

ESCOLA POLITÉCNICA DA USP

DEPTO. DE ENGENHARIA MECÂNICA

ÁREA DE PROJETO E FABRICAÇÃO

PMC-581

PROJETO MECÂNICO II

TEMA:

**ENSAIOS NÃO-DESTRUTIVOS
UTILIZANDO REDES NEURAIS E
FREQUÊNCIAS NATURAIS**

Aluno:

*Ricardo Miguel de Moura
nº USP 2820919*

*Prof. Orientador:
Dr. Paulo Kaminski*

*Data de apresentação:
11/12/96*

ÍNDICE:

Apresentação	3
Parte I - Comparação de Ensaios Não-Destrutivos	4
Teste Visual	4
Teste de Pressão	5
Teste de Líquido Penetrante	6
Métodos Térmicos	7
Uso de Radiação	7
Ensaios por Ultrasom	8
Ensaios Dinâmicos Convencionais	8
Tabela Comparativa	9
Parte II - Redes Neurais	10
Parte III - Exemplificação do Ensaio Proposto	16
Introdução	16
Metodologia - Etapa 1	17
Metodologia - Etapa 2	23
Resultados, Análises e Conclusões	25
Bibliografia	26
Anexos	27

APRESENTAÇÃO:

A identificação e determinação de defeitos numa estrutura é um problema bastante comum em engenharia, estando presente na fase de produção de um componente (teste não-destrutivo), assim como durante sua operação (verificação da integridade estrutural). Neste trabalho a localização das falhas estruturais é realizada com o uso de Redes Neurais Artificiais (RNA) com treinamento supervisionado, utilizando-se freqüências naturais como parâmetro físico para a identificação. O conjunto de dados usado para treinamento é obtido através de simulação numérica (Método de Elementos Finitos). A abordagem proposta é exemplificada através da localização de uma trinca em uma barra engastada, baseando-se em medidas experimentais das cinco primeiras freqüências naturais da estrutura.

A estrutura deste trabalho divide-se em quatro partes básicas. Inicialmente é feita uma comparação dos ensaios não-destrutivos mais comuns, salientando-se suas vantagens e desvantagens. O próxima parte trata de uma introdução sobre o conceito de Redes Neurais e suas aplicações. Após esta etapa introdutória, a metodologia de um ensaio utilizando Redes Neurais e freqüências naturais é exemplificada através de dois modelos simples. Por último são interpretados os resultados obtidos, e feitas as análises e conclusões, bem como observações sobre estudos futuros.

PARTE I

COMPARAÇÃO DE ENSAIOS NÃO-DESTRUTIVOS

Serão expostos a seguir os ensaios não-destrutivos mais conhecidos e com maior gama de aplicação. Foi dada uma atenção especial para as características comparativas entre os métodos, como facilidade de aplicação, experiência do operador, custo, etc., sendo deixado de lado características específicas sobre detalhes construtivos.

1.1)TESTE VISUAL:

Simples, de fácil aplicação, rápido e geralmente de baixo custo. O ensaio visual foi o primeiro método de ensaio não-destrutivo aplicado pelo homem. Embora seja o meio de inspeção mais antigo, este ensaio ainda é fundamental.

O procedimento consiste na iluminação da peça pela luz, geralmente no espectro visível. O componente é examinado a olho nu ou por algum dispositivo óptico. O equipamento necessário é extremamente simples, embora uma iluminação correta seja essencial. As superfícies devem ser devidamente limpas antes da inspeção. O olho humano, neste caso, opera como dispositivo indispensável ao teste, devendo-se estar ciente de suas limitações e variações de indivíduo para indivíduo. Sua precisão está diretamente ligada com a superfície a ser examinada, com o nível de brilho e com o contraste entre a peça e o ambiente de fundo.

Para contornar a limitação natural do olho humano, empregam-se dispositivos ópticos, como espelhos, lentes, microscópios, etc. Também vale lembrar o uso da fotografia como um documento óptico para futura comparação e referência. Todos estes dispositivos necessitam de superfícies extremamente planas e limpas, para evitar distorções de imagem ou perda do poder de reflexão.

Como grande inconveniente existe a necessidade de uma interpretação correta, baseada na experiência do examinador e a impossibilidade de longos períodos ininterruptos de exame devido à perda de precisão do olho humano. Este por sua vez, varia de indivíduo para indivíduo. O olho humano normal tem sensibilidade relativa variável na faixa dos 5500 a 5600 angstrons.

Obviamente, ainda permanece o fato da verificação se dar somente na superfície do componente, havendo a necessidade de uso de outro modo de inspeção para garantir a integridade do mesmo. Muitos acidentes com perdas de vidas humanas têm sido provocados pela exagerada confiança só no teste visual.

Curva da Sensibilidade Relativa do Olho Humano

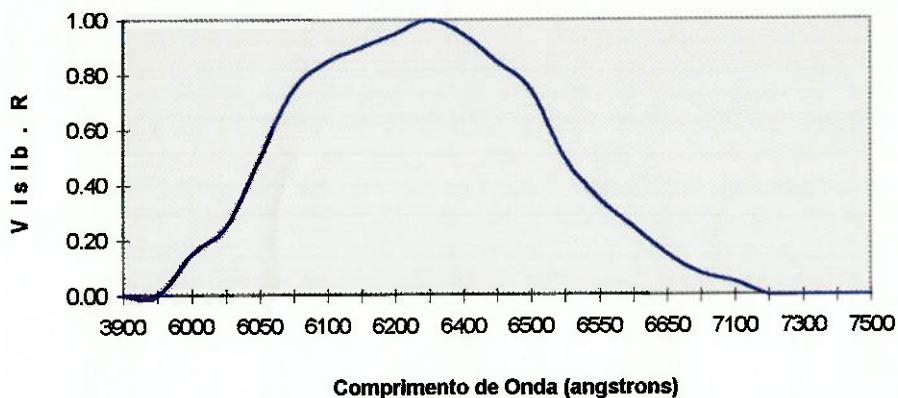


Fig.1 - Curva aproximada da sensibilidade relativa do olho humano - [ref. 6]

1.2)TESTE DE PRESSÃO:

Neste teste não destrutivo são revelados defeitos pelo fluxo de gás ou líquidos através das trincas. O objetivo do teste é garantir a estanqueidade dos recipientes submetidos a pressões de fluidos. Sendo assim, são muito utilizados em vasos de pressão.

O teste de pressão mais simples é o teste hidrostático, onde um objeto oco é preenchido com água a uma pressão maior que a pressão externa. Esta pressão é aumentada gradualmente e chega normalmente a mais de duas vezes a pressão de trabalho. Ainda é possível o uso de ar preenchendo cavidades internas, agindo com um meio líquido no exterior e causando a formação de bolhas. Entretanto, o efeito de expansão dos gases a altas pressões pode tornar o procedimento perigoso, caso ocorra uma falha no teste. Por este motivo, seu uso é pouco recomendado, a não ser para verificação de espessura, quando o teste tem grande sensibilidade. Aconselha-se que seja feita a prova hidrostática antes do teste de bolha com gases. Os líquidos e os gases utilizados também têm grande influência no resultado.

A prova hidrostática é utilizada na indústria com duas finalidades: verificar se o recipiente resiste bem a 1,5 vezes a pressão de trabalho, e detectar vazamentos. A pressão de carga deve obrigatoriamente ser exercida através de água, evitando expansão do gás no caso de um acidente.

O teste de bolha tem como vantagens a rapidez, pode ser feito por pessoal pouco qualificado, é barato, dá a localização precisa da trica e testa toda a estrutura simultaneamente. Como desvantagens este teste somente pode localizar defeitos relativamente grandes e com extensões que atravessam a parede da estrutura.

1.3)TESTE DE LÍQUIDO PENETRANTE:

Considerado como uma extensão do teste visual, o teste de líquido penetrante é usado para a detecção de descontinuidades superficiais. Poucas falhas superficiais podem ser reveladas por este teste, além das reconhecidas por um examinador experiente em um teste visual, embora este exame se torne muito mais fácil com o uso do líquido penetrante. Isto permite que o método seja usado em grande escala, já que a velocidade e confiabilidade do teste são em muito melhoradas.

O teste consiste na limpeza da peça e posterior aplicação do penetrante sobre sua superfície (fig5-a). Após permitir um tempo suficiente para a penetração do líquido em possíveis falhas superficiais se completar, o excesso de material é removido, utilizando-se algumas vezes um pó revelador, e a superfície é seca (fig5-b). As falhas funcionam como capilaridades que capturam o material. Com a superfície seca, o penetrante pode sair das trincas, denunciando a falha. O uso de líquidos fluorescentes ou reveladores na presença de determinados espectros de luz, também é empregado (fig5-c) . Por último são feitas a inspeção e a interpretação.

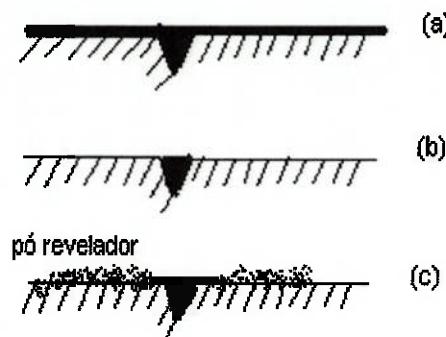


Fig. 2 -Teste com líquido penetrante

Este teste pode ser usado para materiais magnéticos e não-magnéticos. É um teste barato, confiável, rápido e de fácil aplicação. Sua maior desvantagem é o uso limitado a defeitos que tenham abertura para superfície. Também as indicações de profundidade e tamanho da trinca não são muito precisas. Outro cuidado está no manuseio dos penetrantes, já que alguns são voláteis ou tóxicos.

1.4) MÉTODOS TÉRMICOS:

Este teste consiste basicamente no aquecimento do elemento, e na observação de seu perfil de distribuição de temperatura. Falhas e defeitos alteram esta distribuição. O perfil de temperatura é obtido com o uso de substâncias indicadoras de temperatura, como pigmentos, fósforos, etc, com aparelhos sensíveis à radiação infravermelha, ou com filmes fotográficos sensíveis à radiação ultravioleta.

O aquecimento da peça pode ser feito com contato direto com uma fonte de calor (condução), por passagem de corrente elétrica, por irradiação, etc.

Como desvantagens, temos a necessidade de ambientes escuros para uma visualização do calor emitido, e não do calor refletido pelo objeto e o inconveniente de manter a peça aquecida uniformemente durante um certo período de tempo.

1.5) USO DE RADIAÇÃO

O uso da radiografia como ensaio não-destrutivo compreende a exposição da peça ou estrutura à ação de radiação penetrante, como raios X ou raios gama. Colocando-se a peça entre um detector ou um filme sensível e a fonte de radiação, é possível verificar o grau de absorção ou penetração dentro do material. Isto porque a absorção de radiação varia com a espessura e tipo de material exposto. Existem dezenas de variações deste princípio básico, cada uma específica para um certo tipo de aplicação.

Uma técnica muito utilizada é a de contaminação de fluidos. Ela é utilizada em tubulações ou canalizações. Na proximidade da zona onde ocorre o vazamento, é colocada uma válvula ou registro. É dada pressão na linha com o fluido (transportado pela canalização) e são fechadas as válvulas de entrada e saída. Em seguida, mantém-se a pressão de canalização (com os dois registros fechados), injetando mais fluido à válvula adaptada misturado à um isótopo adequado ao caso. O material radioativo vai se deslocando dentro da tubulação para onde existe o vazamento. Utilizando contadores é possível determinar o local do vazamento.

As desvantagens deste processo são: alto custo de equipamentos, necessidade de pessoal especializado, necessidade de proteção das instalações contra possíveis vazamentos de radiação, e definição prévia de parâmetros como: formação de penumbra, contraste, tempo de exposição, intensidade dos raios, etc.

O efeito da radiação no corpo humano se dá devido à ionização dos tecidos. Este efeito é cumulativo e o conceito de dose de radiação define uma exposição máxima do operador relacionada com a taxa de emissão de radiação do aparelho. O fatores de proteção contra emissões radioativas são: distância e barragens de irradiações. O primeiro parte do princípio da divergência dos raios-X. Assim, quanto maior a distância que separa o operador do tubo, menor a intensidade de radiação a qual ele é exposto. A utilização de barragens pode ser feita com folhas de chumbo de diversas espessuras.

No caso dos raios gama, outra importante preocupação está no seu correto armazenamento, visto que a fonte de radiação permanece constantemente ativa. Sua área de aplicação é vasta devido à alta precisão e grande alcance dos resultados.

1.6) ENSAIOS POR ULTRASOM

Aplicando-se pulsos de vibrações mecânicas de alta freqüência - chamadas vibrações ultrasônicas - em peças, pode-se verificar a existência de falhas internas em materiais metálicos ou não metálicos. Estas vibrações podem ser constantes ou em pulsos. Utilizando-se transdutores, é possível comparar as vibrações emitidas, com as recebidas, após a passagem do sinal pela peça. Quanto maior a freqüência de vibração, menor é o tamanho do defeito possível.

Os maiores problemas na aplicação deste método são: a dificuldade de ajuste entre os transdutores e a peça a ser ensaiada, a falta de sensibilidade à defeitos próximos à superfície do transdutor emissor, a perda de eficiência para uso de materiais muito elásticos, a limitação de detecção de defeitos com tamanho mínimo de um terço do comprimento da onda.

1.7) ENSAIOS DINÂMICOS CONVENCIONAIS:

Historicamente este método teve origem com o teste de percusão de uma peça metálica por meio de um martelo, chamado "teste de tinido". O timbre de som resultante dava uma noção se a peça possuia ou não rachaduras. Evidentemente, este método só permitia a detecção de descontinuidades grosseiras e exigia grande experiência do inspetor.

Formalmente falando, o método baseia-se na excitação dinâmica de uma estrutura ou componente em particular, através de um choque. Toda estrutura tem freqüências naturais características e também um amortecimento próprio. Estas propriedades dependem basicamente da forma da peça, de seu material e seus vínculos e restrições ao movimento.

Comparando a queda da freqüência natural em função do tempo, entre duas peças iguais, uma intacta e outra a ser testada, torna-se possível verificar se há falhas na peça de teste. Esta comparação de 'assinaturas' das estruturas, porém, só consegue indicar a existência de defeitos, não informando sobre sua localização ou tamanho.

O objetivo do presente trabalho é justamente, solucionar a deficiência dos ensaios dinâmicos, relativa à localização e extensão de falhas em estruturas.

TABELA COMPARATIVA

ENSAIOS NÃO-DESTRUTIVOS

	Custo	Alcance	Precisão	Treinamento do Operador	Equipamento	Cuidados Especiais
Visual	Muito baixo	Superficial	Limitada e Variável	Alto	Simples	Luz, Contraste
Pressão	Baixo	Toda a Estrutura	Alta só p/ defeitos grandes	Baixo	Simples	Perigo de Explosão
Liq. Penetrante	Baixo	Superficial	Razoável	Baixo	Simples	Liq. tóxicos e voláteis
Térmico	Razoável	Toda a Estrutura	Alta	Alto	Complexo	Ambientes Escuros
Radiação	Muito alto	Toda a Estrutura	Muito Alta	Muito Alto	Muito Complexo	Proteção p/ Radiação

PARTE II

REDES NEURAIS

O conceito de Redes Neurais surgiu na década de 50, quando o estudo da matemática e estatística começou a ser aplicado numa tentativa de simulação do cérebro humano. A rapidez de processamento do cérebro, sua robustez, flexibilidade de operar com informações confusas e inconsistentes e principalmente, a capacidade de aprender, se ajustando a novos ambientes, foram suficientes para motivar o estudo de novos algoritmos. Com o desenvolvimento dos computadores na década de 80, houve um grande desenvolvimento nesta área, que hoje engloba em seus campos de aplicação, desde o reconhecimento de padrões de escrita, como assinaturas, imagens, até aplicações em neurociências.

Ao contrário da programação, que exige o conhecimento de um algoritmo que solucione o problema que se propõe a resolver, a rede neural permite solucionar problemas para os quais os algoritmos de solução são desconhecidos ou conhecidos, porém de implementação inviável, quer por considerações técnicas, quer por considerações econômicas.

Formalmente podemos definir uma rede neural como sendo “uma estrutura distribuída de processamento paralelo de informação, formada por elementos processadores (que podem possuir memória local e executar operações locais de processamento de informações) interconectados por vias unidirecionais chamadas conexões. Cada elemento processador, chamado de neurônio, tem uma único sinal de saída que se ramifica em diversas conexões, servindo como entrada em outros processadores; Este sinal pode ser de qualquer tipo matemático desejado. O processamento de informação que ocorre em cada elemento pode ser definido arbitrariamente, com a ressalva que o mesmo deve ser completamente local, isto é, só pode ser uma função dos sinais que chegam ao elemento processador através das conexões de entrada e dos valores armazenados na memória local do elemento ref.[9]. Abaixo, temos uma rede neural típica:

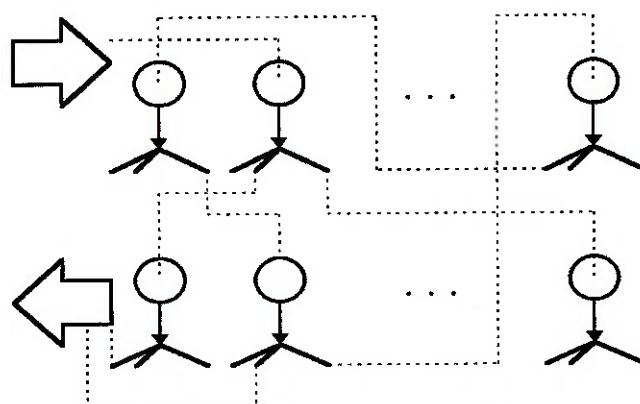


Fig. 3 - Rede Neural Típica

Uma vez recebidos os sinais de entrada de outros elementos, o neurônio analisado multiplica cada sinal um por um ‘peso’, soma o resultado e o utiliza como único sinal de saída, sendo este enviado aos neurônios das camadas inferiores. A rede se forma com a interconexão de várias células nervosas. O ‘peso’ representa a força entre as conexões que ligam estes neurônios. Abaixo, um elemento processador genérico:

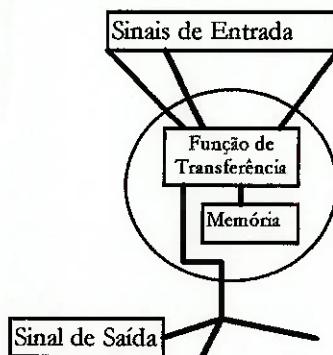


Fig. 4 - Elemento processador genérico

A função de transferência do elemento também pode modificar os valores da memória local, gerando assim um ‘aprendizado’ do processador. Este aprendizado é governado por equações matemáticas que caracterizam o regime de treinamento da rede neural. Basicamente podemos ter três tipos de regime de treinamento: treinamento supervisionado, treinamento através de notas (graded-training) e auto-organização.

O treinamento supervisionado assume que a rede está operando com um sistema que relaciona uma dada entrada com uma saída. Em outras palavras, a rede neural recebe como entrada um vetor \mathbf{x} e emite um vetor de saída \mathbf{y} . O treinamento supervisionado implica na rede receber uma seqüência de exemplos $(x_1, y_1), (x_2, y_2), \dots, (x_k, y_k)$, de pares entrada/saída corretos ou desejáveis. Com cada x_k que fornecemos à rede neural também fornecemos a ‘saída correta’ y_k . Deste modo, a rede sabe exatamente qual a saída que deveria estar emitindo. Podemos dizer que a saída atual da rede neural \mathbf{y}' é uma estimativa da saída correta \mathbf{y} . Dados estes dois valores, pode-se treinar a rede para que a diferença entre os mesmos seja a menor possível.

O treinamento através de notas é parecido com o supervisionado, com a diferença que, ao invés de fornecermos o valor y_k correto para uma entrada x_k , fornecemos uma ‘nota’ que mede quão bem a rede desempenhou seu papel de estimar o valor correto numa seqüência de múltiplos pares (x, y) . Dito de outro modo, fornecemos à rede um valor numérico que representa uma medida da performance da mesma num intervalo de tempo avaliado por uma função definida apropriadamente neste intervalo. O treinamento tem por objetivo então, minimizar ou maximizar esta função.

Na auto-organização a rede se modifica em resposta às entradas x_k recebidas. Não se definem portanto nem notas nem valores desejados y_k . Embora este tipo de treinamento possa parecer à primeira vista sem sentido, um grande número de funções de processamento de informação podem ser realizadas deste modo. Como exemplos podemos citar a estimativa de funções de densidade de probabilidade, a separação de dados em diferentes categorias e o processamento de sinais [ref. 9].

Como uma das características inerentes às redes neurais temos o fato de que para conseguirmos uma aproximação adequada do sistema que estamos modelando, é necessário um grande volume de dados para o treinamento. Devemos reservar uma parte destes dados para o teste de aceitação da rede, não usando todos os dados disponíveis para treinar a mesma, para evitar o problema do excesso de treinamento. Este problema ocorre quando a rede, ao invés de aproximar o sistema desejado de um modo que permita a interpolação de uma saída coerente y , dado uma entrada x não apresentada anteriormente, aproxima ‘bem demais’ o sistema nos pontos conhecidos, porém muito mal em pontos não apresentados. Uma analogia com o que ocorre em redes neurais pode ser vista no caso de interpolação polinomial, quando ao tentarmos ajustar um polinômio de quarto grau a três pontos, iremos garantir que o erro de aproximação nestes pontos será nulo, porém podemos ter oscilações muito grandes nos espaços que os separam. Neste caso, dizemos que a rede perdeu a capacidade de generalização.

Para evitar problemas com perda de capacidade de generalização, costuma-se separar parte dos dados de treinamento (normalmente em torno de 10%) e usá-los como dados de teste. O critério de parada do treinamento pode ser estipulado de várias maneiras: caso o erro de treinamento seja menor que um certo valor mínimo, caso o erro de treinamento não diminua após um número pré-definido de ciclos ou caso o erro de teste não diminua após um número pré-definido de ciclos. A última abordagem tem a vantagem de parar o treinamento no ponto ótimo de capacidade de generalização da rede. Quanto maior o número de ciclos, menor o erro de treinamento. Porém, o mesmo não acontece com o erro de teste, provando que a rede se tornou específica para um conjunto limitado de dados. Isto pode ser melhor observado na figura abaixo:

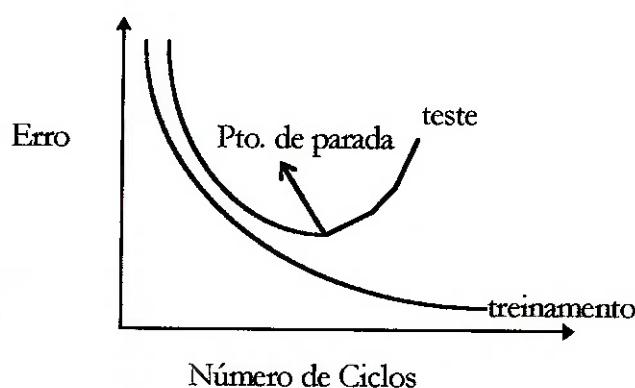


Fig. 5 - Erro de cada conjunto de dados

Há algumas diferenças básicas entre os métodos computacionais usuais (von Neuman), e o uso de Redes Neurais. Primeiramente, não há nenhum código ou programa associado com as redes. Os pesos das conexões e as funções de transferência de cada célula cumprem este papel. Segundo, uma Rede Neural pode trabalhar com entradas inconsistentes ou com ruído. Esta característica de robustez se deve ao fato dela ser formada por várias unidades de processamento independentes, o que se chama de processamento paralelo. Em programas convencionais estruturados, um único bloco pode inutilizar todo um código.

A maior vantagem das Redes Neurais está, sem dúvida, na capacidade de interpolação, utilizando dados de entrada conhecidos para treinamento. Esta capacidade de 'aprender' está ligada com o algoritmo de convergência utilizado para a correção dos pesos e das funções de transferência dos neurônios. Um método que apresenta bons resultados, sendo largamente utilizado e por este motivo, escolhido neste trabalho, é o algoritmo de '*backpropagation*'. Ele utiliza diversos sinais de entrada para um mesmo neurônio e envia somente um único sinal de saída.

A maior dificuldade no uso de Redes Neurais é a escolha dos valores de diferentes parâmetros para cada tipo de aplicação. O número de neurônios por camada, o número de camadas, as funções de transferência, o algoritmo de convergência, parâmetro de disparo, número de ciclos ou tempo de treinamento, etc., são algumas das variáveis que devem ser definidas. Muitos destes valores são escolhidos por experimentação.

No presente trabalho será utilizada a rede do tipo *backpropagation* que pertence à categoria do treinamento supervisionado.

A REDE BACKPROPAGATION:

A rede *backpropagation* possui uma arquitetura hierárquica que consiste em fileiras, ou camadas de unidades processadoras totalmente interconectadas. O processamento da informação que desejamos que a rede *backpropagation* faça é a aproximação de uma função ou mapeamento limitado $f: A \subset R^n \rightarrow R^m$, de um subespaço compacto $f[A]$ do espaço Euclídeo n-dimensional para um subespaço Euclídeo m-dimensional, através do treino com exemplos $(x_1, y_1), (x_2, y_2) \dots (x_k, y_k)$, do mapeamento, onde $y_k = f(x_k)$. Se assume que estes exemplos de treinamento são gerados selecionando x_k vetores aleatoriamente de A de acordo com uma função densidade de probabilidade fixa $p(x)$ [ref. 9].

Uma imagem macroscópica da rede *backpropagation* é mostrada na Figura 6, a seguir. De forma geral a rede consiste de k fileiras ou camadas de unidades processadoras, numeradas de baixo para cima começando por 1. A primeira camada é composta de n elementos que simplesmente recebem como entrada os componentes individuais x_i do vetor de entrada x e os distribuem, sem modificação,

para todas as unidades da segunda camada. Cada unidade em uma dada camada recebe a saída de todas as unidades da camada anterior. Isto ocorre até o fim da última fileira da rede (k -ésima), onde a camada de saída que existe em m unidades de processamento gera a estimativa y' do vetor saída desejado y . As fileiras de 2 até $k-1$ são chamadas de fileiras ocultas, pois têm pelo menos uma camada de neurônios entre as entradas e saídas da rede.

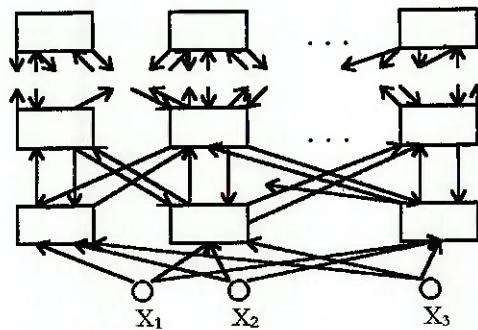


Fig.6 - Arquitetura macroscópica da rede backpropagation

Além das conexões ‘para frente’ (*feedforward*) mencionadas acima, cada unidade de uma camada escondida recebe uma realimentação de erro de cada uma das unidades que estão à sua frente. Essas realimentações, ao contrário das conexões para frente, carregam sinais diferentes, porém que saem de uma mesma unidade.

Cada unidade individual é composta de um único elemento processador chamado de *sol* e vários elementos processadores *planetas*. Cada planeta recebe entradas de um dos sóis da camada anterior e de seu próprio sol. Os sóis de camadas escondidas recebem entradas de um planeta de cada um dos sóis da próxima camada. O planeta que envia uma conexão a um dado sol é o mesmo que recebe sua entrada deste sol. Os sóis da última camada recebem a ‘resposta certa’ y_i de seu componente do vetor de saída y' em cada exemplo de treinamento. Como será descrito a seguir, a rede opera em dois estágios distintos: uma varredura para frente e uma varredura para trás [ref. 9].

A operação de rede durante o treinamento consiste em duas varreduras pela rede. A primeira varredura (para frente) começa inserindo o vetor x_k na fileira de entrada de rede. Os elementos processadores da primeira fileira transmitem todos os componentes de x_k para todas as unidades da segunda fileira da rede. As saídas das unidades da segunda fileira são então transmitidas à terceira fileira e repete-se este processamento até chegar-se às m unidades de saída, na fileira k , que emitem as componentes do vetor estimativa y_k . Após a emissão da estimativa, começa a segunda varredura (para trás) pela rede. Os sóis de saída calculam os valores dos erros de estimativa $\delta_{ki} = y_i - y'_i$ e os transmitem a seus planetas. Os planetas recalculam as parcelas da soma dos erros devido à sua entrada $\Delta_{ky}^{novo} = \Delta_{ky}^{velho} + \delta_{ki} \cdot Z_{k-1,ij}$. Estes planetas transmitem então a parcela do erro final devido a seus pesos e os transmitem aos sóis da fileira anterior. Este processo continua até chegarmos à fileira 2. O aprendizado não é feito em todas as

varreduras para trás , mas somente aós N varreduras (designado por época) terem ocorrido. Um contador é incrementado então a cada varredura e quando se completa uma época (o contador chega à N) ocorre a adaptação dos pesos dos planetas que é da forma :

$$\omega_{ij}^{novo} = \omega_{ij}^{velho} + \frac{\alpha}{N} \Delta_{ij}$$

onde o sufixo *l* indica a fileira em que está o planeta, o *i* indica o sol a que o planeta pertence, o *j* é o indexador do próprio planeta e a constante α é o fator de aprendizado (que será detalhado mais adiante). Todo este processo continua até que a rede tenha atingido um nível de performance satisfatório, ou o usuário desista do treinamento e tente experimentar novas configurações iniciais para a rede. Se a rede for considerada satisfatória, passará pelos testes de aceitação e caso obtenha sucesso, estará pronta para ser utilizada. Salienta-se que na versão final a varredura para trás (que efetua o aprendizado) não é mais necessária podendo ser eliminada, o que resulta em uma grande economia de tempo e processamento. Em anexo está um resumo das operações de uma rede *backpropagation* em fase de treinamento.

Uma questão que surge é de como garantir que a lei de adaptação de pesos, descrita anteriormente, mude os pesos da rede de forma a minimizar o erro de aproximação. Sabe-se que se desejamos encontrar um mínimo da função F (a função de erro da rede), devemos caminhar sempre na direção de $-\nabla F$ (onde ∇ denota o gradiente).

Como queremos evitar que o mínimo seja ‘ultrapassado’, devemos sempre caminhar ‘pouco’ a cada passo, resultando numa lei de adaptação que segue:

$$W^{NOVO} = W^{VELHO} - \alpha \cdot \nabla F$$

Porém, pode-se provar matematicamente que:

$$\nabla F = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=1}^N \delta_h^k Z_{(l-1)j}^k$$

onde *l*, *i*, e *j* seguem as definições dadas anteriormente e *k* denota o índice do exemplo (x_k , y_k) aplicado à rede.

Substituindo a somatória infinita por uma somatória finita, com N menor do que o número de exemplos apresentados à rede (quanto menor N, mais rápido será o aprendizado, porém podem ocorrer oscilações) e lembrando que $\Delta_{ij} = \sum_{p=1}^N \delta_h^p Z_{(l-1)j}^p$, temos a lei de adaptação descrita anteriormente:

$$\omega_{ij}^{novo} = \omega_{ij}^{velho} + \frac{\alpha}{N} \Delta_{ij}$$

PARTE III

EXEMPLIFICAÇÃO DO ENSAIO PROPOSTO

INTRODUCÃO

Uma falha numa estrutura causa uma diminuição de sua rigidez e aumento de seu amortecimento. Na maioria dos casos, quanto menor a rigidez, menor o valor das freqüências naturais, sendo a variação de inércia desprezível, principalmente no caso de trincas. Fica possível, então, associar esta variação com a identificação e localização da trinca. A utilização de uma modelagem analítica (identificação sistemática) para este caso de aplicação está restrita a estruturas de geometria simples, sendo seus modelos ainda muito sensíveis [ref. 4] a variações inerentes a medidas experimentais, fato que restringe suas aplicações práticas. O uso de Redes Neurais Artificiais (RNA) para este tipo de aplicação é bastante promissor devido a sua robustez em relação a ruídos e diferenças de dados de entrada (freqüências naturais).

A maior vantagem no uso de freqüências naturais para a identificação de falhas estruturais, utilizada portanto como uma técnica de Ensaio Não-Destrutivo (END), está no fato da medição não precisar ser feita exatamente na falha. Além disso, trata-se de um teste pontual, podendo ser facilmente automatizado. A desvantagem é a pequena sensibilidade das freqüências naturais em relação ao tamanho da trinca, limitando seu uso à aplicações específicas. Uma outra vantagem, que poderia ser comparada com outras tradicionais técnicas de END é a possibilidade de identificação de falhas internas, além do fato do componente a ser testado poder ser de materiais não-magnéticos, como plásticos e compósitos.

A metodologia usada neste trabalho é análoga aquela apresentada na [ref. 3]. A fase de treinamento da RNA é utilizada para extrair as relações de causa e efeito entre as redes neurais e a localização da falha. Desse modo não se torna necessário determinar explicitamente as leis que regem o fenômeno, bastando haver alguma relação. Após o término da fase de testes, essas relações são guardadas nos pesos das conexões da RNA. Entretanto, antes do treinamento é necessário definir a arquitetura da rede neural e seu algoritmo de treinamento, inclusive seus parâmetros de aprendizagem. Esta RNA, em particular, é então treinada com o conjunto de dados de treinamento. O próximo passo é o teste da rede para verificar o quanto ela conseguiu ‘aprender’ as relações do fenômeno [ref. 4 e 10]. A capacidade de generalização da rede só pode ser verificada se algum dado não apresentado na fase de treinamento for incluído na fase de teste. Por essa razão os dados de teste não entraram no conjunto de treinamento.

Na [ref. 3] foi verificada a importância da distribuição e quantidade de dados de entrada dentro do domínio de interesse da metodologia proposta. Além do mais, aquisição de dados experimentais envolve altos custos. Uma série de protótipos com trincas de diferentes tamanhos e localizações seria necessária para garantir uma suficiente quantidade de dados para o treinamento da RNA. Um dos objetivos deste trabalho é analisar a possibilidade e eficiência da obtenção destes dados através de simulação numérica, fazendo uso do Método de Elementos Finitos. Isto pode ser justificado com o baixo custo de obtenção de dados, aliado a uma série de vantagens proporcionadas pela automação, permitindo uma redução no tempo de geração de dados para o treinamento da RNA.

METODOLOGIA

A metodologia proposta será apresentada através do estudo de dois exemplo simples. A razão desta escolha se dá principalmente pela facilidade de obtenção de dados experimentais, incluindo a construção de um corpo-de-provas e a experimentação propriamente dita. Duas fontes distintas foram utilizadas para demonstrar a veracidade do método [refs. 8 e 6]. A metodologia será então dividida em Etapa1 e Etapa2, cada uma respectiva a um modelo.

ETAPA 1

Como primeiro exemplo usa-se uma barra engastada de 749mm de comprimento, 40 mm de largura, e 12 mm de espessura, mostrada na Figura 7. O material usado é aço ($E=210 \times 10^8 \text{ N/mm}^2$ - $\rho = 7,8 \times 10^{-2} \text{ kg/mm}^3$). O *software* de MEF usado é o SAP90 [ref. 11]. O modelo é formado de 151 elementos do tipo *viga*.

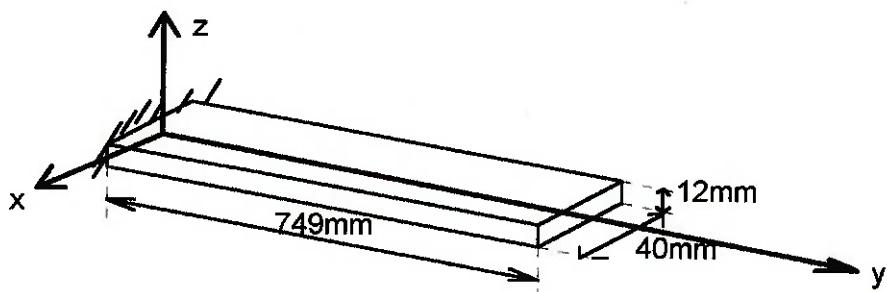


Fig. 7 - Viga Engastada

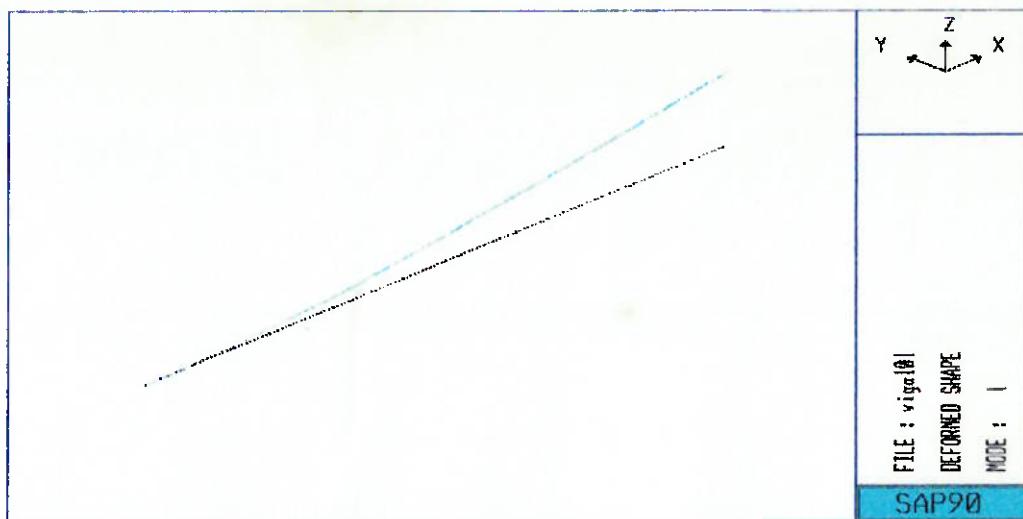


Fig. 8 - Saída gráfica da barra deformada (SAP90)

As seções transversais dos elementos, simulando defeitos, utilizados na viga estão mostrados na Figura 9.

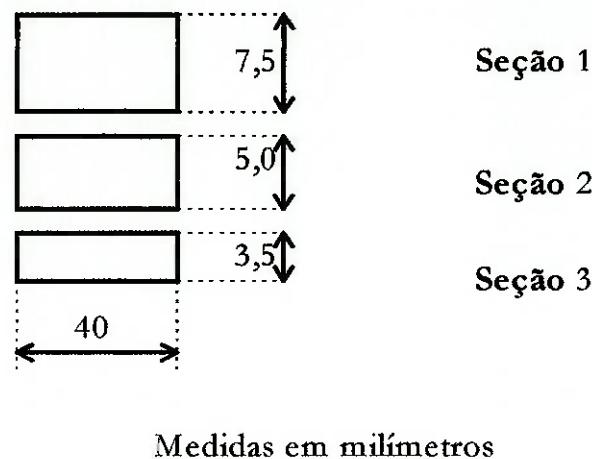


Fig. 9 - Seções transversais

O elementos de seções finas (7,5 mm, 5 mm e 3,5 mm) simulam as trincas. Cada viga possui um destes elementos que ‘caminha’ pela viga, causando mudanças nas freqüências naturais da estrutura. As cinco primeiras freqüências são obtidas para cada posição da trinca relativa ao engaste. A extensão completa da barra é coberta, variando a posição da trinca de 10 em 10 mm. O resultado é um conjunto de 74 valores, cada um relacionado com uma posição da trinca. A geração dos dados de entrada do MEF é feita usando um programa em PASCAL (ver Anexo), criando os modelos de uma forma automatizada.

Este procedimento gera uma tabela com a posição normalizada da trinca em relação ao engastamento (0 até 1) e suas respectivas freqüências naturais. A este conjunto deu-se o nome de FR74-1. O mesmo procedimento é repetido para outros dois tamanhos de trinca (seções de 5 x 40mm e 3,5 x 40mm), obtendo os conjuntos FR74-2 e FR74-3 (em Anexo).

A figura 10 mostra as primeiras quatro freqüências naturais. É importante observar a pequena sensibilidade, em valores absolutos, das freqüências naturais com a variação da posição da trinca e sua própria existência.

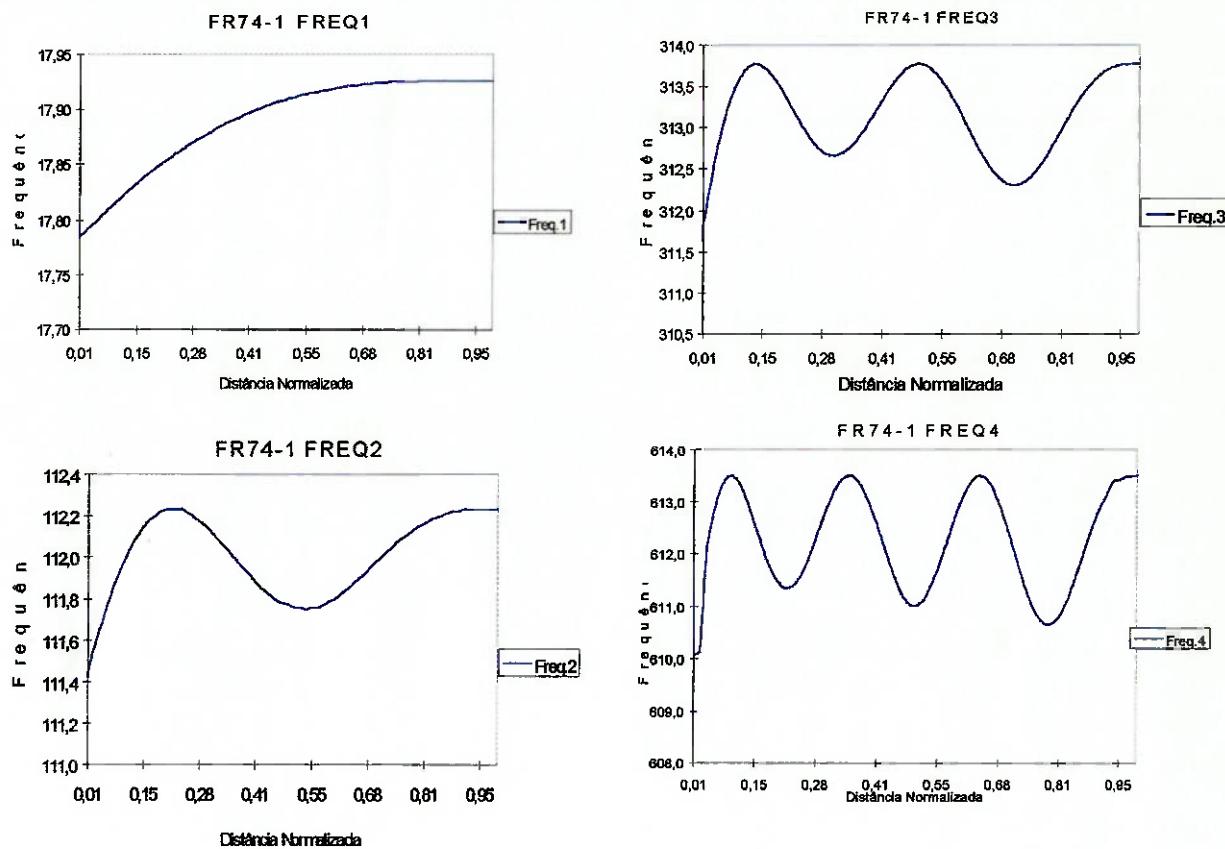


Figura 10 - Quatro primeiras freqüências naturais

O pré-processamento destes conjuntos está apresentado nas [refs. 1 e 2], gerando os grupos de conjuntos FRN74 e FRM74, baseados nas relações:

$$\text{FRN74} \rightarrow nfr_i = \frac{\omega_i^u - \omega_i}{\omega_i^u} \quad \text{FRM74} \rightarrow nfrn_i = \frac{nfr_i}{\sum_{j=1}^5 nfr_j}$$

onde ω_i^u é a freqüência natural da estrutura intacta e i é o índice de ordem da freqüência natural ($1 \rightarrow 5$). O parâmetro $nfrn_i$ (redução da freqüência natural normalizada) desenvolvida no trabalho prévio da [ref. 3], mostrou-se mais eficiente na localização das falhas, não sendo entretanto eficiente na determinação de suas extensões, como pode ser observado na Figura 11.

Uma barra engastada com mesmas dimensões e uma seção de entalhe de 7,5x40mm, foi testada experimentalmente com 28 diferentes posições de trinca [ref. 8], obtendo os grupos de dados FR28, FRN28 e FRM28, respectivamente.

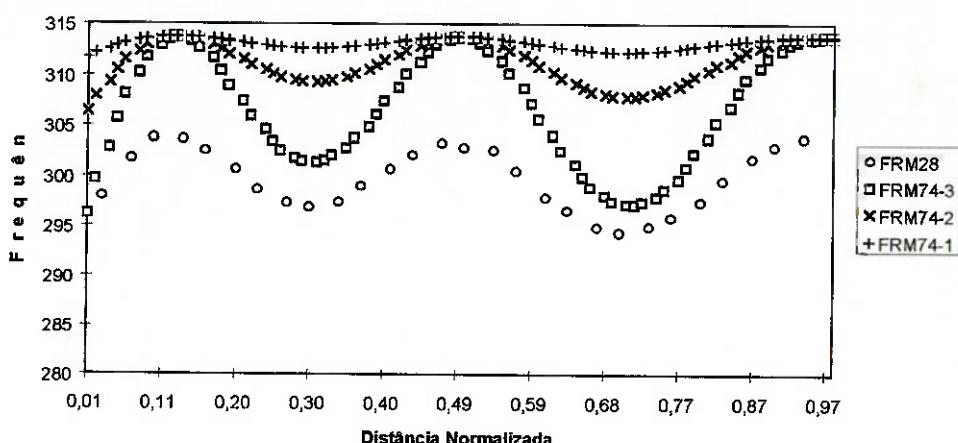
A Tabela 3 mostra os valores das primeiras cinco freqüências naturais para uma barra engastada, sem trinca e com trinca (mín), ambos obtidos experimentalmente e por MEF.

Tabela 3- Freqüências Naturais

	Freq.1	Freq.2	Freq.3	Freq.4	Freq.5
MEF	17.93	112.2	313.7	613.5	1011.3
MEF(min)	17.79	111.4	311.8	610.2	1006.3
EXP.	17.40	108.8	303.8	592.8	974.4
EXP(min).	16.55	105.3	294.3	574.2	943.5

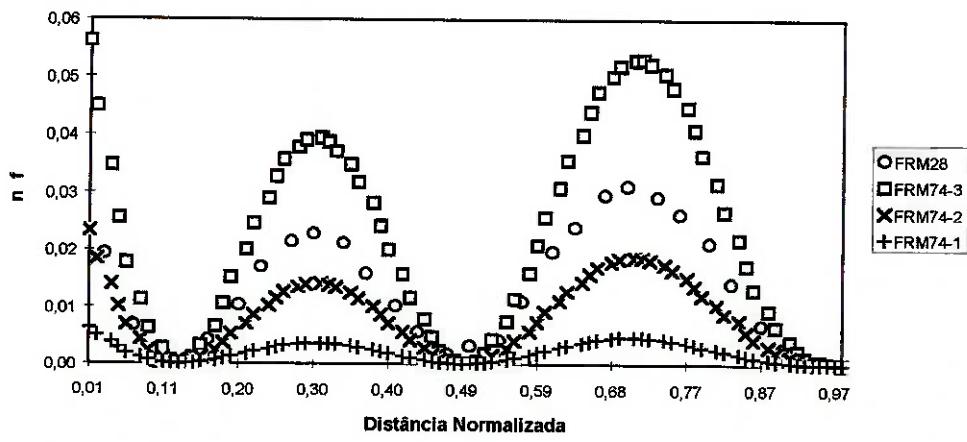
É importante notar que nenhuma das cinco primeiras freqüências naturais obtidas com o MEF, são iguais ao valores experimentais, mesmo as da viga com trinca. Isto é esperado, visto que o MEF normalmente gera uma estrutura com mais rigidez que uma estrutura real (número finitos de graus de liberdade), portanto com maiores freqüências naturais. A Figura 11 mostra o comportamento destes conjuntos para a terceira freqüência natural.

FR222-FREQ3

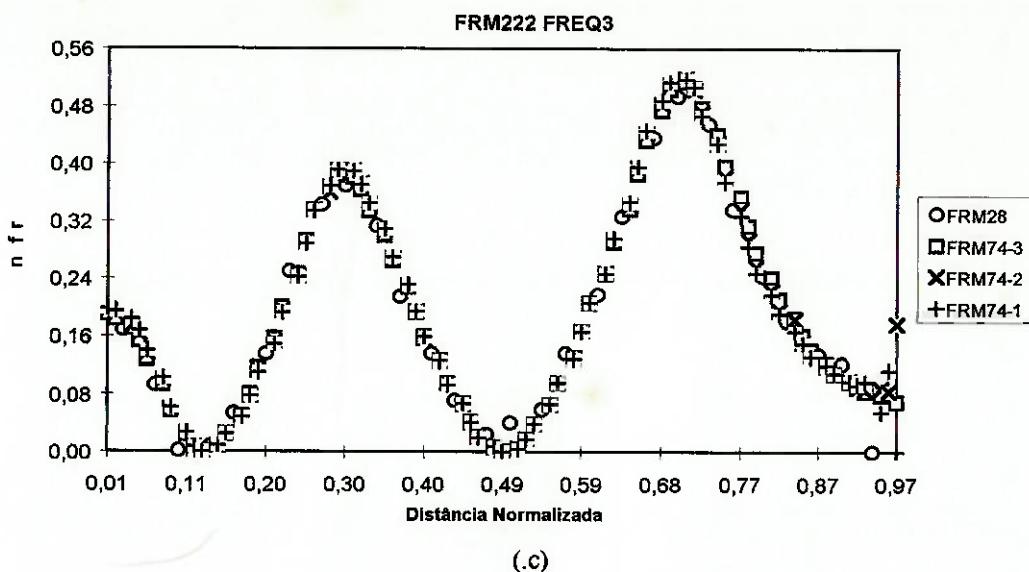


(a)

FRN222 FREQ3



(b)



(.c)

Fig. 11 Dados Experimentais x dados por MEF - terceira freqüência natural

Os dados obtidos através do MEF são usados na fase de treinamento da RNA e os dados experimentais são usados na fase de teste para verificar a eficiência da metodologia. Os dados de teste foram unidos de uma maneira pela qual pudessem englobar o respectivo conjunto de dados de uma barra com trinca maior, obtendo assim os conjuntos FR74, FR148, FR222, FRN74, FRN148, FRN222, FRM74, FRM148, FRM222 respectivamente. É importante verificar que os números 74, 148, e 222 indicam a quantidade de linhas de cada conjunto (cada uma respectiva a uma posição do entalhe e contendo as cinco primeiras freqüências naturais) para o treinamento da RNA. O *software* utilizado para a simulação das RNA foi o Neural Work Professional II Plus, sendo aplicada a técnica de ‘*backpropagation*’ com treinamento supervisionado.

Foi observado que os conjuntos de dados FR74, FR148, FR222 não foram capazes de atingir a convergência. As freqüências naturais usadas para treinamento não incluem os dados utilizados como teste (Figura 11(a)). Como foi comentado na [ref.3], o uso de RNA com treinamento supervisionado tem uma melhor capacidade de interpolação do que extrapolação. Devido a isto, eles foram descartados.

A escolha da melhor topologia foi feita pelo método de tentativa e erro, usando de um parâmetro de comparação para definir a melhor topologia de rede. Este parâmetro usava o co-seno do ângulo entre dois vetores. O primeiro vetor era formado pelos resultados reais (corpo-de-prova), e o outro, formado pelos dados originados pela rede. A topologia que resultasse num coeficiente mais próximo da unidade era escolhida para aquele respectivo conjunto de dados. Sendo assim, a escolha da melhor RNA é baseada na comparação dos parâmetros na fase de teste, e não na fase de treinamento. Com este procedimento pretende-se obter a RNA com melhor capacidade de generalização ao invés da obtenção do conjunto de melhor aproximação na fase de aprendizado, como discutido na introdução sobre Redes Neurais. A Tabela 4 mostra os parâmetros de rede que chegaram nos melhores resultados:

Tabela 4-Parâmetros da RNA

Dados	Momentum Term	Learning Coeficient	Topologia	Comparison Parameter	Comp. Par. com Gaussian Noise
FRN74	0.4	0.5	5 - 8 - 1	0.70	0.55
FRM74	0.4	0.5	5 - 6 - 1	0.98	0.99
FRN148	0.5	0.4	5 - 6 - 1	0.95	0.96
FRM148	0.5	0.4	5 - 8 - 1	0.99	0.98
FRN222	0.4	0.5	5 - 6 - 1	0.97	0.96
FRM222	0.4	0.5	5 - 6 - 1	0.99	0.99

As primeiras duas colunas mostram o ‘Momentum Coeficient’ e o ‘Learning Coeficient’ usados na técnica de *backpropagation* [ref. 4 e 10]. A coluna de topologia mostra o número de (elementos) neurônios por camada da RNA. A última coluna mostra o parâmetro que dá a precisão de cada RNA.

A Figura 12 mostra os conjuntos FRN222 e FRM222. Eles relacionam a posição estimada do entalhe com sua posição real (corpo-de-prova). No caso da resposta estimada ser idêntica à real, o gráfico torna-se uma reta a 45°.

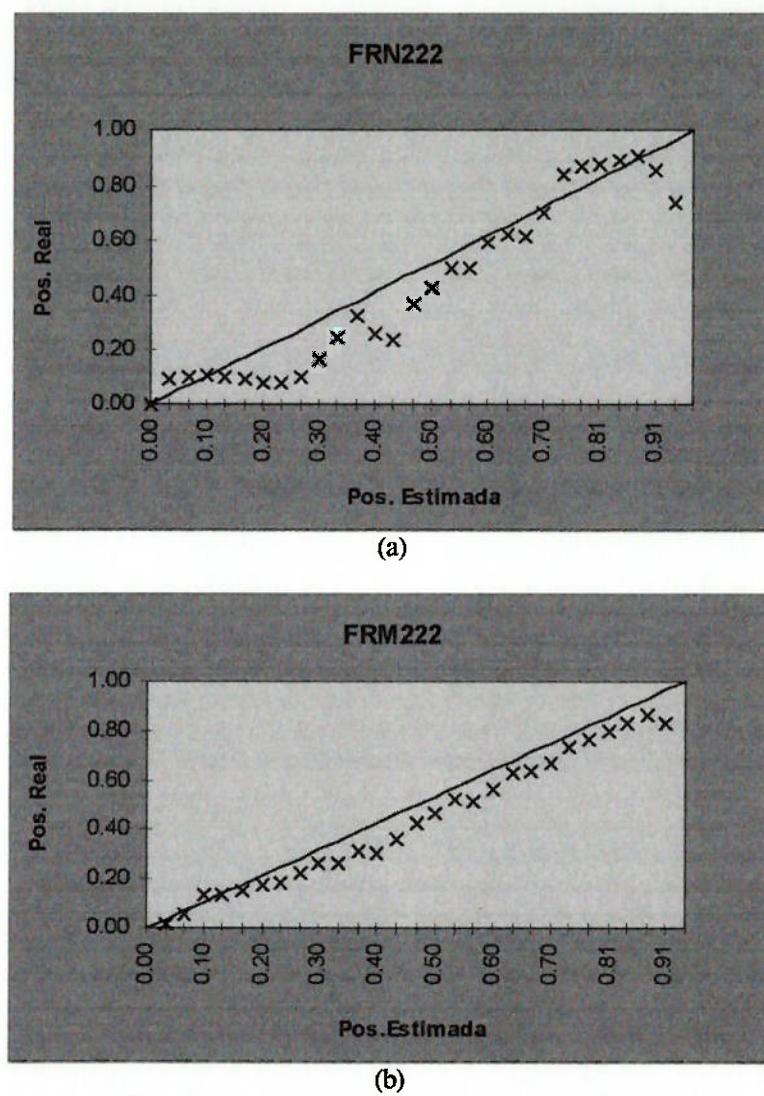


Fig. 12 Posição Estimada x Posição Real

ETAPA 2

Nesta etapa é utilizada uma barra livre-livre respeitando as dimensões da [ref.6]. Diferentemente da Etapa 1, há simetria na estrutura. Por este motivo, o entalhe só caminhou por metade do comprimento da barra. Isto possibilita um maior detalhamento do modelo e menor tempo de processamento, sem prejudicar os resultados.

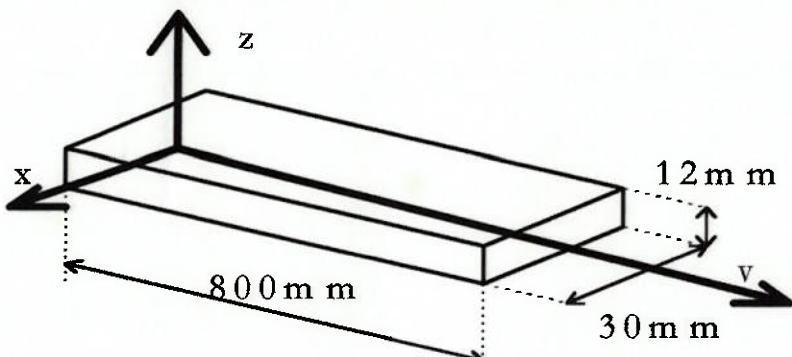
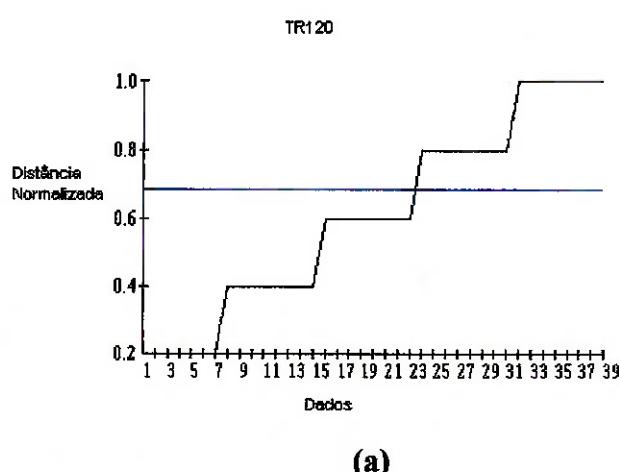
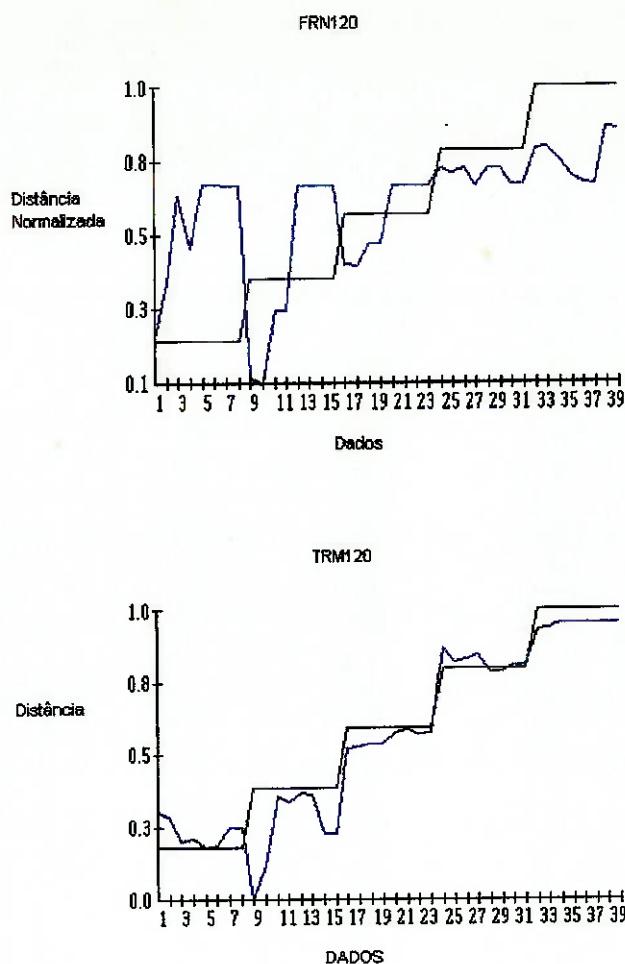


Fig. 13 - Viga livre-livre

O modelo de elementos finitos tem 323 elementos do tipo *viga*. A barra tem 0,8m de comprimentos, sua seção transversal tem 30 x 30 mm e o material utilizado é aço ($E=210$ GPa). Da mesma maneira como na Etapa 1, uma seção mais fina simula um entalhe na barra. Foram utilizados três ‘tipos’ de defeito com seções de 30 x 10 mm, 30 x 15 mm e 30 x 20 mm. Em cada barra foram feitas 40 medições, cada uma com uma posição diferente do entalhe, sendo que metade da distância original foi normalizada de 0 a 1. O conjunto de dados resultante formam três arquivos : TR10, TR15 e TR20. Estes três arquivos juntos formaram o arquivo TR120, com cento e vinte medições, sendo 40 de cada tamanho de defeito. O motivo de unir os arquivos é obter um número suficiente de dados para o treinamento da rede. Utilizando o mesmo tratamento descrito anteriormente, foram gerados os arquivos TRM120 e TRN120. O arquivo de teste é formado pelos dados da [ref.6] e chamado de TREXP e possui 40 medições.

A seguir são mostrados os desempenho dos três grupos de dados: TR120, TRN120 e TRM120, juntamente com as respectivas topologias.





(c)

Fig. 14 - Valor esperado x Valor obtido

Tabela 5-Parâmetros da RNA

Dados	Momentum Term	Learning Coefficient	Topologia	Comparison Parameter	Pesos iniciais
FR120	0.1	0.1	5 - 6 - 1	0.00	0.3
FRN120	0.1	0.1	5 - 4 - 1	0.52	0.3
FRM120	0.1	0.1	5 - 4 - 1	0.96	0.2

A topologia da rede é definida por tentativa e erro. Uma parte dos dados de treinamento (10%) é separada e utilizada para verificação da capacidade de generalização da rede. O treinamento se encerra após 20000 ciclos desde a última atualização do melhor conjunto de pesos da rede.

É interessante lembrar mais uma vez que a rede é treinada somente com dados conseguidos através do MEF, e que o teste é feito com dados experimentais. Mesmo com erros de medição, a rede é capaz de reconhecer o padrão das freqüências e prever com certa segurança a posição do defeito.

RESULTADOS, ANÁLISES E CONCLUSÕES

Como pode ser observado na Etapa 1, a análise da figura 12 mostra que os resultados obtidos são bastante adequados para os tipos de pré-processamentos de freqüências naturais (FRN e FRM). Isto permite concluir que a obtenção do conjunto de dados pode ser feita com o uso de simulação numérica através de MEF. É importante notar que o conjunto de dados de treinamento está livre de ruído, enquanto o mesmo não acontece com os dados experimentais. Mesmo com este ruído, a RNA está apta a estimar a posição do entalhe, graças à capacidade de reconhecimento de padrões e a pouca sensibilidade a ruído nos dados de entrada. Como pode ser observado da última coluna da tabela 2, a inclusão de ruído (Gaussian Noise) no conjunto de dados de treinamento, não melhora necessariamente os resultados.

Os resultados da Etapa 2 (viga livre-livre), observando a Figura 14 (c), também foram bastante satisfatórios. Novamente, a previsão da posição da trinca pode ser feita com precisão razoável, mesmo havendo erros de medição no arquivo de teste (experimental). Uma atenção especial deve ser dada na geração de modelos em MEF. Eles devem conter dados experimentais (reais), já que a RNA trabalha melhor com interpolação do que com extrapolação. No exemplo simulado, o fato pode ser notado analisando-se os conjuntos FRN de dados, que mostra uma sensível melhora obtida na união de conjuntos de dados com tamanhos de trincas diferentes (parâmetro de comparação de 0.70 a 0.97).

A aplicação prática do método tende principalmente para linhas de produção, onde a automatização deste ensaio não-destrutivo garantiria um controle de qualidade em 100% das peças, de uma maneira rápida e segura. A implantação do teste requer um modelo de elementos finitos da peça, intacta e com trincas de vários tamanhos e em várias posições. Requer também um *software* de Redes Neurais para treinamento da Rede. Tendo a RNA pronta, basta utilizar as freqüências naturais da peça medidas na linha de produção como entrada. A resposta da RNA é a existência ou não de alguma trinca e sua respectiva posição.

Após a obtenção da RNA, este teste não requer pessoal altamente especializado, os custos de implementação de medidas de freqüências naturais não são tão altos e poderiam ser diluídos com a grande quantidade de peças testadas. Esta metodologia pode ser utilizada tanto em materiais magnéticos como em não-magnéticos, e não oferece perigo de operação ou toxicidade. Além disto, ela é capaz de analisar toda a peça ou estrutura de uma só vez, interna e externamente, sem que o teste tenha que ser feito exatamente sobre o defeito.

A maior dificuldade na utilização desta metodologia é a pouca sensibilidade da rede à variações nas freqüências, o que pode limitar o método para um tamanho mínimo do defeito. Também existe o problema de aplicar o método quando existir mais de um defeito detectável numa mesma estrutura.

Trabalhos futuros desta técnica devem, além de acusar a posição de falhas estruturais, determinar o tamanho do defeito. A metodologia também deve ser capaz de trabalhar com mais de uma falha por estrutura.

BIBLIOGRAFIA

- [1] Hertz, John A.- *Introduction to the Theory of Neural Computation* - Santa Fé Institute Studies in the Sciences of Complexity-1991
- [2] Kaminski, P. C. *Análise dinâmica de estruturas modificadas. Doctoral dissertation*, Escola Politécnica da Universidade de São Paulo, Brazil, 1992.
- [3] Kaminski, P. C. *The approximate location of damage through the analysis of natural frequencies with artificial neural networks .-Proc. Insn. Mechanical Engineers*, vol 209, pp.117 - 123, 1995.
- [4] Lippmann, R. P. *An introduction to computing with neural nets. IEEE ASSP Magazine*, April 1987, 4, 22.
- [5] McGonnagle,Warren J. - *Nondestructive Testing* - Gordon and Breach Science Publishers - Second Edition -1961
- [6] Montalvão e Silva, J. M. e Araújo Gomes, A. J. M. - *Experimental Dynamic Analisys of Cracked Free-free Beams - Experimental Mechanics*, SEM, Março, 1990.
- [7] Neuro Shell 2 Manual - Ward Systems Group, Inc. - Third Edition -August 1995
- [8] Pabst, U. - *Identifikation von Randbedingungen und Rissen in einfachen schwingenden elastischen Kontinua. Fortschr.-Ber. VDI Reihe 11 Nr. 192* Dusseldorf: VDI-Verlag 1993.
- [9] Robert Hecht-Nielsen - *Neural Computing* - Addison-Wesley, 1990
- [10] Rumelhart D. E. Hinton, G. E. and Williams, R. J. *Learning internal representations by error propagation. In Parallel distributed processing:exploration in the microstruture of cognition*, Vol. 1, 1986, pp.318 - 362 (MIT Press, Cambrige, Massachusetts).
- [11]Wilson,E.L.; Habibullah, A. - *SAP90 Users Manual*, Computers & Structures Inc.
- [12] Wu X., Ghaboussi J., Garret J. H., *Use of neural networks in detection of structural damage. Computer Structures*, Vol 42 (4), 649-659, 1992.

ANEXOS

PROGRAMA DE GERAÇÃO DE DADOS DE ENTRADA PARA O SAP90 ETAPA 1 - VIGA ENGASTADA

PROGRAM CRIAVIGA;

```
var distA:real;
el,
noA,
cont:integer;
arq,arq_in:text;
viganum:string;
num:string[4]; {* ponto onde esta o defeito / identificacao do prog*}
```

BEGIN

```
assign (arq_in,'leviga.txt');
reset (arq_in);

for cont:=1 to 148 do
begin

  readln (arq_in,num);
  writeln ('num=',num);
  readln (arq_in,noA);
  readln (arq_in,distA); {* leitura do arquivo leviga.txt *}
  readln (arq_in,el);
  viganum:='VIGA'+num;
  writeln (viganum);

  assign (arq,viganum);
  rewrite(arq);
  writeln (arq,'VIGA'+num);
  writeln (arq,'SYSTEM');
  writeln (arq,'V=5');
  writeln (arq);
  writeln (arq,'JOINTS');
  writeln (arq,'1 X=0 Y=0 Z=0');
  writeln (arq,noA, ' X=',distA, ' Y=0 Z=0 G=1,',noA,',2');
  writeln (arq,noA+2,' X=',distA+0.001,' Y=0 Z=0');
  writeln (arq,'301 X=0.746 Y=0 Z=0 G=',noA+2,',301,2');
  writeln (arq,'303 X=0.749 Y=0 Z=0');
  writeln (arq);
  writeln (arq,'RESTRAINTS');
```

```

writeln (arq,'1    R=1,1,1,1,1,1');
writeln (arq,'3 303 2 R=1,1,0,1,0,1');
writeln (arq);
writeln (arq,'FRAME');
writeln (arq,'NM=2');
writeln (arq,'1 SH=R T=4.0E-2,1.2E-2 E=210E9 M=3.744');
writeln (arq,'2 SH=R T=4.0E-2,3.5E-3 E=210E9 M=3.744');
writeln (arq,'1 1 3 M=1 LP=1,0 G=48,1,2,2');
writeln (arq,'el+1,,'noA,,'noA+2,' M=2 LP=1,0');
writeln (arq,'el+2,,'noA+2,,'noA+4,' M=1 LP=1,0 G=151-(el+2),1,2,2');
writeln (arq);
writeln (arq,'SELECT');
writeln (arq,'NT=3 ID=2,151,1');
close (arq);
end; {for}
close (arq_in);
END.

```

**EXEMPLO DE PROGRAMA GERADO
ETAPA 1 - BARRA ENGASTADA
VIGA101**

VIGA101
SYSTEM
V=5

JOINTS

```

1 X=0 Y=0 Z=0
99 X= 2.4500000000E-01 Y=0 Z=0 G=1,99,2
101 X= 2.4600000000E-01 Y=0 Z=0
301 X=0.746 Y=0 Z=0 G=101,301,2
303 X=0.749 Y=0 Z=0

```

RESTRAINTS

```

1    R=1,1,1,1,1,1
3 303 2 R=1,1,0,1,0,1

```

FRAME

NM=2

```

1 SH=R T=4.0E-2,1.2E-2 E=210E9 M=3.744
2 SH=R T=4.0E-2,3.5E-3 E=210E9 M=3.744
1 1 3 M=1 LP=1,0 G=48,1,2,2
50 99 101 M=2 LP=1,0
51 101 103 M=1 LP=1,0 G=100,1,2,2

```

SELECT

NT=3 ID=2,151,1

PROGRAMA DE GERAÇÃO DE DADOS DE ENTRADA PARA O SAP90

ETAPA 1 - VIGA ENGASTADA

PROGRAM CRIA_E;

```
var num:real;
  i:integer;
  arq,arq_ext:text;
  progrnome:string;
  nome:string;

BEGIN
  assign (arq_ext,'c:\dosapl\sap90\trinca\le_E.txt');
  reset(arq_ext);

  num:=20895;    {*inicializa cabecalho*}
repeat
  readln (arq_ext,nome);    {*le nome*}

  progrnome:='E_'+nome;
  writeln(progrnome);
  assign (arq,progrnome);    {* cria arquivo destino*}
  rewrite(arq);

  writeln (arq,'E_'+nome);
  writeln (arq,'SYSTEM');
  writeln (arq,'V=7');
  writeln (arq);
  writeln (arq,'JOINTS');
  writeln (arq,'1 X=0 Y=0 Z=0');
  writeln (arq,'321 X=0.8 Y=0 Z=0 G=1,321,2');
  writeln (arq);

  writeln (arq,'RESTRAINTS');
  writeln (arq,'1 321 2     R=1,0,1,1,1,0');
  writeln (arq);
  writeln (arq,'SPRINGS');
  writeln (arq,'1     K=0,1404,0,0,0,0');
  writeln (arq,'1 321 2 K=0,1404,0,0,0,0');
  writeln (arq);
  writeln (arq,'FRAME');
  writeln (arq,'NM=1');
  writeln (arq,'1 SH=R T=3.0E-2,3.0E-2 E=(num/100),E9 M=7.02');
  writeln (arq,'1 1 3 M=1 LP=1,0 G=159,1,2,2');
  writeln (arq);
```

```

writeln (arq,'SELECT');
writeln (arq,'NT=3 ID=2,161,1'); ;

num:=num+(2.1);
close (arq);  {* fecha arquivo destino*}
writeln('num',num);
until (num>=21105);

close (arq_ext); {*fecha arquivo de leitura*}
END.

```

EXEMPLO DE PROGRAMA GERADO
ETAPA 2 - BARRA LIVRE-LIVRE
TR10_101

TRINCA101
 SYSTEM
 V=7

JOINTS

```

1 X=0 Y=0 Z=0
101 X= 2.500000000E-01 Y=0 Z=0 G=1,101,2
103 X= 2.510000000E-01 Y=0 Z=0
105 X= 2.550000000E-01 Y=0 Z=0
323 X=0.8 Y=0 Z=0 G=105,323,2

```

RESTRAINTS

```

1 323 2 R=1,0,1,1,1,0

```

SPRINGS

```

1 K=0,702,0,0,0,0
1 99 2 K=0,1404,0,0,0,0
101 K=0,702,0,0,0,0
103 K=0,702,0,0,0,0
105 321 2 K=0,1404,0,0,0,0
323 K=0,702,0,0,0,0

```

FRAME

NM=2

```

1 SH=R T=3.0E-2,3.0E-2 E=210E9 M=7.02
2 SH=R T=3.0E-2,1.0E-2 E=210E9 M=7.02
1 1 3 M=1 LP=1,0 G=49,1,2,2
51 101 103 M=2 LP=1,0
52 103 105 M=1 LP=1,0 G=109,1,2,2

```

SELECT

NT=3 ID=2,161,1

ARQUIVO DE FREQUÊNCIAS
FR74-1

Distância	Freq.1	Freq.2	Freq.3	Freq.4	Freq.5
0.01335	17.785	111	312	610	1006.3
0.02670	17.790	112	312	610	1008.3
0.04005	17.795	112	313	612	1009.8
0.05340	17.800	112	313	613	1010.8
0.06676	17.805	112	313	613	1011.2
0.08011	17.810	112	313	613	1011.2
0.09346	17.815	112	314	613	1010.8
0.10681	17.819	112	314	613	1010.2
0.12016	17.824	112	314	613	1009.4
0.13351	17.828	112	314	613	1008.7
0.14686	17.833	112	314	613	1008.1
0.16021	17.837	112	314	612	1007.8
0.17356	17.841	112	314	612	1007.7
0.18692	17.845	112	313	612	1008.0
0.20027	17.849	112	313	611	1008.4
0.21362	17.853	112	313	611	1009.0
0.22697	17.856	112	313	611	1009.7
0.24032	17.860	112	313	611	1010.4
0.25367	17.863	112	313	612	1010.9
0.26702	17.867	112	313	612	1011.2
0.28037	17.870	112	313	612	1011.2
0.29372	17.873	112	313	613	1011.0
0.30708	17.876	112	313	613	1010.5
0.32043	17.879	112	313	613	1009.8
0.33378	17.882	112	313	613	1009.1
0.34713	17.885	112	313	613	1008.3
0.36048	17.888	112	313	613	1007.7
0.37383	17.890	112	313	613	1007.3
0.38718	17.892	112	313	613	1007.2
0.40053	17.895	112	313	613	1007.3
0.41389	17.897	112	313	613	1007.7
0.42724	17.899	112	313	612	1008.3
0.44059	17.901	112	314	612	1009.1
0.45394	17.903	112	314	612	1009.8
0.46729	17.905	112	314	611	1010.5
0.48064	17.907	112	314	611	1011.0
0.49399	17.908	112	314	611	1011.2
0.50734	17.910	112	314	611	1011.2
0.52069	17.911	112	314	611	1010.9
0.53405	17.913	112	314	611	1010.3
0.54740	17.914	112	314	612	1009.6
0.56075	17.915	112	313	612	1008.9
0.57410	17.916	112	313	612	1008.2
0.58745	17.917	112	313	613	1007.6
0.60080	17.918	112	313	613	1007.3
0.61415	17.919	112	313	613	1007.2
0.62750	17.920	112	313	613	1007.5
0.64085	17.921	112	313	613	1008.0
0.65421	17.921	112	313	613	1008.6
0.66756	17.922	112	312	613	1009.4
0.68091	17.923	112	312	613	1010.1
0.69426	17.923	112	312	613	1010.7
0.70761	17.924	112	312	612	1011.1
0.72096	17.924	112	312	612	1011.3

0.73431	17.924	112	312	612	1011.1
0.74766	17.925	112	312	611	1010.7
0.76101	17.925	112	313	611	1010.0
0.77437	17.925	112	313	611	1009.2
0.78772	17.925	112	313	611	1008.4
0.80107	17.925	112	313	611	1007.6
0.81442	17.926	112	313	611	1007.1
0.82777	17.926	112	313	611	1006.7
0.84112	17.926	112	313	611	1006.6
0.85447	17.926	112	313	612	1006.8
0.86782	17.926	112	313	612	1007.2
0.88117	17.926	112	314	612	1007.9
0.89453	17.926	112	314	613	1008.6
0.90788	17.926	112	314	613	1009.3
0.92123	17.926	112	314	613	1010.0
0.93458	17.926	112	314	613	1010.6
0.94793	17.926	112	314	613	1010.9
0.96128	17.926	112	314	613	1011.1
0.97463	17.926	112	314	613	1011.2
0.98798	17.926	112	314	614	1011.3

ARQUIVO DE FREQÜÊNCIAS
FR74-2

Distância	Freq.1	Freq.2	Freq.3	Freq.4	Freq.5
0.01335	17.363	109	306	601	994
0.02670	17.383	110	308	605	1000.8
0.04005	17.402	110	309	608	1006.0
0.05340	17.422	110	311	610	1009.5
0.06676	17.441	111	312	612	1011.1
0.08011	17.460	111	312	613	1011.0
0.09346	17.478	111	313	613	1009.4
0.10681	17.496	111	313	613	1006.8
0.12016	17.514	112	314	612	1003.8
0.13351	17.531	112	314	611	1001.0
0.14686	17.548	112	314	610	999
0.16021	17.565	112	313	608	998
0.17356	17.581	112	313	607	998
0.18692	17.597	112	313	606	999
0.20027	17.613	112	312	605	1000.3
0.21362	17.628	112	312	605	1002.7
0.22697	17.642	112	311	605	1005.3
0.24032	17.657	112	311	606	1007.8
0.25367	17.671	112	310	606	1009.8
0.26702	17.684	112	310	607	1011.0
0.28037	17.697	112	310	609	1010.2
0.29372	17.710	112	309	610	1010.4
0.30708	17.723	112	309	611	1008.3
0.32043	17.734	112	309	612	1005.6
0.33378	17.746	112	310	613	1002.6
0.34713	17.757	111	310	613	1,000
0.36048	17.768	111	310	613	997
0.37383	17.778	111	311	613	996
0.38718	17.788	111	311	612	995
0.40053	17.798	111	312	611	995
0.41389	17.807	111	312	610	997

0.42724	17.815	111	312	608	1,000
0.44059	17.824	111	313	607	1002.7
0.45394	17.832	111	313	606	1005.6
0.46729	17.839	110	314	605	1008.2
0.48064	17.846	110	314	604	1010.2
0.49399	17.853	110	314	604	1011.2
0.50734	17.859	110	314	604	1011.0
0.52069	17.865	110	314	604	1009.8
0.53405	17.871	110	313	605	1007.6
0.54740	17.876	110	313	606	1004.9
0.56075	17.881	110	313	608	1002.0
0.57410	17.886	110	312	609	999
0.58745	17.890	110	311	610	997
0.60080	17.894	110	311	612	996
0.61415	17.898	111	310	613	995
0.62750	17.901	111	310	613	996
0.64085	17.904	111	309	613	998
0.65421	17.907	111	309	613	1000.7
0.66756	17.910	111	308	613	1003.7
0.68091	17.912	111	308	612	1006.6
0.69426	17.914	111	308	610	1009.1
0.70761	17.916	111	308	609	1010.7
0.72096	17.917	111	308	607	1011.2
0.73431	17.919	111	308	606	1010.6
0.74766	17.920	112	308	605	1008.9
0.76101	17.921	112	309	603	1006.4
0.77437	17.922	112	309	603	1003.4
0.78772	17.923	112	309	602	1000.3
0.80107	17.924	112	310	602	997
0.81442	17.924	112	310	603	995
0.82777	17.925	112	311	603	993
0.84112	17.925	112	311	604	993
0.85447	17.925	112	312	606	993
0.86782	17.926	112	312	607	995
0.88117	17.926	112	313	609	997
0.89453	17.926	112	313	610	1000.2
0.90788	17.926	112	313	611	1003.2
0.92123	17.926	112	314	612	1006.0
0.93458	17.926	112	314	613	1008.3
0.94793	17.926	112	314	613	1009.9
0.96128	17.926	112	314	613	1010.8
0.97463	17.926	112	314	613	1011.2
0.98798	17.926	112	314	614	1011.3

ARQUIVO DE FREQUÊNCIAS FR74-3

Distância	Freq.1	Freq.2	Freq.3	Freq.4	Freq.5
0.01335	16.345	104	296	586	974
0.02670	16.398	105	300	594	988
0.04005	16.449	106	303	600	999
0.05340	16.500	107	306	606	1006.9
0.06676	16.551	108	308	610	1010.8
0.08011	16.600	109	310	613	1010.5
0.09346	16.649	109	312	613	1006.1
0.10681	16.698	110	313	613	999
0.12016	16.745	110	314	610	990

0.13351	16.792	111	314	607	983
0.14686	16.838	111	313	603	977
0.16021	16.883	112	313	599	975
0.17356	16.927	112	312	595	975
0.18692	16.971	112	310	593	978
0.20027	17.014	112	309	591	983
0.21362	17.056	112	307	590	989
0.22697	17.097	112	306	591	996
0.24032	17.137	112	305	592	1002.3
0.25367	17.176	112	303	594	1007.5
0.26702	17.214	112	303	597	1010.6
0.28037	17.251	112	302	600	1011.0
0.29372	17.288	111	302	604	1008.3
0.30708	17.323	111	301	607	1002.8
0.32043	17.357	111	302	610	995
0.33378	17.391	110	302	612	987
0.34713	17.423	110	303	613	979
0.36048	17.454	110	304	613	973
0.37383	17.484	109	305	612	969
0.38718	17.513	109	306	610	968
0.40053	17.541	108	307	607	970
0.41389	17.567	108	309	603	975
0.42724	17.593	108	310	599	981
0.44059	17.618	108	311	596	988
0.45394	17.641	107	312	592	996
0.46729	17.663	107	313	589	1003.1
0.48064	17.685	107	314	587	1008.3
0.49399	17.705	107	314	587	1011.0
0.50734	17.724	107	314	587	1010.6
0.52069	17.742	107	313	588	1007.2
0.53405	17.759	107	312	590	1001.5
0.54740	17.775	107	311	593	994
0.56075	17.790	107	310	597	986
0.57410	17.803	107	309	601	980
0.58745	17.816	107	307	605	974
0.60080	17.828	107	306	608	970
0.61415	17.840	107	304	611	969
0.62750	17.850	108	303	613	971
0.64085	17.859	108	301	613	975
0.65421	17.868	108	300	613	982
0.66756	17.875	108	299	611	990
0.68091	17.882	109	298	608	998
0.69426	17.889	109	297	605	1005.2
0.70761	17.894	109	297	601	1009.8
0.72096	17.899	110	297	597	1011.2
0.73431	17.904	110	297	593	1009.5
0.74766	17.908	110	298	590	1005.1
0.76101	17.911	110	299	587	999
0.77437	17.914	111	300	584	991
0.78772	17.917	111	301	583	983
0.80107	17.919	111	302	582	976
0.81442	17.920	111	304	583	969
0.82777	17.922	112	305	584	964
0.84112	17.923	112	307	587	962
0.85447	17.924	112	308	590	962
0.86782	17.924	112	310	594	964
0.88117	17.925	112	311	598	970
0.89453	17.925	112	312	602	977
0.90788	17.926	112	312	606	986

0.92123	17.926	112	313	609	995
0.93458	17.926	112	313	611	1001.9
0.94793	17.926	112	314	612	1006.9
0.96128	17.926	112	314	613	1009.7
0.97463	17.926	112	314	613	1011.0
0.98798	17.926	112	314	613	1011.3

ARQUIVO DE FREQUÊNCIAS
TR120

251.5	684.1	1327	2166	3185	0.0200
251.5	684.0	1327	2166	3184	0.0450
251.5	684.0	1327	2166	3184	0.0700
251.5	684.0	1327	2165	3183	0.0950
251.5	684.0	1327	2165	3182	0.1200
251.5	684.0	1327	2164	3181	0.1450
251.5	684.0	1327	2164	3179	0.1700
251.5	683.9	1326	2163	3178	0.1950
251.5	683.8	1326	2162	3177	0.2200
251.5	683.7	1326	2161	3176	0.2450
251.5	683.6	1325	2161	3176	0.2700
251.4	683.4	1325	2160	3177	0.2950
251.4	683.3	1324	2160	3178	0.3200
251.4	683.1	1324	2160	3179	0.3450
251.4	683.0	1324	2161	3181	0.3700
251.4	682.8	1324	2161	3181	0.3950
251.3	682.7	1324	2162	3183	0.4200
251.3	682.7	1324	2162	3183	0.4450
251.3	682.4	1324	2164	3184	0.4700
251.2	682.3	1324	2165	3183	0.4950
251.2	682.2	1325	2165	3182	0.5200
251.2	682.2	1325	2165	3181	0.5450
251.2	682.2	1326	2165	3179	0.5700
251.1	682.2	1326	2165	3178	0.5950
251.0	682.2	1326	2164	3178	0.6200
251.0	682.3	1327	2164	3177	0.6450
251.0	682.4	1327	2163	3178	0.6700
251.0	682.5	1327	2162	3179	0.6950
250.9	682.6	1327	2161	3181	0.7200
250.9	682.8	1327	2161	3182	0.7450
250.9	683.0	1327	2161	3183	0.7700
250.8	683.2	1327	2161	3184	0.7950
250.8	683.3	1326	2161	3184	0.8200
250.8	683.5	1326	2162	3183	0.8450
250.8	684.0	1325	2163	3182	0.8700
250.7	684.0	1325	2164	3181	0.8950
250.7	684.0	1325	2164	3180	0.9200
250.7	684.0	1324	2165	3179	0.9450
250.7	684.0	1324	2165	3178	0.9700
250.7	684.0	1324	2165	3178	0.9950

251.5	684.1	1327	2166	3185	0.0200
251.5	684.0	1327	2166	3185	0.0450
251.5	684.0	1327	2166	3184	0.0700
251.5	684.0	1327	2166	3184	0.0950
251.5	684.0	1327	2165	3183	0.1200
251.5	684.0	1327	2165	3183	0.1450
251.5	684.0	1327	2165	3182	0.1700
251.5	684.0	1327	2164	3181	0.1950
251.5	683.9	1327	2164	3181	0.2200
251.5	683.9	1326	2163	3181	0.2450
251.5	683.8	1326	2163	3181	0.2700
251.5	683.7	1326	2163	3181	0.2950
251.5	683.7	1326	2163	3181	0.3200
251.4	683.6	1326	2163	3182	0.3450
251.4	683.4	1325	2164	3184	0.3700
251.4	683.4	1325	2164	3184	0.3950
251.4	683.4	1325	2164	3184	0.4200
251.4	683.3	1325	2164	3184	0.4450
251.4	683.2	1326	2165	3184	0.4700
251.4	683.2	1326	2166	3184	0.4950
251.4	683.1	1326	2166	3184	0.5200
251.3	683.1	1326	2166	3183	0.5450
251.3	683.1	1327	2165	3181	0.5700
251.3	683.1	1327	2165	3181	0.5950
251.3	683.1	1327	2165	3181	0.6200
251.3	683.1	1327	2165	3181	0.6450
251.2	683.2	1327	2164	3181	0.6700
251.2	683.2	1327	2164	3182	0.6950
251.2	683.4	1327	2164	3183	0.7200
251.2	683.4	1327	2163	3183	0.7450
251.2	683.5	1327	2163	3184	0.7700
251.2	683.6	1327	2163	3184	0.7950
251.1	683.7	1327	2164	3184	0.8200
251.1	683.8	1327	2164	3184	0.8450
251.1	683.9	1326	2164	3184	0.8700
251.1	683.9	1326	2165	3183	0.8950
251.1	683.9	1326	2165	3183	0.9200
251.1	684.0	1326	2165	3182	0.9450
251.1	684.0	1326	2166	3181	0.9700
251.1	684.0	1326	2166	3181	0.9950
251.5	684.1	1327	2166	3185	0.0200
251.5	684.0	1327	2166	3185	0.0450
251.5	684.0	1327	2166	3185	0.0700
251.5	684.0	1327	2166	3184	0.0950
251.5	684.0	1327	2166	3184	0.1200
251.5	684.0	1327	2165	3184	0.1450
251.5	684.0	1327	2165	3183	0.1700
251.5	684.0	1327	2165	3183	0.1950
251.5	684.0	1327	2165	3183	0.2200
251.5	684.0	1327	2165	3183	0.2450
251.5	683.9	1327	2165	3183	0.2700
251.5	683.9	1327	2164	3183	0.2950
251.5	683.9	1327	2164	3183	0.3200
251.5	683.8	1326	2164	3183	0.3450

251.5	683.8	1326	2165	3184	0.3700
251.5	683.8	1326	2165	3184	0.3950
251.5	683.7	1326	2165	3184	0.4200
251.5	683.7	1326	2165	3185	0.4450
251.4	683.6	1326	2165	3184	0.4700
251.4	683.6	1327	2166	3184	0.4950
251.4	683.6	1327	2166	3184	0.5200
251.4	683.6	1327	2166	3184	0.5450
251.4	683.6	1327	2166	3183	0.5700
251.4	683.6	1327	2166	3183	0.5950
251.4	683.6	1327	2166	3183	0.6200
251.4	683.6	1327	2165	3183	0.6450
251.4	683.6	1327	2165	3183	0.6700
251.4	683.7	1327	2165	3183	0.6950
251.4	683.7	1327	2165	3184	0.7200
251.3	683.7	1327	2165	3184	0.7450
251.3	683.8	1327	2165	3184	0.7700
251.3	683.8	1327	2165	3184	0.7950
251.3	683.9	1327	2165	3185	0.8200
251.3	683.9	1327	2165	3184	0.8450
251.3	684.0	1327	2165	3184	0.8700
251.3	684.0	1327	2165	3184	0.8950
251.3	684.0	1327	2165	3183	0.9200
251.3	684.0	1327	2166	3183	0.9450
251.3	684.0	1326	2166	3183	0.9700
251.3	684.0	1326	2166	3183	0.9950