which a specified output is known and in this case, the process finishes when the error ***E*** is smaller than a desired value or it reaches a maximum specified number of iterations. In the later case, the training set is considered unsatisfactory. The error E considered here, is the sum of the squared error between the output value provided by the trained network and the value obtained for a specific input.

The learning of the net is performed by examples. The pattern recognition of the damage signal, the frequency response function, used to feed the training of the net is provided by a reliable numerical FE-model. Once the network is trained, it can execute any pattern recognition task. Figure 2 shows the proposed scheme of using neural network in a diagnostic system.

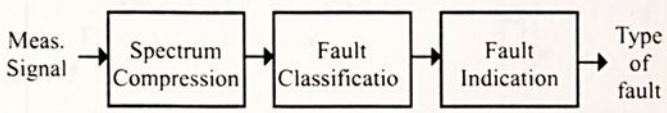


Figure 2: Scheme of proposed diagnostic system

The first step in the diagnosis procedure, after the definition of the set of training signals provided by the representative model, consists in the compression of the spectrum size of the signal in to reduced number of points. This compression constructs a new equivalent signature for the system based on the maximum amplitude points of the original signal. It searches the maximum amplitude points in the original signal at an earlier specified frequency range, i.e., considering a band width of 3.0% around each frequency point related with a maximum amplitude point.

Copyright © 1997 by ASME

Model Updating Procedure

The MUP used to improve the original finite element model is based on the measured frequency response functions (FRF(s)). A detailed discussion can be found in Lammens, 1995 and Pereira, 1996. The procedure operates at an element level and the model changes are directly related to the variation of the parameters of each element. It describes the discrepancy between analytical and experimental models as a force residue written in terms of the analytical dynamic stiffness matrix $[Z^A]$, and the experimental FRF matrix $[H^X]$.

$$\{\varepsilon\} = \mathcal{E}\left(\left[Z^A(p_1 + \Delta p_1, , \ldots, p_m + \Delta p_m)\right], \{H^X\}\right) \cong \{0\} \quad (6)$$

This discrepancy of the models is used to define the updating set of equations and the solution of the updating problem consists in finding m analytical parameter changes that minimizes the difference between the two models. The p-parameters can represent any physical or geometrical property of the model, they can be a parameter of an element in the case of the elements being adjusted independently or a parameter of a set of elements when some elements are adjusted proportionally. The Dp's are parameters correction of the p-parameters that minimize the discrepancy between the two models. The formulation of an approximated solution of the problem, through a first order linearization of the expression (6) in the p-parameters, leads an overdetermined set of linear equations:

$$\{\varepsilon\} = [S]\{\Delta p\} - \{B\} \quad (7)$$

where the elements of the sensitivity matrix [S] and these of the difference vector {B} are known elements. They are obtained from the analytical dynamic stiffness matrix and the experimental measured frequency response functions at each selected measured frequency points respectively. The elements of the vector {Dp} are unknown parameter corrections to be estimated. The solution of this system of linearised equations system provides an improved analytical model. If the discrepancy between the models is not yet sufficiently small, the procedure is iteratively repeated.

IMPROVED MODEL AND TRAINING DATA

To demonstrate the applicability of the proposed methodology, a laboratory spatial frame structure, Figure 3, was investigated. An analytical modeling by finite elements and a modal test of the structure were carried out and compared aiming to define a representative analytical-numerical model able to predict the real behaviour of the structure. The initial comparison of modal parameters from both, analytical and experimental models, showed a deviation of the predicted data from the experimental one, Table 1 and Figure 4.a. The adjustment of the analytical finite element model and the consequent improvement of the correlation of the models was performed by a FRF based model updating procedure (Pereira 1996). The spatial parameters of the finite element model were successfully updated by using the FRF based model updating and, the correlation of the models was improved satisfactory, table 1. The elements selected to be adjusted during the updating process were those elements evolved into the welding connections. Figure 4.b shows the superposition of the FRF(s) in the drive point for the experimental test and the corresponding new reliable finite element model. Defined this reliable finite element model, a wide range of damage possibility was simulated by using this model in order to generate informations for the training of the network. Additionally a real damage condition was introduced in the structure, i.e., a deep cut was done in a bar (see Figure 03). This damage condition was used to demonstrate the capability of the methodology to recognize a real damage from a set of simulated damage conditions.

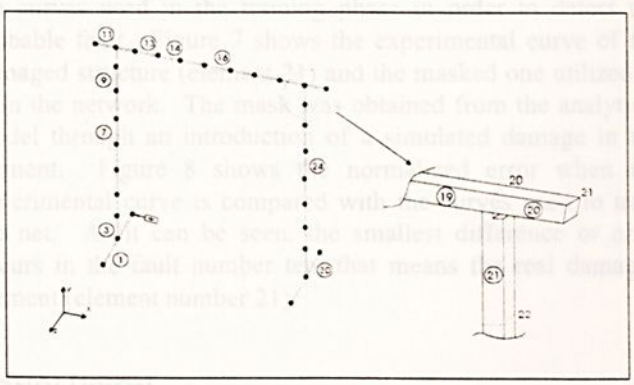


Figure 3: Frame structure - Detail of the cut bar

Table 1: Correlation of the Models

Experimental model		Analytical model		Updated model		Initial correlation		Final correlation (iteration 5)	
mode	freq. [Hz]	mode	freq. [Hz]	mode	freq. [Hz]	Δf [%]	MAC-val.	Δf [%]	MAC-va
1	17.06	1	17.26	1	16.98	1.17	0.994	-0.43	0.995
2	22.10	2	25.30	2	22.38	14.47	0.991	1.26	0.991
3	42.44	3	43.86	3	42.73	3.34	0.990	0.68	0.990
4	97.54	4	102.06	4	97.04	5.71	0.978	-0.02	0.985
5	112.86	5	121.63	5	112.91	8.73	0.975	0.66	0.974
6	142.36	6	144.93	6	141.60	2.73	0.834	-0.53	0.881
7	153.83	7	155.03	7	153.71	0.78	0.954	-0.07	0.953
8	171.13	8	176.21	8	172.56	2.96	0.978	0.83	0.982

Copyright © 1997 by ASME

RESULTS

Different damage conditions of the structure were obtained numerically by using the updated model of the structure. A frequency range covering the first eleven mode shapes of the structure was analyzed. For each damaged element a set of FRF(s) was created which contains the whole informations used to feed the training of the network. The training was based on a compressed set of data obtained from the original ones. A compression method based on the maximum amplitudes of the spectrum signal was used to reduce the number of points of the signal, and to construct a new equivalent signature for the system. The compression method localizes the frequency points related with the maximum amplitudes and creates a masked signal with a band width of 3% of the frequency points of maximum amplitudes. This permits to comprise small deviations of the measured FRF(s) since, in real world, it is almost impossible to calculate a FRF that matches exactly the measured one, due to problems related with the modeling approach as well as the experimental test. The following procedure tries to associate the compressed signal response with a set of specific faults.

Figure 5.a-b shows the original measured FRF (512 points) and the compressed or masked curve (57 points) for the intact frame structure and the damaged structure (element 13) respectively. The number of points of the compressed signal depends on the number of frequencies point related with the maximum amplitude peaks of the signal.

The frame structure, in this analysis, was divided in 30 elements and each element was likely to be damaged. However, in real cases, the analyst usually may have previous information of the elements or region more susceptible to failure and they should take into account this information to search the damaged element. In this case, various elements were investigated, elements of low probability to failure (elements in the mid of bars), elements more liable to failure (elements in the welding connections) and elements of very low sensitivity to the damage. The network was trained to recognize damaged elements through the identification of a set of FRF(s) associated each kind of damage. Elements 3, 7, 9, 11, 13, 14, 16, 20, 21 and 24 were selected to be investigated. Each fault consisted of a reduction of 50% of the sectional area of the associated element. Figures 6.a-6.f give an overview of the error for some investigated faults. Fault number one is related with the intact structure (without damage), fault number two is related with a damage in the element 3, fault number three with a damage in the element 7 and so on. The plots of Figure 6 show the error, normalized in relation to the minor component, among a specific "measured" curve and all damaged curve used in the training of the network. The error is obtained by comparing the output data calculated for the damaged structure (fault in an element) with the output data obtained from the training of the net. As expected in this case, all faults as well as the intact condition of the structure were clearly identified since the network was trained based on these curves. The identification of the damaged element in figure 6.e is not very clear since the error for element 11 (fault nr. 5) is very low too. It happens because elements 11 and 20, due their position in the structure, have few influence in the dynamic behaviour of the model, and even a very large damage in these elements does not affect the dynamic properties of the model. Therefore, the recognition of these faults, based on the changes of the dynamic properties of the model, is a difficult task.

In the above investigated case, the data of the damaged structure was created through the same numerical model used to train the network. Thus, the simulated data used in the training of the net and the "experimental" data of the damaged structure are identical. However, for a real case the experimental measurement data present a light difference in relation to the simulated data used to train the network, turning more difficult the comparison of the data and the recognition of the fault. Hence the compression of the measured data is performed in two stages aiming to comprise this light difference. Initially, the measured FRF curve is compared with the simulated compressed curves utilized to train the network aiming to define if the frequency band of the simulated compressed data include the frequency points of maximum amplitude of the measured curve. If the points are within the frequency band of the simulated curve, the procedure uses the same points of frequency used in training phase to compress the measured signal. In sequence the signal is compared with the curves used in the training phase in order to detect the probable fault. Figure 7 shows the experimental curve of the damaged structure (element 21) and the masked one utilized to train the network. The mask was obtained from the analytical model through an introduction of a simulated damage in the element. Figure 8 shows the normalized error when the experimental curve is compared with the curves used to train the net. As it can be seen, the smallest difference or error occurs in the fault number ten, that means the real damaged element (element number 21)

CONCLUSION

The paper discusses the use of neural networks for fault classification in machine associated with a model updating technique. The updating procedure generates the set of information about the state condition of the structure. A compression method based on the maximum amplitudes of the spectrum signal reduces the number of point of the original signal creating an equivalent signature for the system. These new compressed signals were used to feed the net during the training phase. The compressed data, considering a range of 3% of frequency point around the points of maximum amplitudes, seems to be adequate because it comprises small variations in experimental measurements. The architecture of the network was defined by tests, a systematic criterion to define the optimum architecture of the net is not yet well defined since it does not comply with a systematic definition.

Copyright © 1997 by ASME



However, the results seem to be better when the neurons number in the hidden layer increase. The preliminary results show that the proposed methodology can be applied to classify an unknown signal in patterns fixed beforehand. The procedure successfully identified the damaged element for all simulated test cases as well as for the experimental test.

REFERENCES

Bernieri, A. at all; "A Neural Network Approach for Identification and Fault Diagnosis on Dynamic Systems," *IEEE Trans. on Instrumentation and Meas.*, vol. 43, nº 6 pp. 867-873, Dec./94.

Hecht-Nielsen R.; *Neurocomputing* - Addison-Wesley Publishing Company, 1990.

Hush D.R. and Horne, B.G.; "Progress in Supervised Neural Networks - What's New Since Lippmann," -*IEEE Signal Proc. Mag.*, pp. 8-39 - Jan./1993.

Lammens. S., "*Frequency Response Based Validation of Dynamic Structural Finite Element Models*," Ph.D., Thesis, Katholieke Universiteit Leuven, Belgium, 1995.

Larsson, P. O., Sas, P., "Model Updating Based on Forced Vibration Testing Using Numerically Stable Formulations," Proceedings of the X-IMAC, 1992.

Lippmann, R.P.; "An Introduction to Computing with Neural Nets," *IEEE - ASSP Magazine*, pp. 4-22, April/87

Lopes Jr., V. and Turra, A. E., "Diagnosis of Rotating Systems Using Artificial Neural Networks", Application of Artificial Intelligence in Engineering XI, includes CD Rom - Computational Mechanics Publications, Sep. 1996.

Narenda, K.S. and Parthasarathy, K.; "Identification and Control Dynamical Systems Using Neural Networks," *IEEE Trans. on Neural Networks*, vol. 1, nº 1 pp. 4-24, March 90.

Pereira, J. A., "*Structural Damage Detection Methodology using a Model Updating Procedure based on Frequency Response Functions - FRF(s),"* Tese de Doutorado, Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Campinas, 1996.

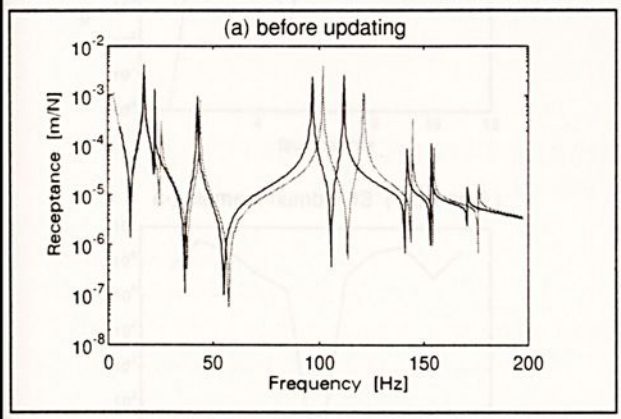
Uhl,T.; "Automation of monitoring and diagnostic process for rotating machinery using neural networks," *ISMA - Intern. Seminar of Modal Analysis* - Leuven, Belgium, Sept./94.

Yuedong, C., and Du, R.; "Artificial Neural Network Architecture Design Using Similarity Measure with Applications in Engineering Monitoring and Diagnosis," *ASME Journal of Dynamic System, Measurement, and Control*, , vol 118, pp. 635-639, sept. 1996.

Wasserman, P.D. *Neural Computing: Theory and Practice* - Van Nostrand Reinhold, 1989.

Warden, K. and Tomlinson G. R.; " Modeling and Classification of Non-linear System Using Neural Networks," Mechanical Systems and Signal Processing, pp. 319-356, 1994.

Copyright © 1997 by ASME



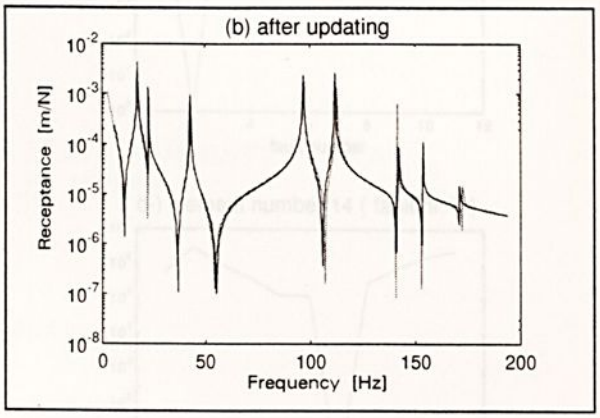
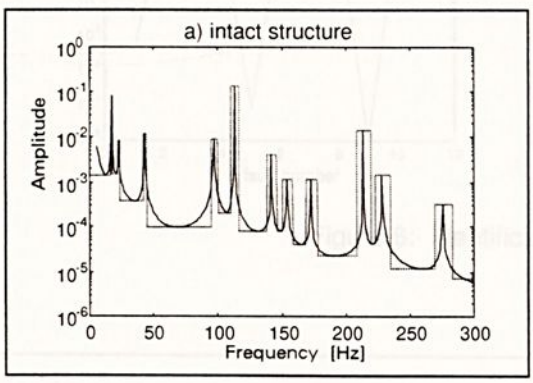


Figure 4: Experimental (full line) and analytical (dashed line) receptances (point 1, x-direction)



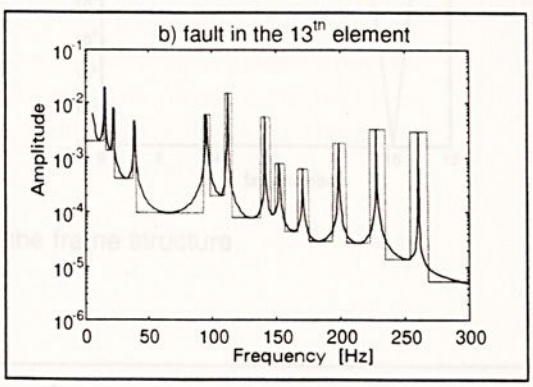


Figure 5: Original (full line) and compressed (dotted line) signal

Copyright © 1997 by ASME

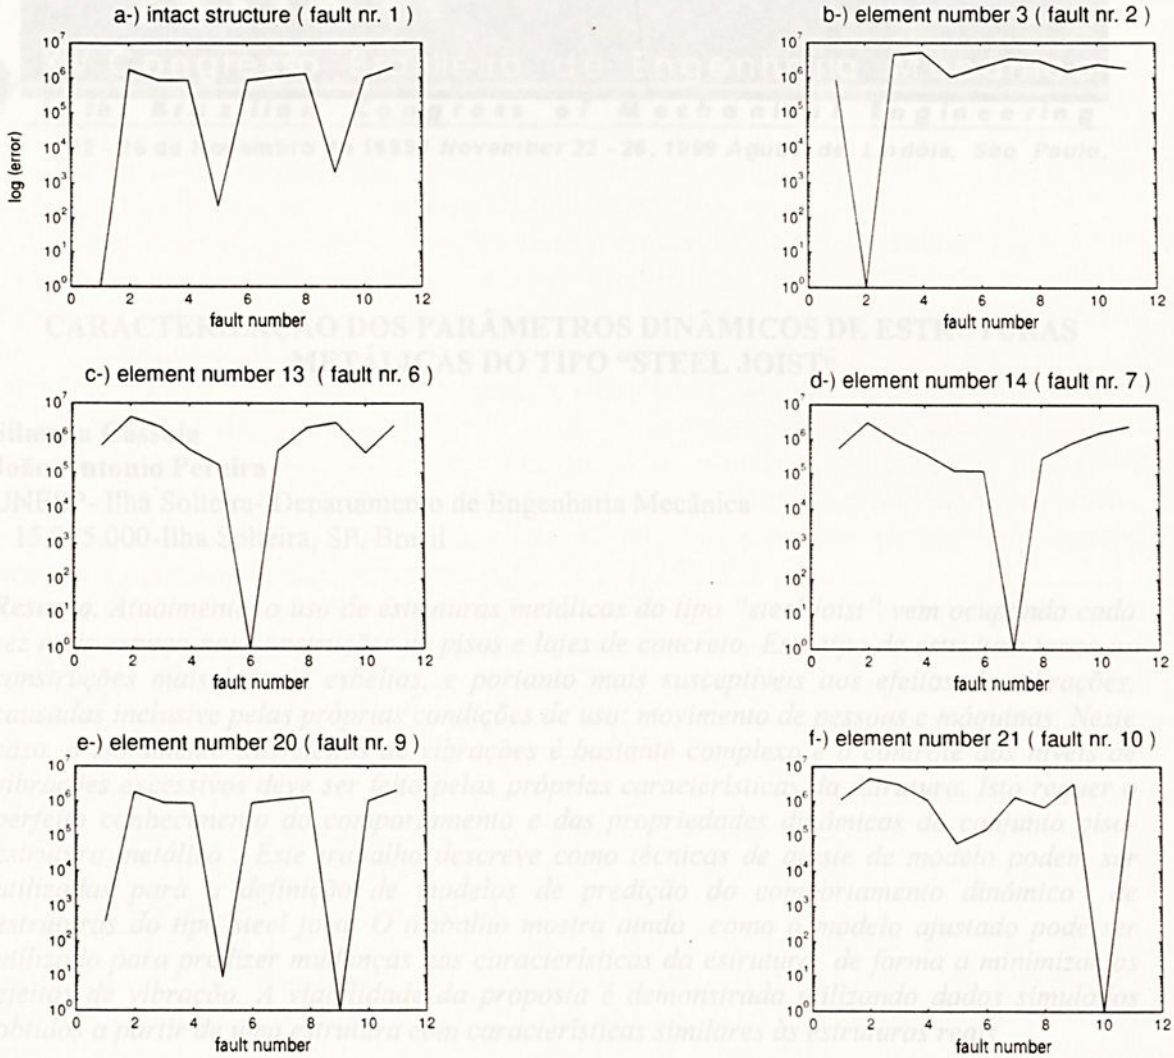


Figure 6: Identification of the fault in the frame structure

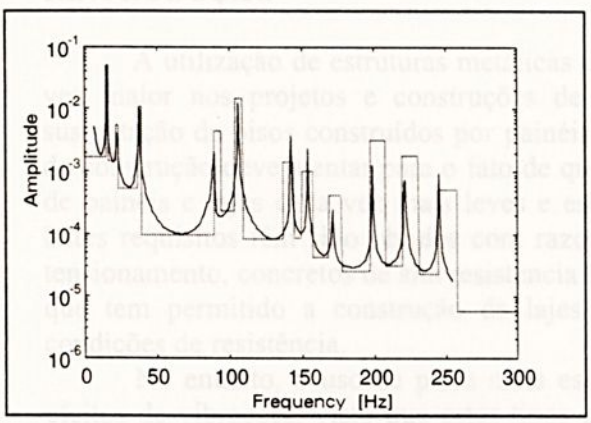


Figure 7: Original (full line) and compressed (doted line) response signal

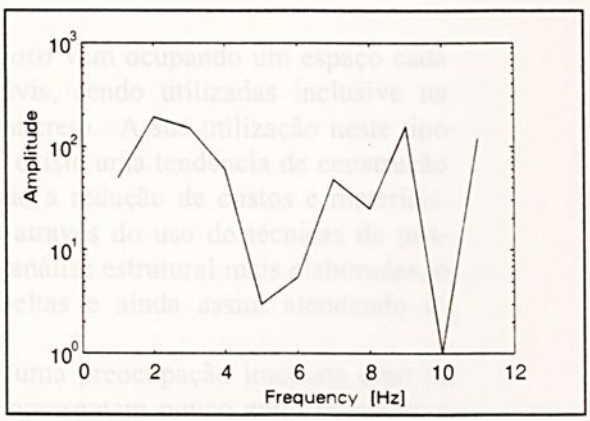


Figure 8: Identified error among the curves

Copyright © 1997 by ASME

P3

XV Congresso Brasileiro de Engenharia Mecânica
15th Brazilian Congress of Mechanical Engineering
22 - 26 de Novembro de 1999 / November 22 - 26, 1999 Águas de Lindóia, São Paulo.

CARACTERIZAÇÃO DOS PARÂMETROS DINÂMICOS DE ESTRUTURAS METÁLICAS DO TIPO "STEEL JOIST"

Silmara Cassola
João Antonio Pereira
UNESP- Ilha Solteira- Departamento de Engenharia Mecânica
15.385.000-Ilha Solteira, SP, Brasil

Resumo. *Atualmente, o uso de estruturas metálicas do tipo "steel joist" vem ocupando cada vez mais espaço nas construções de pisos e lajes de concreto. Este tipo de estrutura torna as construções mais leves e esbeltas, e portanto mais susceptíveis aos efeitos de vibrações, causadas inclusive pelas próprias condições de uso: movimento de pessoas e máquinas. Neste caso, o isolamento dos efeitos de vibrações é bastante complexo e o controle dos níveis de vibrações excessivos deve ser feito pelas próprias características da estrutura. Isto requer o perfeito conhecimento do comportamento e das propriedades dinâmicas do conjunto piso-estrutura metálica . Este trabalho descreve como técnicas de ajuste de modelo podem ser utilizadas para a definição de modelos de predição do comportamento dinâmico de estruturas do tipo steel joist. O trabalho mostra ainda como o modelo ajustado pode ser utilizado para predizer mudanças nas características da estrutura de forma a minimizar os efeitos de vibração. A viabilidade da proposta é demonstrada utilizando dados simulados obtidos a partir de uma estrutura com características similares às estruturas reais.*

Palavras-chave: *Steel joist*, Elementos finitos, Análise modal, Análise de sensibilidade, Ajuste de modelo

1.INTRODUÇÃO

A utilização de estruturas metálicas do tipo *steel joist* vem ocupando um espaço cada vez maior nos projetos e construções de estruturas civis, sendo utilizadas inclusive na sustentação de pisos construídos por painéis e lajes de concreto. A sua utilização neste tipo de construção deve atentar para o fato de que atualmente existe uma tendência de construção de painéis e lajes cada vez mais leves e esbeltos, visando a redução de custos e materiais. Estes requisitos têm sido obtidos com razoável sucesso através do uso de técnicas de pós-tensionamento, concretos de alta resistência e técnicas de análise estrutural mais elaboradas, o que tem permitido a construção de lajes bastante esbeltas e ainda assim atendendo às condições de resistência.

No entanto, o uso de pisos mais esbeltos leva a uma preocupação imediata com os efeitos de vibrações, visto que estes tipos de estruturas apresentam pouco amortecimento e freqüências características na mesma faixa de freqüência de excitações "típicas" identificadas em situações corriqueiras de uso, tais como movimento das pessoas durante suas atividades,

unesp

deslocamento de mobília, etc. Estas excitações podem levar a problemas de vibrações excessivas e o seu controle ou isolamento é bastante complexo, uma vez que a fonte de excitação e os sensores são os mesmos, ou seja, as pessoas.

Neste caso, os níveis de vibrações devem ser controlados pelas próprias características da estrutura através de alterações em suas propriedades físicas (tipo de material) e/ou geométricas (tipos de perfis, variação das seções transversais, etc.). Consequentemente, o estudo do comportamento dinâmico torna-se obrigatório para essas estruturas visto que, o conhecimento dos seus parâmetros modais (freqüência natural, modo próprio e fator de amortecimento) é fundamental para o projeto e desenvolvimento de uma estrutura mais adequada às suas condições de uso. Os níveis de vibrações do conjunto piso-estrutura metálica, sentidos pelos usuários, não devem exceder os valores especificados em norma. As normas classificam estes níveis em: imperceptível, levemente perceptível, claramente perceptível, desagradável e intolerável (CEB N.209, 1991).

A utilização de técnicas mais atuais de projetos, como o método dos elementos finitos, tem permitido analisar o comportamento dinâmico deste tipo de estrutura levando em consideração os efeitos de vibrações. No entanto, a modelagem dinâmica de estruturas de engenharia civil por elementos finitos ainda requer cuidados especiais e várias hipóteses e simplificações, usualmente adotadas neste tipo de análise, podem levar a resultados muito discrepantes em relação às situações reais. Isto é, o modelo analítico pode não representar adequadamente a estrutura real. Portanto, existe a necessidade de se desenvolver um modelo de elementos finitos detalhado da estrutura a fim de se obter uma solução mais realística quando se deseja definir um modelo de predição confiável.

Modelos mais representativos podem ser obtidos através do uso, de forma complementar, da modelagem de elementos finitos (MEF), testes de análise modal experimental (AME), juntamente com técnicas de correlação e ajuste de modelo de elementos finitos (Friswell e Mottershead, 1995, Pereira, 1996). Atualmente, vários estudos vêm sendo realizados, principalmente nos países desenvolvidos, a respeito da aplicação destas técnicas na modelagem e análise do problema de vibração em estruturas de engenharia civil (Reynolds et al., 1998; Cantieni et al., 1998). No Brasil, este assunto está ainda iniciando mas já existe um grande interesse das empresas neste tipo de análise. Trabalhos como Fusco (1996) e Bonilha (1997), estão voltados diretamente para o problema de vibrações em estruturas causadas por pessoas.

Este artigo descreve como a modelagem por elementos finitos e análise modal podem ser utilizadas para a definição de um modelo de predição representativo do modelo real. Técnicas de correlação e comparação de modelos são utilizadas para melhorar o entendimento e consequentemente, o ajuste ou a correção da discrepância entre a modelagem de elementos finitos e os dados experimentais de análise modal. A necessidade do uso de modelos representativos para o estudo e predição dos efeitos de vibração em estruturas de sustentação de lajes e pisos em edificações é demonstrada utilizando dados simulados de uma estrutura do tipo *steel joist*. Um estudo de sensibilidade dos parâmetros do modelo também é apresentado, visando fornecer subsídios que permitam deslocar as freqüências naturais da estrutura da faixa de freqüências de excitações típicas causadas pelas atividades de uso.

2. ANÁLISE DE SENSIBILIDADE E AJUSTE DE MODELO

Nas últimas décadas, técnicas de ajuste de modelo baseadas em dados experimentais têm sido objeto de amplo estudo. Referências relevantes sobre o assunto podem ser encontradas em vários artigos, por exemplo Mottershead e Friswel (1993), Natke (1997) e Maia e Silva (1997).

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

seja, os ω_i's. Os elementos do vetor $\{\Delta p\}$ são incógnitas a serem estimadas. A solução do sistema de equações linearizadas fornece um modelo analítico corrigido. Se a discrepância entre os modelos não for ainda suficientemente pequena, o processo é iterativamente repetido.

As técnicas de análise de sensibilidade são utilizadas como subsídios nos processos de ajuste de modelos, elas permitem estimar quais componentes e parâmetros da estrutura são mais ou menos sensíveis às variações. No processo de ajuste, bem como no estudo de predição dos efeitos dinâmicos da estrutura (por exemplo produzir um deslocamento das freqüências naturais do modelo para evitar uma faixa freqüência indesejada), esta é uma informação importante, porque permite uma seleção adequada de quais parâmetros devem ser mudados.

A sensibilidade das freqüências características do modelo em relação a um parâmetro $\{p\}$ é calculada como a variação desta quantidade em relação a uma pequena variação deste parâmetro. A sensibilidade de primeira ordem da r-ésima autofreqüência λ_r em relação a um parâmetro $\{p\}$ é dada pela bem conhecida expressão:

$$\frac{\partial \lambda_r}{\partial p} = \{\psi\}_r^T \frac{\partial [K]}{\partial p} \{\psi\}_r - \lambda_r \{\psi\}_r^T \frac{\partial [M]}{\partial p} \{\psi\}_r \qquad (3)$$

onde: $\{\psi\}_r^T$ - autovetores
$[M]$ - matriz de massa
$[K]$ - matriz de rigidez

A avaliação da sensibilidade dos parâmetros é feita através de uma rotina implementada juntamente com o programa de ajuste de modelo. Os próximos tópicos discutem a aplicação da proposta para um exemplo simulado.

3. APLICAÇÃO DA PROPOSTA PARA A ESTRUTURA

A estrutura estudada foi uma viga metálica do tipo *steel joist*, com 15 m de comprimento e 0.50 m de altura. Banzos paralelos e extremidades em diagonais (SJI-Technical Digest), Fig. 1. Os banzos são compostos por perfis laminados em cantoneira dupla de abas desiguais, e as diagonais, em ferro redondo soldado nos banzos.

O modelo analítico da estrutura foi elaborado utilizando o método dos elementos finitos, a estrutura foi discretizada em vários elementos bi-nodais considerando como nós a ligação dos banzos com as diagonais. Foi usado elemento tipo viga (beam) tridimensional com 6 graus de liberdade por nó, de forma que os elementos podem sofrer efeitos de compressão/tração, flexão e torção. As restrições foram colocadas nas duas extremidades superiores da estrutura, ficando livres, em ambas, as rotações em *z*, e o deslocamento em *x*, em apenas uma extremidade.

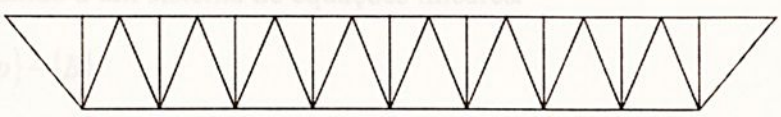


Figura 1 - Estrutura *Steel Joist* Estudada

O processo de ajuste de modelos busca corrigir as imperfeições do modelo analítico, obtido geralmente por elementos finitos, minimizando a diferença dos dados calculados com relação aos dados medidos no modelo real. O principal objetivo é definir um modelo analítico e confiável representativo do modelo experimental. A flexibilidade do modelo analítico permitirá prever o comportamento do sistema em diferentes condições bem como prever eventuais mudanças no modelo original.

As técnicas de ajuste de modelo, no sentido mais amplo, têm sido usadas para a obtenção de um modelo analítico o mais próximo possível do modelo experimental. Neste caso, o modelo experimental é comparado com o modelo analítico através de técnicas de correlação de parâmetros, e quando a concordância não é satisfatória o modelo analítico inicial é corrigido com base nos dados experimentais (Berman e Flannelly, 1971; Heylen, 1987; Larsson e Sas, 1992; Lin e Ewins, 1994; Pereira, 1996; Natke, 1997). Dependendo da estratégia matemática utilizada na formulação do problema e do tipo de parâmetros utilizados no ajuste, os métodos são classificados em diferentes categorias. Neste trabalho o problema de ajuste será formulado com base nas Funções de Resposta em Freqüência- FRF(s) (Larsson e Sas, 1992; Pereira, 1996), e as variáveis de ajuste são parâmetros físicos e/ou geométricos do modelo.

Neste caso, a discrepância entre os modelos é avaliada a partir de um balanço de força e a diferença entre os dados analíticos e experimentais é descrita em termos de uma função resíduo. O resíduo obtido neste caso é definido em termos dos parâmetros do modelo analítico (matriz de rigidez dinâmica $\left[Z^A(\{p\})\right]$) e dos dados experimentais (FRF(s)), Expressão (1). Para uma perfeita correlação entre os modelos os valores de $\{\Delta p\}$ são nulos, no entanto, em situações práticas isto não ocorre visto que os dados experimentais não estão perfeitamente correlacionados com os dados analíticos. A solução do problema é estimada neste caso através da correção dos p-parâmetros do modelo de forma que minimize a discrepância entre eles.

$$\{\varepsilon\} = \mathrm{E}\left(\left[Z^A(p_1 + \Delta p_1, p_2 + \Delta p_2, \ldots, p_m + \Delta p_m)\right], \left\{H^x(\omega_i)\right\}\right) \cong \{0\} \qquad (1)$$

Um conjunto de equações de ajuste é definido a partir da seleção de n-pontos de freqüência (ω_i) e a solução do problema consiste em encontrar m mudanças nos parâmetros analíticos que minimizam a diferença entre os modelos. Os p-parâmetros podem representar qualquer propriedade física ou geométrica do modelo, eles podem ser um parâmetro de um elemento, no caso dos elementos ajustados independentemente, ou um parâmetro de um grupo de elementos, quando alguns elementos são ajustados proporcionalmente.

Em geral, os critérios adotados para comparar os modelos levam a um conjunto de equações não lineares em relação aos parâmetros de ajuste selecionados $\{p\}$. Dependendo do tipo de parâmetros selecionados, a solução das equações torna-se muito complexa ou pode não existir. A linearização destas equações, para a maioria dos sistemas físicos, é uma suposição válida nas faixas de freqüências de interesse para análises de vibração. Uma solução aproximada do problema é obtida através da linearização da Expressão (1) nos p-parâmetros, conduzindo a um sistema de equações lineares.

$$\{\varepsilon\} = [S]\{\Delta p\} - \{B\} \qquad (2)$$

onde os elementos da matriz sensibilidade $[S]$ e do vetor diferença $\{B\}$ são conhecidos. Eles são obtidos a partir da matriz de rigidez dinâmica do modelo analítico e das funções de resposta em freqüência medidas na estrutura para n-pontos de freqüência selecionados, ou

unesp

Os parâmetros modais da estrutura foram obtidos através de um programa de elementos finitos parte do software de ajuste de modelo, **Pro**gram of **M**odel **U**padting - PROMU (Pereira, 1996) desenvolvido e implementado pelos autores. A Tabela 1 mostra as primeiras freqüências naturais do modelo. Como pode ser observado, a estrutura apresenta baixas freqüências que coincidem com a faixa das freqüências de excitação típicas verificadas durante as condições de uso de estruturas para sustentação de pisos de lajes. Uma pessoa caminhando pode excitar freqüências na faixa de 1,7 a 2,3 Hz (CEB N.209, 1991). O modelo analítico original da estrutura foi utilizado para simular os dados "experimentais" a serem utilizados na processo de ajuste, FRF(s), freqüências naturais e modos próprios. Uma vez definido os dados experimentais, um novo modelo foi criado introduzindo-se mudanças conhecidas nos parâmetros geométricos (momento de inércia na direção y) do modelo original. Este novo modelo representa o modelo analítico cujos parâmetros modais são discrepantes em relação ao modelo experimental. A Tabela 1 mostra a comparação do modelo analítico com os dados "experimentais", a coluna 5 apresenta as diferenças de freqüências e a coluna 6, a comparação dos modos (Mac-valores). Mac-valores próximo de 1 significa que os modos estão bem correlacionados, enquanto que Mac-valores próximos de zero significa total ausência de correlação entre os modos comparados.

Tabela 1. Comparação das FRF(s) dos modelos experimental e analítico

Experimental	Analítico	Fx(Hz)	Fa(Hz)	df(%)	Mac(%)
1	1	1,2	1,5	17,77	99,7
2	2	3,4	3,9	14,09	99,5
3	3	6,6	7,4	11,19	99,1
4	4	7,6	7,9	3,34	99,5
5	5	8,2	8,2	0,01	91,5
6	6	9,9	10,2	3,07	99,1
7	7	10,9	11,9	8,66	98,6
8	8	11,8	12,3	4,34	98,9
9	9	14,9	15,7	5,33	98,6
10	10	16,3	17,5	7,40	98,4
11	11	19,3	20,4	5,64	98,3

No exemplo em discussão, um dos objetivos seria investigar formas de alterar as primeiras freqüências do modelo visando sair da faixa de freqüências de excitação típicas encontradas neste tipo de estrutura. Para tal, fez-se uma análise de sensibilidade da estrutura em relação aos seus parâmetros geométricos, variação da inércia na direção y e na direção z. A Figura 2 mostra a variação de sensibilidade da estrutura em relação aos parâmetros Iy para o primeiro modo, e a Fig. 3 mostra um mapa (contornos) da sensibilidade para os dois primeiros modos.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

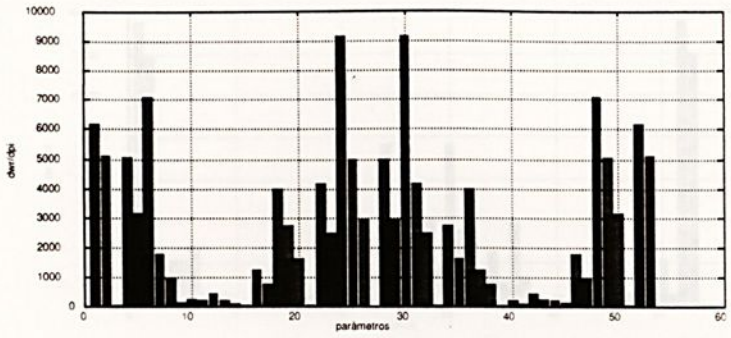


Figura 2 - Sensibilidade da estrutura : primeira freqüência - modelo analítico

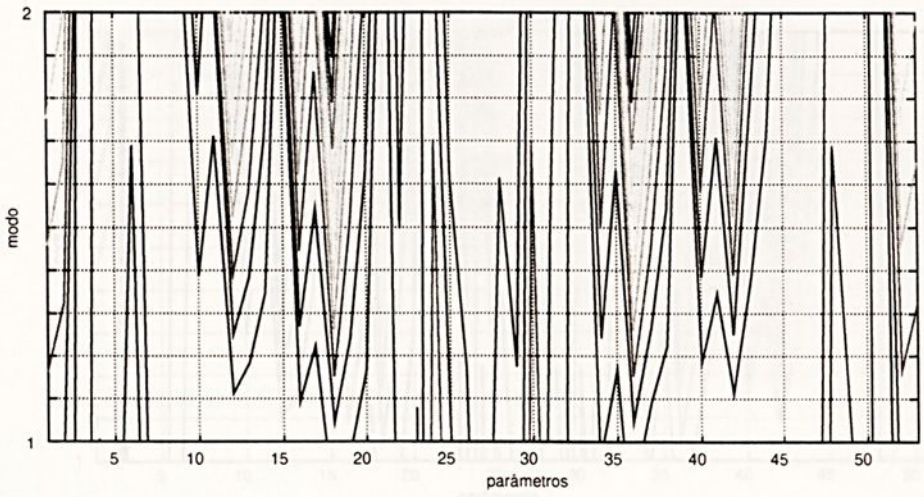


Figura 3 - Sensibilidade da estrutura : duas primeiras freqüências - modelo analítico

Analisando a Figura 2 e a Figura 3, pode-se notar que os parâmetros mais sensíveis são os parâmetros relacionados com os elementos centrais do modelo. No caso de se desejar aumentar as primeiras freqüências do modelo, isto sugere que esta região da estrutura seria a mais adequada para ser alterada. Uma alteração nesta região provavelmente produzirá grandes variações nas primeiras freqüências do modelo levando ao resultado desejado. No entanto, em situações reais essa avaliação pode ser disfarçada visto que o modelo analítico nem sempre é uma boa representação dos dados experimentais e pode levar a informações errôneas, como será discutido a seguir.

Para o exemplo em questão (dados simulados) existe a disponibilidade das matrizes de massa e rigidez do modelo experimental, o que permite checar as informações obtidas na Fig. 2 e na Fig. 3. Utilizando agora as matrizes do modelo original calculou-se as sensibilidades dos parâmetros do modelo em relação às freqüências. A Figura 4 e a Figura 5 mostram a variação da sensibilidade para os mesmos parâmetros utilizados anteriormente.

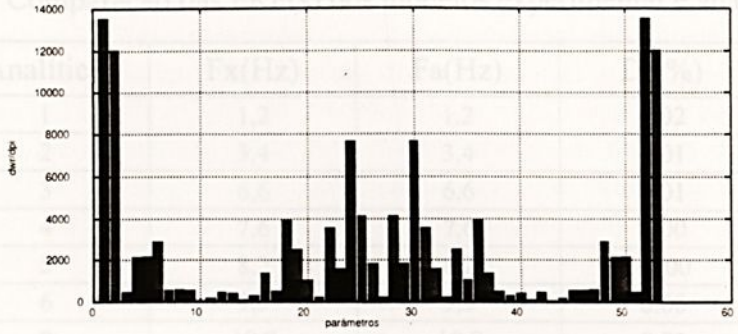


Figura 4 - Sensibilidade da estrutura : primeira freqüência - modelo original

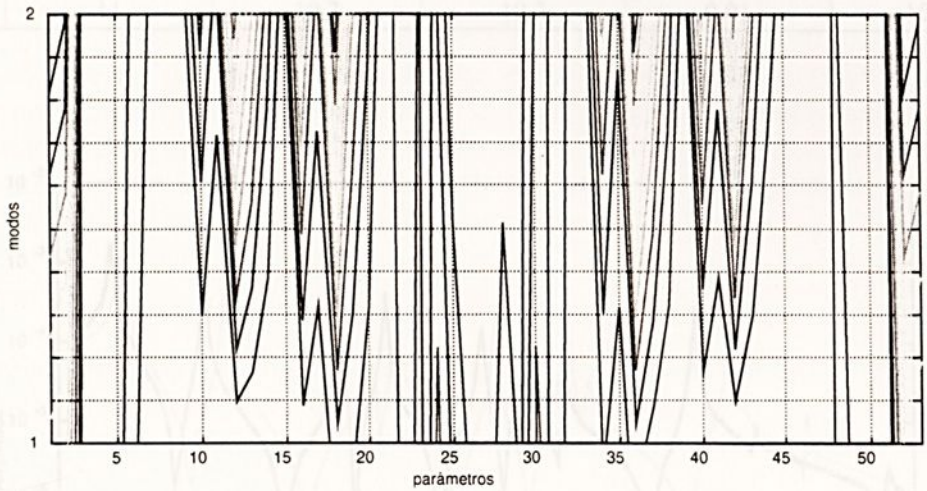


Figura 5 - Sensibilidade da estrutura : duas primeiras freqüências - modelo original

Como pode ser observado através da Fig. 4 e da Fig. 5, os parâmetros mais sensíveis são os parâmetros relacionados com o elementos extremos do modelo, diferentemente do caso anterior. Mostrando assim a necessidade de utilizar um modelo detalhado de elementos finitos que represente satisfatoriamente a estrutura real.

A Tabela 1 mostra claramente que existe uma discrepância entre os dois modelos, a qual dever ser minimizada através do processo de ajuste do modelo analítico em relação aos dados experimentais. Observando o mapa de sensibilidade dos parâmetros da estrutura é possível identificar as regiões mais sensíveis do modelo, as quais foram utilizadas para a seleção dos parâmetros de ajuste. Foram selecionados os elementos da regiões extremas e central da estrutura de acordo com a Fig. 2 e a Fig. 3. Os resultados estão mostrados na Tabela 2, comparação de freqüências e modos próprios.

A Figura 6 mostra a superposição das FRF(s) medidas no ponto de excitação (drive point) para o modelo analítico, experimental e ajustado. A Figura 7 mostra o novo mapa de análise de sensibilidade agora para a modelo ajustado. Como pode ser observado, o mesmo apresenta uma variação idêntica à da estrutura original, ou seja, da "estrutura real".

Tabela 2. Comparação das FRF(s) dos modelos experimental e analítico ajustado

Experimental	Analítico	Fx(Hz)	Fa(Hz)	Df(%)	Mac(%)
1	1	1,2	1,2	0.02	100,0
2	2	3,4	3,4	0.01	100,0
3	3	6,6	6,6	0.01	100,0
4	4	7,6	7,6	0.00	100,0
5	5	8,2	8,2	-0.00	100,0
6	6	9,9	9,9	0.00	100,0
7	7	10,9	10,9	0.01	100,0
8	8	11,8	11,8	0.00	100,0
9	9	14,9	14,9	0.01	100,0
10	10	16,3	16,3	0.01	100,0
11	11	19,3	19,3	0.01	100,0

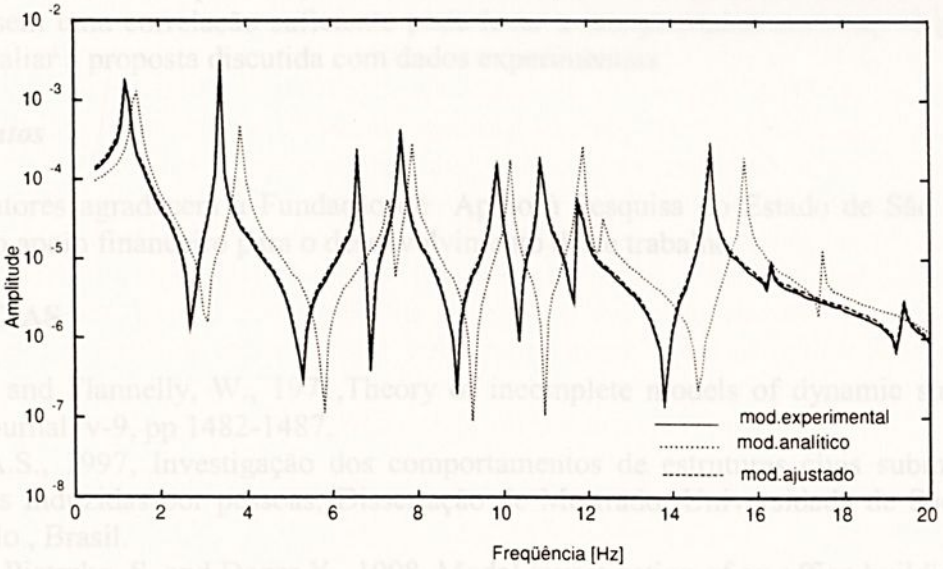


Figura 6 – Superposição das FRF(s) medidas no ponto de excitação para os modelos analítico, experimental e ajustado

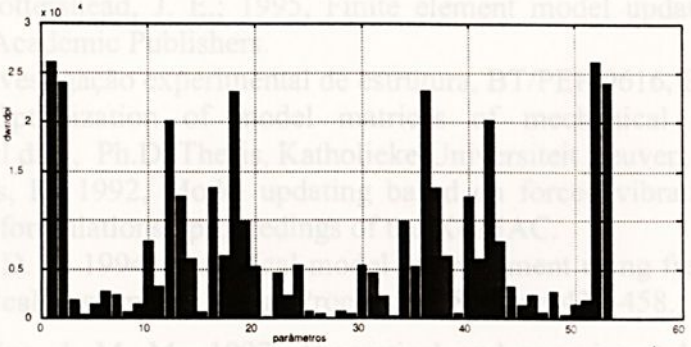


Figura 7 - Sensibilidade da estrutura : modelo ajustado – primeira freqüência

Os resultados acima mostram a importância de se definir um modelo analítico representativo quando se deseja estudar as características dinâmicas de um sistema, principalmente quando o objetivo é predizer seu comportamento dinâmico. Técnicas de ajuste podem ser utilizadas para a definição de modelos de predição bastante próximos dos dados experimentais. A análise de sensibilidade permitiu mostrar quais regiões ou componentes do modelo que levariam a mudanças mais acentuadas das suas propriedades dinâmicas sem provocar grandes alterações na estrutura. Estas informações são fundamentais quando se deseja controlar os níveis de vibrações da estrutura, deslocando as freqüências características do modelo das faixas indesejadas imposta por projetos.

4- CONCLUSÃO

Neste trabalho foi discutido como se obter um modelo de elementos finitos representativo baseado em dados experimentais de análise modal. Técnicas de análise de sensibilidade e ajuste de modelos utilizadas na formulação do problema foram apresentadas.

A importância do desenvolvimento de um modelo representativo para a análise e predição das propriedades dinâmicas dos sistemas foi demonstrada com dados simulados para uma estrutura metálica do tipo *steel joist*. Os resultados mostram que a utilização de modelos de predição sem uma correlação suficiente pode levar a interpretações errôneas. O próximo passo será avaliar a proposta discutida com dados experimentais

Agradecimentos

Os autores agradecem à Fundação de Apoio à Pesquisa do Estado de São Paulo – FAPESP pelo apoio financeiro para o desenvolvimento deste trabalho.

REFERÊNCIAS

Berman, A., and Flannelly, W., 1971,Theory of incomplete models of dynamic structures, AIAA journal, v-9, pp 1482-1487.

Bonilha, L.A.S., 1997, Investigação dos comportamentos de estruturas civis submetidas a vibrações induzidas por pessoas, Dissertação de Mestrado, Universidade de São Paulo, São Paulo , Brasil.

Cantieni, R., Pietrzko, S. and Deger Y., 1998, Modal investigation of an office building floor, proceedings of the XVI-IMAC.

Comite Euro-International du beton – Bulletin d'Information n° 209 ,1991–Vibracion problems in structures- CEB n° 209/1991- Viena.

Friswell, M. J. and Mottershead, J. E.; 1995, Finite element model updating in structural dynamics,Kluwer Academic Publishers.

Fusco,P. B., 1996, A Investigação experimental de estrutura, BT/PEF/9616, EDUSP.

Heylen, W., 1987, Optimization of model matrices of mechanical structures using experimental modal data, Ph.D. Thesis, Katholieke Universiteit Leuven, Belgium.

Larsson, P. O. and Sas, P., 1992, Model updating based on forced vibration testing using numerically stable formulations, proceedings of the X-IMAC.

Lin, R. M. and Ewins, D. J., 1994, Analytical model improvement using frequency response functions, Mechanical System and Signal Processing, 8(4), pp 437-458.

Maia, N. M. M. e Silva, J. M. M. ,1997, Theoretical and experimental modal analysis, Research Studies Press Ltda. John Wiley & Sons Inc.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Mottershead, J. E. and Friswell, M. I., 1993, Model updating in structural dynamics: a survey, Journal of Sound and Vibration, 167(2), pp 347-375.

Natke, H. G. et al, 1997, Some recent advances in model updating, proceedings of DETC'97, ASME Design Engineering Technical Conferences, 16th Biennial Conf. on Mechanics Vib. and Noise: Sacramento-USA. sept/97, paper DETC97/VIB-4142.

Reynolds P. et al., 1998, Modal testing, FE analysis and FE model correlation of a 600 tonne post-tensioned concrete floor. XXIII-International Seminar on Modal Aanalysis.

Reynolds, P., Pavic, A. and Waldron, P., 1998, Modal testing of a 150-tonne concrete slab incorporating a false floor system, proceedings of the XVI-IMAC.

S.J.I. – Technical Digest , published by Steel Joist Institute

Pereira, J. A.,1996, Structural damage detection methodology using a model updating procedure based on frequency response functions - FRF(s), Tese de Doutorado, Universidade Estadual de Campinas, São Paulo, Brasil.

Characterization of Dynamic Parameters of Steel Joist Structures

Abstract. The interest in the use of steel joist structures in long space-span concrete floors is, in general, increasing. The use of this kind of structures allied to prestressing techniques and high strength concrete permits more slender concrete floor construction. However, wiliest such floor may still attending the strength condition, they are more liable to the vibration problems, including those caused by people walking, moving, etc. In this case, the isolation of the vibration effects is very complex and the control must be done by the own characteristic of the structure. So, it requires an accurate modelling of the dynamic behaviour of the model. This work describes the use of finite element model updating in order to define an accurate model of a steel joist structure. It also shows as the updated model can be useful for prediction studies, like to investigate the changes of the structures that may reduce the vibration levels by shifting theirs natural frequencies away from an undesirable range of excitation frequencies. The viability of the proposed has been demonstrated by using simulated data from a structure with characteristic similar to a real structure.

Key-words: Steel joist, Finite Element, Modal Analysis, Sensitivity, Model updating.

APPLIED MECHANICS IN THE AMERICAS Volume 8
Edited by H. I. Weber, P. B. Gonçalves, I. Jasiuk, D. Pamplona, C. Steele and L. Bevilacqua
Published by AAM and ABCM – Rio de Janeiro Brazil 1999

THE OUTLINE OF DAMAGE DETECTION OF A BEAM-STRUCTURE USING A DIAGNOSTIC MODEL COMBINED WITH AN UPDATING PROCEDURE BASED ON FRF

João Antonio Pereira, Professor of Mechanics
Mech. Eng. Dept., FEIS/UNESPE, Ilha Solteira - SP, Brazil
Hans H. Müller-Slany, Professor of Machine Dynamics, Frank Brunzel, Research Assistant
Institute of Mechanics, University of Duisburg, D-47048 Duisburg, Germany
Hans Ingo Weber, Professor of Mechanics
Mech. Eng. Dept., PUC-Rio de Janeiro, Brazil

ABSTRACT

Forced bending vibrations are used to identify the damage of a beam-structure in a model updating procedure. This method is based on a diagnostic model of the undamaged system which has to be a substantially reduced model and at the same time it has to be a dynamical highly accurate one. The damage detection methodology finally is based on a frequency response function of the damaged structure. For a given beam-structure the process of generating a diagnostic model and the damage identification procedure by using a simulated FRF-function will be shown.

INTRODUCTION

The maintenance service of technical systems is a question of high economic account. It is of high interest to avoid unnecessary maintenance work and to guarantee the safety of technical systems. At present diagnostic techniques using vibration measurements is an extremely developing field (Doebling, 1998). Model based damage detection deals with the identification of the variation of system parameters. The first problem in model based damage detection is to find a way of generating a suitable simulation model that describes the dynamical behaviour of the nominal undamaged elastomechanical system. The second problem is to solve the identification of the damaged system parameters. The procedure we are applying here is shown in Fig. 1.

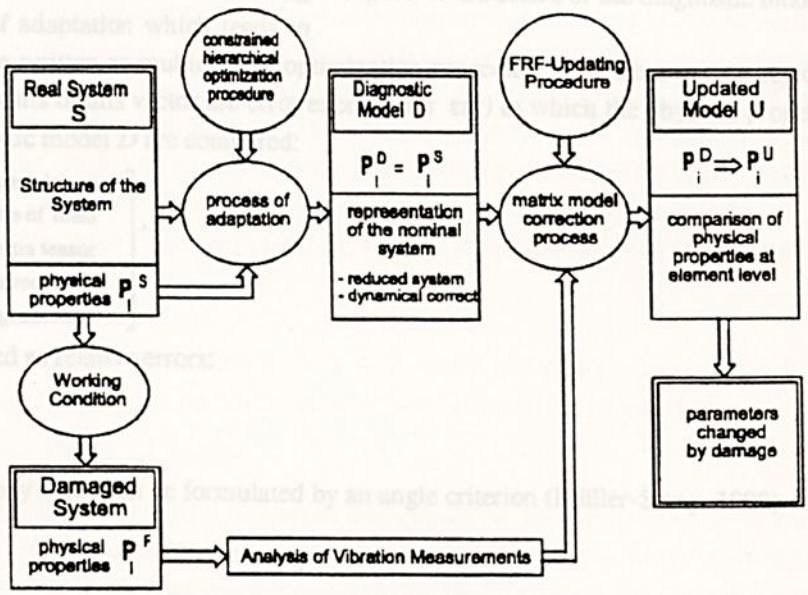


Figure 1: Damage detection procedure

TESTED BEAM-STRUCTURE

We will show the new methodology of damage detection by numerical simulation. The beam-structure under consideration (Fig. 2) is built of two welded bars with rectangular cross section which are clamped on both ends. For this beam-structure we have to collect all important dynamical properties for the generation of the diagnostic model. These are all mass-geometrical values and a set of modal values. The dynamic properties of the nominal model are calculated by using a finite element model containing 100 beam elements. Experiences show that normally the first six eigenvibration are adequate for system modelling. Here the natural vibrations of the system are considered in the plane. The first six eigenmodes and eigenfrequencies are shown in Fig. 3.

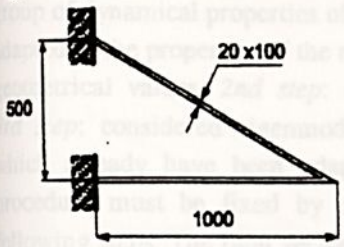


Figure 2: Tested beam-structure

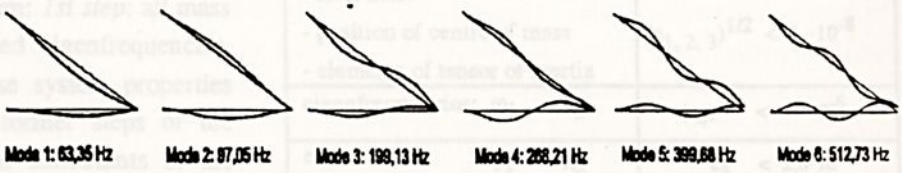


Figure 3: Eigenfrequencies and eigenmodes of the beam-structure

DIAGNOSTIC MODEL

The diagnostic model is a physical and mathematical description of the original undamaged system. It has to be a substantial reduced model but at the same time a dynamical highly accurate one. We fulfil this goal in a process of adaptation in which the differences of the dynamical properties of the original system and the model are minimized (Müller-Slany, 1997). The design of the diagnostic model is a structure built up of 10 large beam-elements (Fig. 4). The design vector which defines the diagnostic model contains 28 design variables: masses, coordinates and bending stiffness of the beam elements. The process of adaptation which leads to the final design of the diagnostic model can be written as multicriteria optimization procedure in which a vector objective function $f(x)$ has to be minimized. The components of this vector are error expressions $\varepsilon(x)$ in which the physical properties $P(x)$ of the original system S and of the diagnostic model D are compared:

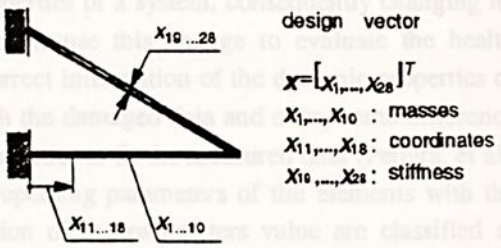


Figure 4: Structure of the diagnostic model

$$f(x) = = \begin{bmatrix} \varepsilon_1(x) \\ \varepsilon_2(x) \\ \varepsilon_3(x) \\ \varepsilon_4(x) \\ \varepsilon_5(x) \end{bmatrix} = \begin{bmatrix} \text{error expression of :complete mass} \\ \text{....position of centre of mass} \\ \text{....elements of inertia tensor} \\ \text{....considered eigenfrequencies} \\ \text{.... considered eigenmodes} \end{bmatrix}. \quad (1)$$

The expressions $\varepsilon_1(x)$ ... $\varepsilon_4(x)$ can be formulated as relative errors:

$$\varepsilon_i(x) = \left[1 - \frac{P_i^D(x)}{P_i^S(x)}\right]^2, \; i=1,...,4 \quad (2)$$

and the expression $\varepsilon_5(x)$ for the vectorial property $P_5(x)$ can be formulated by an angle criterion (Müller-Slany, 1999):

$$\varepsilon_5(x) = 1 - \frac{P_5^D(x)^T P_5^S}{\left|P_5^D(x)\right|\left|P_5^S\right|}. \quad (3)$$

The problem of generating a suitable diagnostic model we can describe by the formulation of a restricted multicriteria optimization problem:

$$\min_{x \in \Sigma} \left\{ f\left[\varepsilon(x)\right] \middle| h(x) = 0 \right\} \Sigma := \left\{ x \in \Re^n \middle| x_L \le x \le x_U \right\}, \quad (4)$$

where: x: vector of design variables, $f(x)$: vector objective function, $\varepsilon(x)$: vector of error expressions, $h(x)$: vector of equality constraints, Σ: feasible range, x_L , x_U : lower and upper bounds of design variables. The problem (4) can be solved numerically by a hierarchical scalarization strategy in 3 steps (Müller-Slany, 1999). The elements of the vector objective function are divided in 3 different groups by scalarization:

$$f(x) \Rightarrow s\{f[\varepsilon(x)]\} = \begin{bmatrix} s_1[\varepsilon_1(x),\varepsilon_2(x),\varepsilon_3(x)] \\ s_2[\varepsilon_4(x)] \\ s_3[\varepsilon_5(x)] \end{bmatrix}. \tag{5}$$

In each step of the hierarchical optimization procedure one group of dynamical properties of the diagnostic model will be adapted to the properties of the real system: *1st step*: all mass geometrical values, *2nd step*: considered eigenfrequencies, *3rd step*: considered eigenmodes. Those system properties which already have been adapted in former steps of the procedure must be fixed by additional constraints in the following steps. The final vector x of design variables creates the diagnostic model for the considered beam-structure. The final errors of the diagnostic model are shown in Table I.

Physical Property	Error of Adaptation
- total mass - position of centre of mass - elements of tensor of inertia	$(\varepsilon_{1,2,3})^{1/2} < 6 \cdot 10^{-8}$
eigenfrequencies: $\omega_1 \ldots \omega_6$	$(\varepsilon_4)^{1/2} < 6 \cdot 10^{-6}$
eigenmodes: $q_1 \ldots q_6$	$\varepsilon_5 < 2{,}6 \cdot 10^{-3}$

Table I: Final errors of the diagnostic model

DAMAGE DETECTION PROCEDURE

Structural damage is likely to take the form of a reduction of the physical properties of a system, consequently changing its dynamic behaviour. Damage detection tools based on vibration measurement use this change to evaluate the health condition of the structure. First, it has to be defined a model that gives the correct information of the dynamic properties of the intact system. This model, called diagnostic model, will be compared with the damaged data and once, some difference between the data is detected the procedure will update the diagnostic model in order to fit the measured data (Pereira, et al., 1995). The damage detection algorithm compares, in an iterative way, the updating parameters of the elements with the parameters of the diagnostic model. Those elements that present a reduction of the parameters value are classified as damaged elements. Those elements whose parameters increase during the updating process are treated as undamaged elements. If the updated model is not satisfactory (high discrepancy between resonance frequencies and low MAC-values), the expected undamaged elements (i.e., these elements whose parameters increased) are removed from the updated data set and the procedure is iteratively repeated only for those probably damaged elements. An element by element FRF-based Model Updating Procedure has been used to damage detection propose. The procedure describes the discrepancy between the models as a force residue and it updates the diagnostic model directly based on the measured frequency response functions of the damaged system (Larson and Sas, 1992; Pereira, 1996). A residual function, written in terms of the analytical dynamic stiffness matrix $[Z^A]$ and the measured FRF matrix $[H^X]$, defines the difference between these models:

$$\{\varepsilon\} = [Z^A(p_1, p_2, \ldots, p_m)]\{H^X\}_j - \{I\}, \tag{6}$$

where: $\{H^X\}_j$ is the experimental FRF from excitation DOF j and $\{I\}_j$ is a zero vector except for comp. j, $i_j = 1$. The updating process consists in finding m parameters changes that minimize the difference between the two models:

$$\{\varepsilon\} = [Z^A(p_1 + \Delta p_1, p_2 + \Delta p_2, \ldots, p_m + \Delta p_m)]\{H^X\}_j - \{I\} \cong \{0\}. \tag{7}$$

An approximated solution for the problem is calculated through a first order linearization of the dynamic stiffness matrix, which leads to a set of updating equations. The updating parameters can be any physical and/or geometrical properties of the FE-model. A key feature of the procedure is that it operates at an element level and the model changes are directly related to the variation of the element-parameters. The symmetry positive definiteness and connectivity characteristics of the FE-model remain uncorrupted, facilitating the comparison between the updated model with the original one. This facilitates the physical understanding of the model changes what makes its application promising for structural damage detection.

IDENTIFICATION OF DAMAGE

The beam-structure, Fig. 2, has been used to investigate the capability of the methodology. A reduction of 72% of the stiffness parameter of some elements, see Fig. 5, was introduced into the original model of the structure (large FE-model) provoking changes on its dynamic properties. Tab. 2 gives an overview of the dynamic parameters of the models and the correlation between the reduced diagnostic model and the damaged one. It shows that there exists a large difference between the resonance frequencies of the models and a deterioration of the modes correlation.

In order to find the correct location of the damage, the procedure assumes that all elements of the structure can be damaged and tries to find, based on the diagnostic model, which is the damaged part of the model. In this case, all ten elements of the model were considered as candidates to be damaged. Tab. II shows the results of the updating process. After some iteration the procedure stabilised, the frequency differences decreased and the MAC-values increased, which shows that the models present a good correlation. Fig. 6 shows the evolution of the updated parameters of the model. As it can be seen, the stiffness-parameters of element number 3 of the reduced diagnostic model presents a reduction of 71%. This element of the diagnostic model is equivalent to the elements where the damage was introduced into the original model. That means, the location of the damage was successfully identified as well as its size.

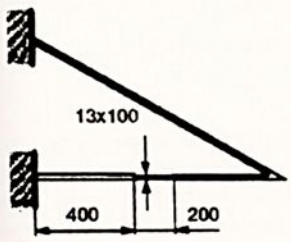


Figure 5: Damaged structure

Diag. Model	Damag. Model	Initial Correlation		Final Correlation	
freq. [Hz]	freq. [Hz]	dif. [%]	MAC-values	dif. [%]	MAC-values
63.35	58.75	7.83	0.943	0.11	0.999
97.05	86.19	12.59	0.956	0.53	0.999
199.14	193.87	2.71	0.988	0.02	0.996
268.21	254.10	5.55	0.987	-0.23	0.995
399.69	381.92	4.65	0.948	-0.18	0.995
512.72	472.06	8.61	0.938	1.29	0.992

Table II: Modal parameters and correlation values

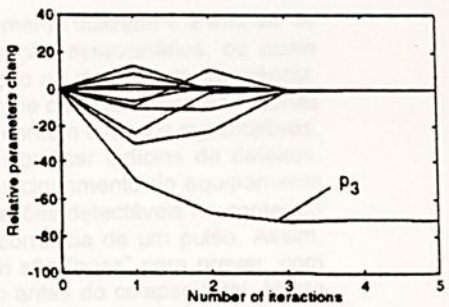


Figure 6: Updating parameters evolutions

ACKNOWLEDGEMENTS

The authors are grateful to CNPq (Brazil) and DAAD (Germany) for the financial support of this research.

REFERENCES

Doebling, Scott W., Charles R. Farrer, Michael B. Prime (1998). A Summary Review of Vibration-Based Damage Identification Methods. The Shock and Vibration Digest, Vol. 30, No. 2, March 1998: 91-105.

Müller-Slany, H. H., Brunzel, F. (1997). A basic Outline according to a new Method of Model based Damage Detection. Proc. DINAME 97, 7th Int. Conf. on Dynamic Problems in Mech., Angra dos Reis, Brazil: 40-42.

Müller-Slany, H.H., Brunzel, F. (1999). The Generation of a useful Diagnostic Model for Model based Damage Detection of Mechanical Systems. To appear: DINAME 99, 9th Int. Conf. on Dynamic Problems in Mech., Rio de Janeiro, Brazil.

Larsson, P. O., Sas, P. (1992). Model Updating Based on Forced Vibration Testing Using Numerically Stable Formulations. Proceedings of the X-IMAC.

Pereira, J. A. (1996). Structural Damage Detection Methodology using a Model Updating Procedure based on Frequency Response Functions - FRF(s). Tese de Doutorado, Univ. Estadual de Campinas, Faculdade de Eng. Mecânica, Campinas.

Pereira, J.A.; Heylen, W.; Lammens, W.S., Sas, P. (1995). Application of Model Updating Technique for Health Condition Monitoring and Damage Detection in Flexible Structures. 15º Bian. Conf. in Vib. and Noise-ASME, Boston-USA.

P5

Detecção De Falhas Em Sinais De Vibração Utilizando A Transformada De Wavelet Discreta

Edmilson R. O. Santos, João A. Pereira e Vicente L. Jr
Departamento de Engenharia Mecânica
Faculdade de Engenharia de Ilha Solteira - FEIS
Universidade Estadual Paulista – Unesp
15385-000 – Ilha Solteira-SP – Brasil

Edison Righeto
Departamento de Matemática
Faculdade de Engenharia de Ilha Solteira - FEIS
Universidade Estadual Paulista – Unesp
15385-000 – Ilha Solteira-SP – Brasil

Congresso Ibero-Americano de Engenharia Mecânica – CIDIM'99, Santiago do Chile/Chile

RESUMO

Existem diversos métodos de análise de sinais, e um freqüentemente utilizado é a análise de Fourier. Este método é muito eficaz na análise de sinais de vibração estacionários, os quais podem representar a distribuição de freqüência dos sinais de vibração no domínio da freqüência. Entretanto, a baixa sensibilidade da análise de Fourier para detecção de características transitórias nos leva a procurar outro caminho - Transformada de Wavelet - que contém avanços significativos, ou seja, adequada para detectar alterações pontuais, que podem significar indícios de defeitos, sendo muito eficiente no diagnóstico preventivo de danos. O mal funcionamento do equipamento em processo de monitoramento pode ser percebido através de alterações detectáveis no conteúdo de freqüências ou amplitudes dos sinal analisado ou mesmo na ocorrência de um pulso. Assim, Wavelets são "boas" para sinais transientes e dessa forma também são "boas" para prever, com bastante segurança, a possibilidade de falha do equipamento muito antes do colapso total. Neste artigo trabalhamos com sinais simulados e demostramos que o caráter local proporcionado pela análise via Wavelet trás vantagens sobre a visão global da análise de Fourier.

INTRODUÇÃO

Detecção de falhas estruturais é de interesse particular em engenharia. Dados de vibrações da estrutura danificada podem exibir diferentes eventos transientes e não lineares. Recentemente tem havido grande interesse no estudo destes tipos de fenômenos. Muitos algoritmos tem sido desenvolvidos para detecção de falhas mecânicas. Uma das mais recentes ferramentas matemática adaptada para sinais que variam no tempo é a transformada de Wavelet (Staszewski W. J., Tomlinson G. R., 1994). Originada no início da década de 1980, (Morlet J., 1980), (Grossmann A., Morlet J., 1985), (Daubachies I., Grossmann A., e Meyer Y., 1989), (Meyer Y., 1986), e (Mallat S., 1989), a transformada de Wavelet é uma decomposição tempo - escala e é bem adaptada para modelar e estudar o comportamento tempo - freqüência para análise transiente ou para detectar sinais impulsivos e descontinuidades. A transformada de Wavelet tem sido aplicada com muito sucesso em diversas áreas incluindo: acústica, processamento de som, processamento de sinais biológicos, sismologia e o estudo de fractais. As aplicações em engenharia mecânica incluem as seguintes áreas e exemplos: física e modelagem matemática - análise de turbulência em mecânica dos fluidos (Farge, 1992), estudo de fractais em matemática (Chui Ch. K., 1992); análise tempo - freqüência - comportamento vibro - acústico de um lançamento em vôo (Fumoux C., Marquette G., 1990), análise de ruído de um compressor (Stazewski W. J., Tomlinson G. R., 1994); identificação de problemas - separação de diferentes componentes de freqüências na solução de problema mal condicionado (Louis A. K. , 1993); processamento de imagens - perfis de contorno de vibração da estrutura (Mallat S., Zhong S., 1992); diagnósticos em sistemas mecânicos - métodos de detecção de falhas em caixa de engrenagem (Stazewski W. J., Tomlinson G. R., 1992) e (Stazewski W. J., Tomlinson G. R., 1994); algoritmos de processamentos de sinais (Stazewski W. J., Worden K., 1993), análise de vibrações (Newland D., 1993). Um dos objetivos deste trabalho é a utilização da transformada de Wavelet, no estudo do comportamento transiente e não linear, aplicada na área de detecção de falhas.

TRANSFORMADA DE WAVELET

A transformada de Wavelet pode ser introduzida em comparação com a transformada de Fourier definida como (Chui Ch. K., 1992):

$$X(f) = \int_{-\infty}^{+\infty} x(t) e^{-j2\pi ft} dt \qquad (1)$$

A transformada de Fourier é uma transformada linear da função $x(t)$ e baseada na decomposição da função em termos de uma base de funções elementares $e^{-j2\pi ft}$. Estas funções elementares $e^{-j2\pi ft}$ são geradas por extensão de uma função única $e^{-j2\pi t}$.

Assume – se que a função $x(t)$ satisfaça a condição:

$$\int_{-\infty}^{+\infty} |x(t)|^2 dt < \infty \qquad (2)$$

que implica que $x(t)$ decai para zero em $\pm\infty$. Como no caso da análise de Fourier, a idéia da transformada de Wavelet é achar uma função $g(t)$ a qual pode gerar uma base para o espaço todo de funções $x(t)$. Se o decaimento dado pela expressão (2) for muito rápido, está função é chamada uma pequena onda ou uma "Wavelet". O rápido decaimento introduz o sentido de localidade na análise, que não é o caso da transformada de Fourier, onde uma função trigonométrica infinita dará uma representação global.

Desde que a Wavelet $g(t)$ tem um decaimento muito rápido, o único caminho para representar todas as funções $x(t)$ é deslocar $g(t)$ no tempo: $g(t-\tau)$. Como no caso da análise de Fourier, pode ser considerado ondas de diferentes freqüências. A segmentação de freqüências é dada por $g(\varphi t-\tau)$, assim, cada função $g(\varphi t-\tau)$ é obtida de uma única Wavelet g(t) pela dilatação φ e translação τ. Estas duas operações são suficientes para produzir uma base, a qual pode representar todas as funções $x(t)$. Uma mudança de variáveis produz:

$$g(\varphi t - \tau) = g\left(\frac{t-b}{a}\right) = g_{a,b}(t) \qquad (3)$$

onde $b=\tau/\varphi$ e $a=1/\varphi$. A transformada de Wavelet pode agora ser definida como:

$$W_g(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) g^*\left(\frac{t-b}{a}\right) dt \qquad (4)$$

onde b é uma translação indicando a localidade, a é a dilatação ou parâmetro de escala, $g(t)$ é uma Wavelet básica (mãe) e $g^*()$ é conjugado complexo de $g()$.

A transformada de Wavelet dada pela Eq. (4), é portanto uma transformação linear que decompõe uma função arbitrária $x(t)$ nas funções elementares $g_{a,b}(t)$, as quais são obtidas da Wavelet $g(t)$ por dilatação e translação. Aqui dilatação representa a harmônica ou período em termos da decomposição harmônica/periódica.

Cada valor da transformada de Wavelet $W_g(a,b)$ é normalizada pelo fator $1/\sqrt{a}$. Esta normalização garante que a energia dada por cada Wavelet $g_{a,b}(t)$ é independente da dilatação a.

Para a função $g(t)$ se qualificar como uma Wavelet, ela deve satisfazer a condição de admissibilidade :

$$C_g = \int_{-\infty}^{+\infty} \frac{|G(f)|^2}{|f|} df < \infty \qquad (5)$$

onde $G(f)$ é a transformada de Fourier da $g(t)$. Admissibilidade é requerida para permitir a inversa da transformada de Wavelet. Existem diferentes funções reais ou complexas usadas como Wavelets (Chui Ch. K., 1992).

A transformada de Wavelet pode ser interpretada como um filtro de resolução de freqüência relativa constante $(\Delta f/f)$, e, apresenta um número de propriedades úteis que podem ser utilizadas.

LOCALIZAÇÃO NO DOMÍNIO TEMPO - FREQÜÊNCIA.

Da definição, as transformadas de Fourier extraem ondas periódicas infinitas da função analisada. Em contraste, a transformada de Wavelet analisa uma função somente localmente na janela definida pela Wavelet. A Eq. (4) é em geral não local. O valor de $W_g(a,b)$ em um ponto(a_0,b_0) depende de $x(t)$ para todo t. Contudo, a expressão (2) e Eq (3) dizem que a função $g(t)$ decai a zero quando $|t| \rightarrow +\infty$. Se for assumido um decaimento rápido, isto é, os valores de g(t) são desprezíveis fora do intervalo $(t_{min}, t_{máx})$, a transformada torna-se local. A localização de freqüência é visível quando a transformada de Wavelet é expressa em termos da transformada de Fourier

$$W_g(a,b) = \sqrt{a} \int_{-\infty}^{+\infty} X(f) G^*_{a,b}(af) e^{i2\pi fb} df \qquad (6)$$

Esta localização depende do parâmetro da dilatação a. A resolução local da transformada de Wavelet no tempo e freqüência é determinada pela duração e largura de banda das funções analisadas, dadas por $\Delta t = a\Delta t_g$ e $\Delta f = \Delta f_g/a$, onde Δt_g e Δf_g são a duração e a largura de banda da função Wavelet básica, respectivamente. Assim, no domínio da freqüência a transformada de Wavelet tem boa resolução nas baixas freqüências e no domínio do tempo boa resolução nas altas freqüências, esta última sendo adequada para análise de sinais transientes.



TRANSFORMADA DE WAVELET DISCRETA

Na transformada de Wavelet, a função ou sinal é expandida segundo uma base a qual tem suporte compacto nos domínios tempo e freqüência. Para os cálculos da transformada de Wavelet, o parâmetro de dilatação *a* e o parâmetro de translação *b* devem ser discretizados. Esta é a chamada transformada de Wavelet discreta que é a mais eficiente e igualmente acurada. A mais comum discretização da Wavelet é a diádica, representada por:

$$\psi_{(j,k)}(t) = \frac{1}{\sqrt{2^j}}\psi\left(\frac{t - 2^j k}{2^j}\right) \quad (7)$$

sendo que *a* tem sido substituído por 2^j e *b* por $2^j k$. Sob condições adequadas a Eq. (8) é uma base ortonormal de L^2R (Daubechies I., 1992), e a função original pode ser expressa como:

$$f(t) = \sum_{j=-\infty}^{\infty}\sum_{k=-\infty}^{\infty} C_{(j,k)}\psi_{(j,k)}(t) \quad (8)$$

$$C_{(j,k)} = \int_{-\infty}^{+\infty} f(t)\psi^*_{(j,k)}(t)dt \quad (9)$$

sendo que $C_{(j,k)}$ são referidos como os coeficientes de Wavelet. Um segundo conjunto de funções bases $\phi(t)$ chamado de escala é então obtida aplicando aproximação de multiresolução para obter base ortonormal de $\psi(t)$:

$$\phi_{(j,k)}(t) = \frac{1}{\sqrt{2^j}}\phi\left(\frac{t - 2^j k}{2^j}\right) \quad (10)$$

A função temporal original pode agora ser escrita como:

$$d_{(j,k)} = \int_{-\infty}^{\infty} f(t)\psi^*_{(j,k)}(t)dt \quad (11)$$

Portanto, os $d_{(j,k)}$, os quais são chamados de coeficientes de escala, $d_{(0,k)}$ é a versão amostrada de *f(t)*, representando a *j – ésima* ordem de resolução de discretização de *f(t)*. Os coeficientes da função escala e os coeficientes da função Wavelet para resolução de ordens maiores do que *j* podem ser obtidos iterativamente por:

$$d_{(j+1,k)} = \sum_{i=-\infty}^{\infty} h(i-2k)d_{(j,k)} \quad (12)$$

$$C_{(j+1,k)} = \sum_{i=-\infty}^{\infty} g(i-2k)d_{(j,k)} \quad (13)$$

As seqüências *h* e *g* são respectivamente filtros passa – baixa e passa – alta obtidos a partir da Wavelet $\psi(t)$. Os coeficientes $d_{j,k}$ representam as freqüências mais baixas (aproximações) do sinal original, e os coeficientes de Wavelet $C_{j,k}$ representam a distribuição das freqüências mais altas (detalhes). A transformada inversa de Wavelet discreta oferece uma representação de $d_{0,k}$ (*f(t)* amostrada) em termos dos filtros h e g e dos coeficientes $C_{j,k}$.

$$d_{(j,k)} = \sum_{i=-\infty}^{\infty} h(k-2i)d_{(j+1,i)} + \sum_{i=-\infty}^{\infty} g(k-2i)C_{(j+1,i)} \quad (14)$$

Os filtros de Wavelet adotados determinam a qualidade da análise. As propriedades e características das Wavelets, para tratar sinais que possuem transitoriedades, discutidas anteriormente serão aplicadas a seguir. Utilizou-se o sistema Daubechies de Wavelets (Daubechies, 1992), porque tem as vantagens de suporte compacto no domínio do tempo, ortogonalidade e simplicidade computacional.

EXEMPLOS

O sinal original proposto neste artigo é constituído de três freqüências 20, 40 e 60 Hz, as quais podem representar as rotações de máquinas, ou freqüências naturais. Este sinal foi definido para um tempo de aquisição de 2 s e amostrado com 2048 pontos. Com a intenção de caracterizar a ocorrência de uma situação transitória foi incluído um impulso 0.39 s após o início da aquisição (posição 400). Adicionalmente, introduziu-se também uma variação de 5% em cada freqüência durante o tempo de aquisição. A primeira freqüência foi alterada a partir do ponto de aquisição 800, a segunda a partir da posição 1000 e terceira a partir da posição 410. A figura 1 mostra o sinal a ser analisado.

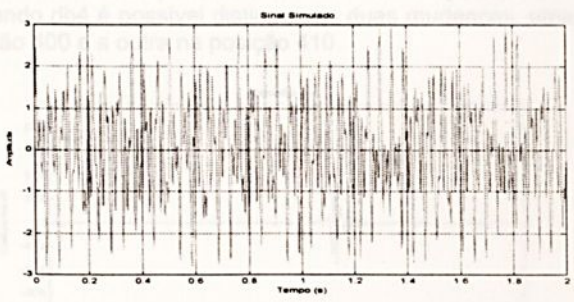


Figura 1 – Representação gráfica do sinal , com freqüências de 20, 40 e 60 Hz.

Para sistemas lineares não há perda de informação significativa quando transforma–se os dados do domínio do tempo para o domínio da freqüência. Existe ainda a vantagem de se utilizar a média dos sinais, a qual diminui o efeito do

ruído. Várias técnicas para detecção e localização de falhas para modelos lineares tem sido propostas utilizando análise modal e análise no domínio da freqüência. No entanto, vários mecanismos de falhas produzem efeitos não lineares. Como há pouca, ou nenhuma, informação a respeito do comportamento do dano, o sinal hipotético acima foi analisado para se avaliar a performance da transformada de Wavelet em comparação com uma simples FFT, para este sinal desconhecido, a priori. O objetivo desta é verificar quais as informações que seriam obtidas se esses dois tipos de análise fossem realizadas.

Uma das principais metas é ter uma idéia clara sobre a eficiência da transformada de Wavelet em detectar mudanças abruptas, portanto, utilizamos como contraponto a análise de Fourier que mostrou não ter sensibilidade para localizar tais eventos. A Figura 2 mostra a FFT do sinal analisado. A seguir o sinal é analisado utilizando as decomposições de Wavelet oriundas da db20 em 4 níveis, dos quais foram escolhidos os níveis que melhor representavam os eventos.

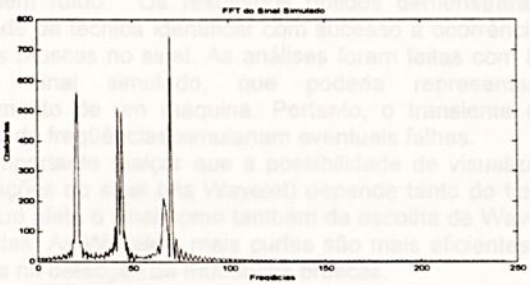


Figura 2 – FFT do sinal

A Transformada de Wavelet discreta (DWT) decompõe o sinal em vários níveis (que depende do comprimento do sinal), e esses representam as aproximações e detalhes. Portanto, os níveis responsáveis pelas aproximações representam as baixas freqüências enquanto que os detalhes as altas freqüências.

A Figura 3 e Figura 4 mostram as decomposições dos coeficientes de detalhes, que identificam claramente os efeitos de transitoriedade do sinal com suas respectivas localizações no tempo, eventos tais não detectáveis pela transformada de Fourier.

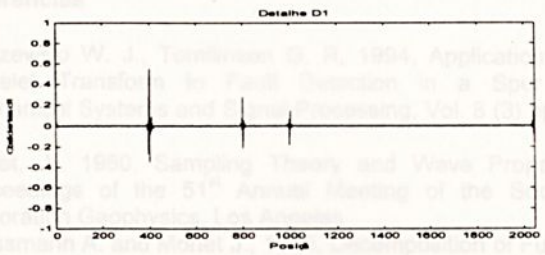


Figura 3 – Decomposição de Wavelet do sinal (detalhe)

Um segundo exemplo foi avaliado, agora introduzindo–se um ruído no sinal anterior. A presença de ruído, o qual é uma situação muito comum em processamento de sinais, torna mais complicado a identificação dos transientes. Assim, adicionou-se 1% de ruído no sinal simulado buscando tornar a análise mais próxima de uma situação real.

A Figura 4 mostra que mesmo com esse ruído a localização do transiente e das variações de freqüências são visivelmente fáceis de determinar. Essa facilidade de visualização depende tanto do tipo de evento como também da Wavelet escolhida. Diferentes combinações foram avaliadas obtendo –se resultados satisfatórios para maioria delas.

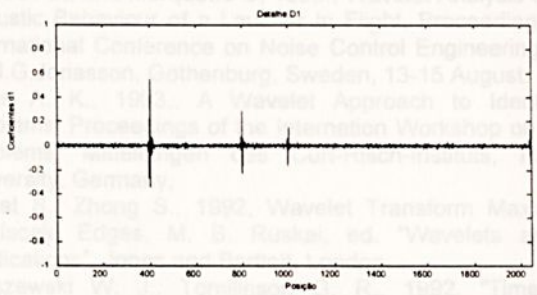


Figura 4 – Decomposição de Wavelet do sinal com ruído (detalhe).

Os gráficos das figuras acima mostram os resultados obtidos para uma análise utilizando db20 e 4 níveis de decomposições. Neste caso foi possível observar a ocorrência de mudança em três posições do sinal, as quais coincidem com as posições das variações introduzidas no sinal original. No entanto, não é possível definir claramente se a primeira mudança mostrada na figura 3 e figura 4 estão associada a primeira variação (posição, 400) ou a segunda variação (posição 410) introduzida no sinal. Isto ocorre porque os eventos estão muito próximos e a decomposição utilizando db20 não permite distingui-los. Neste caso, é recomendando utilizar Wavelets curtas, que são freqüentemente mais eficazes do que as Wavelets longas, devido ao seu suporte ser suficientemente pequeno permitindo uma análise mais refinada do sinal. As figuras abaixo mostram uma análise do sinal original com Wavelets db20 e db4, como pode ser observado para um "zoom" do sinal, na posição 400, a decomposição utilizando db20 não permite visualizar a mudança ocorrida. Já utilizando db4 é possível distinguir as duas mudanças, uma na posição 400 e a outra na posição 410.

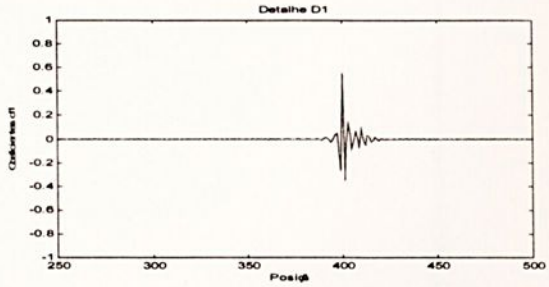


Figura 5 – Decomposição de Wavelet do sinal

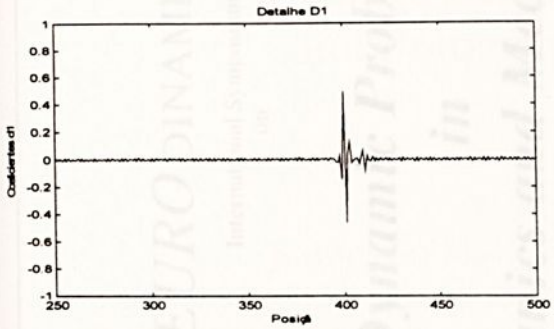


Figura 6 – Decomposição de Wavelet do sinal.

CONCLUSÃO

O desempenho da DWT para localizar eventuais mudanças no sinal foi avaliado para diversos sinais simulados, com e sem ruído. Os resultados obtidos demonstraram a capacidade da técnica identificar com sucesso a ocorrência de variações bruscas no sinal. As análises foram feitas com base em um sinal simulado, que poderia representar o funcionamento de um máquina. Portanto, o transiente e as variações de freqüências simulariam eventuais falhas.

É importante realçar que a possibilidade de visualização das variações do sinal (via Wavelet) depende tanto do tipo de evento que afeta o sinal como também da escolha de Wavelets apropriadas. As Wavelets mais curtas são mais eficientes que as longas na detecção de mudanças bruscas.

O processamento do sinal é outro aspecto importante na análise por Wavelets. Ele requer uma familiaridade do usuário com a técnica, pois envolve à análise de várias Wavelets (diferentes ordens) até que sejam extraídas todas as informações disponíveis no sinal. Portanto, a escolha da Wavelet e respectivo nível para a localização adequada de transientes representa a principal dificuldade da análise. O próximo passo deste trabalho será utilizar a técnica para a detecção de falhas utilizando dados experimentais.

AGRADECIMENTOS

Os autores agradecem à CAPES pelo apoio financeiro para o desenvolvimento do trabalho.

Referências

Staszewski W. J., Tomilinson G. R, 1994, Application of the Wavelet Transform to Fault Detection in a Spur Gear, Mechanical Systems and Signal Processing, Vol. 8 (3) pp 289 – 307

Morlet, J., 1980, Sampling Theory and Wave Propagation, Proceedings of the 51st Annual Meeting of the Society of Exploration Geophysics, Los Angeles

Grossmann A. and Morlet J., 1985, Decomposition of Functions into Wavelets of Constant Shape, and Related Transforms, Mathematics and Physics, Lecture on Recent Results, L. Striet.

Daubechies, I.,. Grossmann A and Y. Meyer, 1989, Painless Nonorthogonal Expansions, J. Math. Phys., Vol. 27, pp 1271-1283.

Meyer Y., 1986, Ondelettes et Fonctions Splines, Cent. Math. Ecole Polytech. Palaiseau., France.

Mallat S., "A, 1989, Theory for Multiresolution Signal Decomposition: The Wavelet Representantion", IEEE Trans. on Pattern Anal. and Machine Intell., Vol. PAMI-2(7).

Farge M., 1992, Wavelet Transform and their Application to Turbulence", Annual Rev.Fluid Mechanics, Vol. 24 pp 395-457.

Chui Ch. K, 1992., Wavelet Analysis and Its Applications. Vol. 1: Introduction to Wavelets, Academic Press, Inc., Boston.

Fumoux C., and Marquette G, 1990., Wavelet Analysis of Vibro-Acoustic Behaviour of a Laucher In Flight, Proceedings of the International Conference on Noise Control Engineering, edited by H.G.Jonasson, Gothenburg, Sweden, 13-15 August.

Louis A. K., 1993,. A Wavelet Approach to Identification Problems, Proceedings of the Internation Workshop on Inverse Problems, Mitteilungen des Curt-Risch-Instituts, Hannover University, Germany,

Mallat S., Zhong S., 1992, Wavelet Transform Maxima and Multiscale Edges, M. B. Ruskai, ed. "Wavelets and their Applications", Jones and Bartlett, London.

Staszewski W. J., Tomilinson G. R., 1992, "Time-Variant Methods in Machinery Diagnostics", International Workshop on Safety Evaluation of Time-Variant and Nonlinear Structures Using Identification Approaches, Lambrecht, Germany, 6-9.

Staszewski W. J., Worden K., 1993, Classification of Faults in Spur Gears, The World Congress on Neural Networks, Portland Oregon, 11 – 15.

Newland, D., 1993, "Wavelet Analysis of Vibration', The 16th Annual Energy Sources Technology Conference and Exhibition, Structural Dynamics and Vibration, Houston, Texas, USA, 31 january – 4 february.

Chui Ch. K., 1992, editor, Wavelet Analysis and Its Applications. Vol. 2: A Tutorial in Theory and Applications, Academic Press, Inc., Boston.

Daubechies I., 1992, Ten Lectures on Wavelets, CBMS – NSF Regional Conference Series In Applied Mathematics SIAM, Philadelphia.

unesp
MRM
Meß-, Regel- und Mikrotechnik
PUC

Universität Ulm

*EURO*DINAME '99

International Symposium
on

Dynamic Problems in Mechanics and Mechatronics

11 - 16 July 1999

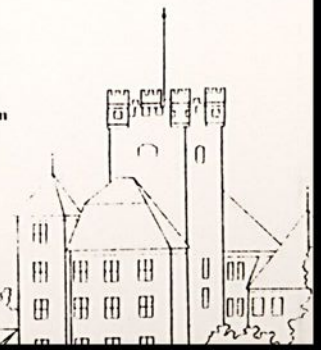


Proceedings

Edited
by

Eberhard P. Hofer
Hans Ingo Weber & Djenane Pamplona

Wissenschaftszentrum
Schloss der Universität Ulm
Reisensburg



P7

Damage Detection Based on Diagnostic Models and Frequency Response Function Updating Procedures

F. Brunzel and H. H. Müller-Slany
Institute of Mech., Univ.of Duisburg, 47048 Duisburg, Germany
email: mueller-slany@mechanik.uni-duisburg.de

J. A. Pereira and E. A. Turra
UNESP, Faculd. de Eng., 15385-000 Ilha Solteira – SP, Brazil
email: japereir@dem.feis.unesp.br

H. I. Weber
PUC-Rio, Dep. Engenharia Mecanica, R. Marques de São Vicente, 225, 122453-900, Rio de Janeiro – RJ, Brazil
email: hans@mec.puc-rio.br

Abstract

The goal of damage detection in elasto-mechanical systems is finding local parameter changes caused by working conditions. In general, here we have to deal with an inverse vibration problem which is known as an ill-conditioned mathematical problem. In the following a way of model based damage detection will be shown which needs a diagnostic model and a special identification procedure. The cooperation of these two parts of the whole process of damage detection will be the result of a German-Brazilian PROBRAL-project which is supported by DAAD and CAPES. The procedure of generation of diagnostic models is developed at the University of Duisburg and the identification process is developed at UNESP.

The diagnostic model must fulfill three basic conditions: firstly for numerical reason it has to be a substantially reduced model, secondly it has to be dynamically highly accurate considering global and local dynamical system properties and thirdly the diagnostic model must be sensitive to local parameter variations. The procedure of generation of a diagnostic model can be formulated as a constraint vector-optimization problem which can be solved by a hierarchical scalarization strategy.

The damage detection methodology is based on frequency response functions of the structure. For the identification process a residual function is formulated by using measured FRF data of the damaged system and simulated FRF data of the diagnostic model. In a process of iteration the residual function will be minimized by changing the system parameters until

the damaged parameter will be found. The correctness of the damage detection is a function of model reduction. The generation procedure for the diagnostic model and the FRF based damage detection is shown by an example of a beam-structure.

1 Introduction

It is of high economic interest to avoid maintenance work on real systems. More than 150 references about damage detection based on vibration measurements can be found in the review paper [Doebling et al, 1998]. They are all based on the fact that modal system properties are functions of the real system parameters. The model based damage detection can be divided in two steps. At first there is to construct a diagnostic model D which represents the real system. This model has to be dynamical highly correct and substantially reduced at the same time. This task is solved by the German members of the cooperation. The second task is to solve the inverse problem of finding the damage by using the diagnostic model. This is the part of the Brazilian members of the cooperation. The procedure of model based damage detection which has been developed together is shown in figure 1.

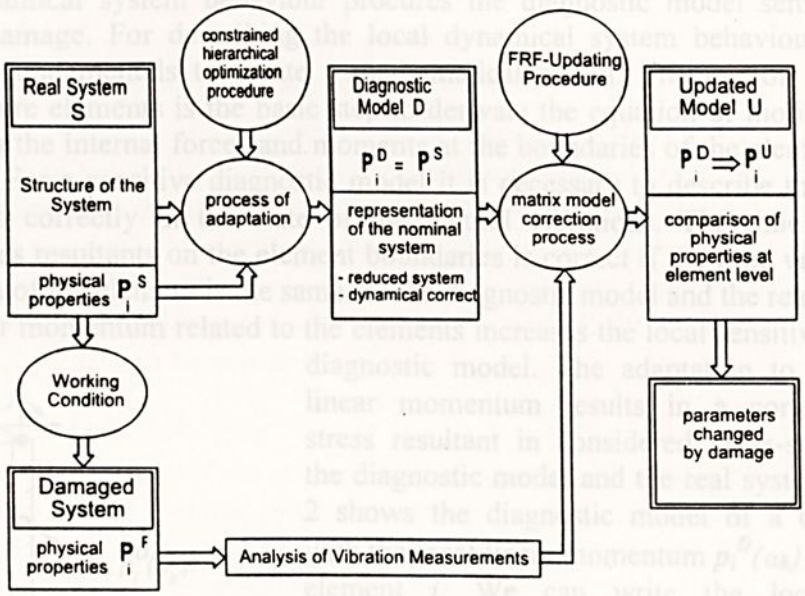


Figure 1: Damage detection procedure

2 The diagnostic model

In the model based damage detection the relation between the physical system parameters and the vibrational behaviour of the system is used to identify the parameter changes. This inverse dynamic vibration problem can be formulated as to find the parameters of the dynamic system from vibration measurement of the real system [Gladwell, 1986]. It corresponds to the inverse eigenvalue problem [Biegler, 1980] where given spectral data are used to determine the elements of the original matrix. In the most cases it is impossible to find a unequivocal solution for this problem. The difficulty of the model based damage detection is increased by working with a highly condensed model by increasing loss of information due to discretisation.

The diagnostic model is a highly condensed FE model of the real system built from beam-elements. In an optimization process this model is adapted to the physical properties which are important for damage detection. This needs a diagnostic model of the system which is sensitive for parameter changing of the real system.

For a successful identification of damaged parameters we have to adapt global and local dynamical properties of the real system to the diagnostic model. Global dynamical properties are: mass-geometrical properties (total mass, centre of mass and tensor of inertia), the natural

frequencies and the natural modes. To make the diagnostic model more sensitive to local parameter changing we adapt the model to the local linear momentum, too.

2.1 Local dynamical properties of the diagnostic model

The local dynamical system behaviour procures the diagnostic model sensitivity to describe the local damage. For describing the local dynamical system behaviour we can utilize the physical fundamentals to create a mathematical model. The use of the linear momentum of structure elements is the basic step to derivate the equation of motion. In the process of adaptation the internal forces and moments at the boundaries of the elements have important influence. For a sensitive diagnostic model it is necessary to describe the internal forces and moments correctly in the state of the natural vibrations. The time variation behaviour of the stress resultants on the element boundaries is correct if the time variation of the linear momentum of the element is the same for the diagnostic model and the real system.

The local linear momentum related to the elements increases the local sensitivity of the diagnostic model. The adaptation to the local linear momentum results in a corresponding stress resultant in considered cross-sections of the diagnostic model and the real system. Figure 2 shows the diagnostic model of a crankshaft with the local linear momentum $\boldsymbol{p}_i^D(\omega_k)$ of a local element i. We can write the local linear momentum $\boldsymbol{p}_i^D(\omega_k)$ of the i-th beam-element of the diagnostic model D in the state of the k-th natural vibration ω_k of the system as follows:

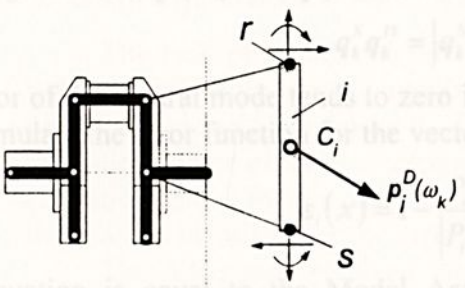


Figure 2: Local linear momentum $\boldsymbol{p}_i^D(\omega_k)$ of the i-th beam of a crankshaft

$$\boldsymbol{p}_i^D(\omega_k) = \left\{ \tfrac{1}{2}\, \omega_k m_i (\boldsymbol{q}_{r,k} + \boldsymbol{q}_{s,k}) \right\}^D . \quad (1)$$

The i-th beam-element with the mass m_i has the eigenvector element $\boldsymbol{q}_{r,k}$ at the node r and the eigenvector element $\boldsymbol{q}_{s,k}$ at the node s for the k-th eigenvector. The vector $\boldsymbol{p}_i^D(\omega_k)$ in equation (1) is part of the $3m$-dimensional total vector $\tilde{\boldsymbol{p}}^D(\omega_k)$ for a diagnostic model with p nodes and m beam-elements:

$$\tilde{\boldsymbol{p}}^D(\omega_k) = \begin{bmatrix} \tfrac{1}{2}\, \omega_k m_1 (\boldsymbol{q}_{1,k} + \boldsymbol{q}_{2,k}) \\ \vdots \\ \tfrac{1}{2}\, \omega_k m_m (\boldsymbol{q}_{p-1,k} + \boldsymbol{q}_{p,k}) \end{bmatrix}^D . \quad (2)$$

It is possible to calculate equal expressions $\boldsymbol{p}_i^S(\omega_k)$ for the original system S on discrete element areas of the diagnostic model by using the FE-analysis. The result of this calculation is a $3m$-dimensional vector $\tilde{\boldsymbol{p}}^S(\omega_k)$ of the local linear momentum of the original system. To increase the local sensitivity of the diagnostic model it is necessary to reduce the error between the vectors $\tilde{\boldsymbol{p}}^D(\omega_k)$ and $\tilde{\boldsymbol{p}}^S(\omega_k)$. The adaptation of the local linear momentum with respect to equation (2) is equal to the adaptation to the eigenvector elements weighted by the mass of the elements.

2.2 Multicriteria optimization for generating diagnostic models

The diagnostic model is described by a design vector $\boldsymbol{x} = [\, x_1, \ldots, x_n]$ with n elements. The elements to create a diagnostic model by beam-elements are the masses of the elements, the coordinates of the nodes and the stiffness of each beam-element. The final design of the diagnostic model is reached if the components of the objective function vector $\boldsymbol{f(x)}$ are

minimized. The elements of the vector objective function $f(x)$ are error expressions $\varepsilon_i(x)$ between the physical properties of the diagnostic model $P_i^D(x)$ and the real system $P_i^S(x)$. Usually we can create the vector $f(x)$ in the following way:

$$f(x) = \begin{bmatrix} \varepsilon_1(x) \\ \varepsilon_2(x) \\ \varepsilon_3(x) \\ \varepsilon_4(x) \\ \varepsilon_5(x) \\ \varepsilon_6(x) \end{bmatrix} = \begin{bmatrix} \text{error expression of: complete mass} \\ \text{...position of centre of mass} \\ \text{...elements of inertia tensor} \\ \text{...considered natural vibrations} \\ \text{...considered natural modes} \\ \text{...considered local linear momentum vector} \end{bmatrix}. \quad (3)$$

The error expressions $\varepsilon_i(x)$ $i = 1, \ldots, 6$ are functions of the design variables $x = 1, \ldots, n$. The first four error expressions of the scalar physical properties can be formulated by relative error equations. Due to numerical reasons we have to calculate the error expressions $\varepsilon_5(x)$ and $\varepsilon_6(x)$ of the vectorial physical properties in a different form. We achieve better results in the optimization procedure by minimizing the angle between the property vectors of the diagnostic model and of the real system. If we consider the natural mode k, the scalar product of the eigenvectors $q^D(\omega_k)$ and $q^S(\omega_k)$ can be written as:

$$q_k^S q_k^D = \left|q_k^S\right| \left|q_k^D\right| \cos\left(q_k^S q_k^D\right). \quad (4)$$

The error of the natural mode tends to zero if the *cos*-function of equation (4) equals 1. So we can formulate the error function for the vectorial properties as:

$$\varepsilon_i(x) = 1 - \frac{P_i^D(x)^T P_i^S}{\left|P_i^D(x)\right| \left|P_i^S\right|}, \; i = 5, 6. \quad (5)$$

This equation is equal to the Modal Assurance Criterion (MAC) which is used in the experimental modal analysis [Ewins, 1984]. For this vector criterion it is necessary that the kinetic energy T_k is equal for the diagnostic model and for the real system in the state of the considered natural vibration k.

Now, the generation of the diagnostic model can be formulated as a constraint vector-optimization problem [Müller-Slany, 1992]:

$$\min_{x \in \Sigma} \left\{ f\left[\varepsilon(x)\right] \middle| h(x) = 0 \right\}, \; \Sigma := \left\{ x \in \Re^n \middle| x_L \le x \le x_U \right\}. \quad (6)$$

The terms of the equation (6) are the vector objective function f, the design vector x, the vector of error expression $\varepsilon(x)$, the vector of equality constrains $h(x)$, the feasible range Σ and the lower and upper bounds x_L and x_U. The optimization problem (6) will be solved by a numerical iteration process with special optimization algorithms. The structure of this optimization process is shown in figure 3. During the process of optimization the design vector will be modified until the final design fulfills the minimization criterion of (6). Finally a diagnostic model has been created which is dynamical highly accurate considering global and local dynamical system properties.

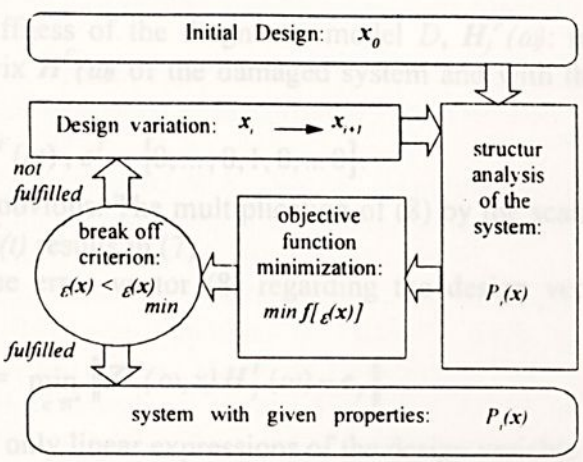


Figure 3: Diagnostic model generation

Vector optimization problems are solved by scalarization of the objective function [Eschenauer et al, 1990]. Usually, the weighted superimpose of all objective vector components to a scalar preference function $s(x)$ leads to a good result. With our special problem this method behaves poor. To solve this problem we use a hierarchical scalarization strategy [Müller-Slany, 1993]. In this strategy the error expressions are combined in preference groups:

1. All mass-geometrical dynamic properties.
2. Dynamic behaviour described by the characteristic polynom: natural frequencies.
3. Dynamic behaviour described by the characteristic equation: natural mode and local vector of linear momentum.

Hereby we can solve the optimization problem of equation (6) in three steps for three scalar preference functions s_1, s_2 and s_3. For the steps two and three it is necessary that the elements of the preference function which are optimized before are written as additional constrain functions. The resulting diagnostic model is highly correct in the sense of the considered dynamical properties.

3 Damage detection

The task of damage detection is to identify changes of local parameters of a system based on vibration measurements. The damage detection procedure is based on the created diagnostic model, see figure 1. The vibration measurements of a system are results of the excitation forces of the real system. It is possible to calculate system responses with the same excitation forces for the diagnostic model. If there are changed design parameters by damage they can be identified by the difference of the system response [Pereira et al, 1995].

The difference between the diagnostic model D and the damaged system F can be determined by the Force-Balance-Method based on FRF data [Larsson, 1992]. Hence the error function can be written in the following form:

$$\underline{\varepsilon}^{DF}(\omega) = \boldsymbol{F}^{D}(\omega) - \boldsymbol{F}^{F}(\omega), \tag{7}$$

if we suppose that the displacement vectors $y^D(t) = y^F(t)$ of both systems are the same. The residue (7) can be converted into a vector error function which can be used in an iterative adaptation process:

$$\underline{\varepsilon}(\omega, \boldsymbol{x}) = \boldsymbol{Z}^{D}(\omega, \boldsymbol{x})\, \boldsymbol{H}_j^{F}(\omega) - \boldsymbol{e}_j, \tag{8}$$

with: $\boldsymbol{Z}^D(\omega, \boldsymbol{x})$: matrix of dynamic stiffness of the diagnostic model D, $\boldsymbol{H}_j^F(\omega)$: measured column vector j of the receptance matrix $\boldsymbol{H}^F(\omega)$ of the damaged system and with the acting experimental force:

$$\boldsymbol{F}^{F}(\omega) = \boldsymbol{e}_j F^{F}(\omega), \quad \boldsymbol{e}_j^{T} = [0, \ldots, 0, 1, 0, \ldots 0]. \tag{9}$$

The connection between (7) and (8) is obvious. The multiplication of (8) by the scalar acting force $F^F(\omega)$ and the condition $y^D(t) = y^F(t)$ results in (7).

The minimization problem of the error vector (8) regarding the design vector $\boldsymbol{x}$ is nonlinear:

$$\min_{\boldsymbol{x} \in \Re^n} \left\| \underline{\varepsilon}(\omega, \boldsymbol{x}) \right\| = \min_{\boldsymbol{x} \in \Re^n} \left\| \boldsymbol{Z}^{D}(\omega, \boldsymbol{x})\, \boldsymbol{H}_j^{F}(\omega) - \boldsymbol{e}_j \right\|. \tag{10}$$

Applying Taylor's expansion and using only linear expressions of the design variable vector $\boldsymbol{x}$ results in [Pereira, 1996]:

$$\underline{\varepsilon}(\omega, \boldsymbol{x}) = \boldsymbol{S}(\omega, \boldsymbol{x}) \Delta \boldsymbol{x} - \Delta \boldsymbol{H}_j^{DF}(\omega, \boldsymbol{x}) \Rightarrow \min. \tag{11}$$

The terms of this equation are: the sensitivity of the dynamic stiffness matrix $S(\omega, x)$, the difference vector of design parameter Δx and the difference vector $\Delta H_j^{DF}(\omega, x)$ between the frequency response of the diagnostic model and the damaged system:

$$\Delta \boldsymbol{H}_j^{DF}(\omega, \boldsymbol{x}) = \boldsymbol{H}_j^{D}(\omega, \boldsymbol{x}) - \boldsymbol{H}_j^{F}(\omega). \tag{12}$$

To find the change Δx of the vector of design variable x the following over-determined equation system must be solved:

$$\boldsymbol{S}(\omega, \boldsymbol{x})\Delta \boldsymbol{x} = \Delta \boldsymbol{H}_j^{DF}(\omega, \boldsymbol{x}). \tag{13}$$

This can be done with an iterative least-square-procedure [Pereira, 1996]. The needed numbers of equations for the approximate solution of (13) are taken from the measured data of the frequency response with different excitation frequencies.

The iterative changing of the diagnostic model D finishes in the damaged model U. It is possible to identify the damage parameter directly because all the parameters of the damaged model U are physical parameters.

The procedure of generation of the diagnostic model and the FRF based damage detection is shown by a beam-structure example in [Pereira, 1999].

4 References

[Biegler, 1980] Biegler-König, F. "Inverse Eigenwertprobleme". Dissertation, Universität Bielefeld, 1980.

[Doebling et al, 1998] Doebling, Scott W.; Charles R. Farrer; Michael B. Prime. "A Summary Review of Vibration-Based Damage Identification Methods". The Shock and Vibration Digest, Vol. 30, No. 2, March 1998: 91-105.

[Eschenauer et al, 1990] Eschenauer, H.; Koski, J.; Osyczka, A. "Multicriteria Design Optimization". Springer-Verlag, Berlin-Heidelberg-New York, 1990.

[Ewins, 1984] Ewins, D.J. „Modal Testing: Theory and Practice". Research Studies Press, John Wiley&Sons, New York, 1984.

[Gladwell, 1986] Gladwell, G.M.L. "Inverse Problems in Vibration". Martinus Nijhoff Publishers, Dordrecht, Boston, Lancaster, 1986.

[Larsson, 1992] Larsson, P.O., Sas, P. "Model Updating Based on Forced Vibration Testing Using Numerically stable Formulations". Proc. 10th IMAC, 1992, Volume II, pp. 966-974.

[Müller-Slany, 1992] Müller-Slany, H.H. "Ein Beitrag zur Lösung von Vektoroptimierungsaufgaben bei der Generierung angepaßter Punktmassensysteme durch hierarchische Skalarisierung". Festschrift zum 80. Geburtstag von Prof. Dr. Kurt Magnus. Institut B für Mechanik, TU München, 1992: 57-66.

[Müller-Slany, 1993] Müller-Slany, H.H. "A Hierarchical Scalarization Strategy in Multicriteria Optimization Problems". In: Brosowsky, B. et al. „Multicriteria Decision". Peter Lang, Frankfurt am Main, 1993: 69-79.

[Pereira, et al, 1995] Pereira, J.A.; Heylen, W.; Lammens, W.S.; Sas, P. "Application of Model Updating Technique for Health Condition Monitoring and Damage Detection in flexible Structures". 15° Bian. Conf. In Vib. And Noise-ASME, Boston-USA, 1995.

[Pereira, 1996] Pereira, J.A. "Structural Damage Detection Methodology using a Model Updating Procedure based on Frequency Response Functions – FRF(s)". Tese de Doutorado, Univ. Estadual de Campinas, Faculdade de Eng. Mecânica, Campinas, 1996.

[Pereira, 1999] Pereira, J.A.; Müller-Slany, H.H.; Brunzel, F.; Weber, H.I. "The outline of damage detection of a beam-structure using a diagnostic model combined with an updating procedure based on FRF", PACAM 6, 4-8 January 1999, Rio de Janeiro, Brazil, pp. 1439-1442.

Schadensdiagnose für elastomechanische Strukturen auf der Basis adaptierter Diagnosemodelle und FRF-Daten

Prof. Dr.-Ing. Hans H. Müller-Slany VDI, Duisburg

Prof. Dr.-Ing. João Antonio Pereira, UNESP Ilha Solteira, Brasilien

Prof. Dr.-Ing. Hans Ingo Weber, PUC Rio de Janeiro, Brasilien

Dipl.-Ing. Frank Brunzel, Duisburg

Abstract

Das Ziel der Schadensdiagnose für elastomechanische Systeme ist die Angabe von Schadensort und Schadensumfang aus Schwingungsmessungen am System unter Betriebsbedingungen. Es wird eine modellgestützte Schadensdiagnose für flexible Strukturen vorgestellt, die auf einem stark kondensierten, aber gleichzeitig dynamisch sehr genauem Diagnosemodell basiert. Das Diagnosemodell ist aus Makroelementen mit realitätsnahen Designparametern aufgebaut und gewährleistet damit den Bezug zwischen Modell und Realität innerhalb der Schadensidentifikation. Für die Generierung des Diagnosemodells wird eine hierarchische Optimierungsprozedur angegeben. Die Identifikation eines Schadens basiert auf Frequency-Response-Daten der geschädigten Struktur. Durch programmgesteuerte Änderung der Parameter des Diagnosemodells wird eine FRF-Residuenfunktion auf der Modellebene minimiert und der geschädigte Parameter nach Ort und Größe identifiziert.

1 Problemübersicht

In der Literaturübersicht [Doebling et al, 1998] werden zum Themenkreis Schadensdiagnose auf der Basis von Schwingungsmessungen an geschädigten Systemen über 150 wissenschaftliche Arbeiten der letzten Jahre referiert. Diese Arbeiten basieren auf der Tatsache, daß die modalen Systemeigenschaften Funktionen der realen Systemparameter sind. Änderungen der Strukturparameter aufgrund von Schadensereignissen bewirken Änderungen in den modalen Eigenschaften, die sich in den Messungen nachweisen lassen. Die Entwicklung leistungsfähiger Schadensdiagnose-Methoden ist eine Aufgabe von höchstem ökonomischen Interesse. Überall dort, wo die Systemuntersuchung auf Schäden durch regelmäßige Inspektionen zu kostenaufwendig ist, sucht man nach geeigneten Diagnosemethoden, mit denen lokale Parameteränderungen im System erkannt werden können. Das Entwicklungsziel der Bereitstellung einer robusten Schadensdiagnose, die realistische, praxisrelevante

Die vorgelegte Arbeit ist das Ergebnis der Zusammenführung der Forschungsergebnisse einer deutsch-brasilianischen Arbeitsgruppe im Rahmen des PROBRAL-Programms, finanziert vom DAAD in Deutschland und von CAPES in Brasilien.

Meßdaten zur Identifikation von Strukturschädigungen nutzt, ist noch lange nicht erreicht. Eines der Hauptprobleme der modellgestützten Schadensdiagnose ist die Vertrauenswürdigkeit des zugrunde liegenden mathematischen Modells, meist als FE-Modell formuliert, das ausreichende Senisitivität bei Änderungen der realen Designparameter besitzt.

Die vorliegende Arbeit widmet sich im besonderen zwei Zielen: Der Generierung eines zuverlässigen hochkondensierten, dynamisch exakten und parameter-sensitiven Diagnosemodells, das zur Schadensdiagnose einsetzbar ist sowie der Entwicklung einer auf FRF-Messungen aufbauenden Identifikationsprozedur für geschädigte Systemparameter nach Schadensort und Umfang. In der modellgestützten Schadensdiagnose wird das gemessene dynamische Verhalten eines elastomechanischen Systems dem dynamischen Verhalten eines mathematischen Modells der ungeschädigten Struktur S gegenübergestellt. Dieses systembeschreibende Modell für den Originalzustand des zu untersuchenden Systems wird im folgenden als *Diagnosemodell D* beschrieben. Lokale Parameterveränderungen auf grund von Schadensereignissen lassen sich bei geeigneter Generierung des Diagnosemodells nach Größe und Schadensort identifizieren. Im Bild 1 ist die Struktur der Schadensidentifikation auf der Basis eines Diagnosemodells gezeigt [Müller-Slany, 1997].

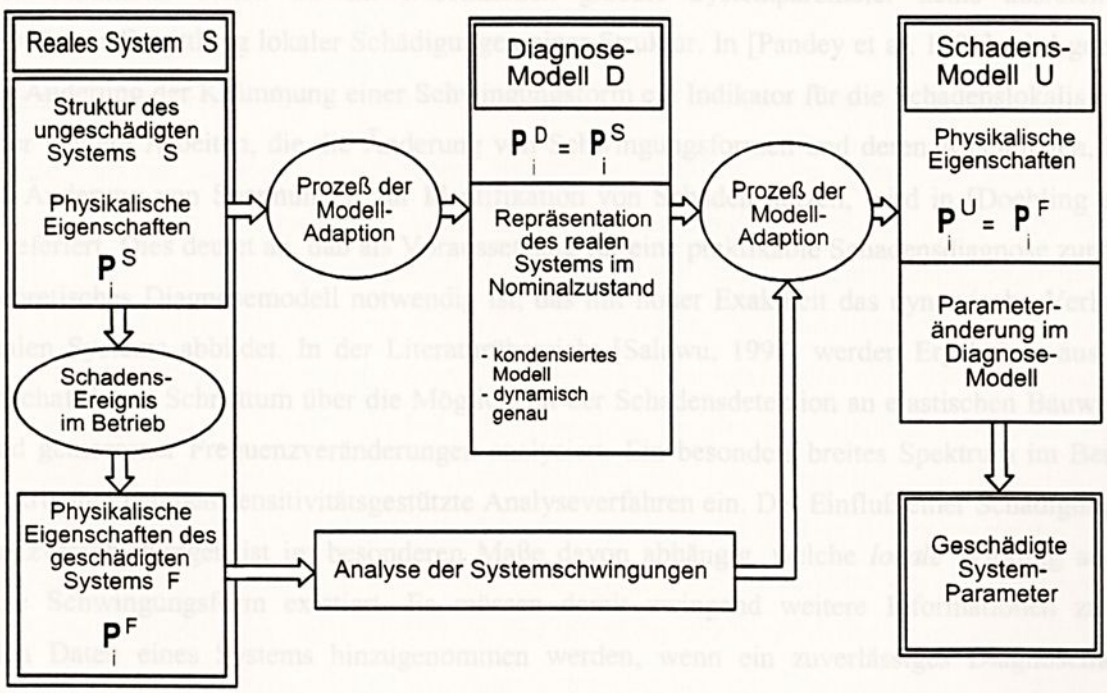


Bild 1: Struktur der modellgestützten Schadensdiagnose

Der Diagnoseprozeß hat seine besonderen spezifischen Ausformungen in den beiden Adaptionsprozessen zur Gewinnung des Diagnose- und Schadens-Modells. Hierin unterscheidet sich die vorgestellte Schadensdiagnose wesentlich von den zahlreichen Arbeiten des einschlägigen Schrifttums.

2 Das Diagnosemodell

In der modellgestützten Schadensdiagnose wird der Zusammenhang zwischen den physikalischen Systemparametern und dem Schwingungsverhalten des Systems in einer inversen Aufgabenformulierung zur Identifikation von Parameteränderungen genutzt. Die inverse Aufgabenstellung der Schwingungsdynamik lautet: Man finde zu einem vorgegebenen, z.B. zu einem gemessenen Eigenschwingungsverhalten die Parameter des dynamischen Systems [Gladwell, 1986]. Dies entspricht der inversen Eigenwertaufgabe [Biegler, 1980], in der zu gegebenen spektralen Daten die Elemente der zugehörigen Ausgangsmatrix zu bestimmen sind. Für diese Aufgabe ist allgemein keine eindeutige Lösung angebbar. Die Schwierigkeiten in der modellgestützten Schadensdiagnose erhöhen sich noch dadurch, daß man im Prinzip Parameteränderungen des realen Systems mit Hilfe von Verfahren sucht, die sich auf hochkondensierte Modelle abstützen, in denen durch die Diskretisierung ein Informationsverlust vorliegt.

Für eine eindeutige Identifikation einer Schädigung nach Schädigungsort und -Umfang reichen die Informationen von Eigenfrequenzen und Eigenformen für das Diagnosemodell allein nicht aus. Diese modalen Parameter bieten als im wesentlichen globale Systemparameter keine ausreichende Sensitivität zur Ermittlung lokaler Schädigungen einer Struktur. In [Pandey et al, 1991] wird gezeigt, daß die Änderung der Krümmung einer Schwingungsform ein Indikator für die Schadenslokalisierung ist. Über weitere Arbeiten, die die Änderung von Schwingungsformen und deren Ableitungen, bzw. die die Änderung von Spannungen zur Identifikation von Schäden nutzen, wird in [Doebling et al, 1998] referiert. Dies deutet an, daß als Voraussetzung für eine praktikable Schadensdiagnose zunächst ein theoretisches Diagnosemodell notwendig ist, das mit hoher Exaktheit das dynamische Verhalten des realen Systems abbildet. In der Literaturübersicht [Salawu, 1997] werden Ergebnisse aus dem wissenschaftlichen Schrifttum über die Möglichkeit der Schadensdetektion an elastischen Bauwerken an hand gemessener Frequenzveränderungen analysiert. Ein besonders breites Spektrum im Bereich dieser Arbeiten nehmen sensitivitätsgestützte Analyseverfahren ein. Der Einfluß einer Schädigung auf Frequenzverschiebungen ist im besonderen Maße davon abhängig, welche *lokale* Wirkung auf die einzelne Schwingungsform existiert. Es müssen damit zwingend weitere Informationen zu den modalen Daten eines Systems hinzugenommen werden, wenn ein zuverlässiges Diagnosemodell generiert werden soll.

Als Diagnosemodell wird ein stark kondensiertes FE-Modell entwickelt, das zur weitgehenden Reduktion der Zahl der Freiheitsgrade aus großen Balkenelementen aufgebaut ist. Die einzelnen Modellelemente entsprechen Makroelementen im Rahmen der FE-Analyse. In einem Optimierungsprozeß wird dieses Modell an diejenigen physikalischen Eigenschaften des Originalsystems angepaßt,



die für Diagnoseaufgaben erfüllt sein müssen. Hierbei steht die Sensitivität des Diagnosemodells und die Inversfähigkeit des Modells zur Rückübertragung von geänderten Modelldaten auf der Parameterebene des Originalsystems im Vordergrund.

Welches sind die dynamisch relevanten Eigenschaften, die ein Diagnosemodell erfüllen muß, um ein reales elastomechanisches System für Diagnoseaufgaben ausreichend genau abbilden zu können? Zunächst sind dies die massengeometrischen Systemdaten: Gesamtmasse, Lage des Massenmittelpunktes und die Elemente des Trägheitstensors sowie die modalen Daten: betrachtete Eigenfrequenzen und Eigenformen des Systems. Anhand von Identifikationsversuchen stellt man aber schnell fest, daß Schadensdetektion auf der Basis derartiger Modelle nur unzuverlässig möglich ist. Nach einem Vorschlag von Pandey [Pandey et al, 1991] werden Veränderungen von Eigenformkrümmungen mit in den Schadensdetektionsprozeß einbezogen, wobei die Schwierigkeit der ausreichend genauen Erfassung ein eigenes Problem ist. Trotzdem wird hier ein ganz entscheidender Schritt in der Modellbildung vorgezeichnet: Die Formulierung und Berücksichtigung lokaler Systemszustandsgrößen. Die hier zu betrachtenden Systemschäden sind immer lokale Ereignisse, z. B. eine lokale Steifigkeitsänderung. Infolgedessen ist es dringend geboten, im Adaptionsprozeß lokale dynamische Eigenschaften besonders zu berücksichtigen.

2.1 Lokale dynamische Eigenschaften für das Diagnosemodell

Zur Beschreibung lokaler dynamischer Systemeigenschaften, die dem zu entwickelnden Diagnosemodell eine hinreichende Sensitivität zur Beschreibung lokaler Schadensereignisse vermitteln, kann man auf die physikalischen Grundlagen zur mathematischen Modellbildung zurückgehen. Grundlage zur Ableitung der Bewegungsgleichung für das dynamische Systemverhalten ist die Anwendung des Impulssatzes auf ein infinitesimales Strukturelement, bzw. die Anwendung von Impuls- und Drallsatz auf ein endliches Makroelement. In diesen Modellbildungsprozeß fließen insbesondere die Schnittgrößen an den Elementgrenzen ein. Eine Voraussetzung für die Modellbildung mit hinreichender lokaler Modellsensitivität ist hiernach die richtige Beschreibung des inneren Kräftespiels im System im Zustand betrachteter Bewegungen, z.B. im Zustand von Eigenschingungen. Das zeitliche Verhalten der Schnittkräfte an den Elementgrenzen wird dann vom Modell korrekt wiedergegeben, wenn sich der zeitveränderliche Impuls des betrachteten Elements von Diagnosemodell und Realsystem nicht unterscheidet.

Mit dem lokalen, elementbezogenem Impuls kann dem Diagnosemodell eine lokale Sensitivität bezüglich lokaler Parameteränderung aufgeprägt werden. Mit der Anpassung an den lokalen Impuls stimmen die Schnittkräfte in diskreten Schnittebenen zwischen Modell und Original überein. Die

hochkondensierte Modellstruktur eines Diagnosemodells für eine Kurbelwelle ist im Bild 2 mit Angabe des Impulsvektors $\boldsymbol{p}_i^D$ eines lokalen Elements angegeben. Der lokale Impuls $\boldsymbol{p}_i^D$ für das *i*-te Balkenelement des Diagnosemodells *D* mit der Masse m_i und den Elementknoten *r* und *s* lautet im Zustand der *k*-ten Eigenschwingung des Systems:

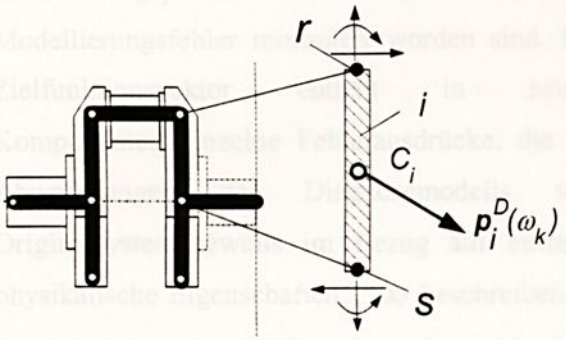


Bild 2: Entwurf eines Diagnosemodells für eine Kurbelwelle mit lokalem Impuls $\boldsymbol{p}_i^D$ des *i*-ten Balkenelements.

$$\boldsymbol{p}_i^D(\omega_k) = \left\{ \tfrac{1}{2}\omega_k\, m_i(\boldsymbol{q}_{r,k} + \boldsymbol{q}_{s,k}) \right\}^D, \qquad (1)$$

mit der Eigenfrequenz ω_k und den Eigenvektorelementen $\boldsymbol{q}_{r,k}$ und $\boldsymbol{q}_{s,k}$ des *k*-ten Eigenvektors für die Knoten *r*, *s*. Der Vektor (1) ist Subvektor des *3m*-dimensionalen Gesamtvektors $\tilde{\boldsymbol{p}}^D(\omega_k)$ aller lokalen Impulse $\boldsymbol{p}_i^D(\omega_k)$ der *m* Balkenelemente für ein Diagnosemodell mit *p* Knoten:

$$\tilde{\boldsymbol{p}}^D(\omega_k) = \begin{bmatrix} \frac{1}{2}\omega_k m_1 \ (\boldsymbol{q}_{1,k}+\boldsymbol{q}_{2,k}) \\ \vdots \\ \frac{1}{2}\omega_k m_m \ (\boldsymbol{q}_{p-1,k}+\boldsymbol{q}_{p,k}) \end{bmatrix}^D. \qquad (2)$$

Vergleichbare Ausdrücke können für das Originalsystems *S* auf den diskreten Elementbereichen des Diagnosemodells numerisch bestimmt werden. Damit erhält man den *3m*-dimensionalen Gesamtvektor $\tilde{\boldsymbol{p}}^S(\omega_k)$ aller lokalen Impulse für das Originalsystem. Im nachfolgenden Generierungsprozeß für das Diagnosemodell muß zur Steigerung der lokalen Modellsensitivität der Fehler zwischen den Vektoren $\tilde{\boldsymbol{p}}^S(\omega_k)$ und $\tilde{\boldsymbol{p}}^D(\omega_k)$ minimiert werden. Anpassung an den lokalen Impulsvektor, d.h. Anpassung an das innere Kräftespiel im Zustand von Systemeigenschwingungen bedeutet nach (2) Anpassung an die Schwingungsform, gewichtet mit den zugehörigen Massen.

2.2 Multikriterien-Optimierungsprozedur zur Generierung eines Diagnosemodells

Generierung eines Diagnosemodells (Bild 3) bedeutet, die Ermittlung eines Entwurfsvariablenvektors $\boldsymbol{x} = [x_1, \ldots, x_n]$, der das Layout des Modells durch *n* Entwurfsgrößen beschreibt. Diese Größen sind diejenigen Variablen, durch die ein Modell aus Balkenelementen beschrieben wird: Elementmassen, Knotenkoordinaten, Elementsteifigkeiten. Das Final-Design $\boldsymbol{x}$ des Diagnosemodells

ist dann gefunden, wenn die Komponenten eines Zielfunktionsvektors $\boldsymbol{f(x)}$ in einem Mehrkriterien-Minimierungsprozeß auf einen zulässigen Modellierungsfehler minimiert worden sind. Der Zielfunktionsvektor enthält in seinen Komponenten einzelne Fehlerausdrücke, die die Abweichungen des Diagnosemodells vom Originalsystem jeweils im Bezug auf einzelne physikalische Eigenschaften $P_i(\boldsymbol{x})$ beschreiben. In der Regel hat der Zielfunktionsvektor folgenden Aufbau:

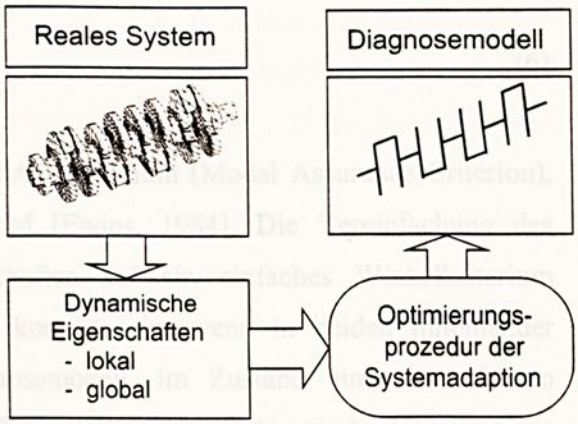


Bild 3: Generierung eines Diagnosemodells

$$\boldsymbol{f(x)} = \begin{bmatrix} \varepsilon_1(\boldsymbol{x}) \\ \varepsilon_2(\boldsymbol{x}) \\ \varepsilon_3(\boldsymbol{x}) \\ \varepsilon_4(\boldsymbol{x}) \\ \varepsilon_5(\boldsymbol{x}) \\ \varepsilon_6(\boldsymbol{x}) \end{bmatrix} = \begin{bmatrix} \textit{Fehlerausdruck für : Gesamtmasse} \\ \textit{...Lage des Massenmittelpunktes} \\ \textit{...Elemente des Trägheitstensors} \\ \textit{...berücksichtigte Eigenfrequenzen} \\ \textit{...berücksichtigte Eigenformen} \\ \textit{...Vektor der lokalen Impulse für ber. Eigenschwingungen} \end{bmatrix} \tag{3}$$

Die Fehlerausdrücke ε_i, $i = 1, ..., 6$ sind Funktionen der Entwurfsvariablen x_k, $k = 1, ..., n$. Für die skalaren physikalischen Eigenschaften $P_1(\boldsymbol{x})$, ..., $P_4(\boldsymbol{x})$ gemäß (3) lauten die zugehörigen Fehlerausdrücke:

$$\varepsilon_i(\boldsymbol{x}) = \left[1 - \frac{P_i^D(\boldsymbol{x})}{P_i^S(\boldsymbol{x})}\right]^2, i=1,...,4. \tag{4}$$

Eine möglichst einfache Formulierung für die Fehlerausdrücke der vektoriellen physikalischen Eigenschaften $P_5(\boldsymbol{x})$ und $P_6(\boldsymbol{x})$ ist aus numerischen Gründen für den nachfolgenden Adaptionsprozeß geboten. Der Optimierungsprozeß zur Modellgenerierung läuft erfolgreicher, wenn der Fehlerausdruck nicht aus der Differenz der Vektoren gebildet wird, sondern aus dem Winkel zwischen den Vektoren. Im Falle der Eigenvektoren $\boldsymbol{q}_k$ der *k-ten* Eigenschwingung folgt aus dem Skalarprodukt:

$$\boldsymbol{q}_k^S \boldsymbol{q}_k^D = |\boldsymbol{q}_k^S||\boldsymbol{q}_k^D| \cos(\boldsymbol{q}_k^S, \boldsymbol{q}_k^D). \tag{5}$$

Das Diagnosemodell D ist dann erfolgreich adaptiert, wenn die *cos*-Funktion in (5) den Wert 1 hat. Damit folgt aus (5) sofort das Fehlerkriterium für die vektoriellen physikalischen Eigenschaften: die Eigenschwingungsformen und den Vektor der lokalen Impulse im Zustand einer Eigenschwingung:

$$\varepsilon_i(\boldsymbol{x}) = 1 - \frac{\boldsymbol{P}_i^{\,D}(\boldsymbol{x})^T \boldsymbol{P}_i^{\,S}}{\left|\boldsymbol{P}_i^{\,D}(\boldsymbol{x})\right| \left|\boldsymbol{P}_i^{\,S}\right|} \quad , \; i = 5,6. \tag{6}$$

Dieser Ausdruck steht in Übereinstimmung mit dem MAC-Kriterium (Modal Assurance Criterion), das in der experimentellen Modalanalyse benutzt wird [Ewins, 1984]. Die Vereinfachung des Fehlerausdrucks für vektorielle dynamische Eigenschaften auf ein einfaches Winkelkriterium zwischen den betrachteten Vektoren kann nur dann korrekt sein, wenn in beiden miteinander verglichenen Systemen, im Original und im Diagnosemodell, im Zustand einer betrachteten Schwingung die gleiche maximale kinetische Energie $T(x)$ auftritt. Für die kinetische Energie eines elastomechanischen Systems im Zustand der *k-ten* Eigenschwingung gilt:

$$T_k(\boldsymbol{x}) = \tfrac{1}{2}\dot{\boldsymbol{q}}_k^T(\boldsymbol{x})\,\boldsymbol{M}(\boldsymbol{x})\dot{\boldsymbol{q}}_k(\boldsymbol{x}) = \tfrac{1}{2}\omega_k^2 \boldsymbol{q}_k^T(\boldsymbol{x})\,\boldsymbol{M}(\boldsymbol{x})\boldsymbol{q}_k(\boldsymbol{x}) \quad . \tag{7}$$

Mit der üblichen Normierung der Eigenvektoren: $\boldsymbol{q}_k^T(\boldsymbol{x})\,\boldsymbol{M}(\boldsymbol{x})\,\boldsymbol{q}_k(\boldsymbol{x}) = 1$ ist die kinetische Energie in (7) nur mehr eine Funktion der Eigenfrequenz. Das Generierungsproblem für das Diagnosemodell kann jetzt als restringiertes Mehrkriterienproblem formuliert werden [Müller-Slany, 1993]:

$$\min_{\boldsymbol{x}\in\Sigma} \left\{ \boldsymbol{f}\left[\varepsilon(\boldsymbol{x})\right] \middle| \boldsymbol{h}(\boldsymbol{x}) = \boldsymbol{0} \right\}, \; \Sigma := \left\{ \boldsymbol{x} \in \Re^n \middle| \boldsymbol{x}_L \le \boldsymbol{x} \le \boldsymbol{x}_U \right\}. \tag{8}$$

Hierin sind: $\boldsymbol{x}$: Entwurfsvariablenvektor, $\boldsymbol{f}$: Vektorzielfunktion, $\varepsilon(\boldsymbol{x})$: Vektor der Fehlerausdrücke, $\boldsymbol{h}(\boldsymbol{x})$: Vektor der Gleichheitsrestriktionen, Σ: zulässiger Bereich, $\boldsymbol{x}_L$, $\boldsymbol{x}_U$: untere und obere Grenze der Entwurfsvariablen. Die Lösung des Optimierungsproblems (8) erfolgt in einem numerisch gesteuertem Iterationsprozeß mit entsprechenden Optimierungs- Algorithmen. Die Grundstruktur ist im Bild 3 dargestellt. Ausgehend von einem Initial-Design werden über eine Strukturanalyse des Systems die Komponenten der Zielfunktion berechnet. Mit Hilfe eines Optimierungs-Algorithmus wird der Entwurf gezielt verändert zur Erfüllung der Minimierungsforderung (8). Nach Ansprechen eines Abbruchkriteriums ist das Diagnosemodell mit den Forderungen nach sehr genauer Abbildung der globalen und lokalen dynamischen Eigenschaften generiert.

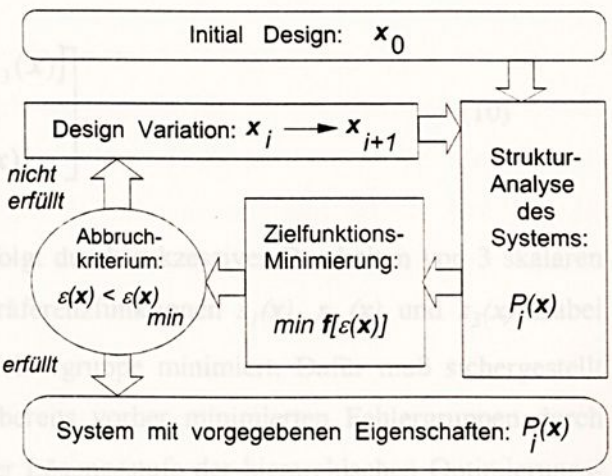


Bild 4: Grundstruktur zur Generierung des Diagnosemodells.

Die eigentliche Lösung des Vektoroptimierungsproblem (8) bedarf einer besonderen Gestaltung der Minimierungsvorschrift des Zielfunktionsvektors $\boldsymbol{f(x)}$, sowie des Iterationsverlaufs, um bei der großen Zahl der zu berücksichtigenden, sehr unterschiedlichen physikalischen Eigenschaften einen erfolgreichen Minimierungslauf zu ermöglichen. Vektoroptimierungsprobleme werden durch Skalarisierung der Vektorzielfunktion gelöst [Esch. et al, 1990]. Bewährt hat sich die gewichtete Überlagerung aller Zielfunktionskomponenten von $\boldsymbol{f(x)}$ zu einer skalaren Präferenzfunktion $s(\boldsymbol{x})$:

$$\boldsymbol{f}(\boldsymbol{x}) \Rightarrow \mathrm{s}\{\boldsymbol{f}[\varepsilon(\boldsymbol{x})]\} = \sum_{i=1}^{6} \mathrm{w}_i \varepsilon_i , \tag{9}$$

mit den Wichtungsfaktoren w_i und den quadratischen Fehlerausdrücken ε_i. Die allgemein angewandte gleichzeitige Überlagerung aller Fehler führt im vorliegenden Problem zu sehr schlechten Konvergenzeigenschaften. Das Vektoroptimierungsproblem zur Generierung zuverlässiger Diagnosemodelle ist auf diese Weise nicht lösbar. Nur durch Trennung der unterschiedlichen Fehlergruppen wird das Problem in einer hierarchisch gestuften Optimierungsprozedur lösbar [Müller-Slany, 1992]. In dieser Prozedur werden die Komponenten des Fehlervektors nicht gleichzeitig überlagert, sondern sie werden zunächst in Präferenzgruppen zusammengefaßt, in denen - analog zu (9) - die Einzelfehler überlagert werden:

1. Präferenzruppe: Alle massengeometrischen dynamischen Eigenschaften.
2. Präferenzruppe: Dynamische Eigenschaften, die durch das charakteristische Polynom beschrieben werden: alle Eigenfrequenzen.
3. Präferenzruppe: Dynamische Eigenschaften, die durch die charakteristische Gleichung beschrieben werden: alle Eigenformen sowie die Vektoren der lokalen Impulse.

Damit erhält die Zielfunktion folgende Form:

$$\boldsymbol{f}(\boldsymbol{x}) \Rightarrow \boldsymbol{s}\{\boldsymbol{f}[\varepsilon(\boldsymbol{x})]\} = \begin{bmatrix} \mathrm{s}_1[\varepsilon_1(\boldsymbol{x}),\varepsilon_2(\boldsymbol{x}),\varepsilon_3(\boldsymbol{x})] \\ \mathrm{s}_2[\varepsilon_4(\boldsymbol{x})] \\ \mathrm{s}_3[\varepsilon_5(\boldsymbol{x}),\varepsilon_6(\boldsymbol{x})] \end{bmatrix}. \tag{10}$$

Die Lösung der Vektoroptimierungsaufgabe (8) erfolgt durch sukzessives Bearbeiten von 3 skalaren Optimierungsaufgaben mit den einzelnen skalaren Präferenzfunktionen $s_1(\boldsymbol{x})$, $s_2(\boldsymbol{x})$, und $s_3(\boldsymbol{x})$. Dabei wird in jeder Optimierungsstufe eine bestimmte Fehlergruppe minimiert. Dafür muß sichergestellt werden, daß in der 2. und 3. Lösungsstufe alle bereits vorher minimierten Fehlergruppen durch Restriktionsgleichungen beschränkt bleiben. In jeder Lösungsstufe der hierarchischen Optimierungsprozedur treten damit zusätzliche Restriktionsgleichungen auf. Insgesamt ergibt sich der nachfolgende Rechengang zur Lösung der Mehrkriterienoptimierung bei der Generierung eines Diagnosemodells:

1. Optimierungsstufe

$$\min_{x\in\Sigma} s_1\{f[\varepsilon_1(x),\varepsilon_2(x),\varepsilon_3(x)]\},\quad s_1\{f[\varepsilon_1(x),\varepsilon_2(x),\varepsilon_3(x)]\}=\sum_{i=1}^{3} w_i\varepsilon_i, \tag{11}$$

$$\Sigma:=\{x\in\Re^n \mid x_L\le x\le x_U\}.$$

2. Optimierungsstufe:

$$\min_{x\in\Sigma}\rangle s_2\{f[\varepsilon_4(x)]\}\mid h(x)=0\langle,\quad s_2\{f[\varepsilon_4(x)]\}=\sum_k \varepsilon(\omega_k), \tag{12}$$

$$\Sigma:=\begin{Bmatrix} x\in\Re^n \mid x_L\le x\le x_U \\ h_1(x)=\varepsilon_1(x)-\Delta=0 \\ h_2(x)=\varepsilon_2(x)-\Delta=0 \\ h_3(x)=\varepsilon_3(x)-\Delta=0 \end{Bmatrix}.$$

3. Optimierungsstufe:

$$\min_{x\in\Sigma}\rangle s_3\{f[\varepsilon_5(x),\varepsilon_6(x)]\}\mid h(x)=0\langle,\quad s_3\{f[\varepsilon_5(x),\varepsilon_6(x)]\}=\sum_k[\varepsilon(q_k)+\varepsilon(\tilde{p}_k)], \tag{13}$$

$$\Sigma:=\begin{Bmatrix} x\in\Re^n \mid x_L\le x\le x_U \\ h_1(x)=\varepsilon_1(x)-\Delta=0 \\ h_2(x)=\varepsilon_2(x)-\Delta=0 \\ h_3(x)=\varepsilon_3(x)-\Delta=0 \\ h_4(x)=\varepsilon_4(\omega_1)-\Delta=0 \\ \vdots \\ h_{3+k}(x)=\varepsilon_{3+k}(\omega_k)-\Delta=0 \end{Bmatrix}.$$

Der Parameter Δ ist der zulässige Fehler für die bereits in den vorhergehenden Optimierungsstufen angepaßten dynamischen Systemeigenschaften. Nach Durchlaufen der 3. Optimierungsstufe ist das Final Design für das gesuchte Diagnosemodell gefunden. Typische Fehler für die massengeometrischen Daten und die ersten 6 anzupassenden Eigenfrequenzen sind $\varepsilon^{1/2} = 10^{-5}$. Für die Eigenformen und Vektoren der lokalen Impulse sind nach dem Fehlerkriterium (7) derzeit Werte von $\varepsilon = 10^{-2}... 10^{-3}$ erreichbar.

Als Optimierungsalgorithmus erweisen sich SQP-Verfahren (sequentiell quadratische Programmierung) als geeignet, die aber zur Sicherstellung der hierarchischen Optimierungsprozedur durchweg im zulässigen Bereich arbeiten müssen. Für die Berechnungen wurde ein Verfahren benutzt, das aus einem SQP-Verfahren und einem GRG-Verfahren (generalisierte reduzierte Gradienten) aufgebaut ist [Bremicker, 1989].

Das Diagnosemodell ist ein hochkondensiertes Makroelemente-Modell, das über einen gezielten Generierungsprozeß über mehrere numerische Fehler-Minimierungsschritte schrittweise an die notwendigen globalen und lokalen dynamischen Eigenschaften des Originalsystems angepaßt wird. Diese Modellentwicklung vereinigt zwei wesentliche Modellvorteile, die für Schadensdiagnose-aufgaben unerläßlich sind: Infolge der Parameteranpassung auf Makroelemente-Ebene des Diagnosemodells bleibt auch im Zustand der hohen Modellkondensation der Bezug zwischen Modellparameter und physikalischem Designparameter des Systems erhalten. Es werden im Adaptionsprozeß keine physikalisch unanschaulichen Matrizenelemente numerisch angepaßt, sondern Parameter auf Realebene. Die zweite Besonderheit der hier vorgestellten Diagnosemodelle ist dadurch gegeben, daß dieser Anpassungsprozeß für theoretisch-analytische physikalische Daten ebenso möglich ist wie für experimentelle Daten. Damit wird auch schon die Möglichkeit der Schadensidenti-fikation vorgegeben. Kurz umrissen kann die Adaptionsprozedur zur Generierung des hier vorgestellten Diagnosemodells als ein „evolutionärer" Anpassungsprozeß (Bild 5) gesehen werden, in dem ausgehend vom ersten Initial-Design (ID) dem Modell in fortlaufenden Schritten weitere wichtige dynamische Systemeigenschaften aufgeprägt werden, bis aus der einfachen Makroelementestruktur schließlich das dynamisch hochgenaue *Diagnosemodell* gebildet wurde. Dieses Modell eignet sich besonders für anschließende Schadens-Diagnoseaufgaben, da es einerseits der Realität sehr genau entspricht, z.B. durch die Anpassung an reale Meßwerte, andererseits der Grad der Modellreduktion so hoch ist, daß numerische Identifikationsaufgaben erfolgreich durchgeführt werden können.

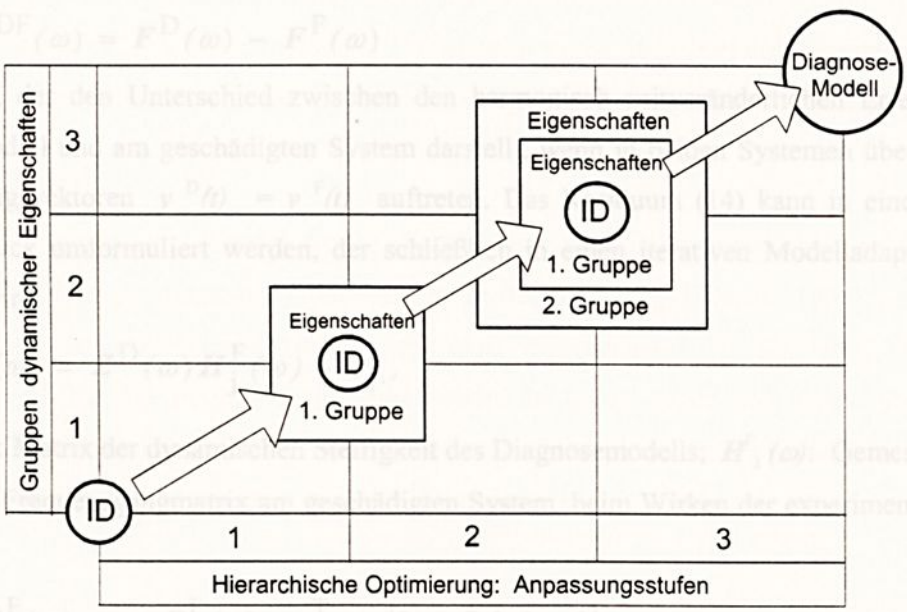


Bild 5: Die hierarchische Generierungsprozedur für das Diagnosemodell als „evolutionärer" Anpassungsprozeß.

3 Schadensidentifikation

Aufgabe der Schadensdiagnose ist die Identifikation einer lokalen Systemparameteränderung während des Betriebes aus aufgenommenen Schwingungsmessungen. Ziel ist dabei die Möglichkeit der sicheren Schadenslokalisierung nach Ort und Umfang. Wie im Strukturbild 1 bereits dargestellt, baut die hier vorgestellte Schadensidentifikation auf das hochkondensierte und für lokale Parametervariationen sensitive Diagnosemodell auf. Im Betriebszustand des geschädigten Systems werden Schwingungsmessungen aufgenommen, die unter bestimmten Erregungsbedingungen gewonnen wurden. Für die gleichen Erregungsbedingungen lassen sich mit Hilfe des vorliegenden Diagnosemodells simulierte Systemantworten ermitteln, die der Antwort des realen Systems im Originalzustand entsprechen. Im folgenden wird nun gezeigt, wie mit Hilfe des Unterschieds zwischen der gemessenen und der simulierten Systemantwort die dafür notwendigen Änderungen der Designparameter zu ermitteln sind, [Pereira et al, 1995]. Diese Änderungen entsprechen den gesuchten Schädigungen. Da das Originalsystem durch das Diagnosemodell repräsentiert wird, ist die ermittelte Parameteränderung ein Indikator für den Schaden am realen System im Rahmen der vorliegenden Modelldiskretisierung.

Für den Unterschied zwischen dem Originalsystem im Nominalzustand – hier repräsentiert durch das Diagnosemodell D - und dem geschädigten System F eignen sich nach [Larsson, Sas 1992] Datenvergleiche, die auf FRF-Daten (Frequenzgangdaten) nach der Force-Balance-Methode basieren. Die Systemunterschiede werden durch den Residuenvektor

$$\underline{\varepsilon}^{DF}(\omega) = \boldsymbol{F}^{D}(\omega) - \boldsymbol{F}^{F}(\omega) \tag{14}$$

beschrieben, der den Unterschied zwischen den harmonisch zeitveränderlichen Erregerkräften am Diagnosemodell und am geschädigten System darstellt, wenn in beiden Systemen übereinstimmende Verschiebungsvektoren $\boldsymbol{y}^{D}(t) = \boldsymbol{y}^{F}(t)$ auftreten. Das Residuum (14) kann in einen vektoriellen Fehlerausdruck umformuliert werden, der schließlich in einen iterativen Modelladaptierungsprozeß eingesetzt wird:

$$\underline{\varepsilon}(\omega) = \boldsymbol{Z}^{D}(\omega)\,\boldsymbol{H}_{j}^{F}(\omega) - \boldsymbol{e}_{j}\,, \tag{15}$$

mit: $\boldsymbol{Z}^{D}(\omega)$: Matrix der dynamischen Steifigkeit des Diagnosemodells; $\boldsymbol{H}^{F}_{j}(\omega)$: Gemessener Spaltenvektor j der Frequenzgangmatrix am geschädigten System, beim Wirken der experimentellen Erregerkraft:

$$\boldsymbol{F}^{F}(\omega) = \boldsymbol{e}_{j}\,F^{F}(\omega),\quad \boldsymbol{e}_{j}^{T} = [0,\ldots,0,1,0,\ldots 0]\,. \tag{16}$$

Der Zusammenhang zwischen (14) und (15) ist sofort einzusehen. Aus der Multiplikation von (15) mit der skalaren Erregung $F^{F}(\omega)$ und dem Einsetzen der Voraussetzung $\boldsymbol{y}^{D}(t) = \boldsymbol{y}^{F}(t)$ folgt wieder (14):

$$\underline{\varepsilon}(\omega)\,\mathrm{F}^{\mathrm{F}}(\omega) = \boldsymbol{Z}^{\mathrm{D}}(\omega)\,\boldsymbol{H}_{\mathrm{j}}^{\mathrm{F}}(\omega)\,\mathrm{F}^{\mathrm{F}}(\omega) - \boldsymbol{F}^{\mathrm{F}}(\omega),$$

mit:
$$\boldsymbol{H}_{\mathrm{j}}^{\mathrm{F}}(\omega)\,\mathrm{F}^{\mathrm{F}}(\omega) = \boldsymbol{H}^{\mathrm{F}}(\omega)\,\boldsymbol{F}^{\mathrm{F}}(\omega) = \boldsymbol{y}^{\mathrm{F}}, \tag{17}$$

$$\boldsymbol{y}^{\mathrm{F}} = \boldsymbol{y}^{\mathrm{D}},$$

folgt:
$$\underline{\varepsilon}^{\,\mathrm{DF}}(\omega) = \boldsymbol{Z}^{\mathrm{D}}(\omega)\,\boldsymbol{y}^{\mathrm{D}} - \boldsymbol{F}^{\mathrm{F}}(\omega) = \boldsymbol{F}^{\mathrm{D}}(\omega) - \boldsymbol{F}^{\mathrm{F}}(\omega).$$

Die Minimierung des Residuenvektors (15) bezüglich der Parameter (Designvariablen) $\boldsymbol{x}$ ist ein nichtlineares Problem:

$$\min_{\boldsymbol{x} \in \Re^n} \left\| \underline{\varepsilon}(\omega, \boldsymbol{x}) \right\| = \min_{\boldsymbol{x} \in \Re^n} \left\| \boldsymbol{Z}^{\mathrm{D}}(\omega, \boldsymbol{x})\,\boldsymbol{H}_{\mathrm{j}}^{\mathrm{F}}(\omega) - \boldsymbol{e}_{\mathrm{j}} \right\|. \tag{18}$$

Nach Anwendung der Taylorentwicklung und ausschließlicher Berücksichtigung linearer Ausdrücke in den Entwurfsvariablen $\boldsymbol{x}$ folgt, [Pereira, 1996]:

$$\underline{\varepsilon}(\boldsymbol{x}) = \frac{\partial \boldsymbol{Z}^{\mathrm{D}}(\boldsymbol{x})}{\partial \boldsymbol{x}} \Delta\boldsymbol{x} - \Delta\boldsymbol{H}^{\mathrm{DF}} = \boldsymbol{S}(\boldsymbol{x})\,\Delta\boldsymbol{x} - \Delta\boldsymbol{H}^{\mathrm{DF}} \Rightarrow \mathit{min}, \tag{19}$$

mit der Sensitivitätsmatrix $\boldsymbol{S(x)}$, dem Entwurfsvariablen-Differenzvektor $\Delta\boldsymbol{x}$ und dem Differenzvektor $\Delta\boldsymbol{H}^{\mathrm{DF}}$ zwischen dem Frequenzgang des Diagnosemodells und dem gemessenen Frequenzgang:

$$\Delta\boldsymbol{H}^{\mathrm{DF}} = \boldsymbol{H}_{\mathrm{j}}^{\mathrm{D}}(\omega) - \boldsymbol{H}_{\mathrm{j}}^{\mathrm{F}}(\omega). \tag{20}$$

Zur Bestimmung der gesuchten Änderungen $\Delta\boldsymbol{x}$ der Entwurfsvariablen $\boldsymbol{x}$ zum Übergang vom Diagnosemodell *D* auf das Schadensmodell *U* (vgl. Bild 1), ist nach (19) das folgende überbestimmte lineare Gleichungssystem iterativ mit Hilfe eines Least-Square-Verfahrens zu lösen, [Pereira, 1996]:

$$\boldsymbol{S}(\boldsymbol{x})\,\Delta\boldsymbol{x} = \Delta\boldsymbol{H}^{\mathrm{DF}}. \tag{21}$$

Die zur näherungsweisen Lösung von (21) erforderliche Gleichungsanzahl, erhält man durch Messungen der Frequenzgänge bei mehreren Erregerfrequenzen. In [Pereira, 1996] wird gezeigt, daß der Meßvektor dabei nicht voll besetzt sein muß, entsprechend der Knotenvorgabe durch das Diagnosemodell. Für die minimal notwendige Anzahl der Gleichungen muß gelten: Das Produkt aus der Anzahl der Meßpunkte mit der Anzahl der gewählten Frequenzen muß größer sein als die Anzahl der für Schäden infrage kommenden Designparameter aus $\boldsymbol{x}$.

Die iterative Lösung von (21) führt schrittweise zur Veränderung des Diagnosemodells in Richtung auf das Schadensmodell. Da die Systemänderungen, dabei nicht im Bereich formaler Matrizen-Elemente, sondern auf der physikalischen Ebene der Makroelemente des Diagnosemodells erfolgen, können aus dem Final Design für das Schadensmodell die realen geschädigten Desingparameter unmittelbar abgelesen werden.

4 Exemplarisches Beispiel

Am exemplarischen Beispiel einer zweiseitig eingespannten Rahmenstruktur soll die vorgestellte modellgestützte Schadensdiagnose, die mit Einsatz eines Diagnosemodells und abgestützt auf FRF-Daten des geschädigten Systems arbeitet, gezeigt werden. Für dieses Beispiel sollen ausschließlich Simulationsdaten verwandt werden. Die in der Praxis erforderlichen Frequenzgangmessungen werden hier durch Simulationsdaten ersetzt, die aus den analytischen Daten einer vorgegebenen Schädigung ermittelt wurden.

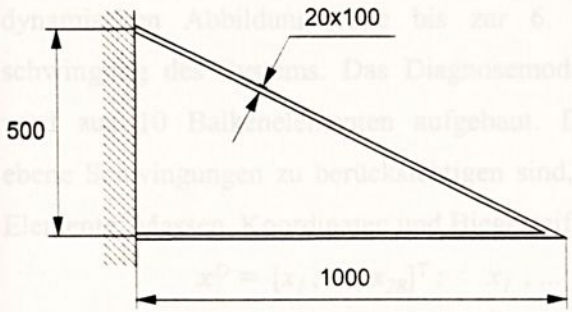


Bild 6: Testbeispiel (Werkstoff: Baustahl)

Das reale, ungeschädigte System ist im Bild 6 dargestellt. Bevor das Layout, z.B. die Zahl der Freiheitsgrade des hochkondensierten Diagnosemodells festgelegt werden kann, ist vorzugeben, welchen Arbeitsbereich die genaue Anpassung der dynamischen Systemeigenschaften umfassen soll. Falls sich diese Vorgaben im anschließenden Schadensdiagnoseprozeß als unzureichend erweisen, ist ein verändertes Diagnosemodell zu erstellen. Für das vorliegende Testbeispiel wird vorgegeben, daß sich die Analysen auf Schwingungsuntersuchungen abstützen sollen, die die ersten 6 Eigenschwingungen der Struktur umfassen. In diesem Bereich liegen bei dem gewählten Querschnitt der Systemelemente nur ebene Schwingungen. Bild 7 zeigt die ersten 6 Eigenschwingungsformen der Struktur. Die im Bild 7 gezeigten modalen Daten, sowie alle massengeometrischen Daten (Gesamtmasse, Elemente des Trägheitstensors und Lage des Massenmittelpunktes) der realen Struktur sollen durch das zu erstellende Diagnosemodell mit hoher Genauigkeit wiedergegeben werden. Dabei ist auch zu prüfen, ob der Vektor der lokalen Impulse (2) hinreichend genau durch das Diagnosemodell beschrieben wird.

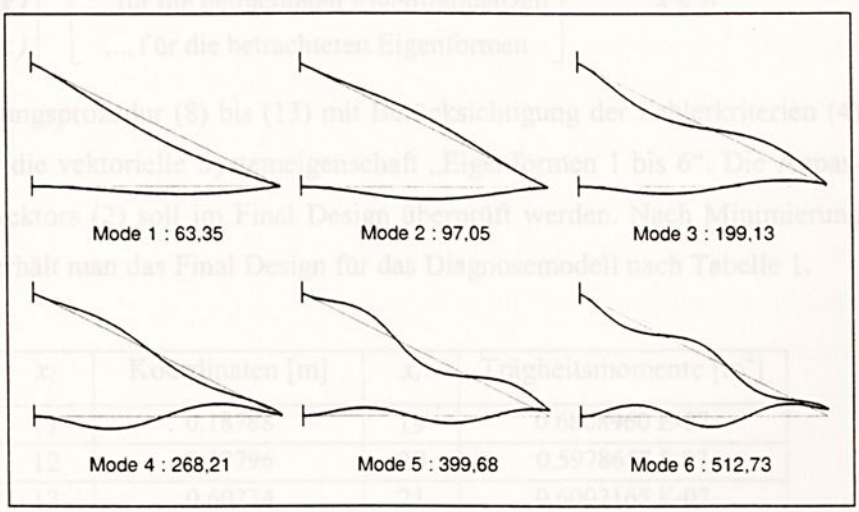


Bild 7: Modale Daten der ersten 6 Eigenschwingungen des Systems

4.1 Generierung des Diagnosemodells

Für die Abbildung des realen Systems nach Bild 6 durch ein möglichst hochkondensiertes einfaches Modell wurde die Struktur aus Makroelementen nach Bild 8 gewählt. Die notwendige Anzahl der Balkenelemente ergibt sich aus der vorgesehenen dynamischen Abbildungsbreite bis zur 6. Eigenschwingung des Systems. Das Diagnosemodell D wird aus 10 Balkenelementen aufgebaut. Da nur ebene Schwingungen zu berücksichtigen sind, enthält der Entwurfsvariablenvektor $\boldsymbol{x}^D$ insgesamt 28 Elemente: Massen, Koordinaten und Biegesteifigkeiten der Balkenelemente:

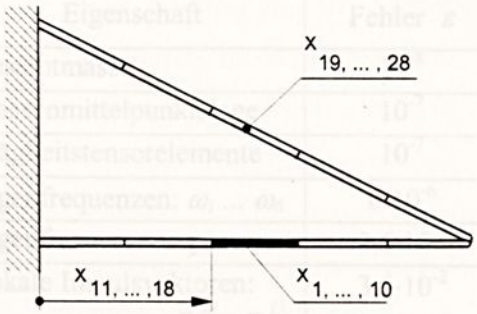


Bild 8: Struktur des Diagnosemodells

$$\boldsymbol{x}^D = [x_1, \ldots, x_{28}]^T: \quad \begin{aligned} x_1, \ldots, x_{10}&: \text{ Balkenmassen,} \\ x_{11}, \ldots, x_{18}&: \text{ Lagekoordinaten,} \\ x_{19}, \ldots, x_{28}&: \text{ Biegesteifigkeiten.} \end{aligned}$$

Generierung eines geeigneten Diagnosemodells bedeutet die Minimierung des Zielfunktionsvektors

$$\boldsymbol{f}(\boldsymbol{x}) = = \begin{bmatrix} \varepsilon_1(\boldsymbol{x}) \\ \varepsilon_2(\boldsymbol{x}) \\ \varepsilon_3(\boldsymbol{x}) \\ \varepsilon_4(\boldsymbol{x}) \\ \varepsilon_5(\boldsymbol{x}) \end{bmatrix} = \begin{bmatrix} \text{Fehlerausdruck : für die Masse} \\ \text{....für die Lage des Schwerpunktes} \\ \text{.... für die Elemente des Trägheitstensors} \\ \text{.... für die betrachteten Eigenfrequenzen} \\ \text{.... f ür die betrachteten Eigenformen} \end{bmatrix} \Rightarrow \underset{\boldsymbol{x} \in \Re^{28}}{\boldsymbol{min}} . \qquad (22)$$

in der hierarchischen Optimierungsprozedur (8) bis (13) mit Berücksichtigung der Fehlerkriterien (4) für skalare Größen und (5) für die vektorielle Systemeigenschaft „Eigenformen 1 bis 6". Die Anpassungsgüte des lokalen Impulsvektors (2) soll im Final Design überprüft werden. Nach Minimierung des Zielfunktionsvektors (22) erhält man das Final Design für das Diagnosemodell nach Tabelle 1.

x_i	Masse [kg]	x_i	Koordinaten [m]	x_i	Trägheitsmomente [m^4]
1	3.1399	11	0.18788	19	0.6808960 E-07
2	3.1372	12	0.39796	20	0.5978657 E 07
3	3.1395	13	0.60274	21	0.6002165 E-07
4	3.1404	14	0.81086	22	0.6579518 E-07
5	3.1420	15	0.81227	23	0.6476081 E-07
6	3.5121	16	0.60401	24	0.6490913 E-07
7	3.5105	17	0.39673	25	0.6597520 E-07
8	3.5097	18	0.18699	26	0.7113523 E-07
9	3.5105			27	0.6901934 E-07
10	3.5114			28	0.5769093 E-07

Tabelle 1: Parameter des Final Design für das Diagnosemodell

Mit den Parametern nach Tabelle 1 ist ein hochkondensiertes und gleichzeitig dynamisch sehr genaues Diagnosemodell, das zur Schadensdiagnose geeignet ist, gefunden worden. Die Fehler der dynamischen Eigenschaften des Diagnosemodells sind in Tabelle 2 zusammengestellt, wobei festzuhalten ist, daß der Fehler in den Vektoren der lokalen Impulse im Zustand von Systemeigenschwingungen in der Vektorzielfunktion der Optimierungsprozedur nicht berücksichtigt wurde. In der Tabelle sind die jeweils größten Einzelfehler aufgeführt.

Physikalische Eigenschaft	Anpassungs-Fehler ε
Gesamtmasse	10^{-8}
Massenmittelpunktslage	10^{-7}
Trägheitstensorelemente	10^{-7}
Eigenfrequenzen: $\omega_1 \ldots \omega_6$	$6 \cdot 10^{-6}$
Eigenformen: $\boldsymbol{q}_1 \ldots \boldsymbol{q}_6$	$2{,}6 \cdot 10^{-2}$
Lokale Impulsvektoren: $\boldsymbol{p}_1^D \ldots \boldsymbol{p}_6^D$	$3{,}5 \cdot 10^{-2}$

Tabelle 2: Anpassungsfehler des Diagnosemodells

4.2 Schadensidentifikation

Die Schädigung der Balkenstruktur wird durch die Querschnittsveränderung eines Balkenelementes (Bild 9) von 20 mm Dicke auf 13 mm Dicke simuliert. Die Schadensidentifikation wird gemäß Kapitel 3 nach der iterativ zu lösenden Beziehung (21) auf der Basis von Frequenzgangmessungen durchgeführt. Als „Messungen" werden für das vorliegende exemplarische Beispiel Simulationsrechnungen für das geschädigte System F mit Hilfe einer FE-Analyse gewonnen. Den Vergleich der FRF-Daten zwischen dem Diagnosemodell und dem geschädigten System zeigt Bild 10. In der Tabelle 3 sind die Vergleichsdaten der modalen Parameter vom Diagnosemodell und vom geschädigten System zusammengefaßt. Die Eigenmoden sind hierbei durch das in der Modalanalyse übliche MAC-Vergleichskriterium bewertet. MAC-Werte von 1 bedeuten völlige Übereinstimmung. Mit

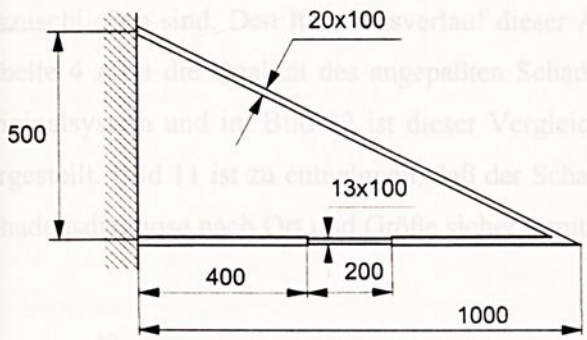


Bild 9: Geschädigte Balkenstruktur F

Diagnosemodell D f [Hz]	Geschädigtes System F f [Hz]	Frequenzdiff. Δf [%]	Mode-Korrelation MAC-Wert
63,35	58,71	7,32	0,943
97,05	86,19	11,19	0,956
199,13	193,88	2,64	0,988
268,21	253,54	5,47	0,987
399,68	382,02	4,42	0,948
512,73	472,85	7,78	0,938

Tabelle 3: Vergleich der modalen Parameter zwischen dem Diagnosemodell D und dem geschädigten System F

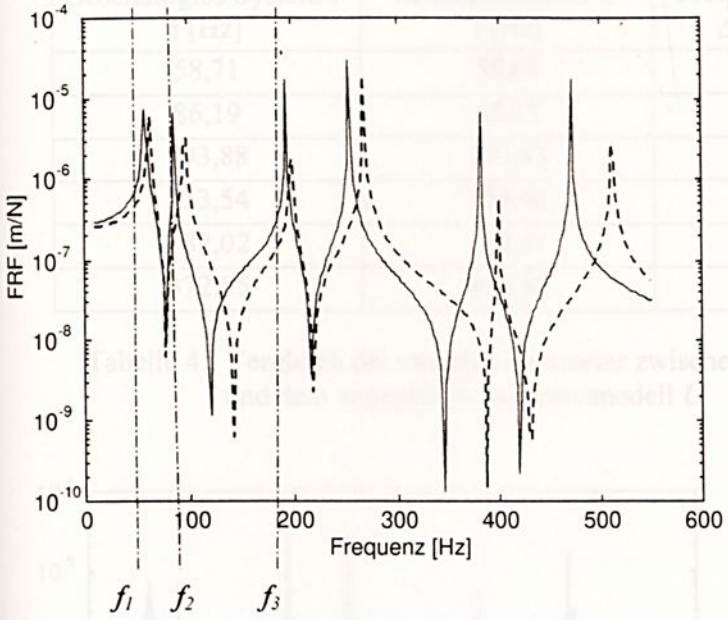


Bild 10: Vergleich von Frequenzgangdaten des Diagnosemodells *D* und des geschädigten Systems *F*
------- *D* ; ——— *F*; f_1, f_2, f_3: Anpassungsfrequenzen

sinkendem MAC-Wert sinkt die Korrelation der Moden zwischen beiden Vergleichssystemen. Die iterative Lösung von (21) wird mit einem Gleichungssystem durchgeführt, das auf den 3 Anpassungsfrequenzen $f_{1,2,3}$ = (48 Hz, 82 Hz, 186 Hz) basiert. Es führt zu einer schrittweisen Veränderung der Designvariablen des Diagnosemodells *D* zum angepaßten Schadensmodell *U*. Als veränderbare Designvariablen wurden dabei ausschließlich die 10 Steifigkeitsparameter x_{19} ... x_{28} der Makroelemente des Diagnosemodells zugelassen, da andere Schädigungen des Systems auszuschließen sind. Den Iterationsverlauf dieser Anpassung zeigt Bild 11. Die zu Tabelle 3 analoge Tabelle 4 zeigt die Qualität des angepaßten Schadensmodells *U* im Vergleich mit dem geschädigten Originalsystem und im Bild 12 ist dieser Vergleich auf der Ebene der zugeordneten Frequenzgänge dargestellt. Bild 11 ist zu entnehmen, daß der Schaden in dieser Simulationsstudie für die vorgestellte Schadensdiagnose nach Ort und Größe sicher ermittelt werden konnte.

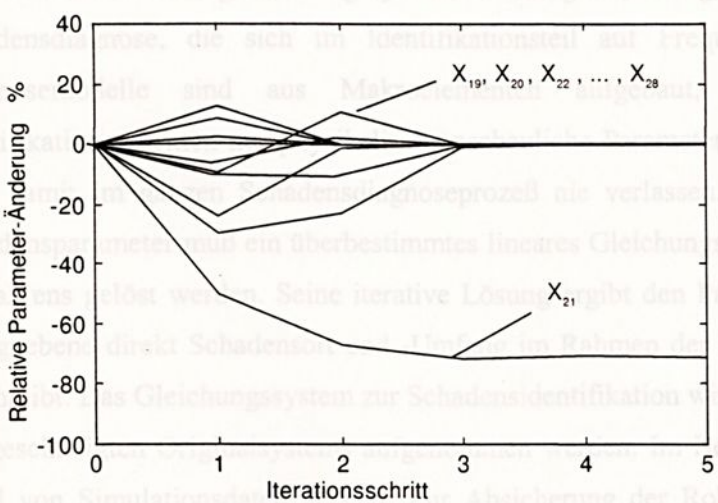


Bild 11: Relative Änderung der Steifigkeitsparameter $x_{19}, \ldots, x_{28}$ bei der iterativen Anpassung des Diagnosemodells *D* an die FRF-Daten des geschädigten Systems *F*
(x_{21}: Identifikation des Schadensparameters)

Geschädigtes System F f [Hz]	Schadensmodell U f [Hz]	Frequenzdiff. Δf [%]	Mode-Korrelation MAC-Wert
58,71	58,68	0,05	0,999
86,19	85,73	0,53	0,999
193,88	193,83	0,03	0,996
253,54	254,68	0,45	0,995
382,02	382,61	0,15	0,995
472,85	478,62	1,22	0,992

Tabelle 4: Vergleich der modalen Parameter zwischen dem geschädigten System F und dem angepaßten Schadensmodell U

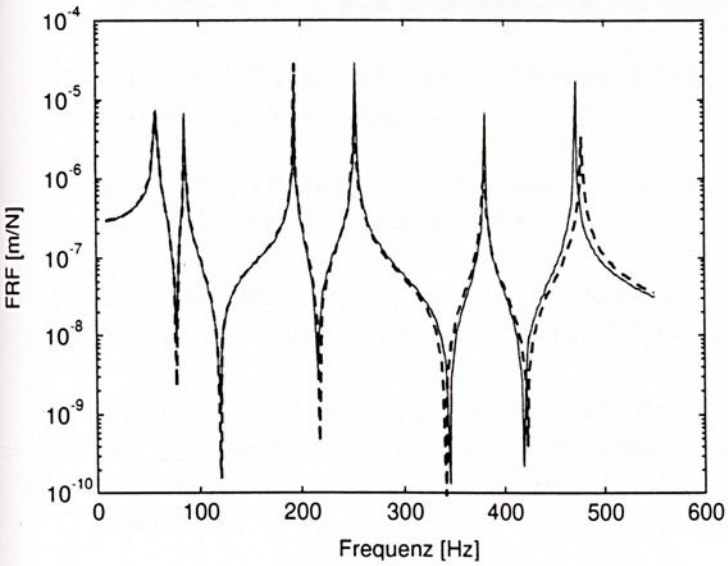


Bild 10: Vergleich von Frequenzgangdaten des geschädigten Systems F und des angepaßten Schadensmodells U

------- U ; ——— F

5 Zusammenfassung

Hochkondensierte und gleichzeitig dynamisch sehr genaue Diagnosemodelle sind die Grundlage einer Schadensdiagnose, die sich im Identifikationsteil auf Frequenzgangmessungen abstützt. Diese Diagnosemodelle sind aus Makroelementen aufgebaut, so daß bei den numerischen Identifikationsschritten nur physikalisch anschauliche Parameter verändert werden. Die Designebene wird damit im ganzen Schadensdiagnoseprozeß nie verlassen. Zur eigentlichen Identifikation der Schadensparameter muß ein überbestimmtes lineares Gleichungssystem mit Hilfe eines Least-Square-Verfahrens gelöst werden. Seine iterative Lösung ergibt den Parameteränderungsvektor, der auf der Designebene direkt Schadensort und -Umfang im Rahmen der Diskretisierung des Diagnosemodells beschreibt. Das Gleichungssystem zur Schadensidentifikation wird aufgebaut aus FRF-Messungen, die am geschädigten Originalsystems aufgenommen werden. Im Beitrag wird das Diagnoseverfahren an Hand von Simulationsdaten gezeigt. Zur Absicherung der Robustheit des Verfahrens sind weitere Identifikationsrechnungen mit Hilfe praxisgerechter Messungen erforderlich.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Schrifttum

[Biegler, 1980] Biegler-König, F. "Inverse Eigenwertprobleme". Dissertation, Universität Bielefeld, 1980.

[Bremicker, 1989] Bremicker, M. "Dekompositionsstrategie in Anwendung auf Probleme der Gestaltsoptimierung". Dissertation, VDI-Fortschrittberichte, Reihe 1, Nr. 173, VDI-Verlag, Düsseldorf, 1989.

[Doebling et al, 1998] Doebling, Scott W.; Charles R. Farrer; Michael B. Prime. "A Summary Review of Vibration-Based Damage Identification Methods". The Shock and Vibration Digest, Vol. 30, No. 2, March 1998: 91-105.

[Esch. et al, 1990] Eschenauer, H., Koski, J. and A. Osyczka. "Multicriteria Design Optimization." Springer-Verlag, Berlin-Heidelberg-New York, 1990.

[Ewins, 1984] Ewins, D.J. "Modal Testing: Theory and Practice". Research Studies Press, John Wiley&Sons, New York, 1984.

[Gladwell, 86] Gladwell, G.M.L. "Inverse Problems in Vibration". Martinus Nijhoff Publishers, Dordrecht, Boston, Lancaster, 1986.

[Larsson, Sas1992] Larsson, P.O., Sas, P. "Model Updating Based on Forced Vibration Testing Using Numerically stable Formulations". Proc. 10th IMAC, 1992, Volume II, pp. 966 – 974.

[Müller-Slany, 1992] Müller-Slany, H.H. "Ein Beitrag zur Lösung von Vektoroptimierungsaufgaben bei der Generierung angepaßter Punktmassensysteme durch hierarchische Skalarisierung". Festschrift zum 80. Geburtstag von Prof. Dr. Kurt Magnus. Institut B für Mechanik, TU München, 1992: 57-66.

[Müller-Slany, 1993] Müller-Slany, H.H. "A Hierarchical Scalarization Strategy in Multicriteria Optimization Problems". In: Brosowski, B. et al. "Multicriteria Decision". Peter Lang, Frankfurt am Main, 1993: 69-79.

[Müller-Slany, 1997] Müller-Slany, H.H., Brunzel, F. "A basic Outline according to a new Method of Model based Damage Detection. Proc. DINAME 97, 3-7 March 1997, Angra dos Reis, Brasilien, pp. 40-42.

[Pandey et al, 1991] Pandey, A.K.; Biswas, M.; Samman, M.M. "Damage detection from changes in curvature mode shapes". J. Sound and Vibration Vol. 145, No. 2, 1991: 321-332.

[Pereira et al, 1995] Pereira, J.A.; Heylen, W.; Lammens, W.S., Sas, P. "Application of Model Updating Technique for Health Condition Monitoring and Damage Detection in flexible Structures". 15º Bian. Conf. in Vib. and Noise-ASME, Boston-USA, 1995.

[Pereira, 1996] Pereira, J.A. " Structural Damage Detection Methodology using a Model Updating Procedure based on Frequency Response Functions - FRF(s)". Tese de Doutorado, Univ. Estadual de Campinas, Faculdade de Eng. Mecânica, Campinas, 1996.

[Salawu,1997] Salawu, O.S. "Detection of structural damage through changes in frequency: a review". Eng. Struct., Vol. 19, No. 9, 1997: 718-723.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

Aplicação de Técnicas de Atualização de Modelos para Modelagem de Estruturas Flexíveis – Localização de Erros

Aplication of Modal Updating Technique for Modelling of Flexible Structures – Error Localization

Alex Pereira do Prado
Orientador: Prof. Dr. João Antonio Pereira
UNESP – Universidade Estadual Paulista "Júlio de Mesquita Filho"
Departamento de Engenharia Mecânica/Campus de Ilha Solteira
Avenida Brasil Sul, 56
CEP: 15385-000 – Ilha Solteira, São Paulo, Brasil
E-mail: alex@dem.feis.unesp.br

Abstract

The dynamic structural characteristics of a model can be evaluated by numerical model, experimental test or using an interaction of both. Model updating techniques use, in a complementary way, analytical and experimental informations in order to create a reliable analytical model. In this context, techniques of comparison and correlation of the models appear as important tools to describe the discrepancies of the models. This article describes how the method of force balance and sensitivity analysis can be used for location of modelling errors in the analytical model. The sensitivity method is used to study as the variation of the physical parameters of the model influences in its dynamic properties. The calculation of sensibility of the model allows identifying which components or parameters of the structure are more sensitive to small variations. The method of force balance describes the discrepancy between the analytic and the experimental models by using the equations of equilibrium. The propose was evaluated with numeric data and the results have been shown quite promising.

Palavras-chave

1) Sensibilidade 2) Correlação 3) Localização de erros

Resumo

A análise das características dinâmicas estruturais de um modelo pode ser feita através de uma investigação numérica, experimental ou ambas. As técnicas de ajuste de modelos utilizam de forma interativa as informações de ambas as modelagens visando definir um modelo analítico o mais próximo possível dos dados medidos. Neste contexto, as técnicas de comparação e correlação de modelos surgem como uma importante ferramenta a ser utilizada na localização prévia da discrepância dos modelos. Este artigo descreve como o método do balanço de força e análise de sensibilidade podem ser usados para a localização de erros na modelagem analítica. O método de sensibilidade é usado para estudar como a variação dos parâmetros físicos do modelo influenciam nas suas propriedades dinâmicas. O método do balanço de força descreve a discrepância entre o modelo analítico e o modelo experimental através das equações de equilíbrio. Os métodos foram avaliados com dados numéricos e os resultados demonstraram que a utilização conjunta dos métodos pode levar bons resultados.

Introdução

As técnicas de comparação e ajuste de modelos vem se consolidando como uma importante ferramenta para modelagem de sistemas mecânicos. Elas utilizam de forma complementar, os resultados teóricos e dados experimentais na modelagem de estruturas mecânicas, visando definir modelos que representem fielmente o comportamento do sistema real. No entanto, o sucesso dessas técnicas estão associados às várias etapas que antecede o ajuste propriamente dito, as quais envolvem a comparação e a localização da discrepância dos modelos, a escolha dos prováveis parâmetros inadequadamente modelados. Os métodos de localização de erros buscam comparar o modelo analítico com dados experimentais de forma que as eventuais regiões ou parâmetros, inadequadamente representadas na modelagem analítica seja identificada, fornecendo os subsídios para a definição dos prováveis parâmetros de correção do modelo. O modelo numérico-analítico, geralmente desenvolvido utilizando técnicas de elementos finitos, é comparado com o modelo experimental e posteriormente ajustado com base nos dados medidos. Neste contexto, os métodos de localização de erros assumem que o modelo experimental é correto e buscam localizar, com base nos dados medidos, as regiões da estrutura inadequadamente representadas na modelagem analítica por elementos finitos. O estudo dos métodos de localização de erros representam desta forma, um passo importante no processo de correlação e ajuste de modelos, visto que eles podem levar a identificação das principais regiões responsáveis pela discrepância entre eles. A localização prévia dessas regiões inadequadamente representadas permite selecionar os prováveis parâmetros definidos incorretamente na modelagem do sistema. Estes parâmetros serão atualizados durante o ajuste do modelo melhorando a correlação entre o modelo analítico e experimental.

O sucesso dos métodos de ajuste de modelo esta fortemente associado à seleção correta dos parâmetros de atualização, ou seja, os parâmetros que serão corrigidos durante o processo de ajuste devem ser os parâmetros inadequadamente representados no modelo inicial. A existência de uma avaliação realística das áreas modeladas grosseiramente facilita à seleção correta destes parâmetros tornando o processo menos trabalhoso além do que, um grande esforço computacional pode ser economizado pois apenas a região modelada inadequadamente será atualizada ao invés de todo o modelo. Isto propiciará uma redução do número de variáveis atualizadas e, na maioria das vezes, um melhor desempenho dos métodos computacionais utilizados na solução do problema (Pereira, 1996).

Este artigo discute a comparação e localização de erros baseado no balanço de força e a implementação do método de análise de sensibilidade para estudar como a variação dos parâmetros físicos do modelo influenciam nas suas propriedades dinâmicas.

Fundamentos Teóricos

Balanço de Força – equilíbrio da equação do movimento

O método do balanço de força descreve a discrepância entre o modelo analítico e o modelo experimental com base nas equações de equilíbrio "dinâmico" do modelo. O vetor balanço de força é calculado em termos do vetor modal e respectiva freqüência de ressonância medidas, combinados com os parâmetros espaciais do modelo analítico (matrizes de massa e rigidez). Para uma freqüência de ressonância ω_r e respectivo modo, o vetor força residual permite uma avaliação da correlação do modelo analítico e experimental (Fissette & Ibrahim, 1988). Se a estrutura é modelada corretamente e não existe diferença entre os modelos, as componentes do vetor força, $\{\Delta F\}$, são nulas, caso contrário elas são diferentes de zero. A equação (1) expressa essa diferença em termos das matrizes de massa e rigidez, calculadas por

elementos finitos, e dos parâmetros modais, freqüência de ressonância e modo próprio "medidos".

$$([K^A]-(\omega_r^X)^2[M^A])\{\psi^X\}_r=\{\Delta F\} \quad (1)$$

onde: $[K^A]$ - matriz de rigidez analítica; ω_r^X - r-ésima freqüência de ressonância experimental; $[M^A]$ - matriz massa analítica; $\{\psi^X\}_r$ - r-ésimo vetor modal experimental; $\{\Delta F\}$ - vetor força.

O vetor *{ΔF}* representa a força residual originada pela discrepância entre modelos. O gráfico do vetor força com relação aos graus de liberdade permite visualizar as componentes do vetor que não estão em equilíbrio naquele modo, levando à uma estimativa dos graus de liberdade e consequentemente, das possíveis regiões do modelo que estão mal representadas pelo modelo analítico. (Fissette & Ibrahim, 1988 e Pereira, 1996).

Métodos de Análise de Sensibilidade

Os métodos de análise de sensibilidade não são de fato métodos estritamente de localização de erros, todavia eles tem um papel importante nas rotinas de localização de erros e ajuste de modelos. O cálculo da sensibilidade do modelo permite identificar quais componentes ou parâmetros da estrutura são mais sensitivos à pequenas variações, indicando assim os componentes ou regiões do modelo onde o ajuste pode ser mais significativo ou não. No entanto, as regiões mais sensíveis não são necessariamente as regiões inadequadamente representadas o que pode dificultar o ajuste do modelo. No processo de ajuste do modelo o conhecimento dos parâmetros mais sensíveis é uma informação bastante relevante para à escolha dos parâmetros de ajuste, uma vez que ela permite evitar a atualização de parâmetros pouco sensitivos, melhorando assim a performance do processo de atualização. Basicamente, a sensibilidade de uma quantidade modal em relação a um parâmetro *p* é calculada como a variação de primeira ordem dessa quantidade em relação à uma pequena variação deste parâmetro (Pereira, 1996 e Friswel & Mottershead, 1996). A sensibilidade dos autovalores do modelo é estimada a partir da equação de equilíbrio (2). Para o *r*-ésimo modo tem-se:

$$[K]\{\psi\}_r+\lambda_r[M]\{\psi\}_r=0 \quad (2)$$

Derivando-se a equação (2) com relação ao *p*-ésimo parâmetro, tem-se a expressão(3).

$$[K]^{'}\{\psi\}_r+[K]\{\psi\}_r^{'}-\lambda_r^{'}[M]\{\psi\}_i-\lambda_r[M]^{'}\{\psi\}_r-\lambda_r[M]\{\psi\}_r^{'}=0 \quad (3)$$

onde: $(\ )^{'},\{\ \}^{'} e [\ ]^{'}$ - são derivadas de primeira ordem.

Pré-multiplicando a equação acima por $\{\psi\}_s^T$ e utilizando-se as propriedades de ortogonalidade das matrizes de massa e rigidez (Timoshenko & Young, 1974), esta pode ser re-arranjada em termos das suas derivadas de primeira ordem.

$$\{\psi\}_s^T[K]^{'}\{\psi\}_r-\lambda_r^{'}\{\psi\}_s^T[M]\{\psi\}_r-\lambda_r\{\psi\}_s^T[M]^{'}\{\psi\}_r+\{\psi\}_r^T([K]\{\psi\}_s-\lambda_r[M]\{\psi\}_s)=0 \quad (4)$$

A sensibilidade de primeira ordem do *r*-ésimo autovalor em relação a um parâmetro *p* é calculada a partir da expressão (4), assumindo-se *r=s* e modos normalizados em relação a massa.

unesp

$$\frac{\partial \lambda_r}{\partial p} = \{\psi\}_r^T \frac{\partial [K]}{\partial p} \{\psi\}_r - \lambda_r \{\psi\}_r^T \frac{\partial [M]}{\partial p} \{\psi\}_r \qquad (5)$$

Avaliação dos Métodos Implementados

Para o estudo e avaliação dos métodos implementados foi utilizado uma estrutura espacial do tipo frame. Os dados analíticos foram obtidos através do método dos elementos finitos e os dados "experimentais" foram simulados a partir do modelo de elementos finitos introduzindo-se uma mudança conhecida no modelo original. Nesta etapa de avaliação dos métodos, o uso de dados simulados é bastante importante visto que permite um estudo sistemático dos métodos discutidos. Dentre as vantagens de se trabalhar com dados simulados está o fato de que simulando-se os dados é possível conhecer exatamente qual foi o "erro" imposto a estrutura e onde este se localiza. Outro aspecto importante é a compatibilidade dos modelos, como o modelo analítico e "experimental" parte da mesma base de dados, não tem-se nenhum problema com relação a equivalência entre os mesmos, principalmente no que se diz respeito à correspondência entre os graus de liberdade dos modelos. Para tornar mais realístico o modelo "experimental", todos os graus de liberdade de rotação dos elementos da estrutura foram eliminados, tendo em vista que em um caso real, os graus de liberdade de rotações não são tão facilmente obtidos.

A simulação apresentada é referente a uma estrutura espacial modelada através do método dos elementos finitos, constituída de elementos de viga perfeitamente conectados entre si, figura 01. Os membros são barras de aço com seção transversal quadrada, módulo de elasticidade $E=2{,}1*10^{11}[N/m^2]$, e densidade de massa $\rho=7850[kg/m^3]$. O modelo analítico da estrutura, criado por elementos finitos, possui 42 nós (nós no meio de cada barra e nas conexões), 60 elementos de viga (6 graus de liberdade por nó). A estrutura é analisada para a condição livre-livre.

O modelo experimental foi criado a partir do modelo analítico de elementos finitos introduzindo-se uma perturbação no modelo inicial. A perturbação consistiu na redução das propriedades geométricas de um elemento (redução do momento de inércia I_y), o que provocou uma alteração das propriedades modais e consequentemente, uma discrepância entre os modelos.

A comparação dos modelos e calculo do balanço de força neste caso não é imediata, pois o modelo experimental é representado apenas pelos deslocamentos x, y e z de cada nó, enquanto o modelo analítico possui 6 GL por nó. A compatibilidade do número de GL(s) dos modelos foi obtida através de técnicas de redução as quais não serão discutidas neste trabalho, para detalhes ver Kidder (1973) e Pereira (1996).

Inicialmente foi feito uma avaliação da influencia de cada elemento na variação dos parâmetros modais da estrutura. A figura 02 mostra a sensibilidade para 24 freqüências do modelo em relação à variação dos parâmetros para cada elemento.

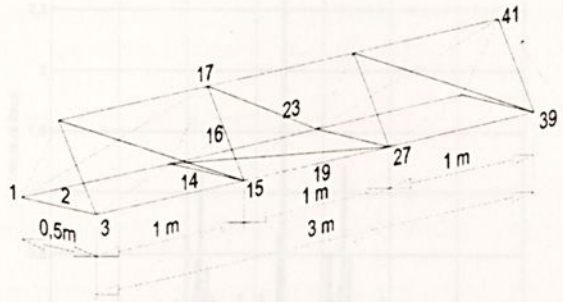


Figura 01 – Estrutura Modelada

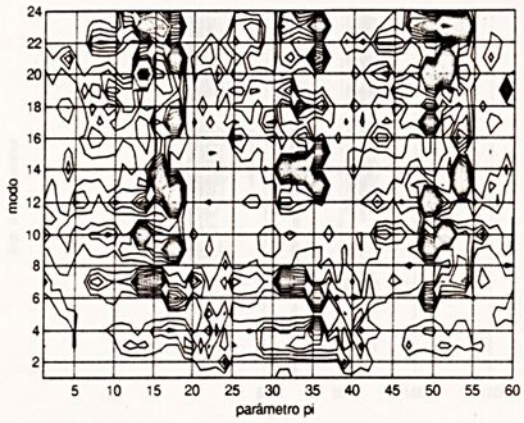


Figura 02 – Sensibilidade da estrutura

A figura 03 mostra a média da sensibilidade dos elementos para os 5 primeiros modos e o gráfico da figura 04 mostra a sensibilidade apenas para a primeira freqüência em relação a inércia dos elementos. Como observado, os elementos 31 e 32 são muito mais sensíveis em relação aos demais sendo que alguns elementos influenciam muito pouco ou não influenciam esta freqüência.

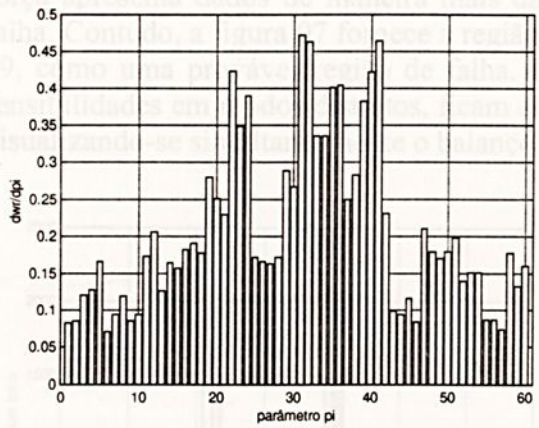


Figura 03 – – Média do Método da Sensibilidade Normalizado para os 5 primeiros modos

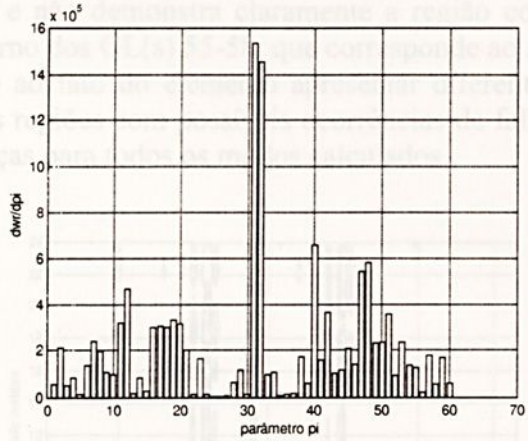


Figura 04 – Método da Sensibilidade (1º modo)

O método de balanço de força foi avaliado para localização de erros na modelagem em duas posições distintas uma relacionada a um elemento de alta sensibilidade e a um elemento pouco sensível para avaliar o comportamento do método em diferentes situações.

Inicialmente foi introduzido um perturbação no elemento 31 (redução de 50% Iz) e os dois modelos foram comparados, apresentando uma grande discrepância principalmente, na freqüência do primeiro modo. A figura 5 mostra o gráfico do balanço de força para o primeiro modo, como pode ser observado, as prováveis regiões responsáveis pela discrepância dos modelos estão em torno dos graus de liberdade 43-45, 65-70 e 80-85 que correspondem aos nós 15, 23 e 29. Os nós 15 e 23 correspondem exatamente aos nós do elemento 31 que foi alterado e o nó 29 corresponde ao elemento 32 diretamente conectado com o elemento perturbado, o que mostra o êxito do método. A figura 06 mostra o balanço de força para os 24 modos calculados, levando a resultados similares ao anterior.

Uma segunda avaliação foi feita para um elemento pouco sensível, elemento 25, como no caso anterior foi introduzido uma redução de 50 % na propriedade de inércia do elemento. As figuras 7-8 mostram os resultados da análise. Na figura 7 duas regiões mostram-se como

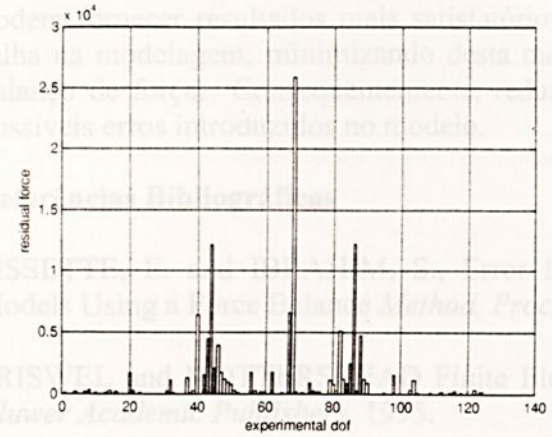


Figura 05 – Método do Balanço de Força (1º modo)
Elemento 31

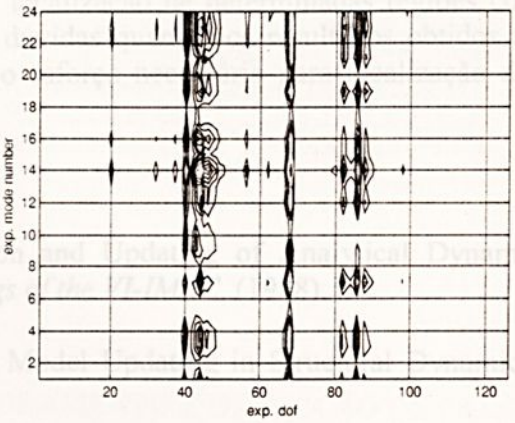


Figura 06 – Método do Balanço de Força
Elemento 31

possíveis responsáveis pela discrepância entre os modelos. Estas regiões aparecem mais espalhadas do que no exemplo anterior e indicam que a falha está em torno dos graus de liberdade 40-50 e 80-85, que correspondem aos nós 15 e 27. Entretanto, o elemento com falha está entre os nós 15 e 19, sendo o nó 27 pertencente a um elemento ligado diretamente ao elemento 25. Devido a baixa sensibilidade do elemento 25 ao primeiro modo, o balanço de força apresenta dados de maneira mais dispersa e não demonstra claramente a região com falha. Contudo, a figura 07 fornece a região em torno dos GL(s) 55-58, que corresponde ao nó 19, como uma provável região de falha. Devido ao fato do elemento apresentar diferentes sensibilidades em modos distintos, ficam claras as regiões com possíveis ocorrências de falha visualizando-se simultaneamente o balanço de forças para todos os modos calculados.

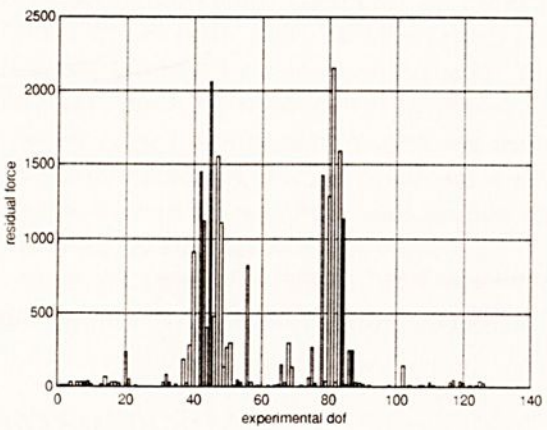


Figura 07 - Método do Balanço de Força (1º modo) –
Elemento 25

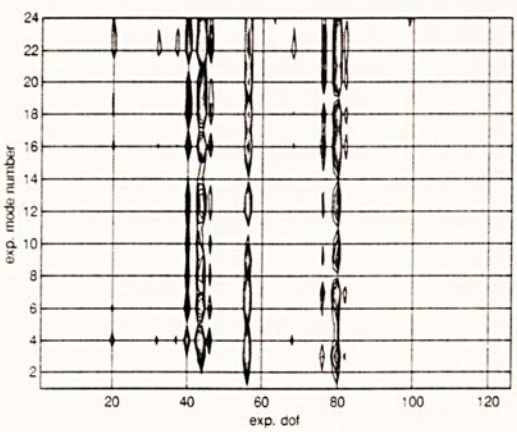


Figura 08 - Método do Balanço de Força
Elemento 25

Conclusão

Este artigo discute a análise de sensibilidade dos autovalores em relação aos parâmetros do modelo e o como o método do balanço de força pode ser utilizado para localizar os prováveis erros de modelagem do sistema. Exemplos numéricos foram utilizados na avaliação dos métodos.

O método da sensibilidade, apesar de não ser de fato um método de localização de erros, revelou-se útil para uma avaliação mais clara das respostas obtidas pelo método do balanço de forças. A sensibilidade aparece como uma orientação que indica quais modos

podem fornecer resultados mais satisfatórios para localização de determinadas regiões com falha na modelagem, minimizando desta maneira dúvidas quanto aos resultados obtidos no balanço de força. Consequentemente, reduzindo o esforço necessário para localização dos possíveis erros introduzidos no modelo.

Referências Bibliográficas

FISSETTE, E. and IBRAHIM, S., Error Location and Updating of Analytical Dynamic Models Using a Force Balance *Method, Proceedings of the VI-IMAC*, (1988).

FRISWEL and MOTTERSHEAD Finite Element Model Updating in Structural Dynamics, *Kluwer Academic Publishers,* 1995.

KIDDER, R.L., Reduction of Structural Frequency Equation, *AIAA Journal*, v-11, n-6, 1973.

PEREIRA, J.A., Structural Damage Detection Methodology Using a Model Updating Procedure Based on Frequency Response Fuctions-FRF(s), *Tese de Doutorado, Universidade Estadual de Campinas-UNICAMP*, (1996).

TIMOSHENKO, S. and YOUNG, D. H., Vibration Problems in Engineering, *John Willey & Sons*, 1974.

COBEM 99
XV Congresso Brasileiro de Engenharia Mecânica
15th Brazilian Congress of Mechanical Engineering
22 - 26 de Novembro de 1999 / November 22 - 26, 1999 Águas de Lindóia, São Paulo.

TÉCNICAS NÃO DESTRUTIVAS DE MONITORAMENTO E DETECÇÃO DE FALHAS ESTRUTURAIS UTILIZANDO REDES NEURAIS

Daniela Demarchi
João Antonio Pereira
Vicente Lopes Júnior
UNESP - Ilha Solteira, Departamento de Engenharia Mecânica
Cx. P. 31 – 15 385-000 – Ilha Solteira, SP, Brasil.

Resumo. *A utilização de Redes Neurais como ferramentas não destrutivas vem ocupando espaço na área de manutenção e monitoramento do comportamento vibratório de estruturas e equipamentos mecânicos. O método consiste em monitorar as vibrações da estrutura a ser analisada, e obter dados que a identifique e que sejam adequados para o processo de treinamento da rede. No entanto, existe a necessidade da geração de uma base de dados que contenha todas as diferentes condições de falha (padrões de reconhecimento) para alimentar o treinamento da rede. Este trabalho estuda a capacidade de generalização de Redes Neurais utilizando o método da retropropagação "backpropagation" para classificar sistemas com diferentes razões de rigidez. Isso permitirá definir uma rede que utilize um número limitado de dados para o treinamento e uma vez treinada, a rede poderá ser usada para identificar falhas intermediárias. Várias condições e intensidade de falhas foram estudadas utilizando dados numéricos. A rede mostrou uma boa capacidade de generalização a qual será testada numa próxima etapa com dados reais.*

Palavras-chave: Backpropagation, Identificação de falhas, Redes neurais, Generalização.

1. INTRODUÇÃO

Os equipamentos mecânicos tornam-se, a cada dia, mais complexos para atender as exigências do mercado que demandam equipamentos funcionais e mais flexíveis. Consequentemente, rotinas e ferramentas mais adequadas para o monitoramento e controle das condições de operação e diagnóstico de falhas destes equipamentos são fundamentais visto que, a ocorrência de falha é uma condição provável durante a utilização dos mesmos. A pressão para reduzir o custo de produção tem levado a uma redução do número de pessoas ligadas a manutenção aumentando também a necessidade de sistemas automáticos e confiáveis. Isto tem levado à procura por novos métodos e técnicas, diferentes das técnicas tradicionais de manutenção planejada, capazes de prever o estado de funcionamento dos sistemas.

Os componentes estruturais das máquinas e equipamentos são constantemente submetidos a grandes esforços, em muitos casos esforços dinâmicos de grande intensidade, o que po-

derá levar à deterioração do seu funcionamento e consequentemente a uma falha. A propagação destas falhas poderá colocar em risco a utilização do equipamento. Tendo em vista os problemas que podem ocorrer, inclusive catastróficos, com a propagação das falhas torna-se necessário a utilização de métodos eficientes para realizar a detecção e posteriormente a localização de falhas incipientes.

Uma metodologia eficiente para a detecção de falhas estruturais deve ser capaz de acompanhar a evolução da falha, reconhecer padrões de comportamento da estrutura com defeitos em comparação com o comportamento da estrutura sem defeitos. Deve incluir ainda uma capacidade de localizar e quantificar a extensão da falha. Estes requisitos parecem ir de encontro as características de reconhecimento de padrões de sistemas baseados em redes neurais artificiais, RNA (Bernieri, 1994).

Um sistema efetivo de condição básica de manutenção (CBM) deve detectar falhas em uma máquina em um estágio incipiente antes que a mesma atinja um estágio avançado e comprometa ou provoque a falha do equipamento. Desta maneira, os sistemas de monitoramento devem ser projetados para medir e monitorar as variáveis de interesse no controle das condições de operação de máquinas e equipamentos. Algoritmos de diagnóstico devem ser avaliados para converter os dados obtidos do sistema de monitoramento em variáveis que demonstrem o real estado de funcionamento dos equipamentos, com uma interferência mínima do pessoal de manutenção. Portanto, existe uma considerável motivação para o desenvolvimento de sistemas robustos capazes de avaliar automaticamente as condições de funcionamento das máquinas em tempo real. Trabalhos recentes (Kim and Li, 1995) tem mostrado que RN pode responder satisfatoriamente aos requisitos de um sistema efetivo de condição de manutenção básica.

Redes Neurais tem emergido recentemente como uma boa ferramenta para reconhecer alterações nos padrões, tornando-se uma ferramenta promissora para monitoramento e classificação de falhas de máquinas e equipamentos. Neste caso, a rede neural deve ser designada para classificar os padrões de entrada em classes pré-definidas ou criar categorias de grupos padrões de acordo com as suas similaridades (Uhl, 1994; Pereira, Lopes Jr. e Weber, 1999).

Além disso, a rede neural pode responder em tempo real às mudanças na condição do sistema a partir de entradas contínuas produzidas pelos sensores. Um outro aspecto importante é a sua habilidade inerente para operar com ruído, dados incompletos ou esparso e atuar a partir de parâmetros reais. Consequentemente, esta técnica deve facilitar a detecção de falhas em tempo real, produzindo uma Técnica não Destrutiva de Detecção para monitorar a condição de operação do sistema baseado nos dados de vibração medidos.

Este trabalho discute a utilização de redes neurais para classificar diferentes estados de operação de um sistema, utilizando o método de retropropagação (backpropagation) para treinamento e classificação dos vários estados do sistema. Diferentes tipos de falhas serão simulados numericamente variando a intensidade e a posição da falha na estrutura. A característica de generalização da rede será avaliada para os diferentes dados obtidos na simulação numérica.

2. CARACTERÍSTICAS GERAIS DA REDE NEURAL MULTI-CAMADAS

Uma rede neural multi-camadas usualmente tem três a quatro camadas de elementos, chamados neurônios, que são classificados como camada de entrada, camadas intermediárias ou ocultas (uma ou mais) e camada de saída (Lucifredi & Hou, 1994). Como ilustrado na figura 1.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

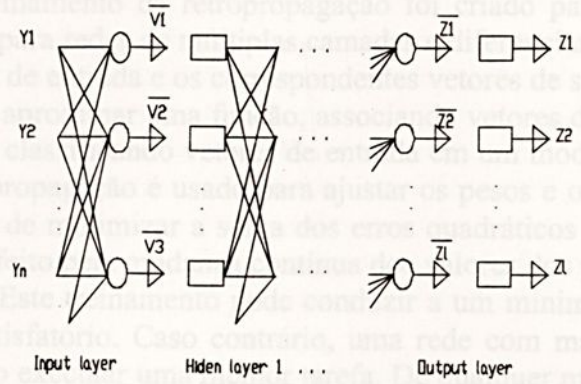


Figura 1- Esboço de uma rede neural multi-camadas.

Cada neurônio em uma camada é ligado a todos os neurônios da camada seguinte. Essas ligações são ponderadas e os valores passam de um neurônio para o próximo. Os dados de entrada são ponderados e passados para a primeira camada oculta e os neurônios da camada oculta são ativados e produzem saídas, as quais são baseadas na somatória dos valores passados a elas, devidamente ponderados pelos pesos, e sobre a função de ativação.

Da mesma forma a primeira camada intermediária passa os valores à segunda camada (se ela existir) e assim sucessivamente. No final os valores são passados para a camada de saída que produzem as saídas da rede.

O primeiro estágio, e o mais importante, de uma rede neural é chamado de "treinamento" ou "aprendizado". O treinamento faz uso de ajustes de entrada da rede para cada saída desejada. A rede aprende através de ajustagem dos pesos de interconexão entre as camadas, (Wasserman, 1993; Lopes Jr. & Demarchi, 1998). As saídas que a rede está produzindo são repetidamente comparadas com as saídas desejadas e a cada iteração os pesos de conexão são ajustados na direção das saídas desejadas. Um dos algoritmos mais utilizados no treinamento de redes neurais multi-camadas é a retropropagação. A rede é treinada de forma iterativa e os erros de comparação dos padrões são calculados a cada iteração, e o treinamento é considerado satisfatório quando se atinge um valor suficientemente pequeno para o erro.

Se uma rede é bem treinada, isto é, se ela tem uma boa capacidade de generalização, ela pode fazer o trabalho de classificação corretamente para novos dados de entrada que não foram utilizados no treinamento. Ou seja, após o treinamento, a rede está apta à avaliar o comportamento do equipamento, inclusive em condições intermediárias àquelas usadas no treinamento da rede. Isso permite um acompanhamento das condições de operação e a detecção de possíveis mudanças (falhas) do sistema, fornecendo assim subsídios suficientes para decidir sobre a necessidade ou não de uma intervenção no sistema. A intervenção no momento correto evita que o problema detectado afete de forma irreversível a estrutura ou o equipamento.

2.1 Treinamento da rede

Uma rede é treinada para aplicações de grupos de entradas produzirem um grupo de saída desejada. Cada grupo de entrada (ou saída) é referenciado como um vetor. O treinamento é executado seqüencialmente aplicando os vetores de entrada, durante o ajuste dos pesos da rede de acordo com um procedimento pré determinado. Durante o treinamento, os pesos da rede gradualmente convergem para valores de modo que um vetor de entrada produza um vetor de saída desejável. Os algoritmos de treinamento possuem duas categorias: supervisionado que requer o pareamento de cada vetor de entrada com o vetor alvo representando a saída desejada (juntos eles formam um par de treinamento) e o não supervisionado que não requer um vetor alvo para as saídas e, consequentemente, sem comparações pré-determinadas.

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

O algoritmo de treinamento da retropropagação foi criado para generalizar o controle instruído Widrow-Hoff para redes de múltiplas camadas e diferenciar funções de transferência não lineares. Os vetores de entrada e os correspondentes vetores de saída são usados para treinar a rede até ela poder aproximar uma função, associando vetores de entrada com os vetores específicos de saída, ou classificando vetores de entrada em um modo apropriado já definido. O treinamento da retropropagação é usado para ajustar os pesos e o erro sistemático, "bias", da rede com o objetivo de minimizar a soma dos erros quadráticos (Rumelhart, Hinton, and Williams, 1986). Isto é feito pela mudança contínua dos valores dos pesos e "bias" da rede na direção do menor erro. Este treinamento pode conduzir a um mínimo local. O mínimo local encontrado pode ser satisfatório. Caso contrário, uma rede com mais camadas e neurônios deve ser testada podendo executar uma melhor tarefa. De qualquer modo, o número de neurônios ou camadas a aumentar pode não ser óbvio.

Para treinar uma rede, vetores são apresentados à ela e os seus vetores de saída são calculados e posteriormente, a soma dos erros quadrados é então calculada. Se a soma dos erros quadrados de todos os vetores for menor que o erro meta, o treinamento termina. Se os erros da rede for pequeno o bastante, os vetores podem ser apresentados para a rede e ela responderá com um vetor de saída correto. A topologia e o tamanho da rede dependem da sua aplicação específica e, a definição de uma possível mudança ótima é um caso dependente. Para o problema em estudo utilizou-se o algoritmo ***backpropagation*** com uma camada intermediária de 3 neurônios e uma camada de saída com apenas 1 neurônio. Utilizou-se a função tansig juntamente com a pureling como funções de transferências no treinamento da rede.

3. PROCEDIMENTOS E GERAÇÃO DOS DADOS PARA O TREINAMENTO

Para se trabalhar com redes é necessário primeiramente definir que estrutura será analisada e definir, através de testes, ou a partir do seu histórico de funcionamento, os dados referentes às várias condições de falha que se pretende controlar. Neste caso, o objetivo maior foi estudar a capacidade de generalização da rede portanto, utilizou-se um conjunto de dados simulados visto que isso permite comparar os resultados obtidos com os valores exatos pois os erros introduzidos são bem definidos.

Os dados foram obtidos utilizado uma viga engastada de seção quadrada de uma polegada e comprimento de 676mm, inicialmente sem falha. Posteriormente, introduziu-se na estrutura dois tipos de falha, uma localizada a 100mm da extremidade engastada e a outra localizada a 608mm, ou seja, próxima a extremidade livre. Em ambos os casos, a intensidade da falha foi variada de 10 em 10% até uma falha máxima de 50% da altura "*a*" da barra, fig. 2. Os efeitos destas falhas são diferentes e apresentam uma variação não linear. Adicionalmente, o comportamento da estrutura varia para cada posição da falha, o que permite estudar como a rede responde a situações críticas (mais sensível) e situações menos severas.



Figura 2 - Representação da estrutura utilizada na medição.

Os dados foram obtidos utilizando um software de simulação desenvolvido pelos autores que permite extrair as freqüências, modos próprios e funções de resposta em freqüência

FRF(s) da estrutura. Os dados foram calculados para as diferentes condições e intensidade de falhas e comparados com os dados originais calculados para a estrutura sem falha.

O programa permite várias formas de comparação dos dados, o que possibilitou a definição de vários "set" de dados, baseados nas freqüências, modos e funções de resposta. Maior atenção foi dada neste caso para a variação das freqüências visto que este é um parâmetro global, sensível a falha, e relativamente fácil de ser identificado em situações práticas. Para se escolher o padrão de entrada adequado foram realizados vários testes, pois este é um processo fundamental dentro desta metodologia. Para a entrada de dados foram apresentadas duas condições, a primeira condição (sem defeito) tendo como saída 0 e a segunda condição (com defeito máximo) tendo como saída 1.

Primeiramente, usou-se como dados de entrada para o treinamento da rede a diferença de freqüência em porcentagem para situações intermediárias e posteriormente, utilizou-se apenas as condições extremas, falha máxima e sem falha. Como foi possível treinar a rede com estes dados tornou-se interessante então avaliar a capacidade de generalização desta rede, ou seja, apresentar a ela dados não treinados e observar qual a resposta por ela apresentada.

Isto também foi feito para outros dados de entrada tais como, a diferença de freqüência ou, uma máscara retangular dos dados. Todo esse processo de treinamento e verificação da capacidade de generalização da rede foi realizado igualmente para a falha localizada próxima da extremidade livre da viga como para a localizada próxima a extremidade engastada. Os dados obtidos estão apresentados a seguir.

4. RESULTADOS

Realizadas todas as etapas descritas anteriormente foi possível então obter os dados utilizados para o treinamento da rede bem como as respostas por ela gerada. A tabelas 1 e 2 apresentam os dados utilizados no treinamento da rede para falhas localizadas próxima do engaste e da extremidade livre respectivamente.

Tabela 1- Dados utilizados no treinamento da rede.

% de Falha	Freqüências do 1º ao 5º modo					Diferença de Freqüência em Porcentagem do 1º ao 5º modo				
	1º	2º	3º	4º	5º	1º	2º	3º	4º	5º
0%	46.6	291.4	813.8	1588.8	1919.4	0	0	0	0	0
10%	46.3	291.2	814.1	1578.0	1916.6	-0.67	-0.07	0.04	-0.11	-0.15
20%	45.8	290.9	814.3	1583.5	1913.1	-1.70	-0.17	0.06	-0.34	0.33
30%	45.0	290.4	814.4	1576.9	1908.5	-3.33	-0.35	0.07	-0.75	-0.57
40%	43.8	289.6	814.2	1565.1	1902.4	-6.05	-0.63	0.04	-1.49	-0.88
50%	41.5	288.1	813.5	1544.2	1894.0	-10.7	-1.12	-0.04	-2.81	-1.32

Tabela 2- Dados utilizados no treinamento da rede.

% de Falha	Freqüências do 1º ao 5º modo					Diferença de Freqüência em Porcentagem do 1º ao 5º modo ($x10^{-2}$)				
	1º	2º	3º	4º	5º	1º	2º	3º	4º	5º
0%	46.6	291.4	813.8	1588.9	1919.5	0	0	0	0	0
10%	46.6	291.4	813.8	1588.6	1919.8	2.21	0.75	-0.37	-1.56	1.41
20%	46.6	291.5	813.8	1588.2	1920.0	2.20	0.69	-0.70	-2.51	1.40
30%	46.6	291.5	813.7	1587.6	1920.3	2.20	0.59	-1.30	-4.22	1.38
40%	46.6	291.5	813.5	1586.4	1920.6	3.30	0.67	-3.23	-9.99	2.05
50%	46.6	291.5	813.0	1584.0	1920.8	2.18	-0.03	-5.07	-15.08	1.33



Os dados apresentados nas tabela 1 e 2 foram utilizados para o treinamento da rede com diferentes situações de falha. Primeiro, a rede foi treinada para condições de falhas próximas do engaste, utilizando todos os dados referentes às várias intensidade da falha. Os dados apresentados à rede foram as diferenças de freqüências, em porcentagem, para a falha localizada próxima a extremidade engastada da viga. Uma vez treinada com sucesso, a mesma foi utilizada para a confirmação do reconhecimento dos dados treinados. A figura 3 mostra a resposta da rede treinada para as várias intensidade de falha testadas.

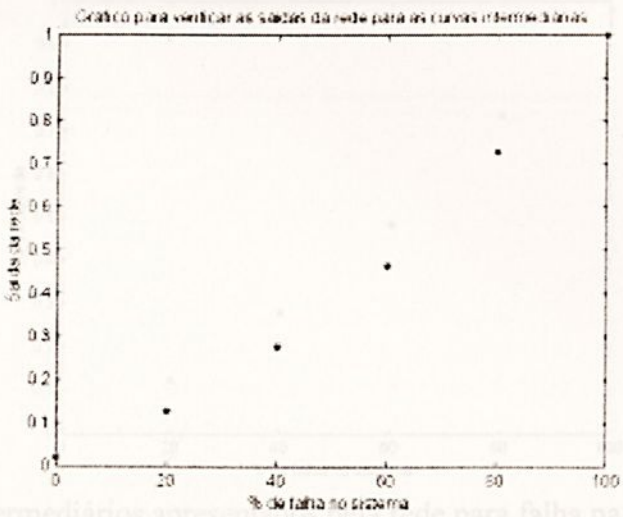


Figura 3- Valores intermediários apresentados pela rede para falha na extremidade engastada.

Uma vez testada a capacidade de reconhecimento da rede utilizando todos os dados, a mesma foi treinada novamente apenas com os dados extremos, para uma avaliação da sua capacidade de generalização. Neste caso, foi utilizado um conjunto "reduzido" de dados, isto é, condição de falha nula e falha máxima, durante o treinamento da rede. Os dados apresentados à rede foram as diferenças de freqüência, como no caso anterior. Uma vez treinada com sucesso, a mesma foi utilizada para o reconhecimento de padrões intermediários. A figura 4 mostra os resultados de reconhecimento para situações intermediárias de falha de intensidade igual 20%, 40% ….. Como pode ser observado, neste caso, a rede identifica todas as condições de falhas testadas.

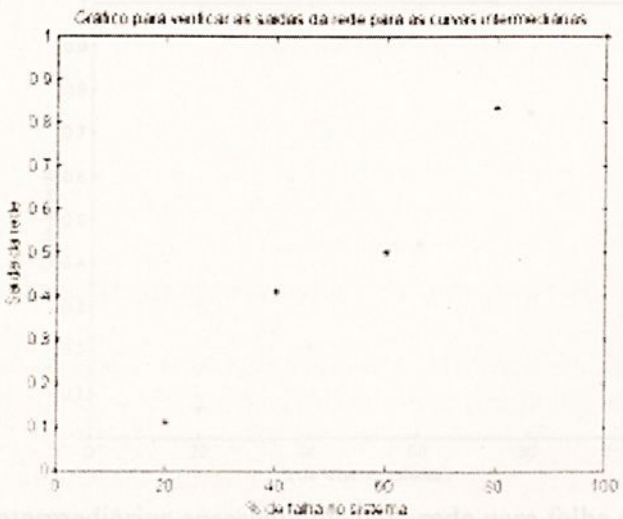


Figura 4- Valores intermediários apresentados pela rede para falha na extremidade engastada.

Numa Segunda etapa, a rede foi treinada para condições de falhas próximas da extremidade livre, utilizando todos os dados referentes às várias intensidade da falha. Os dados apresentados à rede foram as diferenças de freqüência, em porcentagem, para a falha localizada próxima a extremidade livre da viga. Uma vez treinada com sucesso, a mesma foi utilizada para a confirmação do reconhecimento dos dados treinados. A figura 5 mostra a resposta da rede treinada para as várias intensidade de falha testadas.

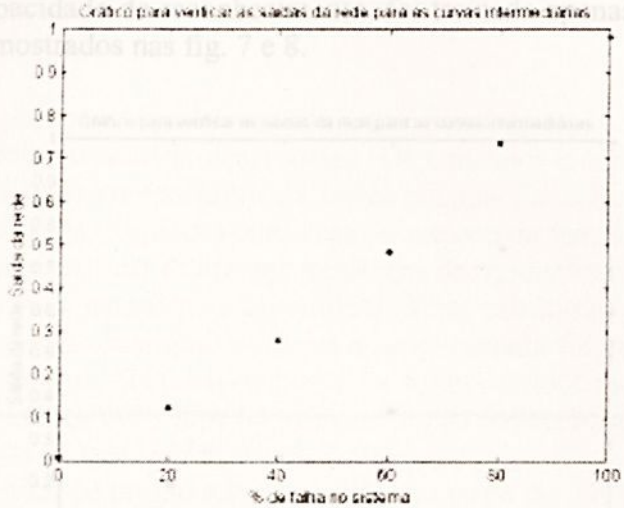


Figura 5- Valores intermediários apresentados pela rede para falha na extremidade livre.

Uma vez testada a capacidade de reconhecimento da rede utilizando todos os dados, a mesma foi treinada novamente apenas com os dados extremos, para uma avaliação da sua capacidade de generalização. Neste caso, foi utilizado um conjunto "reduzido" de dados, isto é, condição de falha nula e falha máxima, durante o treinamento da rede. Os dados apresentados à rede foram as diferenças de freqüência, como no caso anterior. Uma vez treinada com sucesso, a mesma foi utilizada para o reconhecimento de padrões intermediários. A figura 6 mostra os resultados de reconhecimento para situações intermediárias de falha de intensidade igual 20%, 40% ….. Como pode ser observado, neste caso, a rede identifica todas as condições de falhas testadas.



Figura 6- Valores intermediários apresentados pela rede para falha na extremidade livre.

Testes adicionais foram realizados utilizando outras informações extraídas dos dados mostrados nas tabelas 1 e 2, diferença absoluta das freqüências, amplitude e freqüência obtidas a partir das funções de resposta e freqüência. Estes testes visaram observar a resposta da rede para uma mesma situação de falha utilizando outras formas de informações. A seguir será apresentado apenas os resultados utilizando diferenças absoluta de freqüência, para o caso 2, devido as limitações de espaço. Os demais casos apresentaram resultados similares. Como nos casos anteriores, a rede foi treinada com todos os dados e, posteriormente, após a comprovação da sua capacidade de reconhecimento, foi treinada apenas com os dados extremos. Os resultados são mostrados nas fig. 7 e 8.

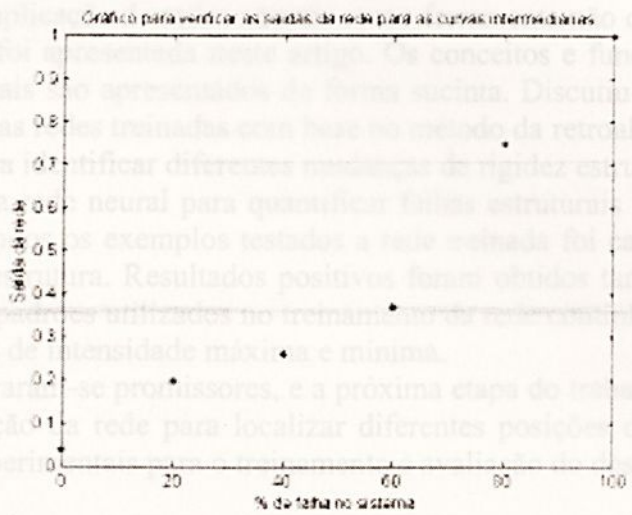


Figura 7- Valores intermediários apresentados pela rede para falha na extremidade livre.

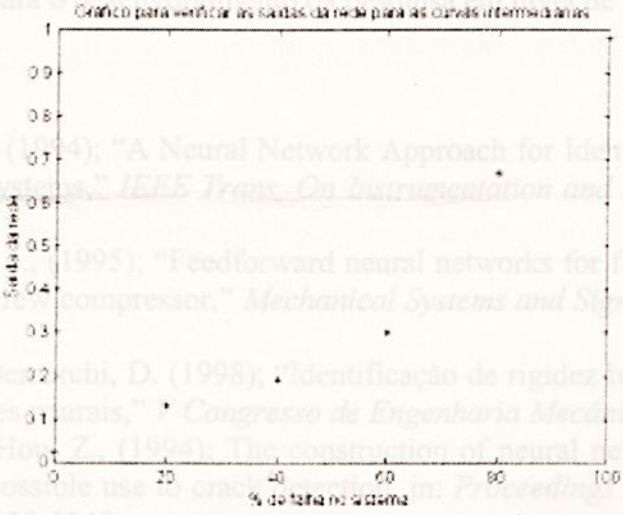


Figura 8- Valores intermediários apresentados pela rede para falha na extremidade livre.

As respostas produzidas pela rede mostram que a influência da falha na estrutura varia de forma não linear com o aumento da sua severidade e que a influência da intensidade da falha tem um comportamento que se aproxima de uma exponencial. Este comportamento foi posteriormente comprovado simulando incrementos na intensidade da falha e calculando as variações das freqüências do novo modelo alterado.

Os resultados obtidos mostram que as redes treinadas identificaram corretamente as várias condições de falha e ainda apresenta uma boa capacidade de generalização. Todas as redes

que obtiveram convergência no treinamento utilizando dados reduzidos responderam adequadamente para valores diferentes aos a ela apresentados no treinamento. Esta característica mostra que a sua utilização em situações reais pode representar um grande avanço uma vez que a mesma não necessita de um grande número de padrões de falhas previamente definidos para todas as diferentes condições de falha. Neste caso, a rede pode ser treinada com um conjunto específico (reduzido) de dados, e ser utilizada para a identificação de condições de falhas distintas daquelas usadas no treinamento.

5. CONCLUSÃO

Uma descrição da aplicação de redes neurais como ferramenta não destrutiva para avaliação de falha estrutural foi apresentada neste artigo. Os conceitos e fundamentos básicos envolvidos em redes neurais são apresentados de forma sucinta. Discutiu-se também a capacidade de generalização das redes treinadas com base no método da retroalimentação bem como a sua potencialidade para identificar diferentes mudanças de rigidez estrutural.

A potencialidade da rede neural para quantificar falhas estruturais foi demonstrado com dados numéricos. Em todos os exemplos testados a rede treinada foi capaz de quantificar as falhas introduzidas na estrutura. Resultados positivos foram obtidos também naquelas situações onde o número de padrões utilizados no treinamento da rede continha apenas as informações referentes as falhas de intensidade máxima e mínima.

Os resultados mostraram-se promissores, e a próxima etapa do trabalho será estudar a capacidade de generalização da rede para localizar diferentes posições de falhas e posteriormente utilizar dados experimentais para o treinamento e avaliação do desempenho da rede.

Agradecimentos

Os autores agradecem ao apoio financeiro dado pela Fundação de Amparo à Pesquisa do Estado de São Paulo para o desenvolvimento da pesquisa em nível de mestrado.

REFERÊNCIAS

Bernieri, A. at all (1994); "A Neural Network Approach for Identification and Fault Diagnosis on Dynamic Systems," *IEEE Trans. On Instrumentation and Meas.*, vol. 43, nº 6 pp. 867-873, Dec./94.

Kim, T., & Li, C. J., (1995); "Feedforward neural networks for fault diagnosis and severity assessment of a screw compressor," *Mechanical Systems and Signal Processing*, pp. 485-496.

Lopes Jr., V. & Demarchi, D. (1998); "Identificação de rigidez bilinear em sistemas mecânicos através de redes neurais," *V Congresso de Engenharia Mecânica - Norte Nordeste*.

Lucifredi, A., & Hou, Z., (1994); The construction of neural networks for bilinear systems identification a possible use to crack detection, in: *Proceedings ISMA19*- Belgium Leuven, September, pp. 1139-1149.

Pereira, J. A., Lopes Jr. V. e Weber, H. I., (1999); "Automation in Fault Detection Using Neural Network and Modal Updating", Journal of the Brazilian Society of Mechanical Sciences, Vol. XXI.

Rumelhart, D. E., Hinton, G. E., Williams, R. J., (1986); *Learning Internal representation by error propagation,* **Parallel distributing processing: Explorations in the microstructures of cognition V. 1,** MIT Press, Cambridge – M.A., E.U.A..

Uh1, T. (1994); "Automation of monitoring and diagnostic process for rotating machinery using neural networks," *ISMA – Intern. Seminar of Modal Analysis*, Sept./94.

unesp

Wasserman, P. D., (1993); **Neural computing – Theory and practice,** Van Nostrand Reinhold, Nova Iorque – N.Y., E.U.A..

NON-DESCTRUCTIVE EVALUATITON TOOL FOR MONITORING AND DETECTION OF STRUCTURAL DAMAGE BY USING NEURAL NETWORK

Abstract: The use of Neural Network as Non-Destructive Evaluation tool for fault detection based on vibration measurement is gaining more importance in the context of operation condition and health monitoring of mechanical systems. The propose consist in the monitoring of the vibration condition of the structure that will be evaluated in order to define a set of data able to identify it and suitable for the training process. However, there exist the necessity of generation of a large set of data containing the different patterns representing all failure condition that is likely to occur in the structure. This work studies the capability of generalization of Neural Network using the backpropagation algorithm to classify the input patters of a system with different stiffness ratio. This will bring to definition of Neural Networks capable to use a reduced set of data during training phase and, once it is successfully trained, it could identify intermediate failure condition. Several condition and intensity of fault has been studied by using numerical data. The Neural Network demonstrated a good capacity of generalization for all case studied. In a next step this generalization capability will be tested with experimental data.

Keywords: Neural Network, Backpropagation, Generalization, Fault Detection.

RBCM - J. of the Braz. Soc. Mechanical Sciences
Vol. XXI - No.1 - 1999 - pp. 99-108
ISSN 0100-7386
Printed in Brazil

Automation In Fault Detection Using Neural Network and Model Updating

João Antonio Pereira
Vicente Lopes Jr.
UNESP - Universidade Estadual Paulista
Faculdade de Engenharia de Ilha Solteira
Departamento Engenharia Mecanica
15385-000 Ilha Solteira, SP Brazil
japereir@dem.feis.unesp.br

Hans Ingo Weber
UNICAMP - Universidade Estadual de Campinas
Faculdade de Engenharia Mecânica
Departamento de Projeto Mecânico
13083-970 Campinas, SP Brazil
hans@mec.puc-rio.br

Abstract

In this article, an implementation of structural health monitoring process automation based on vibration measurements is proposed. The work presents an alternative approach which intent is to exploit the capability of model updating techniques associated to neural networks to be used in a process of automation of fault detection. The updating procedure supplies a reliable model which permits to simulate any damage condition in order to establish direct correlation between faults and deviation in the response of the model. The ability of the neural networks to recognise, at known signature, changes in the actual data of a model in real time are explored to investigate changes of the actual operation conditions of the system. The learning of the network is performed using a compressed spectrum signal created for each specific type of fault. Different fault conditions for a frame structure are evaluated using simulated data as well as measured experimental data.

Keywords: *Neural Network, Fault Detection, Model Updating, Predictive Maintenance*

Introduction

The entire life cycle of a product involves an iterative engineering effort. The initial design concept is likely to give rise to a variety of design options each of which will be evaluated against the requirements of the product specification. At this stage, usually, is constructed a prototype and their properties are evaluated and compared with the design requirement. The Structural Dynamic Modification (SDM) is a term usually used in modal analysis and implies the incorporation, into an existing model, of design modification or new information gained either from experimental testing or other source, in order to evaluate the accuracy of the model.

The SDM algorithm is useful for solving the forward variational problems for structures, i.e., for a given variation into the mass, stiffness or damping properties, it leads to the corresponding changes in the modal properties of the model. However, to access a high performance against the requirements of the product specification demands a safety and reliable monitoring of the operation conditions and failure diagnostic of the model. This involves a solution of an inverse problem, or modal sensitivity problem. That is, for a given variation in the modal properties of the structure, which corresponding changes in its mass, stiffness and damping properties have taken place. Application as fault detection requires solutions of this kind of inverse problem. Unlike the forward variational problem, fault detection applications can not be solved in a straightforward manner. Its solution, for most practical cases, requires the inversion of a rank deficient matrix, which creates numerical difficulties to identify the correct changes of the structural properties that have to taken place into the model.

Numerous researches have proposed solutions using modal sensitivity problem to damage detection of structures through vibration changes. As modal testing has become more widespread, finite element model updating using measured modal test data has also become popular in the field of damage detection. The relative success and the potentiality demonstrated by these techniques, mainly, those based on vibration properties have shown that they are promising tools for damage detection purpose (Pereira, 1994; Hemez, 1993; Zimmerman, 1995). However, for purpose of monitoring, they are still under investigation (far to be consolidated). The recent literature has been shown some attempts to use permanently working monitoring system, based on natural excitation source actuating in the system to evaluate its health condition (Rohrmann and Rucker, 1994) but the results are still limited.

Presented at DINAME 97 - 7th International Conference on Dynamic Problems in Mechanics, 3-7 March 1997. Angra dos Reis, RJ. Brasil. Technical Editor: Agenor de Toledo Fleury.



Artificial Neural Networks (ANN) have recently emerged as a good tool for pattern recognition turning their application in promising tools for monitoring and fault classification of machines and equipments. The technique offers promise for solving inverse varational problem in the context of monitoring and fault detection because of their pattern recognition and interpolation capabilities. In order to identify the fault in the model, it must be trained using a set of solutions to its corresponding forward variational problem. In this case, the neural networks should be designed to classify the input patterns in pre-defined classes or to create categories of group patterns according to their similarity. An important feature of the neural networks, in this context, is their inherent ability to operate on noisy, incomplete or sparse data and to model process from actual system parameters (Uhl, 1994). The neural network could respond in real time to the changes in the system state, provided by continuous sensor inputs. Hence this technique should facilitate fault identification in real time, providing a good Non-Destructive Evaluation (NDE) tool to investigate the state of operation and health condition of a system based on measured vibration data. Nevertheless, several attempts to use neural networks faced difficulties to generate reliable set of information to train the net. It demands a wide range of experimental tests to cover the whole possibility of damages of the model, which makes its use prohibitive.

This work presents an alternative proposal to exploit the capability of neural network associating it with model updating technique to investigate the state of operation and health condition of the system. It creates a very reliable updated finite element model, using a FRF-based model updating approach (Larson, 1992; Lammens, 1994; Pereira, 1996) and uses SDM to generate the patterns faults to feed the ANN during the training phase. The approach initially adjusts the finite element model and validates its response properties in terms of the dynamic measured data of the real system. Following, it simulates different types of damage conditions to train the network.

The proposed approach is addressed to fault detection on the frequency analysis domain, where each machine defect generally produces a set of vibration components that allows the recognition of different faults. However, its application is similar for others kind of signal since there are many others parameters that can be measured to evaluate the operation condition of a machine such as pressure, temperature, sound, oil particles, etc.

Methodology

An Artificial Neural Network approach associated with a Finite Element Model Updating Procedure (MUP) has been used to operate the monitoring and failure diagnosis of machines and equipments. The updating approach performs an improvement of the FE-Model in order to define a representative mathematical model of the actual system. The improved model permits to create the various damage conditions required to define the reliable set of information data concerning each kind of failure liable to occur in the life cycle of the system. The network is designed to classify the input patterns of the model in pre-defined classes of inputs or to create categories of group patterns according to their similarity, by a training process phase. In the monitoring phase, it compares the actual measured data with the input patters aiming at recognising the existence of fault in the system. The updated FE-model permits to generate the various damage conditions necessary for the training of the network. So, the ANN may lead to diagnose of the system in real time, facilitating the identification of faults in the operating system.

The approach comprehends a definition of a reliable FE-Model, the generation of whole expected failure conditions, the training of the ANN and finally, the recognition and location of each kind of fault. The ANN learns by example and the pattern of damaged signal used to feed the training of the network, frequency response functions, is created in a straight forward manner by applying SDM. Once the network is trained, it can execute any patter recognition task.

The classification of the vibration signal, generated from the improved finite element model, comprehend a separation of the vibration data in signals of components operating normally, signals of components operating with fault; a compression of the signals and finally, classification of the compressed patterns using a backpropagation algorithm. The compression of the pattern data is important because it transforms a large set of data in an equivalent reduced set containing the same information provided by the original signal. This reduction decreases significantly the time spent to train the network as well as the reduction of the instability in the recognition process (Lopes Jr. and Turra, 1996). The compression process consists in the compression of the spectrum size of the signal in a reduced number of points. It constructs a new equivalent signature for the system based on the maximum amplitude and corresponding frequencies points of the original signal. The algorithm



searches the maximum amplitude points in the original signal at an earlier specified frequency range and considers a band width of 3.0% around each frequency point related with maximum amplitude points.

Background of the Neural Network

ANN is made by a number of processing elements which are connected to form layers of neurons. Each neuron is a simple mathematical processing unit that, when it is interconnected, produces a complex structure with different architectures, which can be trained to recognise defined patters. It is common to specify the architecture of the network by referring to the number of hidden layers; layers that are neither inputs nor outputs. The topologies and size of the network depend on the specific application, and the definition of an optimal choice is case dependent (Bernieri, 1994; Worden and Tomlinson, 1994; Yuedong and Du, 1996). Figure 1 shows the architecture used, in this approach, it has one hidden layer with 500 neurons for an output layers with 31 neurons.

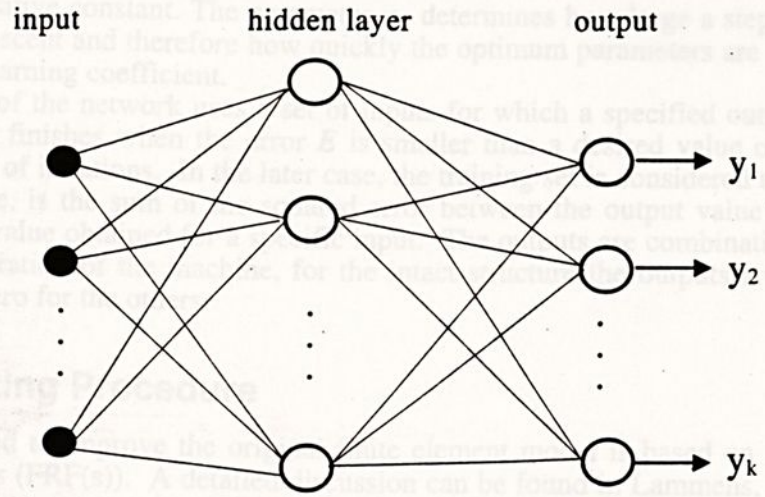


Fig. 1 Architecture of the neural network with one hidden layer

The input x's are weighted by $w^h_{j,i}$ and by the bias b^h_j , and the output results feed the hidden layer. The output of the j^{th} hidden unit can be described by:

$$y^h_j = F_1\left(b^h_j + \sum_{i=1}^{N} W^h_{i,j}.x_i\right) \qquad (1)$$

where the superscript (h) means that the quantities pertain to the hidden unit and $\mathbf{F_1}(\,.\,)$ is a sigmoid nonlinear function. The output of the net is biased and weighted by sum of the hidden layer outputs:

$$y_l = F_2\left(b^o_l + \sum_{j=1}^{H} W^o_{j,l}.y^h_j\right) \qquad l = 1, 2, \ \ldots, k \qquad (2)$$

where the superscript (o) refers to the output unit. **H** is the number of units in the hidden layer and $\mathbf{F_2}(.)$ is a linear activation transfer function. The net is trained starting with a random set of weights and biases and calculating the output for every input set. Then, the error E is computed from the output layer backwards, which has historically been called the backpropagated error, and the learning algorithm the backpropagation. Several publications (Hecht and Nielsen, 1990; Wasserman, 1989; Hush and Horne, 1993) have presented details of this algorithm.

$$E = sumsqr(\{T\} - \{y\}) \tag{3}$$

where sumsqr is the sum of square of the elements, and T is the desired output. The error E is formulated as a function of the weights and biases and then, the minimisation is performed by means of the usual steepest algorithm. The error E is denoted by $\{\alpha_j\}$, where the index j aking on as many values as there are weights and biases. When the parameter α_j changes by $\delta\alpha_j$, the error E changes by

$$\delta E = \frac{\partial}{\partial \alpha_j}(E)\,\delta\alpha_j \tag{4}$$

where $\delta/\delta\alpha_j$ is evaluated using the current values of the parameter. To ensure that changes in α_j results in a decrease in E, it selects

$$\delta\alpha_j = -\eta \frac{\partial}{\partial \alpha_j}(E) \tag{5}$$

where η is a positive constant. The parameter η determines how large a step is made in the direction of the steepest descent and therefore how quickly the optimum parameters are obtained. For this reason η is called the learning coefficient.

The training of the network uses a set of inputs for which a specified output is known and in this case, the process finishes when the error E is smaller than a desired value or it reaches a maximum specified number of iterations. In the later case, the training set is considered unsatisfactory. The error E considered here, is the sum of the squared error between the output value provided by the trained network and the value obtained for a specific input. The outputs are combination of zeros and ones for each state of operation of the machine, for the intact structure the outputs are equal one for the first component and zero for the others.

Model Updating Procedure

The MUP used to improve the original finite element model is based on the measured frequency response functions (FRF(s)). A detailed discussion can be found in Lammens, 1995 and Pereira, 1996. The procedure operates at an element level and the model changes are directly related to the variation of the parameters of each element. It describes the discrepancy between analytical and experimental models as a force residue written in terms of the analytical dynamic stiffness matrix $[Z^A]$, and the experimental FRF matrix $[H^x]$.

$$\{\varepsilon\} = \varepsilon\left([Z^A(p_1 + \Delta p_1, p_2 + \Delta p_2, \ldots, p_m + \Delta p_m)], \{H^X\}\right) \cong \{0\} \tag{6}$$

This discrepancy of the models is used to define the updating set of equations and the solution of the updating problem consists in finding m analytical parameter changes that minimises the difference between the two models. The p-parameters can represent any physical or geometrical property of the model, they can be a parameter of an element in the case of the elements being adjusted independently or a parameter of a set of elements when some elements are adjusted proportionally. The Δp's are parameters correction of the p-parameters that minimise the discrepancy between the two models. The formulation of an approximated solution of the problem, through a first order linearization of the expression (6) in the p-parameters, leads an overdetermined set of linear equations:

$$\{\varepsilon\} = [S]\{\Delta p\} - \{B\} \tag{7}$$

where the elements of the sensitivity matrix [S] and these of the difference vector {B} are known elements. They are obtained from the analytical dynamic stiffness matrix and the experimental measured frequency response functions at each selected measured frequency points respectively. The

elements of the vector {Δp} are unknown parameter corrections to be estimated. The solution of this system of linearised equations system provides an improved analytical model. If the discrepancy between the models is not yet sufficiently small, the procedure is iteratively repeated.

Experimental Test

To demonstrate the applicability of the proposed methodology, a laboratory spatial frame structure, Fig. 3, has been investigated. An analytical modelling by finite elements and a modal test of the structure were carried out and compared aiming at defining a representative analytical-numerical model able to predict the real behaviour of the structure. The initial comparison of modal parameters from both, analytical and experimental models, showed a deviation of the predicted data from the experimental one, Table 1 and Fig. 4.a. The adjustment of the analytical finite element model and the consequent improvement of the correlation of the models was performed by a FRF based model updating procedure (Pereira, 1996). The spatial parameters of the finite element model were successfully updated by using the FRF based model updating and, the correlation of the models was improved satisfactory, table 1. The elements selected to be adjusted during the updating process were those elements evolved into the welding connections. Figure 4.b shows the superposition of the FRF(s) in the drive point for the experimental test and the corresponding new reliable finite element model. The updating process, as shown in Table 1 and Fig. 4, allowed the definition of a representative mathematical model of the actual system.

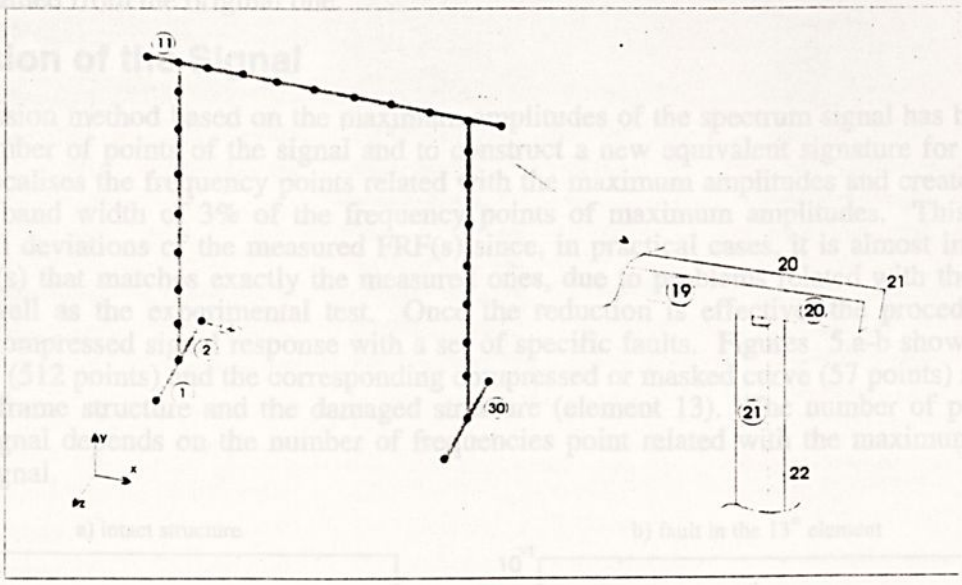


Fig. 3 Frame structure - Detail of the cut bar

Table 1 Experimental, Analytical and Updated models correlation

Experimental model		Analytical model		Updated model		Initial correlation		Final correlation (iteration 5)	
mode	freq. [Hz]	mode	freq. [Hz]	mode	freq. [Hz]	Δf [%]	MAC-val.	Δf [%]	MAC-val.
1	17.06	1	17.26	1	16.98	1.17	0.994	-0.43	0.995
2	22.10	2	25.30	2	22.38	14.47	0.991	1.26	0.991
3	42.44	3	43.86	3	42.73	3.34	0.990	0.68	0.990
4	97.54	4	102.06	4	97.04	5.71	0.978	-0.02	0.985
5	112.86	5	121.63	5	112.91	8.73	0.975	0.66	0.974
6	142.36	6	144.93	6	141.60	2.73	0.834	-0.53	0.881
7	153.83	7	155.03	7	153.71	0.78	0.954	-0.07	0.953
8	171.13	8	176.21	8	172.56	2.96	0.978	0.83	0.982

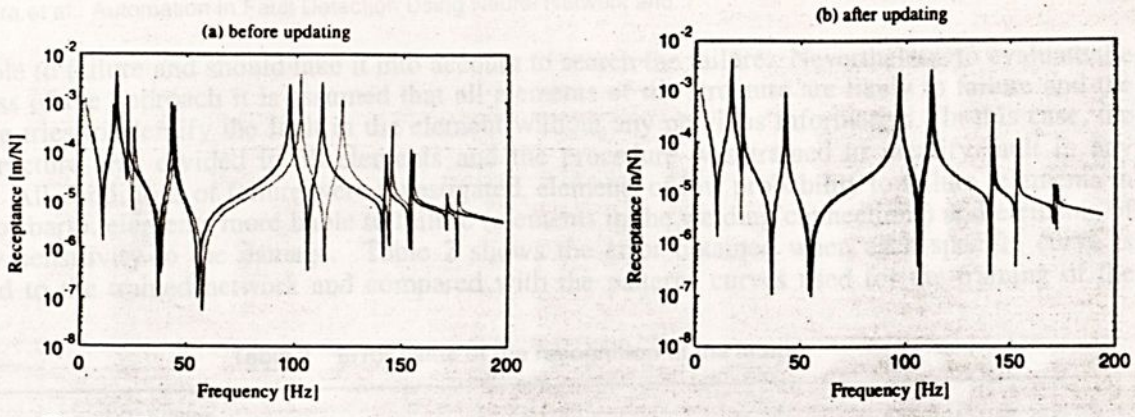


Fig. 4 Experimental (full line) and analytical (dashed line) receptances (point 1, x-direction)

Different damage conditions of the structure were obtained numerically by using the updated FE-model of the structure. Each fault introduced to the structure consisted of a reduction of 50% of the sectional area of the associated element. A frequency range covering the first eleven mode shapes of the structure was analysed. For each damaged element a set of FRF(s) was created which contains the whole informations used to feed the training of the network. The training was based on the compressed set of data obtained from the original one.

Compression of the Signal

A compression method based on the maximum amplitudes of the spectrum signal has been used to reduce the number of points of the signal and to construct a new equivalent signature for the system. The method localises the frequency points related with the maximum amplitudes and creates a masked signal with a band width of 3% of the frequency points of maximum amplitudes. This permits to comprise small deviations of the measured FRF(s) since, in practical cases, it is almost impossible to calculate FRF(s) that matches exactly the measured ones, due to problems related with the modelling approach as well as the experimental test. Once the reduction is effective, the procedure tries to associate the compressed signal response with a set of specific faults. Figures 5.a-b show an original measured FRF (512 points) and the corresponding compressed or masked curve (57 points) respectively for the intact frame structure and the damaged structure (element 13). The number of points of the compressed signal depends on the number of frequencies point related with the maximum amplitude peaks of the signal.

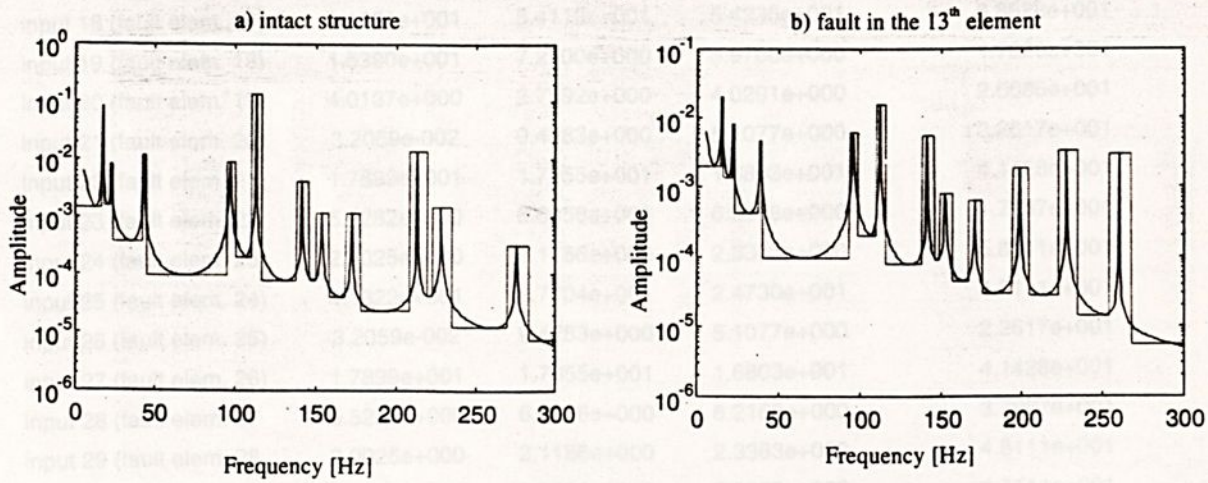


Fig. 5 Original (full line) and compressed (dotted line) signal

Numerical Results

Machines failure is a phenomenon liable to occur during the service life of most machines and equipaments. However, in some cases, the analyst may have previous information of the region more

susceptible to failure and should take it into account to search the failure. Nevertheless, to evaluate the robustness of the approach it is assumed that all elements of the structure are likely to failure and the procedure tries to identify the fault in the element without any previous information. In this case, the frame structure was divided in 30 elements and the procedure was trained to identify fault in any element. All conditions of failure were investigated, elements of low probability to failure (elements in the mid of bars), elements more liable to failure (elements in the welding connections) and elements of very low sensitivity to the damage. Table 2 shows the error obtained when each specific curve is submitted to the trained network and compared with the patterns curves used for the training of the network.

Table 2 Error value of the recognition of the faults.

Fault Condition / Curves	Undamaged	Fault Element 1	Fault Element 2	...	Fault Element 30
input 1 (intact struct.)	**9.6063e-006**	4.8641e+000	3.7970e+000		1.1696e+001
input 2 (fault elem. 1)	6.7413e+000	**9.7144e-006**	9.7573e-001		4.0104e+001
input 3 (fault elem. 2)	1.7271e+001	2.5262e+000	**9.6776e-006**		2.0471e+001
input 4 (fault elem. 3)	3.2935e+001	3.2589e+001	3.3665e+001		5.4743e+001
input 5 (fault elem. 4)	1.6834e+001	1.7251e+001	1.5313e+001		1.3523e+001
input 6(fault elem. 5)	1.7713e+001	2.0244e+001	2.0787e+001		9.6019e+000
input 7 (fault elem. 6)	2.9976e+001	3.0634e+001	3.0579e+001		1.8342e+001
input 8 (fault elem. 7)	3.9097e+001	4.7494e+001	4.5525e+001		1.3870e+001
input 9 (fault elem. 8)	2.0037e+001	1.6979e+001	1.5710e+001		1.3138e+001
input 10 (fault elem. 9)	1.5272e+001	2.6424e+001	2.2509e+001		1.1539e+001
input 11 (fault elem. 10)	1.3199e+001	1.7504e+001	1.3277e+001		2.5670e+001
input 12 (fault elem. 11)	3.9884e-002	1.7489e+001	1.7140e+001		2.6266e+001
input 13 (fault elem. 12)	3.4204e+001	3.0950e+001	3.0608e+001		3.4119e+001
input 14 (fault elem. 13)	9.8143e+000	1.1770e+001	1.2617e+001		1.5352e+001
input 15 (fault elem. 14)	4.5487e+000	5.7721e+000	6.3547e+000		1.7717e+001
input 16 (fault elem. 15)	1.9961e+001	1.9895e+001	1.6745e+001		2.6779e+001
input 17 (fault elem. 16)	3.1467e+001	2.1154e+001	2.1000e+001		4.4202e+001
input 18 (fault elem. 17)	3.1031e+001	5.4119e+001	5.4335e+001		6.8628e+001
input 19 (fault elem. 18)	1.5390e+001	7.2700e+000	5.9768e+000		1.7626e+001
input 20 (fault elem. 19)	4.0137e+000	2.7592e+000	4.0291e+000		2.5086e+001
input 21 (fault elem. 20)	3.2059e-002	9.4283e+000	5.1077e+000		2.2617e+001
input 22 (fault elem. 21)	1.7899e+001	1.7955e+001	1.6803e+001		4.1428e+001
input 23 (fault elem. 22	5.5282e+000	6.6056e+000	6.2168e+000		1.7987e+001
input 24 (fault elem. 23)	2.0025e+000	2.1186e+000	2.3363e+000		5.8111e+001
input 25 (fault elem. 24)	4.1322e+001	2.7704e+001	2.4730e+001		4.8111e+001
input 26 (fault elem. 25)	3.2059e-002	9.4283e+000	5.1077e+000		2.2617e+001
input 27 (fault elem. 26)	1.7899e+001	1.7955e+001	1.6803e+001		4.1428e+001
input 28 (fault elem. 27	5.5282e+000	6.6056e+000	6.2168e+000		3.7987e+001
input 29 (fault elem. 28	2.0025e+000	2.1186e+000	2.3363e+000		4.8111e+001
input 30 (fault elem. 29)	2.0025e+000	2.1186e+000	2.3363e+000		4.7111e+001
input 31 (fault elem. 30)	4.1322e+001	2.7704e+001	2.4730e+001	...	**9.1069e-006**

Figures 6.a-6.s give an overview of the normalised errors for some investigated failure conditions. The plots show the errors, normalized in relation to the minor component, obtained through a "comparison" of each specific "measured" curve with all others curves used for the training of the network.



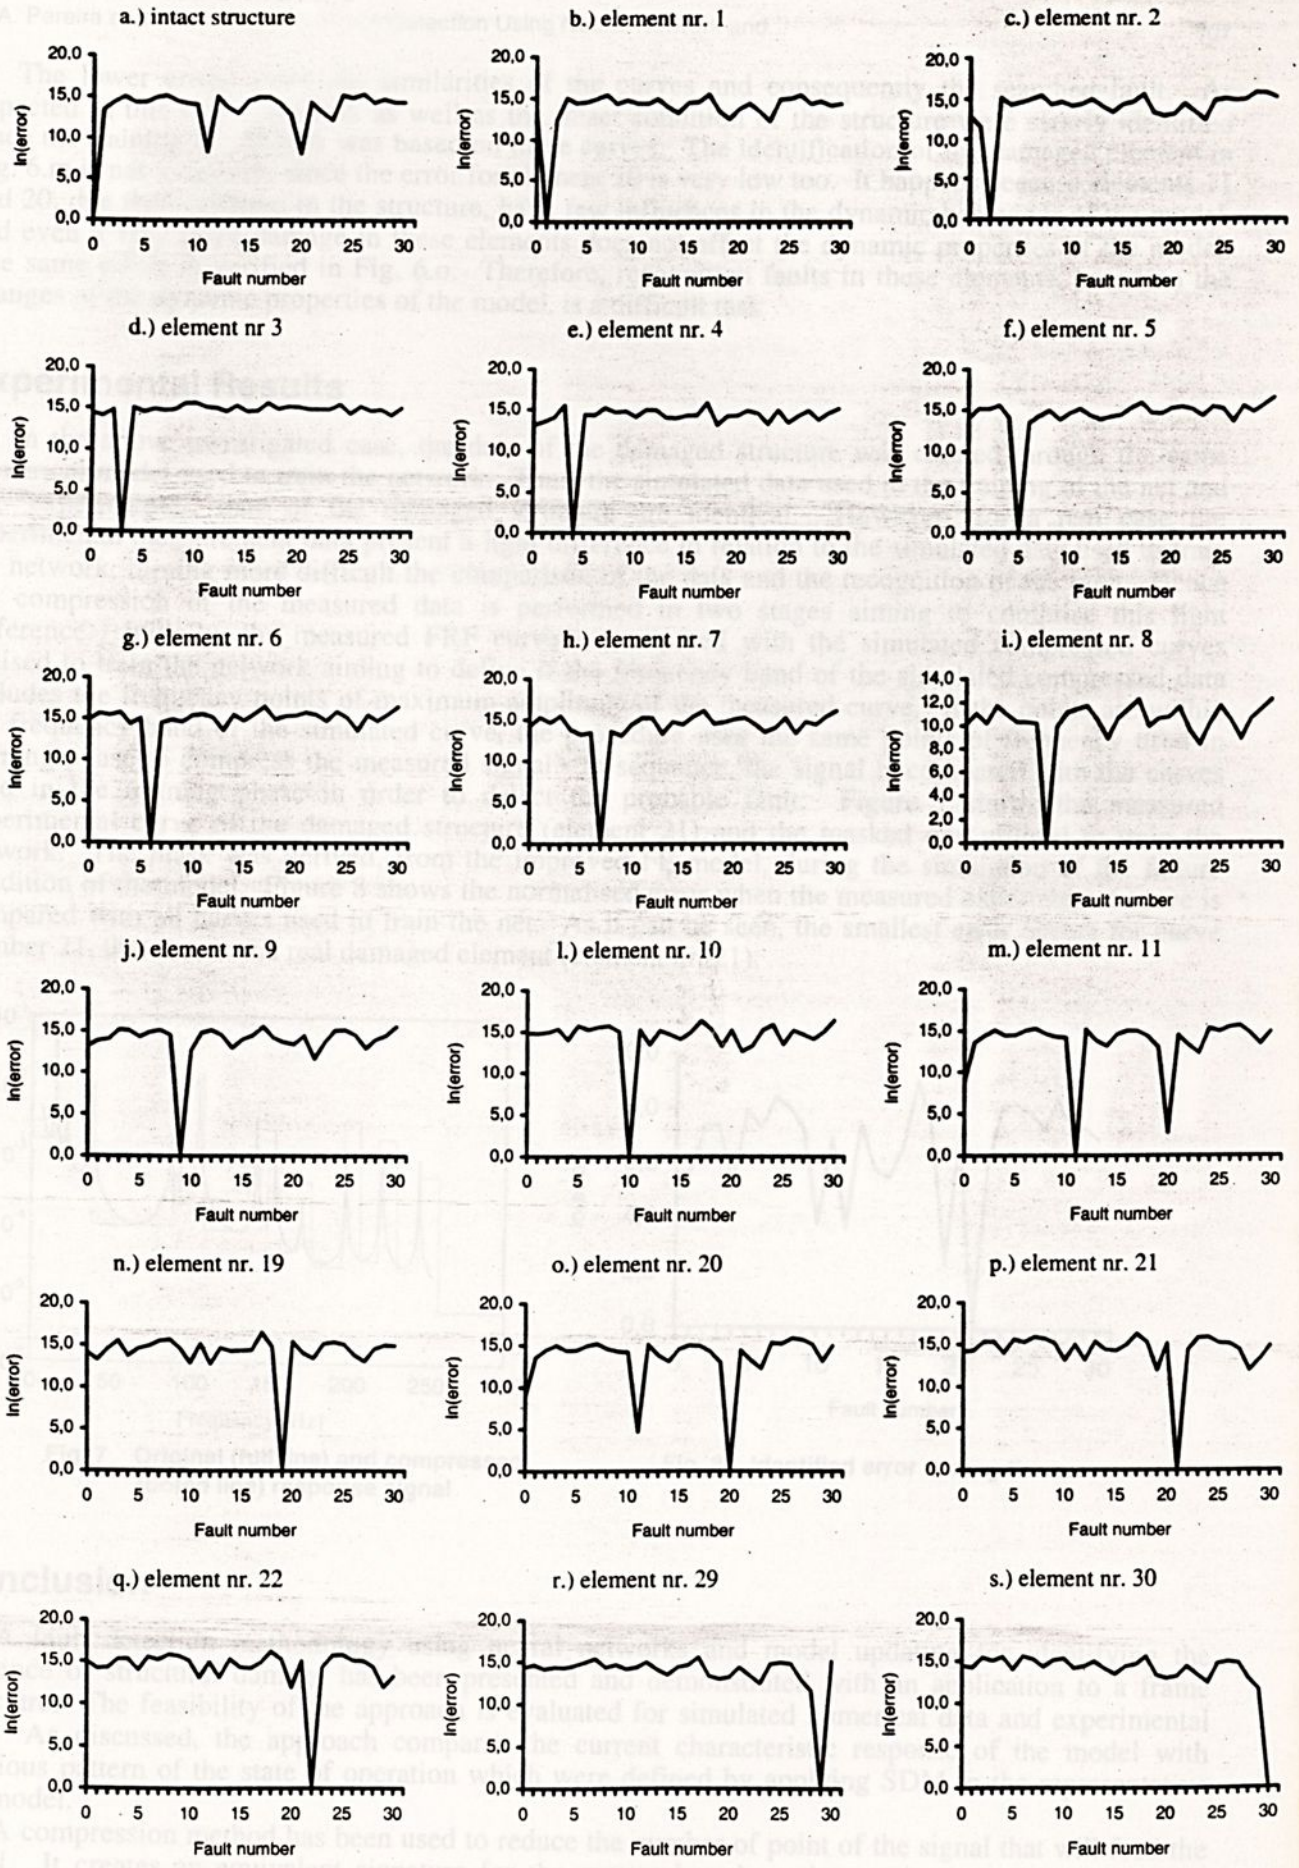


Fig. 6 Identification of the fault in the frame structure

The lower errors show the similarities of the curves and consequently the searched fault. As expected in this case, all faults as well as the intact condition of the structure were clearly identified since the training of network was based on these curves. The identification of the damaged element in Fig. 6.m is not very clear since the error for element 20 is very low too. It happens because elements 11 and 20, due their position in the structure, have few influences in the dynamic behaviour of the model, and even a very large damage in these elements does not affect the dynamic properties of the model. The same effect is verified in Fig. 6.o. Therefore, recognition faults in these elements, based on the changes of the dynamic properties of the model, is a difficult task

Experimental Results

In the above investigated case, the data of the damaged structure was created through the same numerical model used to train the network. Thus, the simulated data used in the training of the net and the "experimental" data of the damaged structure are identical. Howevep, for a real case the experimental measurement data present a light difference in relation to the simulated data used to train the network, turning more difficult the comparison of the data and the recognition of the fault. Hence the compression of the measured data is performed in two stages aiming to comprise this light difference. Initially, the measured FRF curve is compared with the simulated compressed curves utilised to train the network aiming to define if the frequency band of the simulated compressed data includes the frequency points of maximum amplitude of the measured curve. If the points are within the frequency band of the simulated curve, the procedure uses the same points of frequency used in training phase to compress the measured signal. In sequence, the signal is compared with the curves used in the training phase in order to detect the probable fault. Figure 7 shows the measured experimental curve of the damaged structure (element 21) and the masked one utilised to train the network. The mask was derived, from the improved FE-model, during the simulation of the failure condition of the model. Figure 8 shows the normalised error when the measured experimental curve is compared with all curves used to train the net. As it can be seen, the smallest error occurs for curve number 21, that means the real damaged element (element nr. 21).

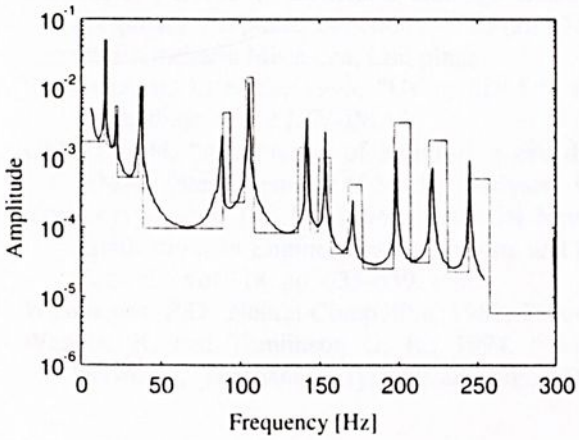


Fig. 7 Original (full line) and compressed (doted line) response signal

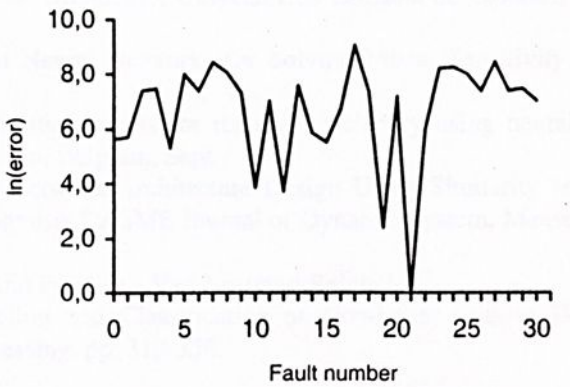


Fig. 8 Identified error among the curves

Conclusion

A fault detection methodology using neural networks and model updating for identifying the presence of structural damage has been presented and demonstrated with an application to a frame structure. The feasibility of the approach is evaluated for simulated numerical data and experimental test. As discussed, the approach compares the current characteristic response of the model with previous pattern of the state of operation which were defined by applying SDM in the representative FE-model.

A compression method has been used to reduce the number of point of the signal that will feed the ANN. It creates an equivalent signature for the system based on the maximum amplitudes of the original spectrum signal. Considering a frequency range of 3% around of the points of maximum amplitudes is satisfactory in this study case. It seems to suppress the effects of small oscillation

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

(variations) in experimental measurements. The architecture of the network has been defined by tests since it does not comply a criterion to define the optimum architecture. However, the results seem to be better when the neurons number in the hidden layer increase. Parallel issues such as fault into elements of low sensitivity and robustness when the measured data comprise small deviation of previous pattern due measurement difficulties have been addressed.

In general for condition monitoring such issues are extremely important since it is essential to recognise a fault in time to permit action to be taken in order to avoid failure of the component. The preliminary results show that the proposed methodology can be applied to classify an unknown signal in patterns fixed beforehand. Although the approach has successfully identified the damaged element for all simulated test cases as well as for the experimental test, its success is not unconditional. In order to explore in depth the potential for application of such propose to monitoring health condition and failure location in real structures, further research addressing more complex case studies must to be done.

References

Bernieri, A. at all; 1994, "A Neural Network Approach for Identification and Fault Diagnosis on Dynamic Systems," IEEE Trans. on Instrumentation and Meas., vol. 43, n° 6 pp. 867-873. Dec.

Hecht-Nielsen R.; 1990, Neurocomputing - Addison-Wesley Publishing Company.

Hush D.R. and Horne, B.G.; 1993, "Progress in Supervised Neural Networks - What's New Since Lippmann," - IEEE Signal Proc. Mag., pp. 8-39 - Jan.

Lammens. S., 1995, "Frequency Response Based Validation of Dynamic Structural Finite Element Models," Ph.D., Thesis, Katholieke Universiteit Leuven, Belgium.

Larsson, P. O. and Sas, P., 1992, "Model Updating Based on Forced Vibration Testing Using Numerically Stable Formulations," Proceedings of the X-IMAC.

Lippmann, R.P.; 1987, "An Introduction to Computing with Neural Nets," IEEE - ASSP Magazine, pp. 4-22, April.

Lopes Jr., V. and Turra, A. E., 1996, "Diagnosis of Rotating Systems Using Artificial Neural Networks", Application of Artificial Intelligence in Engineering XI, includes CD Rom - Computational Mechanics Publications, Sep.

Narenda, K.S. and Parthasarathy, K., 1990, "Identification and Control Dynamical Systems Using Neural Networks," IEEE Trans. on Neural Networks, vol. 1, n° 1 pp. 4-24, March.

Pereira, J. A., 1996, "Structural Damage Detection Methodology using a Model Updating Procedure based on Frequency Response Functions - FRF(s)," Tese de Doutorado, Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Campinas.

Schwaarz, B. J., et all; 1996, "Using SDM to train Neural Networks for Solving Modal Sensitivity Problems",. Proceedings of the XIV-IMAC.

Uhl,T.; 1994, "Automation of monitoring and diagnostic process for rotating machinery using neural networks," ISMA - Intern. Seminar of Modal Analysis - Leuven, Belgium, Sept.

Yuedong, C., and Du, R.; 1996, "Artificial Neural Network Architecture Design Using Similarity Measure with Applications in Engineering Monitoring and Diagnosis," ASME Journal of Dynamic System, Measurement, and Control, , vol 118, pp. 635-639, sept.

Wasserman, P.D., Neural Computing, 1989, Theory and Practice - Van Nostrand Reinhold.

Warden, K. and Tomlinson G. R.; 1994, " Modeling and Classification of Non-linear System Using Neural Networks," Mechanical Systems and Signal Processing, pp. 319-356.



ANAIS



Natal - RN

CONEM 2000

Congresso Nacional de Engenharia Mecânica

- Apresentação
- Patrocinadores
- Comissão Organizadora
- Corpo de Revisores
- Pesquisa
- Temas

ORGANIZAÇÃO:

UFRN - Departamento de Engenharia Mecânica
Programa de Pós-graduação em Engenharia Mecânica

PROMOÇÃO:

25 ABCM

UTILIZAÇÃO DE TÉCNICA DE PROCESSAMENTO DE SINAIS PARA MELHORAR O DESEMPENHO DE REDES NEURAIS ARTIFICIAIS

Edmilson R. O. Santos,
Edison Righeto,
João A. Pereira
Vicente L. Jr ,
Universidade Estadual Paulista-UNESP, Faculdade de Engenharia de Ilha Solteira – FEIS, Departamento de Engenharia Mecânica, 15385-000, Ilha Solteira-SP – Brasil.
Email: oliveira@dem.feis.unesp.br

Resumo

Uma das ferramentas que tem sido bastante investigada para localização e detecção de falhas em sistemas mecânicos são as Redes Neurais Artificiais-RNA. No entanto esta ferramenta depende enormemente do padrão de entrada utilizado durante o processo de treinamento da rede. Se o padrão de entrada não for adequado, as vantagens da aplicação de RNA poderão ser perdidas. A Transformada Wavelet (TW) é uma técnica que possui excelentes características de localização tempo–freqüência e, proporciona maiores informações sobre as características do sinal. Portanto, em algumas aplicações, a utilização da TW na escolha do padrão de entradas do sinal poderá melhorar a eficiência da rede neural. A proposta deste trabalho é introduzir a Transformada Wavelet como um meio alternativo de extrair as características mais representativas dos dados de vibração e, utiliza-las como padrões de entrada no treinamento de Rede Neural Artificial. Neste caso, as informações a respeito das condições de funcionamento do sistema serão obtidas a partir dos coeficientes da TW afim de fornecer uma representação mais compacta dos sinais, quando comparado com sistemas convencionais como análise de Fourier.

Palavras-chave: Transformada Wavelet, Redutor, Redes Neurais Artificiais.

1. INTRODUÇÃO

O monitoramento e diagnose de máquinas e equipamentos é uma área emergente em engenharia. Ela envolve obter dados reais os quais informam as condições de operação da máquina. Em máquinas rotativas tais como redutores, ventiladores, e outras, os sinais de vibração são comumente usados para monitoramento. O controle da variação dos níveis do sinal é uma boa indicação do estado do sistema, porque o perfil de vibração pode mudar devido ao aparecimento de falha no sistema. Muitas técnicas já demonstraram um variado grau de sucesso em identificação de falhas utilizando sinais de vibração. Mas a maior parte destas técnicas não são adequadas para sinais transientes. Uma das mais recentes técnicas de processamento de sinais, Transformada Wavelet , tem-se mostrado mais adequada. A TW de um sinal temporal é uma expansão em termos de uma família de funções geradas a partir de uma única função base "wavelet mãe" por dilatação e translação. O termo dilatação significa expandir ou comprimir a "wavelet mãe" de forma que esta função proporcione uma visão mais detalhada ou não do sinal. Já a translação é uma forma que função Wavelet, alterada pela

dilatação, utiliza para percorrer o sinal por toda sua duração. A aplicação da TW para diagnosticar falhas em máquinas já foi utilizada em diversas situações, como por exemplo nos trabalhos dos seguintes autores: Hazarika *et al.* (1997), Lee e White (1997), Newland (1993), Paya *et al.* (1997) e Petrilli *et al.* (1995). Embora, uma inspeção visual de certas características da análise espectral seja adequada para identificar falhas, um método menos subjetivo e confiável é necessário para a diagnose do sinal de vibração, especialmente quando o avanço da falha é pequeno ou existem múltiplas falhas no sistema (Paya, *et al.* 1997). O problema de detecção de falhas neste caso é essencialmente um reconhecimento de padrão: dados do sistema sem defeito devem ser distinguíveis dos dados de um sistema com falha. Redes neurais artificiais são técnicas computacionais para identificação de padrões através de modelos matemáticos inspirados nos neurônios biológicos dos organismos inteligentes (Wasserman, 1989). As RNAs são bem conhecidas por suas capacidades de identificar e classificar, sendo que nos últimos anos tem atraído a atenção de muitos pesquisadores, principalmente no campo da engenharia elétrica e controle. A proposta deste trabalho é introduzir a Transformada Wavelet como um meio alternativo de extrair características a partir de dados de vibração ocasionados por falhas de um redutor e, assim, servir como um padrão de entrada para o treinamento de uma rede neural artificial. Um padrão de entrada com informações mais específicas, através do emprego da análise Wavelet, poderá melhorar o desempenho do sistema de monitoramento da condição de operação das máquinas. O tipo de rede usada no presente estudo foi a rede neural artificial supervisionada de multi camadas, com o método de treinamento retro propagação. Os dados utilizados na avaliação da metodologia proposta foram dados simulados gerados a partir de um modelo matemático com base em parâmetros reais de um redutor.

2. TRANSFORMADA WAVELET

A transformada Wavelet (TW) é definida de forma semelhante a transformada de Fourier (TF),

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(\omega) e^{i\omega t} d\omega , \tag{1}$$

e

$$F(\omega) = \int_{-\infty}^{+\infty} f(t) e^{-i\omega t} dt. \tag{2}$$

A Eq. (2) é chamada de transformada de Fourier da função *f(t)* e a Eq. (1) é chamada de transformada de Fourier inversa. A TF converte os dados no domínio do tempo para o domínio de freqüência através de senos e cosenos como funções base, e estas apresentam características médias da função *f(t)*. A TW é definida de maneira similar a TF. Entretanto, em lugar de utilizar harmônicos, a TW utiliza uma família de funções geradas a partir de uma única função base chamada de "wavelet mãe", a qual pode ser expandida/comprimida e transladada ao longo do tempo de duração do sinal. Assim, com essa família de funções pode-se ter uma visão mais detalhada ou não de *f(t)*.

A TW converte dados no domínio do tempo para o domínio tempo-escala, onde pode ser visualizado características localizadas do sinal original. A Eq. (3) expressa uma família de funções que pode ser utilizadas para decompor a função temporal, cujo o parâmetro real $a>0$ permite uma expansão ou compressão e o parâmetro b a translação da função base:

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

$$w_{(a,b)} = a^{-1/2} W\left(\frac{t-b}{a}\right), \quad (3)$$

$W(t)$ representa a wavelet mãe. Uma função $f(t)$, $t \in [0, T]$, pode ser decomposta em uma soma de wavelets em um número finito de escalas como:

$$f(t) = w_0 + \sum_{j=0}^{\infty} \sum_{k=0}^{2^j-1} w_{2^j+k} W(2^j t - kT),$$

(4)

e

$$w_0 = \int_0^T f(t)dt,$$

(5)

$$w_{2^j+k} \int_o^T f(t)W(2^j t - kT)dt. \quad (6)$$

O parâmetro j descreve os diferentes níveis das wavelets. O parametro k é responsável pela posição das wavelets em cada nível, por isso ele cobre o intervalo de k=0 à k=2^j-1. O comprimento dos dados a ser transferidos do domínio do tempo deve ser potência de dois (isto é 2^n). Existem muitos tipos de wavelets mas, para o presente estudo será utilizado a Daubechies (db4), (Daubechies, 1992).

3. REDES NEURAIS ARTIFICIAIS

As RNAs são inspiradas em sistemas nervosos biológicos, portanto, elas são compostas de elementos que desempenham, de uma forma análoga, as funções mais elementares dos neurônios biológicos. Modelos de redes neurais tem um maior potencial em áreas tais como reconhecimento de voz e imagem onde muitas hipóteses são colocadas em paralelo, altas velocidades computacionais são requeridas e, os sistemas disponíveis estão longe de igualar o desempenho humano. Modelos de redes neurais exploram muitas hipóteses competindo simultaneamente e utilizando maciçamente redes paralelas compostas de muitos elementos computacionais conectados por ligações com ponderações variáveis. Os elementos computacionais ou nós utilizados em modelos de redes neurais são funções não lineares.

O nó mais simples tem entradas ponderadas e passa as informações para o próximo nível através de uma função de ativação. O desenvolvimento das redes levou a utilização de vários tipos de funções de ativação. As principais são: degrau, rampa, logística, tangente hiperbólica e gaussiana (Wasserman, 1989). Modelos de redes neurais são especificados pela configuração da rede, características nodais e, treinamento ou aprendizado de regras. Estas regras especificam um conjunto inicial de ponderações e indica como a ponderação deve ser adaptada durante o uso para melhorar o seu desempenho. Tanto a escolha da configuração da rede, como as regras de treinamento são tópicos ainda em desenvolvimento.

Os métodos de treinamento de uma rede neural podem ser divididos em duas categorias: aprendizado supervisionado, e aprendizado não supervisionado. O primeiro tipo de aprendizado é o mais comum e empregado nos diversos tipos de redes neurais existentes. O aprendizado supervisionado consiste em apresentar a rede neural uma série de dados de entrada e as respectivas saídas esperadas. Um algoritmo será empregado para ajustar os pesos

das conexões entre os neurônios pelo cálculo do erro, isto é, a diferença entre a saída esperada e aquela efetivamente calculada. Entre os algoritmos para o cálculo destaca-se o algoritmo de retro propagação do erro.

Este primeiro método de treinamento é denominado de supervisionado pois é necessário apresentar a rede as respostas esperadas. Uma desvantagem deste tipo de aprendizado é a necessidade de se dispor de conjunto de dados de treinamento. Dependendo do tamanho da rede serão necessários vários casos de treinamento para que todos os pesos sejam obtidos de maneira ideal. Outro tipo de treinamento é denominado não supervisionado. Neste caso, não é necessário apresentar à rede as respostas esperadas. No treinamento não supervisionado os pesos são ajustados para que as entradas similares produzam saídas similares. O algoritmo de treinamento extrai regularidades estatísticas do conjunto de dados de treinamento.

4. SINAIS DE VIBRAÇÃO SIMULADOS

O principal objetivo deste estudo é demonstrar a aplicabilidade da metodologia proposta para o reconhecimento das condições de operação de um sistema utilizando dados reais. Entretanto, afim de testar a potencialidade e limitações do método, será avaliado inicialmente com sinais simulados para um redutor com um par de redução. Os sinais utilizados são classificados por famílias (cada uma delas com 8 sinais), as quais representam sinais normais e defeituosos. Cada família representa uma condição do redutor, e o que difere um sinal do outro, em cada família, é o efeito causado pela introdução de um ruído branco no sinal. Os sinais propostos estão definidos para um tempo de aquisição de 0.128 s e amostrados com 1024 pontos. Os sinais simulados utilizam dados de um redutor de engrenagens helicoidais de um único par de redução, Tab. 1.

Tabela 1. Características geométricas do redutor

Número de dentes do pinhão	44
Número de dentes da coroa	95
Freqüência do eixo de entrada	30 (Hz)
Freqüência do eixo de saída	14 (Hz)
Freqüência de engrenamento	1320 (Hz)

Cada sinal da família de sinais normais é constituído da freqüência de engrenamento, freqüência de giro (pinhão) e 5% de ruído branco, Fig. 1.

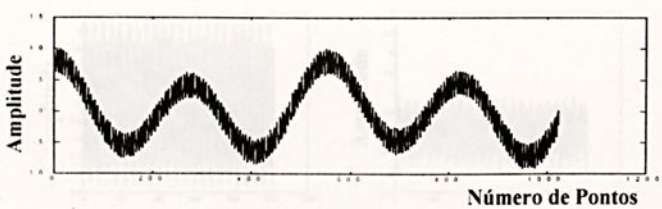


Figura 1. Sinal Normal

Um sinal da família de sinais defeituosos (1) tem as mesmas características de um sinal normal, freqüência de engrenamento, freqüência de giro (pinhão), 5% de ruído branco, e adicionalmente um impulso a cada 256 pontos (ou 0.032 s) representando o efeito de um dente quebrado, Fig. 2.

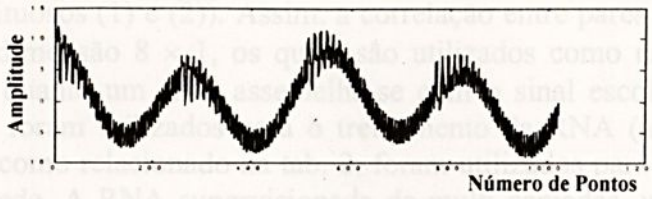


Figura 2. Sinal Defeituoso (1)

Um sinal da família de sinais defeituosos (2) tem as mesmas características de um sinal normal, freqüência de engrenamento, freqüência de giro (pinhão), 5% de ruído branco, e adicionalmente um impulso a cada 64 pontos (ou 0.008 s) representando um defeito de rolamento, Fig. 3.

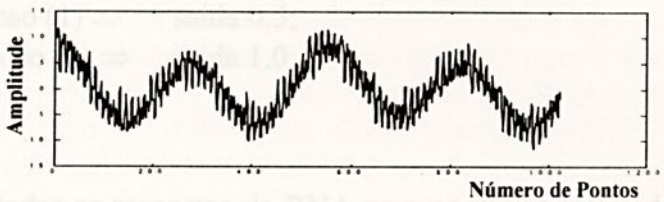


Figura 3. Sinal Defeituoso (2)

5. METODOLOGIA

As famílias de sinais simulados são pré processadas via transformada wavelet discreta (DWT), ou seja, cada sinal de uma família é decomposto em 8 componentes, Fig. 4. Parte dessas componentes são responsáveis pelas baixas freqüências (aproximações) e as outras pelas altas freqüências (detalhes).

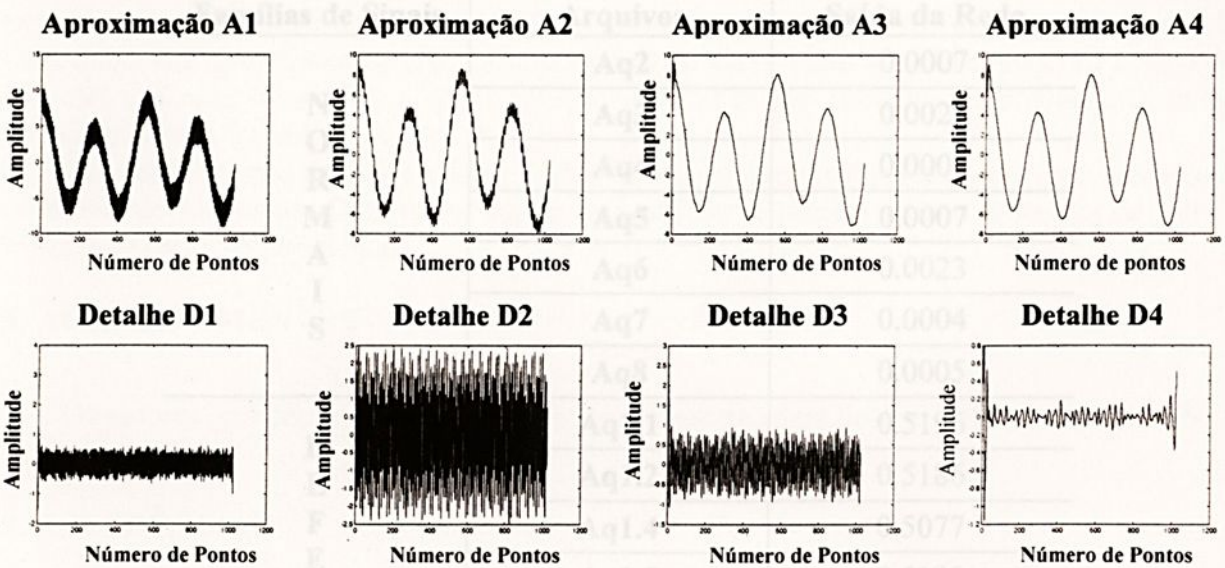


Figura 4. Decomposição de um sinal normal pela DWT

Mediante a seleção do nível e do tipo de wavelet pode-se decompor os sinais com mais ou menos componentes e também com maior ou menor resolução. Um sinal da família de sinais normais decomposto foi escolhido como referência para estabelecer a correlação entre seus componentes e os componentes dos demais, e também em relação aos componentes das

outras famílias (defeituosos (1) e (2)). Assim, a correlação entre pares de sinais decompostos geram vetores com dimensão 8 × 1, os quais são utilizados como entrada da RNA. Esses vetores representam quanto um sinal assemelha-se com o sinal escolhido como referência. Parte desses vetores foram utilizados para o treinamento da RNA (arquivos Aq1, Aq1.3 e Aq2.6) e os demais, como relacionado na tab. 2, foram utilizados para testar a capacidade de reconhecimento da rede. A RNA supervisionada de multi camadas, utilizou o algoritmo de treinamento retro propagação, com função tangente hiperbólica. A camada intermediária foi estabelecida através de tentativas, e assim pela experiência adquirida chegou-se a 10 neurônios com o melhor desempenho para o treinamento da RNA. Afim de simplificar os resultados de classificação ou distinção entre tipos diferentes de falhas, as saídas designadas para cada situação são as seguintes:

1. sinal normal ⇒ saída 0;
2. sinal defeituoso (1) ⇒ saída 0.5;
3. sinal defeituoso (2) ⇒ saída 1.0 .

6. RESULTADOS

Na tab. 2 estão todas as respostas da RNA para os vários testes de reconhecimento dos vetores não utilizados durante o treinamento. Para o primeiro bloco referente aos sinais normais, pode-se observar que as respostas da RNA foram as esperadas (aproximadamente zero). As respostas da RNA para o segundo e terceiro bloco, também foram muito satisfatórias, ou seja, os arquivos que apresentam as piores resposta ainda mostram uma identificação próxima do esperado, ou seja, apenas uma diferença de 2% e 3% respectivamente.

Tabela 2. Arquivos utilizados para testar a RNA

Famílias de Sinais	Arquivos	Saída da Rede
NORMAIS	Aq2	0.0007
	Aq3	0.0023
	Aq4	0.0004
	Aq5	0.0007
	Aq6	0.0023
	Aq7	0.0004
	Aq8	0.0005
DEFEITO (1)	Aq1.1	0.5196
	Aq1.2	0.5186
	Aq1.4	0.5077
	Aq1.5	0.5196
	Aq1.6	0.5186
	Aq1.7	0.5077
	Aq1.8	0.5146

DEFEITO (2)	**Aq2.1**	0.9735
	Aq2.2	0.9783
	Aq2.3	0.9794
	Aq2.4	0.9730
	Aq2.5	0.9684
	Aq2.7	0.9786
	Aq2.8	0.9789

Os resultados apresentados mostram que a TW é uma ferramenta de pré processamento de sinais de vibração muito eficiente, e que estes dados podem ser utilizados como entradas para uma RNA com objetivo de melhorar o desempenho desta na identificação dos tipos de falhas. Embora, não foi feito uma comparação direta com outros tipos de ferramentas, um trabalho desenvolvido por Petrilli *et al.* (1995), mostrou que RNAs que utilizavam sinais pré processados pela TW para o seu treinamento obteve uma convergência muito mais rápida do que os mesmos sinais pré processados pela FFT. Isto ocorre porque a capacidade da DWT em analisar transientes e guardar informações importantes do sinal permiti associar as falhas com os respectivos componentes, assim a RNA pode ter informações mais precisas e consequentemente um melhor diagnóstico.

7. CONCLUSÃO

Os resultados apresentados e discutidos neste trabalho mostram que o desempenho da DTW como um pré processador dos sinais de vibração foi satisfatório e também demonstra que ela pode ser utilizada como ferramenta para detectar ocorrências de variações bruscas.

A análise via DWT requer uma familiaridade do usuário com a técnica, pois para processamento do sinal deve-se determinar primeiro qual tipo de wavelet é mais adequada para que a extração das característica importantes do sinal sejam a melhor possível. O tipo de wavelet utilizada foi a db4, a qual também mostrou-se ser eficiente no processamento de sinais em outros trabalhos.

Uma combinação da DWT e RNA é uma técnica eficaz e adequada para o monitoramento contínuo de máquinas. O próximo passo será utilizar a técnica para a detecção de falhas utilizando dados experimentais.

8. AGRADECIMENTOS

Os autores agradecem à CAPES pelo apoio financeiro para desenvolvimento do trabalho.

9. REFERÊNCIAS

- Daubechies, I., 1992, "Ten Lectures on Wavelets", CBMS – NSF Regional Conference Series In Applied Mathematics SIAM, Philadelphia.
- Hazarika, N, Chen, J. Z., Tsoi, A. C. and Sergejew, A., 1997, " Classification Of EEG Signals Using The Wavelet Transform", Elsevier, Signal Processing, Vol. 59, pp. 61-72.

- Lee, S-K., White, P. R., 1997, " Fault Identification for Rotating Machinery Using Adaptive Signal Processing and Time-Frequency Analysis", Proceedings of DETC'97, Sacramento, California.
- Newland, D., 1993, "Wavelet Analysis of Vibration", The 16th Annual Energy Sources Technology Conference and Exhibition, Structural Dynamics and Vibration, Houston, Texas, USA, 31 january – 4 february.
- Paya, B. A., Esat, I. and Badi, M. N. M., 1997, "Artificial Neural Network Based Fault Diagnostics of Rotating Machinery Using Wavelet Transforms as a Preprocessor"; Mechanical System and Signal Processing, Vol. 11, Nº: 5, pp: 751-765.
- Petrilli, O., Paya, B., Esat, I. I. and Badi, M. N. M., 1995, " Neural NetWork Based Fault Detection Using Different Signal Processing Techniques As Pre-Processor", Structural Dynamics and Vibration, ASME, Vol. 70.
- Staszewski, W. J., Worden, K., 1993, "Classification of Faults in Spur Gears", The World Congress on Neural Networks, Portland Oregon, 11 – 15.
- Wasserman, Philip D., 1989, " Neural Computing Theory And Practice".

ANAIS



Natal - RN

CONEM 2000

Congresso Nacional de Engenharia Mecânica

- Apresentação
- Patrocinadores
- Comissão Organizadora
- Corpo de Revisores
- Pesquisa
- Temas

ORGANIZAÇÃO:

UFRN - Departamento de Engenharia Mecânica
Programa de Pós-graduação em Engenharia Mecânica

PROMOÇÃO:

ABCM

unesp

IDENTIFICAÇÃO DOS PARÂMETROS MODAIS DE PLACA

Silmara Cassola
João Antonio Pereira
Amarildo Tabone Paschoalini
UNESP- Faculdade de Engenharia de Ilha Solteira- Departamento de Engenharia Mecânica
Av. Brasil, 56 - 15.385.000 - Ilha Solteira, SP, Brasil, silmara@dem.feis.unesp.br

Resumo

O estudo do comportamento dinâmico de estruturas de laje de concreto é tratado neste trabalho. Estruturas bastante leves e esbeltas estão cada vez mais presentes na construção civil, e são muito susceptíveis aos efeitos de vibrações causadas pelos próprios usuários. Neste caso, o isolamento é bastante complexo, e os níveis de vibrações devem ser controlados pelas próprias características da estrutura, o que torna o conhecimento das suas propriedades dinâmicas uma condição fundamental para o desenvolvimento de projetos que ofereçam não apenas segurança, mas também conforto aos usuários. Este trabalho descreve a proposta de aplicação de uma técnica de ajuste de modelo para o caso de placas.

Palavras-chave: Técnica de ajuste de modelo, Elementos finitos, Placas

1. INTRODUÇÃO

O uso de técnicas de pós-tensionamento, de concretos de alta resistência e de técnicas elaboradas de análise estrutural, tem permitido a construção de lajes bastante esbeltas, e ainda atendendo às condições de resistência impostas pelas Normas Técnicas. No entanto, o uso de pisos mais esbeltos leva a uma preocupação imediata com os efeitos de vibrações, pois estas estruturas apresentam pouco amortecimento e freqüências naturais baixas, e podem ser facilmente excitadas pelos próprios usuários. O isolamento é bastante complexo, uma vez que as pessoas são a fonte e os sensores da vibração. Neste caso, os níveis de vibrações devem ser controlados pelas próprias características da estrutura o que torna imprescindível o conhecimento dos seus parâmetros dinâmicos (freqüências naturais, modos próprios, fator de amortecimento), visto que os efeitos de vibrações em construções tem um efeito psicológico muito acentuado nas pessoas. Quando exposto a vibrações, o ser humano apresenta reações subjetivas que vão desde a simples percepção e desconforto, até apreensão e dor (CEB nº209, 1991). De acordo com Stephenson et al. (1998), há um grande interesse no mundo inteiro no conhecimento da resposta de pisos ao impacto causado pelo uso cotidiano das pessoas, tal como um simples caminhar. Este assunto é particularmente relevante quando se consideram estruturas esbeltas, e as investigações buscam um maior entendimento do comportamento deste tipo de estrutura, e de que maneira suas

características de vibração podem ser relacionadas com o conforto humano, de forma a se evitar as freqüências que podem causar desconforto, ainda que não seja necessariamente o tempo todo.

A elaboração de modelos analíticos de estruturas de pisos de lajes de concreto visa conhecer o seu comportamento dinâmico por meio da simulação de diferentes condições de operação e carregamento, sem que se tenha de construir um modelo real para cada condição, o qual é bastante oneroso e complexo. No entanto, a modelagem dinâmica de estruturas de engenharia civil por elementos finitos ainda requer cuidados especiais e várias hipóteses e simplificações, usualmente adotadas neste tipo de análise, podem levar a resultados muito discrepantes em relação às situações reais. Isto é, o modelo analítico pode não representar adequadamente a estrutura real. Portanto, existe a necessidade de se desenvolver modelos mais elaborados, e eventualmente validar o modelo de elementos finitos da estrutura a fim de se obter uma solução mais realística, principalmente quando se deseja definir um modelo de predição confiável e representativo (Cassola e Pereira, 1999). As técnicas de ajuste de modelo têm produzido resultados bastante satisfatórios nesta área.

O processo de ajuste de modelos busca corrigir as imperfeições do modelo analítico, obtido geralmente por elementos finitos, minimizando a diferença dos dados calculados com relação aos dados medidos no modelo real. O principal objetivo é definir um modelo analítico representativo e confiável do modelo experimental.

Este artigo descreve a implementação de um programa de ajuste de modelo utilizando Funções de Resposta em Freqüência – FRF(s) - para a modelagem de estruturas do tipo placa. A modelagem por elementos finitos e análise modal experimental é usada neste caso para a definição de um modelo de predição representativo do modelo real para o caso de placas. Técnicas de correlação e comparação de modelos são utilizadas para identificar a discrepância entre os modelos e posteriormente, corrigir o modelo de elementos finitos com base nos dados experimentais.

A proposta é testada com dados simulados numericamente. A fim de definir uma condição mais próxima da condição real de teste, estes dados foram contaminados com ruído gaussiano, distribuição normal com média zero e variância unitária.

2. TÉCNICA DE AJUSTE DE MODELO

As técnicas de ajuste de modelo têm sido usadas para a obtenção de um modelo analítico o mais próximo possível do modelo experimental. Vários autores vêm trabalhando nesta área ao longo das últimas décadas. Wang et al (1997), Cantieni et al (1998), Reynolds et al (1998 a), Reynolds et al (1998 b), Papadimitriou et al (1998), Pavic et al (1999), são alguns dos estudos realizados abordando técnicas de ajuste de modelo nos problemas de vibração em engenharia civil.

A metodologia proposta envolve basicamente três etapas. Na primeira etapa, com base no sistema físico, como por exemplo a estrutura de uma laje, são derivados o modelo experimental, por meio da análise modal experimental (AME), e o modelo analítico, pelo método dos elementos finitos (MEF). Baseado nestes modelos são obtidos os parâmetros modais (freqüências naturais, amortecimento modal e modos próprios) experimentais e os parâmetros modais analíticos, respectivamente, por meio do programa de ajuste de modelo **PRO**gram **M**odel **U**pdating - **PROMU**. Numa segunda etapa, estes parâmetros são comparados com critérios, por meio de técnicas de correlação de parâmetros, pode-se verificar se os modelos são correlacionados ou não. Se os modelos são correlacionados, tem-se um modelo analítico representativo do sistema físico, e todo estudo efetuado por meio deste modelo apresentará

cm 1 2 3 4 5 6 7 unesp 1 12 13 14 15 16 17 18

resultados compatíveis com a realidade. Por outro lado, se os modelos não são correlacionados, a utilização do modelo analítico para estudar o comportamento do sistema pode levar a resultados não realísticos. Neste caso, e como terceira etapa, o uso de técnicas de ajuste de modelo pode levar a uma melhor representação do modelo analítico, e consequentemente a resultados mais realísticos com relação ao comportamento do sistema. Para tal, assume-se que o modelo experimental é o correto e procede-se à correção dos parâmetros do modelo analítico com base nos dados experimentais. Dependendo da estratégia matemática utilizada na formulação do problema e do tipo de parâmetros utilizados no ajuste, os métodos são classificados em diferentes categorias (Morttershead and Friswell, 1993, Lin and Ewins, 1994, Natke et al, 1997, Friswell et al, 1998). Neste trabalho o problema de ajuste será formulado com base nas Funções de Resposta em Freqüência - FRF(s) medidas (Larsson e Sas, 1992, Pereira, 1996), e as variáveis de ajuste podem ser selecionadas dentre os parâmetros físicos e/ou geométricos do modelo.

A discrepância entre os modelos é avaliada com base em um balanço de força e a diferença entre os dados analíticos e experimentais é descrita como uma função resíduo. O resíduo obtido neste caso é definido em função dos parâmetros do modelo analítico (matriz de rigidez dinâmica $\left[Z^A(\{p\})\right]$) e dos dados experimentais (FRF(s)), conforme mostra esquematicamente a Expressão (1). Para uma perfeita correlação entre os modelos os valores de $\{\Delta p\}$ são nulos, no entanto, em situações práticas isto não ocorre visto que os dados experimentais não estão perfeitamente correlacionados com os dados analíticos. A solução do problema é estimada neste caso por meio do cálculo da correção dos p-parâmetros do modelo que minimize a discrepância entre os modelos.

$$\{\varepsilon\} = \varepsilon\left(\left[Z^A(p_1 + \Delta p_1, p_2 + \Delta p_2, ..., p_m + \Delta p_m)\right], \left\{H^x(\omega_i)\right\}\right) \cong \{0\} \tag{1}$$

A equação do balanço de força é definida pela diferença da força atuando no modelo experimental e a correspondente força necessária para produzir uma resposta do modelo analítico igual à resposta experimental. A Equação 2 mostra de forma simplificada, após a linearização com relação aos parâmetros de ajuste, o resíduo com relação aos parâmetros medidos e aos parâmetros calculados por elementos finitos (Larsson and Sas, 1992 e Pereira et al., 1994).

$$\{\varepsilon(\omega_k)\} = \left[Z_k(\{p_0\})\right]\left\{H_k\right\}_j + \sum_{i=1}^{n_p} \frac{\partial\left[Z_k(\{p\})\right]}{\partial p_i}\Delta p_i \left\{H_k\right\}_j - \{1\}_j \tag{2}$$

Um conjunto de equações de ajuste é definido com base na seleção de n-pontos de freqüência (ω_i) e a solução do problema consiste em encontrar ***m*** mudanças nos parâmetros analíticos que minimizam a diferença entre os modelos. Os p-parâmetros podem representar qualquer propriedade física ou geométrica do modelo, eles podem ser um parâmetro de um elemento, no caso dos elementos ajustados independentemente, ou um parâmetro de um grupo de elementos, quando alguns elementos são ajustados proporcionalmente.

Em geral, os critérios adotados para comparar os modelos levam a um conjunto de equações não lineares em relação aos parâmetros de ajuste selecionados $\{p\}$. Dependendo do tipo de parâmetros selecionados, a solução das equações torna-se muito complexa ou pode não existir. A linearização destas equações, para a maioria dos sistemas físicos, é uma suposição válida nas faixas de freqüências de interesse para análises de vibração. Uma solução aproximada do



problema é obtida por meio da linearização da Expressão (2) nos p-parâmetros, conduzindo a um sistema de equações lineares, como mostra a Expressão (3):

$$\{\varepsilon\} = [S]\{\Delta p\} - \{B\} \tag{3}$$

na qual os elementos da matriz sensibilidade $[S]$ e do vetor diferença $\{B\}$ são conhecidos. Eles são obtidos com base na matriz de rigidez dinâmica do modelo analítico e nas funções de resposta em freqüência medidas na estrutura para n-pontos de freqüência selecionados, ou seja, os $\omega_{i's}$. Os elementos do vetor $\{\Delta p\}$ são incógnitas a serem estimadas. A solução do sistema de equações linearizadas fornece um modelo analítico corrigido. Se a discrepância entre os modelos não for ainda suficientemente pequena, o processo é iterativamente repetido.

A seguir é discutida a aplicação da proposta para um exemplo simulado.

3. APLICAÇÃO DA PROPOSTA PARA A ESTRUTURA DE PLACA

O modelo analítico da plcaca foi gerado por programa computacional de elementos finitos para análise dinâmica implementado pelos autores. O programa considera elementos isoparamétricos, quadrilaterais, quadráticos da família Lagrangeana (9 nós) com integração numérica consistente, isto é, 3x3 (m=9) pontos de integração na superfície média, pois de acordo com Paschoalini (1995) o elemento da família Lagrangeana apresenta melhor desempenho do que o elemento da família Serendipity na análise dinâmica.

As dimensões laterais da placa estudada são 5.00 m x 3.50 m, e coincidem com as direções *x* e *y* respectivamente. O modelo é definido para uma malha 5x5 (25 elementos), 121 nós (5 gl(s) por nó), sendo 40 nós totalmente restringidos, ou seja, todos os lados estão engastados, e portanto a estrutura possui 405 graus de liberdade. Os dados de entrada são as dimensões da placa, suas propriedades geométricas (espessura) e as propriedades do material (módulo de elasticidade, coeficiente de poisson e densidade), condições de contorno e incidências nodais.

O modelo experimental, neste caso, é um modelo simulado e foi definido com base neste modelo inicial de elementos finitos introduzindo pequenas variações na espessura dos elementos, ou seja, a espessura varia entre 0.018 e 0.022 m, o que representa pequena irregularidade no piso. A Figura 1 mostra as dimensões da placa e a malha de elementos finitos.

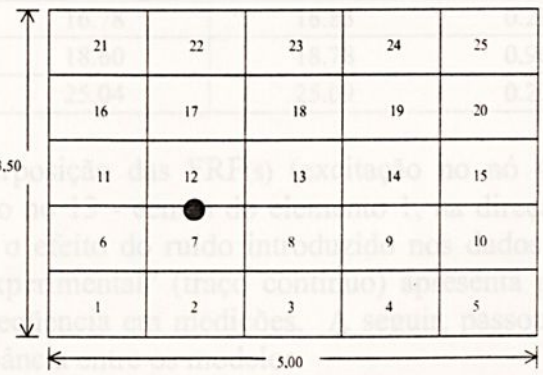


Figura 1: Elementos da Placa

Os dados "experimentais" são obtidos assumindo que apenas um número reduzido de graus de liberdade e modos próprios são disponíveis no modelo experimental. Foram utilizadas apenas as FRF(s) relacionadas com os deslocamentos na direção *z*, isto representa considerar apenas

20% dos graus de liberdade do modelo analítico da estrutura. As FRF(s) são definidas numa faixa de freqüência de 5 Hz a 26 Hz, para uma excitação aplicada na direção *z* (perpendicular à superfície da placa) como indicado. As FRF(s) foram contaminadas por ruído gaussiano a fim de definir uma condição mais próxima da condição real de teste.

O modelo analítico a ser comparado com o modelo "experimental" é definido considerando que todos os elementos possuem a mesma espessura, 0.020 m. E ainda, é introduzida uma variação significativa em uma propriedade da estrutura, que consiste no aumento em 45% da espessura do elemento 23. Isto acarreta um aumento nas freqüências naturais do modelo analítico em relação ao modelo "experimental", e diferenças nos modos próprios.

A fase de correlação dos dados pressupõe uma base de comparação compatível para os modelos, na qual os ngl(s) analíticos e "experimentais" devem ser geometricamente e numericamente correspondentes. Como os modelos são derivados do mesmo modelo inicial de elementos finitos, a compatibilidade geométrica (topologia) dos modelos é perfeita, e a diferença entre o número de graus de liberdade entre os modelos é corrigida por meio da redução do modelo analítico (método da redução dinâmica). Uma vez definida a compatibilidade dos modelos, as respostas e parâmetros modais são comparados visando definir a correlação dos mesmos.

A Tabela 1 e a Figura 2 mostram a discrepância entre os modelos. O primeiro e o terceiro modos apresentam as maiores diferenças de freqüência. O primeiro modo apresenta uma grande diferença de freqüência, 5.422%, mas o MAC-valor está acima de 98%, o que significa que o primeiro modo de vibrar os modelos não foram afetados significativamente. O contrário pode ser observado no quarto modo, o qual apresenta pequena diferença de freqüência e o menor valor de MAC, 94.3%. Outras técnicas de comparação e correlação foram utilizadas, mostrando a discrepância entre os modelos, no entanto, em virtude das limitações de espaço, os resultados não são apresentados.

Tabela 1 - Comparação das FRF(s) dos modelos "experimental" e analítico

Modo Exp.	Modo Ana.	Fx (Hz)	Fa (Hz)	Df (%)	MAC (%)
1	1	6.24	6.57	5.422	99.9
2	2	10.02	10.10	0.797	99.7
3	3	15.18	15.59	2.717	95.5
4	4	16.78	16.83	0.296	94.3
5	5	18.60	18.78	0.967	98.9
6	6	25.04	25.09	0.221	98.1

A Figura 2 mostra a superposição das FRF(s) (excitação no nó 48 na direção *z*, como indicado na Fig. 1, e resposta no nó 13 - centro do elemento 1, na direção *z*) antes e depois do ajuste. A Figura mostra ainda o efeito do ruído introduzido nos dados experimentais. Como pode ser observado, a FRF "experimental" (traço contínuo) apresenta pequenas oscilações de amplitude, o que ocorre com freqüência em medições. A seguir, passou-se para o processo de ajuste, visando corrigir a discrepância entre os modelos.

Para o processo de ajuste, foi escolhido o parâmetro espessura, para todos os elementos, pois este é um parâmetro bastante susceptível a erros de modelagem. As freqüências de ajuste foram selecionadas graficamente, em regiões da curva de receptância medida próxima das freqüências naturais, e abaixo dos valores desta (Fig. 2), o que evita variações bruscas de diferença entre as



receptâncias durante as iterações, que levariam a problemas numéricos durante o processo de ajuste.

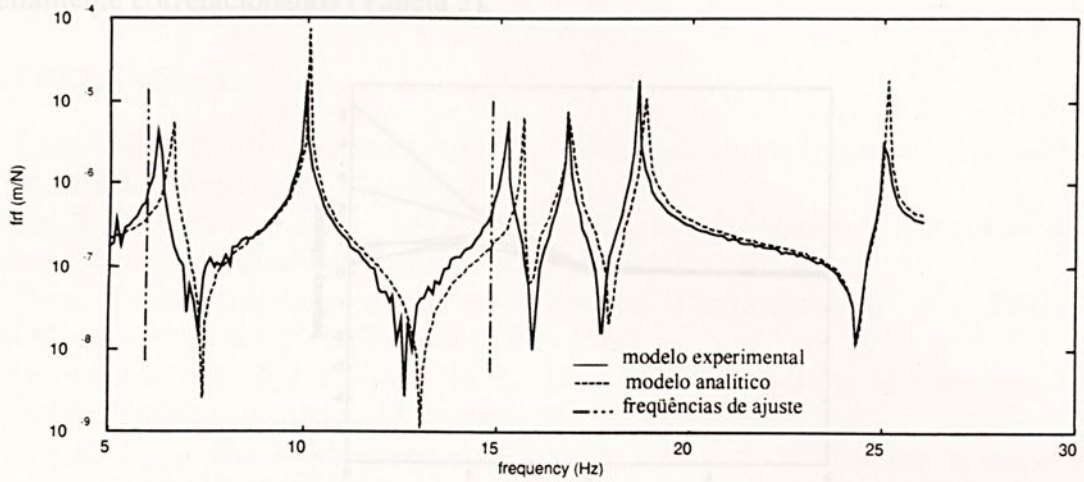
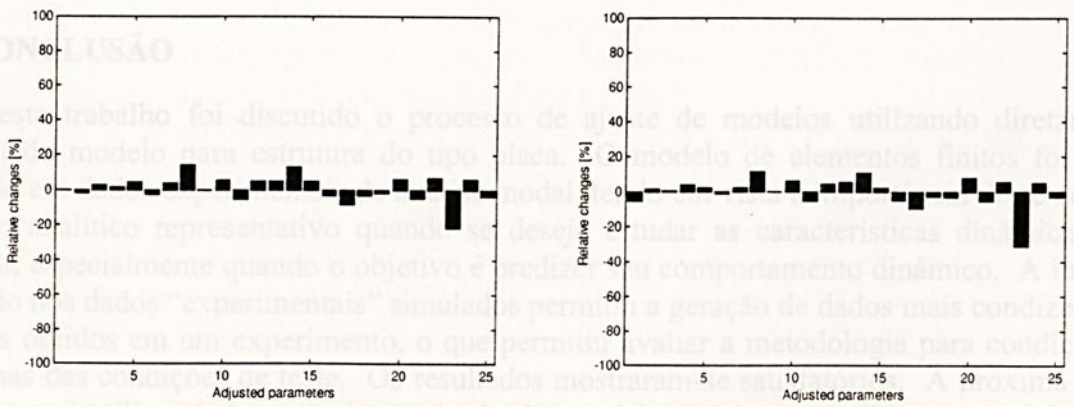


Figura 2: Superposição das FRF(s) medidas no centro do elemento 1

A Tabela 2 mostra os resultados da correlação entre o modelo analítico ajustado e o modelo "experimental", e a Figura 3 mostra o gráfico da variação dos parâmetros corrigidos. Os valores das espessuras do modelo analítico, inicialmente igual a 0.020 sofrem aumento ou redução de 5% a 10%, ou seja, dentro da faixa de 0.018 a 0.022. O parâmetro com a perturbação significativa é claramente localizado e corretamente estimado após algumas iterações.

Tabela 2 - Comparação das FRF(s) dos modelos "experimental" e analítico ajustado

Modo Exp.	Modo Ana.	Fx (Hz)	Fa (Hz)	Df (%)	MAC (%)
1	1	6.24	6.24	-0.002	100.0
2	2	10.02	10.03	0.155	100.0
3	3	15.18	15.18	0.005	99.8
4	4	16.78	16.79	0.071	100.0
5	5	18.60	18.60	0.003	99.8
6	6	25.04	25.05	0.048	99.8



(a) primeira iteração (b) quarta iteração

Figura 3: Evolução da variação dos parâmetros

Com 4 iterações, a diferença de freqüência entre os modelos "experimental" e analítico é praticamente nula, como mostram a Figura 4 e a Figura 5, e os modos apresentam-se perfeitamente correlacionados (Tabela 2).

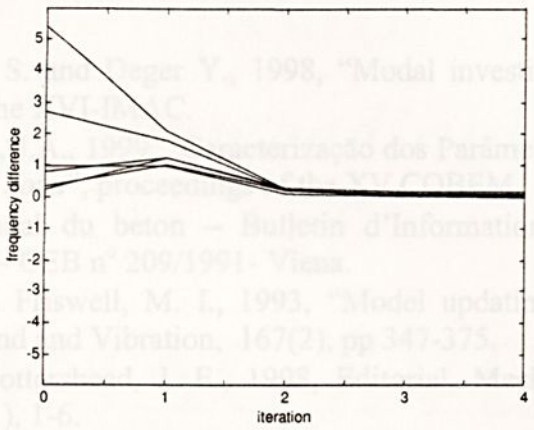


Figura 4: Diferença das freqüências naturais dos modelos experimental e analítico

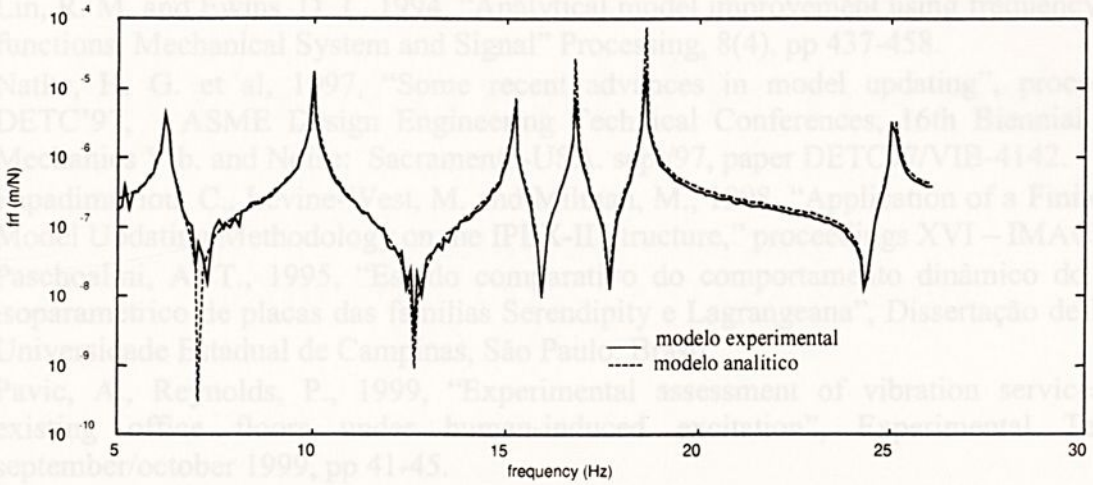


Figura 5: Superposição das FRF(s) medidas no centro do elemento 1

4. CONCLUSÃO

Neste trabalho foi discutido o processo de ajuste de modelos utilizando diretamente as FRF(s) do modelo para estrutura do tipo placa. O modelo de elementos finitos foi ajustado baseado em dados experimentais de análise modal, tendo em vista a importância de se definir um modelo analítico representativo quando se deseja estudar as características dinâmicas de um sistema, especialmente quando o objetivo é predizer seu comportamento dinâmico. A introdução de ruído nos dados "experimentais" simulados permitiu a geração de dados mais condizentes com aqueles obtidos em um experimento, o que permitiu avaliar a metodologia para condições mais próximas das condições de teste. Os resultados mostraram-se satisfatórios. A próxima etapa do trabalho será utilizar dados experimentais obtidos em laboratório para validar a metodologia.

Agradecimentos

Os autores agradecem à Fundação de Apoio à Pesquisa do Estado de São Paulo – FAPESP pelo apoio financeiro para o desenvolvimento deste trabalho.

5. REFERÊNCIAS

- Cantieni, R., Pietrzko, S. and Deger Y., 1998, "Modal investigation of an office building floor", proceedings of the XVI-IMAC.
- Cassola, S., and Pereira, J.A., 1999, "Caracterização dos Parâmetros Dinâmicos de Estruturas Metálicas do Tipo *Steel Joist*", proceedings of the XV COBEM.
- Comite Euro-International du beton – Bulletin d'Information nº 209 ,1991–"Vibracion problems in structures" - CEB nº 209/1991- Viena.
- Mottershead, J. E. and Friswell, M. I., 1993, "Model updating in structural dynamics: a survey", Journal of Sound and Vibration, 167(2), pp 347-375.
- Friswell, M. J. and Mottershead, J. E., 1998, Editorial, Mechanical Systems and Signal Processing, MSSP, 12(1), 1-6.
- Larsson, P. O. and Sas, P., 1992, "Model updating based on forced vibration testing using numerically stable formulations", proceedings of the X-IMAC.
- Lin, R. M. and Ewins, D. J., 1994, "Analytical model improvement using frequency response functions, Mechanical System and Signal" Processing, 8(4), pp 437-458.
- Natke, H. G. et al, 1997, "Some recent advances in model updating", proceedings of DETC'97, ASME Design Engineering Technical Conferences, 16th Biennial Conf. on Mechanics Vib. and Noise: Sacramento-USA. sept/97, paper DETC97/VIB-4142.
- Papadimitriou, C., Levine-West, M. and Milman, M., 1998, "Application of a Finite Element Model Updating Methodology on the IPEX-II Structure," proceedings XVI – IMAC.
- Paschoalini, A. T., 1995, "Estudo comparativo do comportamento dinâmico do elemento isoparamétrico de placas das famílias Serendipity e Lagrangeana", Dissertação de Mestrado, Universidade Estadual de Campinas, São Paulo, Brasil.
- Pavic, A., Reynolds, P., 1999, "Experimental assessment of vibration serviceability of existing office floors under human-induced excitation", Experimental Techniques, september/october 1999, pp 41-45.
- Pereira, J. A., et al., 1994, "Model updating and failure detection based on experimental FRF's: case study on a space frame structure", proceedings of the 19th ISMA, pp 669-681.
- Pereira, J. A.,1996, "Structural damage detection methodology using a model updating procedure based on frequency response functions - FRF(s)", Tese de Doutorado, Universidade Estadual de Campinas, São Paulo, Brasil.
- Reynolds P. et al., 1998(a), "Modal testing, FE analysis and FE model correlation of a 600 tonne post-tensioned concrete floor". XXIII-International Seminar on Modal Analysis.
- Reynolds, P., Pavic, A. and Waldron, P., 1998(b), "Modal testing of a 150-tonne concrete slab incorporating a false floor system", proceedings of the XVI-IMAC.
- Stephenson, A. C. and Humphreys, 1998, "Quantification of Steel Floor Vibration and its Relationship to Human Comfort", Journal of Constructional Steel Research, **46**: pp 1-3, paper nº 256.
- Wang, M. L., Heo, G. and Satpathi, D., 1997, "Dynamic Characterization of a Long Span Bridge: a Finite Element Based Approach", proceedings Soil Dynamics and Earthquake Engineering, **16**: pp 503-512

P13

IMAC XVIII

Proceedings of

IMAC-XVIII: A Conference on Structural Dynamics

FEBRUARY 7-10, 2000
THE WESTIN LA CANTERA RESORT
SAN ANTONIO, TEXAS

TECHNICAL PROGRAM CHAIR:
Alfred L. Wicks, Virginia Polytechnic Institute and State University
Dominick J. DeMichele, Honorary Technical Chair

SOCIETY FOR EXPERIMENTAL MECHANICS, INC.:
Patricia Deuschle, Acting Executive Director
Katherine M. Ramsay, Conference Manager

Organized By:

SOCIETY FOR EXPERIMENTAL MECHANICS, INC.
Bethel, Connecticut 06801

unesp

Non-Destructive Evaluation Tool for Monitoring and Detection of Structural Damage by Using Neural Network.

D. Demarchi, J. A. Pereira e V. Lopes, Jr.,

Department of Mechanical Engineering – UNESP
15385-000 Ilha Solteira SP, Brazil
e-mail: japereir@dem.feis.unesp.br

ABSTRACT

This work studies the capability of generalization of Neural Network using vibration based measurement data aiming at operating condition and health monitoring of mechanical systems. The procedure uses the backpropagation algorithm to classify the input patters of a system with different stiffness ratios. It has been investigated a large set of input data, containing various stiffness ratios as well as a reduced set containing only the extreme ones in order to study generalizing capability of the network. This allows to definition of Neural Networks capable to use a reduced set of data during the training phase. Once it is successfully trained, it could identify intermediate failure condition. Several conditions and intensities of damages have been studied by using numerical data. The Neural Network demonstrated a good capacity of generalization for all case. Finally, the proposal was tested with experimental data.

1. INTRODUCTION

The use of Neural Network as Non-destructive Evaluation tool for damage detection based on vibration measurement is gaining more importance in the context of operation condition and health monitoring of mechanical systems. An efficient vibration based methodology must be able to recognize the pattern behavior of a damaged structure compared with the behavior of an undamaged one. It still desired that it tracks the evolution of the damage and furthermore, locates and quantifies the extent of it. The fulfillment of these requirements, in general, requires an increasing knowledge of the structural model that is not always possible mainly for complex systems that presents, in many cases, non-linear characteristics, and it can not be satisfactorily treated by linear theory. Neural networks may be applied to successfully classify problems associated with non-linearity, provided that they are well represented by input patterns. Furthermore, the learning capabilities of neural networks are well suited to process information from a large number of operation conditions, which is likely to provide information on the life expectancy of the structures.

Therefore, the use of neural networks could reduce the complexity of model based evaluation tools, once neural networks have shown the effectiveness pertaining to problems in different applications areas (Li & Kim, 1992; Uh1, T. 1994; Liu et all, 1996; Trendafilova et all, 1998; Pereira et al., 1999).

Actually, there exist a considerable motivation to design robust tools, which may incorporate self-diagnostic technology into the mechanical systems to monitor the operation conditions and structural damage.

The ability of Neural networks for pattern recognition turning it in an promising tool for monitoring and fault classification of machines and equipments aiming at performing automatically, in a real time, the evaluation of their operation conditions. In this case, the neural networks should be designed to classify the input patterns in pre-defined classes or to create categories of group patterns according to their similarity. An important feature of the neural networks, in this context, is their inherent ability to operate on noisy, incomplete or sparse data and to model process from actual system parameters (Uhl, 1994). The neural network could respond in real time to the changes in the System State, provided by continuous sensor inputs. Hence this technique should facilitate damage identification in real time, providing a good NDE tool based on measured vibration data.

However, the several attempts to use neural networks faced difficulties to generate reliable information to train the network. There exists the necessity of generation of a large set of data, containing the different patterns representing all failure conditions that are likely to occur in the structure to cover most of the possibility of damages. This work studies the capability of generalization of Neural Network to classify the input patters of a system with different stiffness ratio. This will bring to definition of Neural Networks capable to use a reduced set of data during training phase and, once it is successfully trained, it could identify intermediate damage condition unseen in the training. The approach is supported on multi-layers neural networks based on the backpropagation algorithm. Several condition and intensity of fault have been studied by using numerical data. The Neural Network demonstrated a good capacity of generalization for all case. Experimental data have also been used to test its generalization capability.

2. MULTI-LAYER NEURAL NETWORK

A multi-layer neural network usually presents a set of three or four layers of elements that are called neurons. Each neuron is a simple mathematical processing unit that, when interconnected, produces complex structures whit different architectures, that can be trained to recognize changes of the system. These layers are defined as the input layer, intermediate or hidden layers and the output layer (Lucifredi & Hou, 1994). Figure 1 illustrates how they are distributed, for a general neural network configuration.

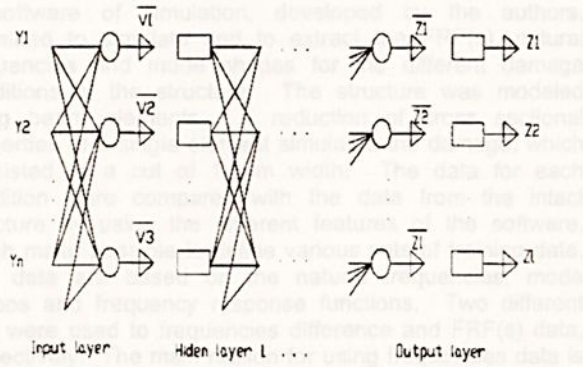


Figure 1- Multi-layers Neural Network.

Each neuron of a layer connects to all others neurons of the adjacent layer. These connections have specific weight coefficients, calculated during the training phase that weights the values that pass from a neuron to next one. Conversely, the input data are weighted and supplied for the first hidden layer and their neurons are activated producing outputs, which are based on a summation of those values correctly weighted into the activation function. To pass the information from the first intermediate layers to the second (if there exist one) the procedure is the same. Finally, the values pass to the output layer that gives the network output

The first stage, called training or learning phase, it is the most important step in the neural network. The training consist to adjust the inputs to the specified output. The network outputs obtained are compared with the target outputs during the training process and the weight of each connections are adjusted aiming at finding the target outputs. It learns through a adjust of the interconnection weights among the layers (Lopes Jr. & Demarchi, 1998; Wasserman, 1993).

The back-propagation algorithm [reference] is one of the most used learning algorithms for multi-layers neural networks. It proceeds the training iteratively and calculates, for each iteration, the comparison errors and uses the errors and bias to readjust the values of the interconnection weights as well as the offset of each node. Once the error is sufficiently small (threshold) the training process is supposed successfully.

Once learning is completed, the neural network is capable of furnishing not only the desired outputs for the known inputs but also the "very reasonably" outputs for some unseen intermediate conditions (in relation to the learning process) provided to it. This capability of generalization makes the use of neural network very attractive in field of health monitoring and damage detection, since it could reduce the amount of data (all kind of expected damage) used during the training process. In this case, the accomplishment of the evaluation of the operation conditions of a system could detect unforeseen changes (damage) that could eventually occur during its lifetime, providing sufficient information to decide if there exist or not a necessity of an intervention in the system.

3. TRAINING PROCESS OF THE NETWORK

To investigate the capability and performance of the network it is necessary to define the structure of the network and to define, through several tests or by using its historical functioning, the training data. These data must contain the different expected operation conditions including all kinds of damage which one intents to evaluate or control. It is common to specify the architecture of the network by referring to its number of hidden layers; layers that are neither inputs nor outputs. The topologies and size of the network depend on each specific application, and the definition of an optimal choice is case dependent (Bernieri, 1994, Worden and Tomlinson, 1994, Yuedong and Du, 1996). Different sizes and topologies for the network were investigated previously and it has been used the brackpropagation algorithm, with an intermediate layer containing 3 neurons and an output layer with one neuron. The tansig and pureling functions from Matlab were used as transfer functions in the training process.

In this work, the main interest is faced to the study of generalization capability of the network therefore, it uses, in a first moment, a set of simulated data. These data provides an exact base of comparison that permits to confront the obtained results with the exact values since the errors (damage) introduced for the generation of the data are well defined. Later it discusses the use of experimental data.

A beam-structure of sectional area of 25.4 x 25.4 mm and length of 830 mm has been investigated. The material properties were Young's module, E=210 GPa, Poisson's ratio, ν= 0.3 and density, ρ= 7850 kg/m^3. Initially, the data was created for the intact structure and subsequently, for two different damage cases. The damage consists of a reduction of the inertial property of the model. In the first case, the damage was fixed in the position 85 mm, near to the clamped-end, and in the second one, it was fixed in the position 773 mm near to the free-end of the bar, fig. 02. In both cases, the intensity of the damage was increased in steps of 10 %, from a range of 0 % to 80 % of the height "h" of the beam. The reduction of 80% was considered the maximum permitted damage in the structure.

The effects caused by each amount of damage present a non-linear variation. Furthermore, the behavior of the structure varies for each case, which permits to study how the neural network will respond to the critical (high sensitivity) as well as the less severe damage conditions.

unesp

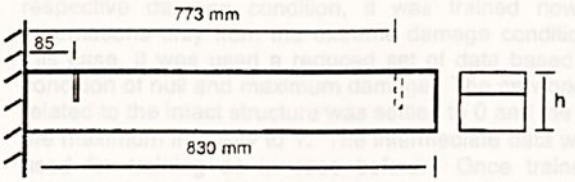


Figure 2: Beam structure

A software of simulation, developed by the authors, permitted to simulate and to extract the FRF(s), natural frequencies and mode shapes for the different damage conditions of the structure. The structure was modeled using beam elements. A reduction of cross sectional properties of a single element simulated the damage, which consisted of a cut of 1 mm width. The data for each condition were compared with the data from the intact structure by using the different features of the software, which make possible to define various sets of training data. The data are based on the natural frequencies, mode shapes and frequency response functions. Two different sets were used to frequencies difference and FRF(s) data, respectively. The main reason for using frequencies data is that natural frequencies are global properties with a relatively high sensitivity due to changes in structural parameters. They are also reasonably easy to be identified in practical situations.

Different forms to present the data to the network were tested, since the choice of the data and how they will feed the training process is a fundamental decision in the process. The network could respond better if the input data are presented in more suitable form. In this process, the training data consisted of frequency differences of the five first modes. The procedure calculates, for different intensities of damage, the frequency difference between the damaged and undamaged condition. Table 1 shows the changes of the frequencies for the analyzed damage intensities. Five first frequencies were considered for damage near to the clamped-end. The table of Frequencies for the damage near to the free-end of the bar will be omitted, only the neural network results of this condition will be presented.

Two sets of data were used in the training process of the network. Initially, it used data containing information of all damage intensity conditions and subsequently, data containing information of only a reduced number of damage conditions. For the later condition, only the extremes damages were used i.e., the undamaged and maximum intensity condition. For this reduced set of data, the network output related to the intact structure was settled to 0, and for the case of maximum intensity to 1. The intermediate data were not used for training, aiming to check if the network was able to identify them in the recognition phase. Once the network succeed the training using a reduced set of data, then its capability of generalization was evaluated i.e., the network was furnished with data unseen in the training process and observed how it responded to these conditions.

Table 1- Used data for training process – Case 1.

Damage	Frequencies (1º to 5º modes)				
	1º	2º	3º	4º	5º
0%	30.9	193.4	540.7	1056.9	1563.1
10%	30.9	193.4	540.7	1056.9	1562.9
20%	30.8	193.3	540.6	1056.9	1562.6
30%	30.8	193.2	540.6	1056.9	1562.3
40%	30.7	193.0	540.5	1056.9	1561.9
50%	30.5	192.6	540.3	1056.9	1561.3

Different forms of data such as normalized frequencies, modes correlation, FRF(s) difference were used for training and verifying the generalization capability of the network for both cases, damage near the clamped and the free-end of the bar. However, due to space limitation will be presented only part of the results, those related with the frequency differences.

4. RESULTS

After procedure all steps previously described, the training data and subsequently the responses of the network were obtained. Initially, it was investigated the effects of a damage near to the clamped-end of the bar. For each intensity of damage, the network was provided with vectors containing the differences of the natural frequencies between the damaged and undamaged conditions. The training data, extracted from table 1, consisted of six vectors related, respectively, with undamaged condition, damage of 10% of intensity, and so on. The small error of comparison and bias obtained (convergence) confirmed the success of the training of the network. Once it was trained, the data were presented to the network aiming at confirming if it was able to recognize all damage intensities.

Figure 3 shows the response obtained for several tested conditions. The net identified all damage patterns presented, as can be observed in the figure.

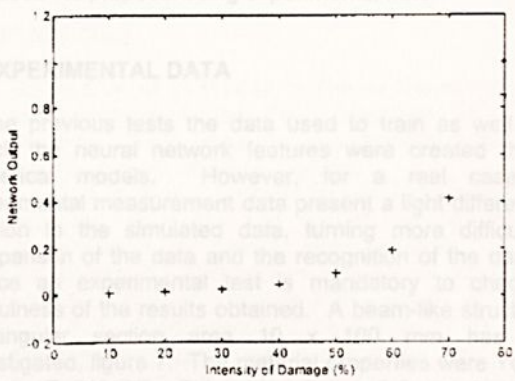


Figure 3- Network output using all intensity values of damage

Confirmed the capability of the network to recognize each respective damage condition, it was trained now using informations only from the extreme damage conditions. In this case, it was used a reduced set of data based on the condition of null and maximum damage. The network output related to the intact structure was settled to 0 and the one for the maximum intensity to 1. The intermediate data were not used for training as in case before. Once trained, the network was used to recognize intermediate patters of damage not used in the training phase.

Figure 4 shows the results obtained when data from intermediate conditions, unseen in the training phase, were presented to the network. This aims to check its capability of generalization. Intermediate conditions of damage, intensity of 20%, 40% ... as well as the extremes ones were evaluated.

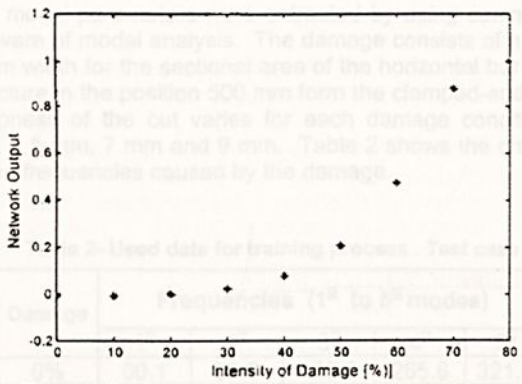


Figure 4- Network output using a reduced set of data.

Figure 5 shows the results for the damage condition near to free-end of the bar. It represents a condition of low sensitivity to the damage. This is a critical condition since the damage (reduction of the structural parameter of the model) causes very small changes in the modal parameters of the model. As in the previous tests, the network was trained using data from different intensities of damage and finally, by using a reduced set of data containing informations concerning to only the extreme conditions.

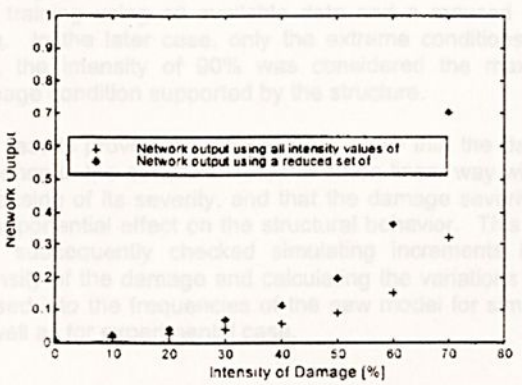


Figure 5- Network output using both all/reduced set of data.

Additional tests were done using other forms of presenting the data differences to the network such as frequencies points extracted from the FRF(s), amplitudes of the FRF(s) for some specific frequency points and others. Following, it is presented only the results of absolute difference frequencies for the low sensitivity damage case. However, the results were very similar for the various tests. Figure 6 shows the results obtained and how the network behaves for recognize different intensities of damage using data information of all as well as a reduced set of data to training the network.

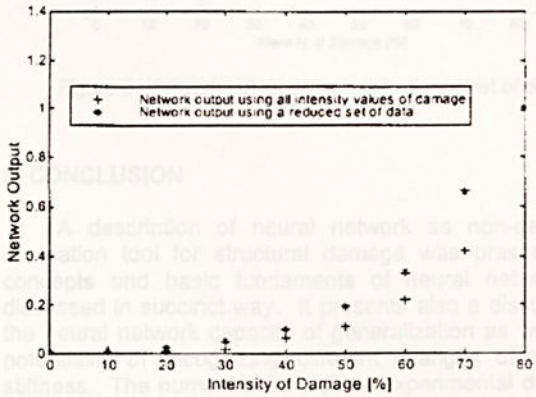


Figure 6- Network output using both all/educed set of data.

The results have shown that a neural network could identify correctly different conditions of damage. All networks successfully trained (presented convergence) responded satisfactory for unseen damage intensities presented to them. Furthermore, it presents a good capability of generalization, which makes its use very promising in the health monitoring area. This feature shows that its use in real world could be very interesting. Since it could respond satisfactorily even not using a large number of patterns previously defined for all different conditions of damage. The network could be trained by using a specific set of data (reduced) in order to be used to identify distinct conditions of damage of those used for training process. Next section discuses the proposal using experimental data

5. EXPERIMENTAL DATA

In the previous tests the data used to train as well as to check the neural network features were created through numerical models. However, for a real case, the experimental measurement data present a light difference in relation to the simulated data, turning more difficult the comparison of the data and the recognition of the damage. Hence an experimental test is mandatory to check the usefulness of the results obtained. A beam-like structure of rectangular section area 10 x 100 mm has been investigated, figure 7. The material properties were Young's module, E=210 GPa, Poisson's ratio, ν= 0.3 and density, ρ= 7850 kg/m^3.

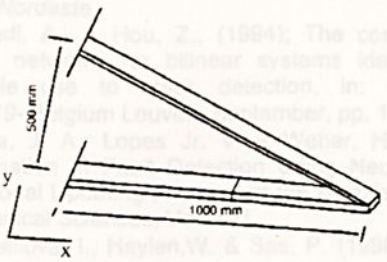


Figure 7- Beam-like Structure

Initially, the data was measured for the intact structure and subsequently, for four different damage intensities. The FRF(s) were measured in 20 points in the y-direction for a hammer-excitation in point 10 (middle of the horizontal bar). The modal parameters were extracted by using commercial software of modal analysis. The damage consists of a cut of 1 mm width for the sectional area of the horizontal bar of the structure in the position 500 mm form the clamped-end. The deepness of the cut varies for each damage condition, 2 mm, 3.5 mm, 7 mm and 9 mm. Table 2 shows the changes of the frequencies caused by the damage.

Table 2- Used data for training process . Test case

Damage	Frequencies (1º to 5º modes)				
	1º	2º	3º	4º	5º
0%	60.1	99.2	185.9	265.6	321.1
20%	60.1	99.2	185.9	265.6	321.8
35%	60.1	99.2	186.7	266.4	320.3
70%	59.4	98.4	185.9	266.4	316.0
90%	59.4	96.1	183.6	265.6	311.7

As in the previous tests, the network was trained using data from all different intensities of damage and finally, by using a reduced set of data containing informations concerning to only the extreme conditions. Different intensities of damage were introduced in the structure, equivalent to a reduction 20%, 35%, 70% and 90% of the height "h" of the horizontal bar. Figure 8 shows the results obtained for both conditions i.e., training using all available data and a reduced set of data. In the later case, only the extreme conditions were use, the intensity of 90% was considered the maximum damage condition supported by the structure.

The results provided by the network show that the damage influence in the structure varies in a non-linear way with the increasing of its severity, and that the damage severity has an exponential effect on the structural behavior. This effect was subsequently checked simulating increments in the intensity of the damage and calculating the variations that it caused into the frequencies of the new model for simulated as well as for experimental case.

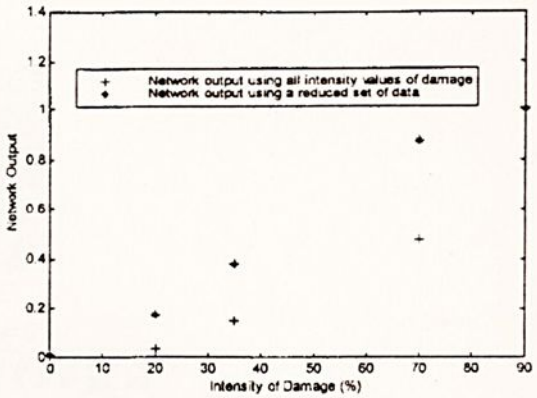


Figure 8- Network output using both/reduced set of data.

5. CONCLUSION

A description of neural network as non-destructive evaluation tool for structural damage was present. The concepts and basic fundaments of neural network it is discussed in succinct way. It presents also a discussion of the neural network capacity of generalization as well as its potentiality of recognizing different changes of structural stiffness. The numerical as well as experimental data were used. The network succeeded to quantify the damage in all tests including those using a reduced set of training data containing only information from the extreme conditions of damage. The obtained results have shown promising and they will be explored in subsequently works. The next step will be to investigate the generalizing capability of the network to locate damage at different positions of the structure.

ACKNOWLEDGMENT

The authors acknowledge the support of the Research Support Foundation of the State of Sao Paulo (FAPESP) – Brazil. Enga. Demachi gratefully acknowledges the support of FAPESP, grant no. CMS-9701471, to her master studies

REFERÊNCIAS

[1] Bernieri, A. at all (1994); "A Neural Network Approach for Identification and Fault Diagnosis on Dynamic Systems," *IEEE Trans. On Instrumentation and Meas.*, vol. 43, nº 6 pp. 867-873, Dec./94.

[2] Li, C. J. & Kim, T. (1992); "A new feedforward neural networks structural and weight learing algorithm-augmentation by training with residuals," *ASME – Proceeding of Symposium on Neural Networks in Manufacturing and Robotics*, PED – vol. 57, pp. 65-74.

[3] Liu, T. I., Singonahalli, J. H. & Iyer, N. R. (1996); "Detection of roller bearing defects using expert system and Fuzzy logic," *Mechanical Systems and Signal Processing*, pp. 595-614.

[4] Lopes Jr., V. & Demarchi, D. (1998); "Identificação de rigidez bilinear em sistemas mecânicos através de

redes neurais," *V Congresso de Engenharia Mecânica - Norte Nordeste.*

[5] Lucifredi, A., & Hou, Z., (1994); The construction of neural networks for bilinear systems identification a possible use to crack detection, in: *Proceedings ISMA19*- Belgium Leuven, September, pp. 1139-1149.

[6] Pereira, J. A., Lopes Jr. V. e Weber, H. I., (1999); "Automation in Fault Detection Using Neural Network and Modal Updating", Journal of the Brazilian Society of Mechanical Sciences, Vol. XXI.

[7] Trendafilova, I., Heylen,W. & Sas, P. (1998); "Damage localization in structures. A pattern recognition," *Proceedings of ISMA23*, vol. 1, pp. 99-106.

[8] Uh1, T. (1994); "Automation of monitoring and diagnostic process for rotating machinery using neural networks," *ISMA – Intern. Seminar of Modal Analysis*, Sept./94.

[9] Warden, K. and Tomlinson G. R.; (1994) "Modeling and Classification of Non-linear System Using Neural Networks," Mechanical Systems and Signal Processing, pp. 319-356.

[10] Wasserman, P. D., (1993); Neural computing – Theory and practice, Van Nostrand Reinhold, Nova Iorque – N.Y., E.U.A..

[11] Yuedong, C., and Du, R.; (1996) "Artificial Neural Network Architecture Design Using Similarity Measure with Applications in Engineering Monitoring and Diagnosis," ASME Journal of Dynamic System, Measurement, and Control, vol 118, pp. 635-639.

P14

IMAC XVIII

Proceedings of

IMAC-XVIII: A Conference on Structural Dynamics

FEBRUARY 7-10, 2000
THE WESTIN LA CANTERA RESORT
SAN ANTONIO, TEXAS

TECHNICAL PROGRAM CHAIR:
Alfred L. Wicks, Virginia Polytechnic Institute and State University
Dominick J. DeMichele, Honorary Technical Chair

SOCIETY FOR EXPERIMENTAL MECHANICS, INC.:
Patricia Deuschle, Acting Executive Director
Katherine M. Ramsay, Conference Manager

Organized By:

SOCIETY FOR EXPERIMENTAL MECHANICS, INC.
Bethel, Connecticut 06801

unesp

STRUCTURAL FRF ACQUISITION VIA ELECTRIC IMPEDANCE MEASUREMENT APPLIED TO DAMAGE LOCATION

Vicente Lopes, Jr., João Antonio Pereira

Department of Mechanical Engineering – UNESP
15385-000 Ilha Solteira SP, Brazil

Daniel J. Inman

Center for Intelligent Material Systems and Structures
Virginia Polytechnic Institute and State University
Blacksburg, VA 24061-0261

ABSTRACT

Continuing development of new materials makes systems lighter and stronger permitting more complex systems to provide more functionality and flexibility that demands a more effective evaluation of their structural health. Smart material technology has become an area of increasing interest in this field. The combination of smart materials and artificial neural networks can be used as an excellent tool for pattern recognition, turning their application adequate for monitoring and fault classification of equipment and structures. In order to identify the fault, the neural network must be trained using a set of solutions to its corresponding forward variational problem. After the training process, the net can successfully solve the inverse variational problem in the context of monitoring and fault detection because of their pattern recognition and interpolation capabilities. The use of structural frequency response function is a fundamental portion of structural dynamic analysis, and it can be extracted from measured electric impedance through the electromechanical interaction of a piezoceramic and a structure. In this paper we use the FRF obtained by a mathematical model (FEM) in order to generate the training data for the neural networks, and the identification of damage can be done by measuring electric impedance, since suitable data normalization correlates FRF and electrical impedance.

1. INTRODUCTION

Non-Destructive Evaluation (NDE) tools based on vibration measurement are gaining increasing importance in the context of operation condition monitoring and fault detection of machines and equipments. In a more conventional sense, they compare the monitored vibration level of the system, usually the response function, with a standard vibration level (undamaged system) aiming at identifying changes in the actual system. The improving of available instrumentation, including active self-testing technology, has changed existing healthy monitoring concepts. Actually, there exists a considerable motivation to design a robust tool, which incorporates self-diagnostic technology into the mechanical systems to monitor the operation conditions and structural damage.

The engineering community has shown a great interest in the development of real-time condition monitoring of machine health to reduce cost and improve safety. Smart materials technology permits us to combine ordinary structural components with special components (smart components) that can function as sensors as well as actuators in the system. This technology can improve the performance of the system and its capability to detect operation anomalies. Such system could adjust its dynamic properties in order to minimize the possibility of structural damage.

A fully adaptive structure could, in principle, be adjusted to resist the normal loading condition in its normal operation, but it could also actuate as an appropriate system to resist abnormal loads. Another function of interest for adaptive structure is the provision of an alarm to inform the need for repair actuation. Developing of on-line structural health monitoring system for complex structures is an important issue in the structural engineering community. The goal of this technique is to allow systems and structures to monitor their own integrity while in operation and throughout their lives, minimizing maintenance processes and inspection cycles.

Extensive analysis and investigations have focused on integrating smart material technology into health monitoring systems [1-3]. This is due to the fact that they possess very important characteristics for fault detection and diagnostics, such as that they can behave as sensors, as well as actuators for the systems that do not contain natural exciting forces. Furthermore, they come in a variety of sizes and abilities, allowing them to be placed almost everywhere.

unesp

One of the important aspects of structural health monitoring technique is that it provides the information on the life expectancy of the structures, as well as it detects and locates damage. In general, this requires an increasing knowledge of the model of the structures that is not always possible. As well, several dynamic systems present non-linear characteristics, which can not be satisfactorily treated by linear theory. Neural networks may be applied to successfully classify problems associated with non-linearity, provided that they are well represented by input patterns. Furthermore, the learning capabilities of neural networks are well suited to process a large number of distributed sensors, which is usually the case for smart structures applications.

An intelligent maintenance schedule, that only repairs the system if indeed necessary, could be economically very attractive. Integrating smart material and neural networks, which could avoid the complexity introduced by conventional computational methods, could do it.

The incorporation of mass, stiffness, and electromechanical coupling of the piezoceramic patches has a significant influence on the dynamics properties of the system [4-5]. In this paper, a piezoelectric beam element is derived by using the linear piezoelectric constitutive equation. The simulated examples showed that although the absolute values of the dynamics properties change when the piezoceramic patches are considered, the normalized values of natural frequencies remain constant. Then, it is possible to use the data from the conventional FEM program to train the neural networks and to do the damage identification by measuring electric impedance.

2. PIEZOELECTRICITY BACKGROUND

The dynamics of the piezoelectric sensor/actuator plays an increasing importance when higher performance from closed loop systems or damage monitoring is required for strategic applications. For a piezoceramic, the 3 direction (z-axis) is usually associated with the direction of poling and the material is approximately isotropic in the other two directions

Materials that become electrically polarized when they are deformed present the direct piezoelectric effect, producing an electrical charge at the surface of the material. The converse piezoelectric effect results in a strain in the material when placed within an electric field. The direct and converse effects result an electromechanical coupling. While piezoelectric elements exhibits nonlinear hysteresis at high excitation levels, the response required in the current typical structural applications is approximately linear. In this work we will use the linear constitutive relations for piezoelectric materials [6].

$$\{T\} = \left[c^E\right]\{S\} - [e]\{E\} \quad (1)$$

$$\{D\} = [e]^T\{S\} + \left[\varepsilon^S\right]\{E\} \quad (2)$$

where the superscript $(\,)^S$ means that the values are measured at constant strain and the superscript, $(\,)^E$ means that the values are measured at constant electric field, $\{T\}$ is the stress tensor [N/m^2], $\{D\}$ is the electric displacement vector [C/m^2], $\{S\}$ is the strain tensor [m/m], $\{E\}$ is the electric field [V/m = N/C], $\left[c^E\right]$ is the elasticity tensor at constant electric field [N/m^2], $[e]$ is the dielectric permittivity tensor [N.m/V.m^2 = C/m^2], and $\left[\varepsilon^S\right]$ is the dielectric tensor at constant mechanical strain (permitivity matrix) [N.m/V^2.m]. The letters in brackets indicate the units of the variables (in the SI system of units) with N, m, V, and C denoting Newton, meter, Volts, and Coulomb, respectively.

$$\{T\} = \begin{bmatrix} T_{11} & T_{22} & T_{33} & T_{23} & T_{13} & T_{12} \end{bmatrix}^T$$

$$\{S\} = \begin{bmatrix} S_{11} & S_{22} & S_{33} & 2S_{23} & 2S_{13} & 2S_{12} \end{bmatrix}^T$$

$$D = \begin{bmatrix} D_1 & D_2 & D_3 \end{bmatrix}^T; \qquad E = \begin{bmatrix} E_1 & E_2 & E_3 \end{bmatrix}^T$$

$$\left[\varepsilon^S\right] = \begin{bmatrix} \varepsilon_1^S & 0 & 0 \\ 0 & \varepsilon_1^S & 0 \\ 0 & 0 & \varepsilon_3^S \end{bmatrix}; \qquad [e] = \begin{bmatrix} 0 & 0 & e_{31} \\ 0 & 0 & e_{31} \\ 0 & 0 & e_{33} \\ 0 & 0 & 0 \\ 0 & e_{15} & 0 \\ 0 & e_{15} & 0 \end{bmatrix}$$

$$\left[c^E\right] = \begin{bmatrix} c_{11}^E & c_{12}^E & c_{13}^E & 0 & 0 & 0 \\ c_{12}^E & c_{11}^E & c_{13}^E & 0 & 0 & 0 \\ c_{13}^E & c_{13}^E & c_{33}^E & 0 & 0 & 0 \\ 0 & 0 & 0 & c_{55}^E & 0 & 0 \\ 0 & 0 & 0 & 0 & c_{55}^E & 0 \\ 0 & 0 & 0 & 0 & 0 & c_{66}^E \end{bmatrix}$$

If each element of the matrix of piezoelectric material constant, [e], is designed by e_{ij} where *i* corresponds to the row and *j* corresponds to the column of the matrix, then e_{ij} corresponds to the stress developed in the *j-th* direction due to an electric field applied in the *i-th* direction. The piezoelectric strain constant d_{ij}, relating the voltage applied in the i-th direction to a strain developed in j-th direction, are provided more often than the stress constants. However, the piezoelectric stress constants can be obtained from the strain constants since the constitutive equation can also be write as:

$$\{S\} = \left[s^E\right]\{T\} + [d]\{E\} \quad (3)$$

$$\{D\} = [d]^T\{T\} + \left[\varepsilon^T\right]\{E\} \quad (4)$$

where ε^T, is the dielectric tensor at constant stress. The relative dielectric constant, K^T, is the ratio of the permitivity of the material, ε^T, to the permitivity of the free space, ε_0. (ε_0 = 8.9.10^{-12} Farads/m or Amp.sec/V.m). Then,

$$[c^E] = [s^E]^{-1}; \qquad [e] = [c^E][d]$$

$$[\varepsilon^S] = [\varepsilon^T] - [d]^T [c^E][d]; \qquad K^T = \frac{\varepsilon^T}{\varepsilon_0}$$

with

$$[d] = \begin{bmatrix} 0 & 0 & d_{31} \\ 0 & 0 & d_{31} \\ 0 & 0 & d_{33} \\ 0 & 0 & 0 \\ 0 & d_{15} & 0 \\ 0 & 0 & d_{15} \end{bmatrix}$$

3. FINITE ELEMENT FORMULATION

The finite element method is a method of transformation and approximation of a integral formulation, by an approximation linear algebraic formulation, where the coefficients are integral evaluations on the sub-area of the area of resolution [7]. The equations of motion for coupled electromechanical systems are derived using the coordinate system of figure 1. The Rayleigh-Ritz formulation is used to derive the equations of motion of the electroelastic beam. The assumed displacement field shapes within the elastic body and electric potential field shapes will be combined through the piezoelectric properties to form a set of coupled electromechanical equations of motion. The generalized form of Hamilton's principle for a coupled electromechanical system is [8-9],

$$\int_{t_1}^{t_2} [\delta(T - U + W_e - W_m) + \delta W]\, dt = 0 \qquad (5)$$

where t_1 and t_2 are two arbitrary instants, T is the Kinetic energy, U is the potential energy, W_e is the work done by electrical energy, and W_m is the work done by magnetic energy, which is negligible for piezoceramic material.

$$T = \int_{V_s} \frac{1}{2} \rho_S \dot{u}^T \dot{u}\, dV + \int_{V_p} \frac{1}{2} \rho_P \dot{u}^T \dot{u}\, dV \qquad (6)$$

$$U = \int_{V_s} \frac{1}{2} S^T T\, dV + \int_{V_p} \frac{1}{2} S^T T\, dV \qquad (7)$$

$$W_e = \int_{V_p} \frac{1}{2} E^T D\, dV \qquad (8)$$

where ρ is the mass density and the subscript s and p refer to the structure and piezoelectric material, respectively. The virtual work, δW, done by external forces and the prescribed surface charge, Q, is,

$$\delta W = \int_{V_S} \delta u^T P_b\, dV + \int_{S_S} \delta u^T P_S\, ds_s + \delta u^T P_C - \int_{S_p} \delta\phi\, Q\, ds_P \qquad (9)$$

where P_b is the body force, P_S is the surface force, P_c is the concentrated load, and Q is the surface charge. To formulate an electroelastic matrix of a finite element method, the displacement vector, $\{u\}$, and the electric potential, ϕ, must be expressed in terms of nodal value, i, via the interpolation function

$$u(x) = [N_u]\{u_i\} \qquad (10)$$

$$\phi(x) = [N_\phi]\{\phi_i\} \qquad (11)$$

Since the constitutive relations for both structure and piezoelectric material have been defined, the strain can be linked to the nodal displacement through the derivative of $\{u\}$, and as well a gradient operator can link the electrical field with the electrical potential.

$$\{S(x,t)\} = [B_u(x)]\{u_i(t)\} \qquad (12a)$$

$$\{E(x,t)\} = -[B_\phi(x)]\{\phi_i(t)\} \qquad (12b)$$

with

$$[B_u(x)] = [L_u][N_u(x)] \qquad (13a)$$

$$[B_\phi(x)] = \nabla [N_\phi(x)] \qquad (13b)$$

where $[L_u]$ is the differential operator for the particular elasticity problem and ∇ is the gradient operator. At this point, the coupled electromechanical system equation can be derived by substituting the generalized stress, strain, and energy equations into the variational equation (5). Allowing arbitrary variations of $\{u_i\}$ and $\{\phi_i\}$, two equilibrium matrix equations, in generalized coordinates, are obtained.

unesp

$$\left(\left[M_S^e\right]+\left[M_P^e\right]\right)\{\ddot{u}_i\}+\left(\left[K_S^e\right]+\left[K_{uu}^e\right]\right)\{u_i\} - \left[K_{u\phi}^e\right]\{\phi_i\} = \{F^e\} \tag{14}$$

$$\left[K_{\phi u}^e\right]\{u_i\} - \left[K_{\phi\phi}^e\right]\{\phi_i\} = \{Q^e\} \tag{15}$$

where the mass and stiffness matrices for the structure and piezoelectric path elements are defined as:

$$\left[M_S^e\right] = \int_{V_S} [N_u]^T \rho_S [N_u]\, dV \tag{16a}$$

$$\left[M_P^e\right] = \int_{V_P} [N_u]^T \rho_P [N_u]\, dV \tag{16b}$$

$$\left[K_S^e\right] = \int_{V_S} [B_u]^T [c_S] [B_u]\, dV \tag{17a}$$

$$\left[K_{uu}^e\right] = \int_{V_P} [B_u]^T \left[c^E\right] [B_u]\, dV \tag{17b}$$

The piezoelectric capacitance matrix, $K_{\phi\phi}$, and the electromechanical coupling matrix, $K_{u\phi}$, are

$$\left[K_{\phi\phi}^e\right] = \int_{V_P} [B_\phi]^T \left[\varepsilon^S\right] [B_\phi]\, dV \tag{18a}$$

$$\left[K_{u\phi}^e\right] = \int_{V_P} [B_u]^T [e] [B_\phi]\, dV \tag{18b}$$

with $\left[K_{\phi u}^e\right] = \left[K_{u\phi}^e\right]^T$. The force vectors are given by:

$$\{F^e\} = \int_{V_S} [N_u]^T \{P_B\} dV + \int_{S_S} [N_u]^T \{P_S\} ds_S + [N_u]^T \{P_C\} \tag{19}$$

$$\{Q^e\} = -\int_{S_P} [N_\phi]^T Q\, ds_P \tag{20}$$

For the entire structure, using the standard assembly technique for the finite element method, we obtain the complete equation for a coupled electromechanical system as

$$\begin{bmatrix} [M_{uu}] & 0 \\ 0 & 0 \end{bmatrix} \begin{Bmatrix} \{\ddot{u}\} \\ \{\ddot{\phi}\} \end{Bmatrix} + \begin{bmatrix} [K_{uu}] & [K_{u\phi}] \\ [K_{\phi u}] & [K_{\phi\phi}] \end{bmatrix} \begin{Bmatrix} \{u\} \\ \{\phi\} \end{Bmatrix} = \begin{Bmatrix} \{F\} \\ \{Q\} \end{Bmatrix}$$

where

$$\left[M_{uu}\right] = \sum_{i=1}^{ne} \left[M_S^e\right]_i + \sum_{j=1}^{np} \left[M_P^e\right]_j \tag{21}$$

$$\left[K_{uu}\right] = \sum_{i=1}^{ne} \left[K_S^e\right]_i + \sum_{j=1}^{np} \left[K_{uu}^e\right]_j \tag{22a}$$

$$\left[K_{u\phi}\right] = \sum_{j=1}^{np} \left[K_{u\phi}^e\right]_j \tag{22b}$$

$$\left[K_{\phi\phi}\right] = \sum_{j=1}^{np} \left[K_{\phi\phi}^e\right]_j \tag{22c}$$

where *ne* is the number of structural elements and *np* is the number of piezoelectric patches in the structure. The symbol summation, in the above equations, means finite element assembling matrices. At this point it is important to note that the mass and stiffness matrices for a finite element and therefore for the complete structure are not positive definite.

4. EIGENVALUE ANALYSIS

Natural frequencies and mode shapes can be obtained by reducing the assembled global matrices to a standard eigenvalue form. It can be done by suitable grounding the structure by specifying one or more nodal value of electrical potential. Then the new piezoelectric capacitance matrix, $K_{\phi\phi}^*$, is non-singular and the eigenvalue problem, for the undamped homogeneous system, can be written as

$$\left([K] - \omega^2 [M]\right)\{u\} = \{0\} \tag{23}$$

where

$$[M] = \left[M_{uu}\right] \tag{24a}$$

$$[K] = \left[K_{uu}\right] - \left[K_{u\phi}\right]\left[K_{\phi\phi}^*\right]^{-1}\left[K_{\phi u}\right] \tag{24b}$$

and $[\circ]^{-1}$ indicates the inverse of the matrix.

4. APLICATION - Clamped-Free Beam with Bonded PZT

Now, the general equations from the previous section will be applied for the case of a clamped-free beam with a pair of bonded PZT, as shown in Figure 1. Different numbers and locations of PZT's can be considered. The poling of the piezoelectrics is in the *z*-direction.

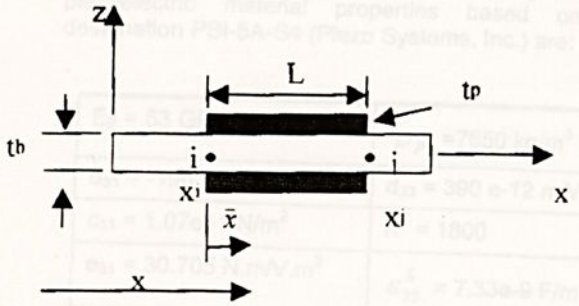


Figure 1. Section of the beam with bonded PZT

For a Euler-Bernoulli beam, the commonly used interpolation function for the displacement at any point $s = \bar{x}/L = (x - x_i)/L$ where s is the local coordinate and x is the global coordinate is

$$u(x) = N_1(x)u_1 + N_2(x)\theta_1 + N_3(x)u_2 + N_4(x)\theta_2$$

$$\phi(x) = N_{\phi 1}(x)\,\phi_1 + N_{\phi 2}(x)\,\phi_2$$

with:

$$N_1(x) = 1 - 3s^2 + 2s^3$$

$$N_2(x) = L\,s\,(1 - 2s + 2s^2$$

$$N_3(x) = s^2\,(3 - 2s)$$

$$N_4(x) = L\,s^2\,(s - 1)$$

$$N_{\phi 1} = 1 - \frac{z - t_b/2}{t_p}; \qquad N_{\phi 2} = \frac{z - t_b/2}{t_p}$$

where t_b and t_p are the thickness of beam and PZT, respectively. From beam bending theory, the relevant strain-displacement relation is

$$S(x,t) = -z\frac{\partial^2 u(x)}{\partial x^2} \tag{25}$$

Differentiation of $u(x)$ twice with respect to x,

$$\frac{d}{dx} = \frac{1}{L}\frac{d}{ds}; \qquad \frac{d^2}{dx^2} = \frac{1}{L^2}\frac{d^2}{ds^2} \tag{26}$$

Then,

$$\frac{\partial^2}{\partial x^2}u(x) = \frac{1}{L^2}\frac{\partial^2}{\partial s^2}[N_u]\{u_i\} = [B_u]\{u_i\} \tag{27}$$

where

$$[B_u] = \frac{1}{L^2}\frac{d^2}{ds^2}[N_u] \tag{28}$$

For this one dimensional piezoelectric beam, only the normal stress T_{11}, strain S_{11}, and transverse electric field E_3 are considered. Now, if we assume that the electric field is constant through the PZT thickness, the gradient operator is

$$E = -\frac{\partial}{\partial_z}\phi = -\frac{\partial}{\partial_z}[N_\phi]\{\phi_i\} = -[B_\phi]\{\phi_i\} \tag{29}$$

Substituting these functions into equations 16 – 18 and integrating over y and z directions, the mass, stiffness, piezoelectric capacitance, and electromechanical coupling matrices for each element can be found.

$$[M_S^e] = \rho_S\,A_S\,L_S\int_0^1 [N_u]^T\,[N_u]\,ds \tag{30a}$$

$$[M_P^e] = \rho_P\,A_P\,L_P\int_0^1 [N_u]^T\,[N_u]\,ds \tag{30b}$$

$$[K_S^e] = E_S\,I_S\,L_S\int_0^1 [B_u]^T\,[B_u]\,ds \tag{30c}$$

$$[K_{uu}^e] = A_{uu}\int_0^1 [B_u]^T\,[B_u]\,ds \tag{30d}$$

$$[K_{u\phi}^e] = A_{u\phi}\int_0^1 [B_u]^T\,[B_\phi]\,ds \tag{30e}$$

$$[K_{\phi\phi}^e] = -A_P\,\varepsilon_{33}^S\,L_P\int_0^1 [B_\phi]^T\,[B_\phi]\,ds \tag{30f}$$

with

$$A_{uu} = w_b\,c^E\,L_P\,\frac{1}{3}\left(3t_b^2\,t_P + 3t_b\,t_P^2 + t_P^3\right)$$

$$A_{u\phi} = -w_b\,e_{31}\,L_P\,\frac{1}{2}\left(2t_b\,t_P + t_P^2\right)$$

where A is the cross section area, L is the element length, and w is the width. To verify the current procedure, it was utilized an aluminum beam with 500x30x5 mm of length, width, and thickness, respectively. The properties of aluminum are:, Es = 70 GPa, ρ_S = 2710 kg/m^3. The total number of structural degree of freedom used were 42 (20 elements, 2 DOF by node). The number of electrical degree of freedom change as a function of the number of PZT

considered in each example (2 DOF by PZT). The piezoelectric material properties based on material designation PSI-5A-S4 (Piezo Systems, Inc.) are:

E_P = 63 GPa	ρ_P =7650 kg/m^3
d_{31} = -190 e-12 m/V	d_{33} = 390 e-12 m/V
c_{11} = 1.07e11 N/m^2	K^T = 1800
e_{31} = 30.705 N.m/V.m^2	ε_{33}^S = 7.33e-9 F/m

Table 1: Material properties of the piezoelectric element

The five first natural frequencies of the beam without PZT, obtained by FEM considering 20 elements, are 16.42, 102.9, 288.13, 564.6, and 933.35 Hz. Figure 2 shows the FRF for the beam without PZT, for intercalated PZT in the elements (10 PZT pairs), and PZT in all 20 elements. The PZT has the same length and width of the structural element and a thickness of 0.5 mm. The results considering the bonded PZT pairs were compared with some results from literature, and the results were close.

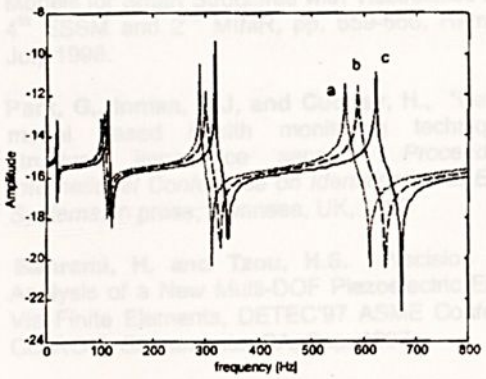


Figure 2: FRF for: a) original beam; b) PZT on intercalated elements; c) PZT on all elements

To test the capability of the proposed technique different damage situations were simulated on the original structure and on the beam with intercalated PZT elements. The damage consisted of a reduction of 5, 10, 15, 20, and 25% of the stiffness of each element. The effect of each damage condition is normalized. The normalization considers the difference of the natural frequencies, in percentage, between the undamaged structure and each damage situation. Table 2 shows the normalized values obtained for damaged elements 1, 5, and 9, that were used to train the neural network. Some values are not shown due to space limitation. In this normalization the maximum value is set to unity for each damage percentage.

Structures with several different locations and numbers of PZT elements were also analyzed. The normalized values of frequency remained practically constant for all tested configurations.

Freq.		1st	2nd	3rd	...	7th
E 1	5%	1,0	0.83	0.70		0.33
	10	1,0	0.83	0.69		0.33
	15	1,0	0.82	0.68		0.32
	20	1,0	0.81	0.67		0.31
	25	1,0	0.80	0.65		0.31
E 5	5%	1,0	0.0	0.52		0.42
	10	1,0	0.0	0.52		0.42
	15	1,0	0.0	0.52		0.42
	20	1,0	0.0	0.52		0.42
	25	1,0	0.0	0.52		0.42
E 9	5%	0.41	0.89	0.31		1.0
	10	0.42	089	0.31		1.0
	15	0.42	0.91	0.31		1.0
	20	0.43	0.91	0.31		1.0
	25	0.43	0.92	0.32		1.0

Table 2. Normalized values for damage in element 1, 5, and 9 used in the training process of the ANN.

5. DISCUSSION AND CONCLUSION

The analytical model of a beam with piezoelectric material coupling the electrical and mechanical coordinates was derived using a generalized Hamilton's principle. It was found that the incorporation of mass, stiffness, capacitance, and coupling matrix of the piezoelectric patch has a significant influence on the dynamic properties of the system. This model of smart structure contains additional degrees of freedom at each node, the electrical potential, and it makes the global mass and stiffness matrices non-positive definite, which require special numerical preparation to solve the eigenvalue problem.

It was shown that for some normalization it is possible to obtain the same results for the system considering or not the PZT influence on the analytical model. Once one has defined a good analytical model, which could be done by incorporating an updating procedure, one can use this model to generate the data to be used in the training process of the neural networks. This approach could avoid one of the major problems in the neural network-based damage identification method, which requires the training data containing all the essential features of damaged mechanism, since it is not always possible for practical situations. Hence, the analytically trained network can be used to compare to measured impedance data in order to determine the presence of damage.

The experimental measurements are done using the electrical impedance method, which is easier than

measuring FRF's with conventional instrumentation. In this technique, these measurements are applied to the nets in order to verify the health condition of the system. This procedure was tested for a beam system; other more complex structures must be analyzed to verify the validity of this kind of data normalization. However, the methodology presented remains valid for more complex structures.

ACKNOWLEDGMENTS

The first two authors acknowledge the support of the Research Support Foundation of the State of Sao Paulo (FAPESP – Brazil). Dr. Inman gratefully acknowledges the support of National Science Foundation, grant no. CMS-9701471, through the Multidisciplinary Center for Earthquake Engineering Research, Buffalo, New York.

REFERENCES

[1] **Banks, H.T., Inman, D.J., Leo, D.J., and Wang**, Y., "An Experimentally Validated Damage Detection Theory in Smart Structures", *Journal of Sound and Vibrations*, Vol.191, pp. 859-880, 1996

[2] **Lam, M.J., Inman, D.J. and Friswell, M.I.**, "Improved Models for Smart Structures with Viscoelastic Elements," 4th ESSM and 2nd MIMR, pp. 659-666, Harrogate, 6-8 July 1998.

[3] **Park, G., Inman, D.J, and Cudney, H.**, "Developing a model based health monitoring technique using structural impedance sensors", *Proceedings, 2nd International Conference on Identification in Engineering Systems*, in press, Swansea, UK, 1999

[4] **Bahrami, H. and Tzou, H.S.** Precision Placement Analysis of a New Multi-DOF Piezoelectric End-Effector Via Finite Elements, DETEC'97 ASME Conferences, in CD-ROM, Sacramento, CA, Sep. 1997.

[5] **Gabbert, U. Berger, H., Koppe, H.and Cao, X.** On Modelling and Analysis of Piezoelectric Adaptive Structures by the Finite Element Method, 4th ESSM, pp. 621-628, Harrogate, July 1998.

[6] **Clark, R.L., Saunders, W.R., and Gibbs, G.P.** Adaptibe Structures: Dynamics and Control, John Wiley & Sons, Inc. 1998.

[7] **Bathe, K.J. and Wilson, E.L.** Numerical Methods in Finite Element Analysis, Prentice Hall, Inc. New Jersey, 1976.

[8] **Hagood, N.W., Chung, W.H., and von Flotow, A.** Modeling of Piezoelectric Actuator Dynamics for Active Structural Control, Journal of Intell. Mater. Syst. And Struct., Vol 1, pp. 4-25, July 1990.

[9] **Allik, H. and Hughes, T.J.R.** Finite Method for Piezoelectric Vibration, International Journal for Numerical Methods in Engineering, Vol. 2, pp. 151-157, 1970.

P15

USING OF MODEL UPDATING CONSIDERING DAMPED FRF(S)

Borges, A. S e J. A. Pereira

Department of Mechanical Engineering – UNESP
15385-000 Ilha Solteira SP, Brazil

Reliable finite element (FE) models are becoming more and more important for projects in the industry. Defining a reliable model leads a growing number of details that must be included in the numerical formulation in order to obtain refined models. In this context new technologies has been presented aiming to yield representative models. Model updating is one of those technologies, it allows to an improving of the predictive capabilities of computer-based models. This paper presents a FRF-based finite element model updating procedure whose the updating variables are physical parameters of the model. It includes the damping effects in the updating procedure assuming the damping mechanism is proportional to the mass and stiffness matrices. The updating parameters are defined at element level or macro regions of the model i.e., the parameters are adjusted locally, facilitating the physical interpretation of the adjustment of the model. Different tests will be discussed aiming at defining the characteristics and potentialities of the methodology.

Resume of COBEM
AUT1010

ID DE AUTOR: aut1010

SENHA: CZRAOCCUHB

ID DO RESUMO:TRB1005

SENHA: QLCOSXVAOX

