



UNIVERSIDADE ESTADUAL PAULISTA  
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

# IDENTIFICAÇÃO DE FALHAS ESTRUTURAIS USANDO SENSORES E ATUADORES PIEZELÉTRICOS E REDES NEURAIS ARTIFICIAIS

*Rogério Mendonça Furtado*

Dissertação apresentada à Faculdade de Engenharia de Ilha Solteira da Universidade Estadual Paulista “Júlio de Mesquita Filho”, como parte dos requisitos exigidos para a obtenção do título de **Mestre em Engenharia Mecânica**.

**Orientador: PROF. DR. VICENTE LOPES JÚNIOR**

Ilha Solteira, Fevereiro de 2004

*“Talvez não tenhamos conseguido fazer o melhor,  
Mas lutamos para que o melhor fosse feito...  
Não somos o que deveríamos ser,  
Não somos o que iremos ser,  
Mas, graças a Deus, não somos o que éramos antes”.*

*Martin Luther King*

## *Dedicatória*

*A Deus por ter me concedido o dom da vida, aos meus pais Rui e Janete por terem investido suas vidas em seus filhos e a minha irmã Renata, que acima de tudo é uma grande amiga e companheira.*

# *Agradecimentos*

Ao professor Vicente Lopes Júnior por sua postura, a qual eu admiro, e pela amizade que foi além de uma mera relação profissional.

A minha namorada Flávia Luz de Souza por sua tolerância e apoio nos momentos difíceis.

Aos amigos de longa estrada e aos novos que tive o prazer de conhecer nesses anos agradáveis e inesquecíveis que passei em Ilha Solteira.

Aos companheiros de república, Adriano, Gilson, Luiz e Sandhoerts, pelos anos que passamos juntos.

Aos amigos do grupo de materiais e sistemas inteligentes, GMSINT.

Ao grupo de polímeros (GPol), do departamento de Física e Química.

Aos professores que compartilharam comigo parte de seus conhecimentos.

Aos técnicos que me auxiliaram nas execuções das tarefas.

Ao Departamento de Engenharia Mecânica – DEM

A Faculdade de Engenharia de Ilha Solteira da Universidade Estadual Paulista, a qual serei eternamente grato.

A Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo suporte financeiro que possibilitou a execução deste trabalho.

FURTADO, R. M. *Identificação de falhas estruturais usando sensores e atuadores piezelétricos e redes neurais artificiais*, Ilha Solteira, 2004 . 152p., Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Estadual Paulista.

## RESUMO

A proposta deste trabalho é a obtenção de uma metodologia robusta para identificação de falhas estruturais combinando as vantagens de duas metodologias, que não são baseadas em modelos matemáticos, ou seja: impedância elétrica obtida com atuador e sensor piezocerâmico (materiais inteligentes) e redes neurais artificiais. O termo *materiais inteligentes* (smart materials) conhecido também por material ativo é dado a uma classe de material que exhibe propriedades não encontradas em materiais convencionais. Alguns destes materiais são: compostos de materiais piezelétricos, eletroresistivo e magnetorresistivo, fluidos e sólidos electro-reológicos, e outros. Uma das principais características do PZT (Titanato Zirconato de Chumbo), que permite utilizá-lo como sensor e atuador, é o efeito piezelétrico, ou seja, a aplicação de um campo elétrico resulta em deformação do material (efeito inverso), enquanto, a aplicação de tensão mecânica resulta no surgimento de um campo elétrico (efeito direto). Estas características associadas ao conceito de impedância elétrica e ao conceito de falha métrica permitem a localização e o monitoramento da falha. Esta técnica utiliza altas frequências e excita os modos locais, proporcionando, assim, o monitoramento de qualquer mudança da impedância mecânica estrutural na região de influência do PZT. Redes neurais artificiais (RNA) fazem parte de um amplo conceito chamado *inteligência artificial*. Redes neurais têm sua base associada ao funcionamento do cérebro humano, que após treinamento possuem a capacidade de “aprender”. Esta ciência é objeto de estudo em diversos centros de pesquisa e, embora já tenha grande aplicabilidade, o sucesso de sua utilização depende do caso em que está sendo aplicada e de certa sutileza do projetista, uma vez que o processo ainda é empírico e teorias ainda estão sendo formuladas. Existem diversas concepções de redes neurais. O tipo de rede abordada neste trabalho será a rede com retropropagação do erro “backpropagation”, que utiliza o treinamento supervisionado. O conceito de redes neurais será aplicado no trabalho com a função de detecção e quantificação da falha. Se o modelo da estrutura for conhecido, pode-se treinar a rede para diversas condições de falhas e em diversos estágios, obtendo-se assim a base de treinamento da

rede. As simulações numéricas são obtidas através de modelos gerados pelo método dos elementos finitos. O trabalho conclui apresentando resultados obtidos nos testes experimentais.

***Palavra-Chave:*** Impedância elétrica, Materiais Piezelétricos, Redes Neurais Artificiais, Monitoramento de Danos, Identificação de Falhas.

FURTADO, R. M. *Faults identification using piezoelectric sensor and actuator and artificial neural networks*, Ilha Solteira, 2004. 152p., (Master Thesis), Engineering Faculty, Paulista State University.

## **ABSTRACT**

The proposal of this work is the obtaining of a robust methodology for identification of structural faults combining the advantages of two methodologies, which are not based on mathematical models. The methodology applies electric impedance technique, obtained with actuator and sensor piezoceramic (smart materials), and artificial neural networks. The term "smart materials" is given for a material class that not exhibits properties found in conventional materials. Some of these materials are: composed of piezoelectric material, electrostrictive and magnetostrictive, electrorheological fluids and solids shape memory alloys, and others. One of the main characteristics of PZT (Lead Zirconate Titanate), that allows to use it as sensor and actuator, is the piezoelectric effect, where the application of an electric field results in deformation of the material (inverse effect), while the application of mechanical tension results in the appearance of an electric field (direct effect). These characteristics associated to the concept of electric impedance and the concept of metric fault allow the location and the monitoring of the fault. This technique uses high frequencies and low voltage and it excites local modes, providing, the monitoring of any change on the structural mechanical impedance in the area of influence of the PZT. Artificial Neural Networks (ANN) are part of a wide concept called artificial intelligence. Neural networks has its base associated to the operation of the human brain, that after training possess the capacity "to learn". This science is a study object in several research centers and, although it already has great application. The success of its use depends of the case and planner's certain keenness, once the process is still empiric and theories are still being formulated. Several conceptions of neural networks exist. The network approach in this work considers "backpropagation" algorithm and supervised training. The concept of neural networks will be applied for detection and quantification of the faults. If the model of the structure is known, it should be used to train the net for several conditions of faults and several apprenticeships. The numeric simulations are obtained through models generated by the finite element method. The work concludes presenting some results for experimental tests.

**Key-word:** Electric Impedance, Piezoelectric Materials, Artificial Neural Networks, Faults Monitoring, Fault Identification.

# Sumário

---

<b>CAPÍTULO 1</b>	<b>25</b>
<b>INTRODUÇÃO</b>	<b>25</b>
1.1 Motivação	25
1.2 Estruturas Inteligentes	26
1.3 Organização da Dissertação	30
<b>CAPÍTULO 2</b>	<b>32</b>
<b>CONCEITOS BÁSICOS UTILIZADOS NA METODOLOGIA</b>	<b>32</b>
2.1 Conceitos Básicos de Piezeletricidade	32
2.1.1 Equações Constitutivas da Piezeletricidade	35
2.1.2 Sensores e Atuadores Piezelétricos	38
2.1.3 Atuadores Piezelétricos	39
2.1.4 Sensores Piezelétricos	41
2.2 A Técnica da Impedância Elétrica	41
2.2.1 Área de atuação do PZT	45
2.2.2 Características da Resposta Medida em Frequência	46
2.2.3 Falha Métrica	47
<b>CAPÍTULO 3</b>	<b>48</b>
<b>CONCEITOS BÁSICOS DE REDES NEURAIIS ARTIFICIAIS</b>	<b>48</b>
3.1 Introdução e o Modelo Biológico	48
3.2 Breve Histórico Sobre Redes Neurais Artificiais	51
3.3 Modelo Neural Artificial	53
3.4 Estrutura da Rede Neural Artificial	59
3.5 Generalização e Representação	61
3.5.1 Representação com uma Camada de Neurônios	62
3.5.2 Representação de Duas ou mais Camadas de Neurônios	64
3.6 Treinamento da Rede Neural	66
3.6.1 Aprendizado Hebbiano	68
3.6.2 Os Perceptrons e seu Treinamento	69
3.6.3 Regra Delta	71
3.6.4 Algoritmo Backpropagation	74
3.6.5 Algoritmo Backpropagation com Momento	82
3.6.6 Vantagens do Backpropagation	83
3.6.7 Desvantagens do Backpropagation	84

<b>CAPÍTULO 4</b>	<b>85</b>
<b>METODOLOGIA PROPOSTA E APLICAÇÕES NUMÉRICAS</b>	<b>85</b>
4.1 Metodologia Proposta	85
4.2 Aplicações Numéricas	87
4.2.1 Pré - Processamento	88
4.3 Exemplo – 1: Viga de Aço Engastada	89
4.3.1 Localização da falha	95
4.3.2 Quantificação da Falha	99
4.4 Exemplo – 2: Viga de Alumínio Livre-Livre	101
4.4.1 Localização da falha	105
4.4.2 Quantificação da Falha	108
4.5 Generalização	110
4.5.1 Viga de Aço Livre-Livre	110
4.5.2 Viga de Alumínio Engastada-Livre	114
<b>CAPÍTULO 5</b>	<b>119</b>
<b>RESULTADOS EXPERIMENTAIS</b>	<b>119</b>
5.1 Barra de Alumínio	121
5.1.1 Localização da Falha	122
5.2 Estrutura do Tipo Virabrequim	125
5.2.1 Localização da falha	126
5.2.2 Quantificação da Falha	129
5.3 Barra de Aço	131
<b>CAPÍTULO 6</b>	<b>136</b>
<b>CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS</b>	<b>136</b>
6.1 Considerações Finais	136
6.2 Sugestões para Trabalhos Futuros	138
<b>CAPÍTULO 7</b>	<b>140</b>
<b>REFERÊNCIAS</b>	<b>140</b>
<b>APÊNDICE - A</b>	<b>145</b>
<b>MEDIDAS DE IMPEDÂNCIA ELÉTRICA COM APARELHO DE BAIXO CUSTO</b>	<b>145</b>
A.1 Medida de Impedância Convencional	146
A.2 Circuito Alternativo para a Medição da Impedância Elétrica	147
A.3 Cadeia de Medição	151

# Lista de Figuras

---

Figura 1.1 – Conceitos prevaletentes de estruturas inteligentes.	27
Figura 2.1 – Célula unitária de PZT: 1) Tipo Perovskite Titanato Zirconato de Chumbo (PZT), célula unitária no estado de simetria cúbica acima da temperatura de Curie. 2) Célula unitária distorcida tetragonalmente após a temperatura de Curie.	33
Figura 2.2 – Dipolos elétricos nos domínios: 1) cerâmica ferroelétrica não-polarizada, 2) durante a polarização e 3) após a polarização (cerâmica piezelétrica)	34
Figura 2.3 – Direções dos materiais piezelétricos.	37
Figura 2.4 – Tensão elétrica aplicada em fase, gerando movimento longitudinal.	39
Figura 2.5 – Tensão elétrica aplicada em antifase, gerando movimento de flexão.	39
Figura 2.6 – Elementos piezelétricos ligados em fase.	39
Figura 2.7 – Elementos piezelétricos ligados em anti-fase.	40
Figura 2.8 – Modelos equivalentes de um sensor piezelétrico.	41
Figura 2.9 – Modelo usado para representar o acoplamento de um PZT com a estrutura base.	42
Figura 3.1 – Modelo de um neurônio biológico.	51
Figura 3.2 – Modelo de neurônio de McCulloch – Pitts	53
Figura 3.3 – Funções de ativação. (a) Função linear. (b) Função degrau. (c) Função rampa. (d) Função sigmóide. (e) Função gaussiana.	58
Figura 3.4 – Rede neural multicamada com duas camadas ocultas.	60
Figura 3.5 – Exemplo de uma rede recorrente.	61
Figura 3.6 – neurônio com duas entradas.	62
Figura 3.7 – Separação em duas categorias.	63
Figura 3.8 – (a) Classes linearmente separáveis; (b) Classes não-separáveis linearmente	63
Figura 3.9 – Superfícies convexas. (a) e (b) fechadas; (c) aberta	64
Figura 3.10 – (a) Classes separáveis por curva convexa; (b) classes não separáveis por curva convexa.	65
Figura 3.11 – Superfícies de representação convexas resultando numa não-convexa.	65

Figura 3.12 – Treinamento supervisionado.	67
Figura 3.13 – Treinamento não-supervisionado.	67
Figura 3.14 – Exemplo de um perceptron com uma camada.	69
Figura 3.15 – Rede neural ADALINE.	71
Figura 3.16 – Detalhes do sinal que percorre um neurônio j.	74
Figura 3.17 – Ilustração dos dois tipos básicos de sinais de uma rede neural, sinal “forward” e sinal “backward” (sinal do erro).	75
Figura 3.18 – Detalhes do sinal de saída de um neurônio k conectado a um neurônio j localizado na camada intermediária.	78
Figura 3.19 – Ajuste dos pesos. (a)-para pequenas taxas de aprendizagem. (b)-para grandes taxas de aprendizagem. (c)-para grandes taxas de aprendizagem com o termo momento.	82
Figura 3.20 – Desenho ilustrativo do treinamento via backpropagation	83
Figura 4.1 – Diagrama do esquema de identificação da falha.	86
Figura 4.2 – Viga de aço engastada simulada.	90
Figura 4.3 – Elemento de viga utilizado.	90
Figura 4.4 – Três primeiras frequências naturais, em função da distância da viga normalizada.	94
Figura 4.5 – $nrfn_1$ , $nrfn_2$ e $nrfn_3$ , em função da distância da viga normalizada.	95
Figura 4.6 – Normalização $nrfn_i$ para as cinco primeiras frequências em função da distância normalizada.	96
Figura 4.7 – Resposta da rede escolhida (5 14 1).	98
Figura 4.8 – Viga de alumínio livre-livre simulada.	101
Figura 4.9 – Variações das 2º e 3º frequências naturais, em função da distância da viga normalizada.	104
Figura 4.10 – $nrfn_2$ e $nrfn_3$ , em função da distância da viga normalizada.	105
Figura 4.11 – Normalizações $nrfn_i$ para as cinco primeiras frequências naturais, em função da distância da viga normalizada.	106
Figura 4.12 – Resposta da rede escolhida (5 16 1).	107
Figura 4.13 – Variações das 2º e 3º frequências naturais para a viga de aço livre-livre.	112
Figura 4.14 – $nrfn_2$ e $nrfn_3$ para a viga de aço livre-livre.	112
Figura 4.15 – Variações das 2º e 3º frequências naturais para a viga de alumínio engastada-livre.	115

Figura 4.16 – $n_{rfn_2}$ e $n_{rfn_3}$ para a viga de alumínio engastada-livre.	116
Figura 5.1 – Microcomputador e aparelho HP Analyzer 4192A.	120
Figura 5.2 – Barra de alumínio utilizada.	121
Figura 5.3 – Medidas do PZT 1 com e sem falha na posição 1: (a) impedância elétrica; (b) componente real da impedância elétrica.	122
Figura 5.4 – Localização da falha inserida na posição 1.	123
Figura 5.5 – Localização da falha inserida na posição 2.	124
Figura 5.6 – Localização das falhas inseridas na viga.	125
Figura 5.7 – Estrutura do tipo virabrequim.	126
Figura 5.8 – Detalhe da falha introduzida.	127
Figura 5.9 – Falha métrica para os quatro PZT's em cada condição de falha.	128
Figura 5.10 – Evolução da falha métrica para o PZT_4	129
Figura 5.11 – Componente real da impedância elétrica no PZT_4 nas condições sem falha e com falha máxima.	130
Figura 5.12 – Viga de aço com PZT colado.	132
Figura 5.13 – Sistema de aquisição de dados.	132
Figura 5.14 – Impedância elétrica obtida através do MIBC e do HP 4192A, para a situação sem falha.	133
Figura 5.15 – Impedância elétrica obtida através do MIBC e do HP 4192A, para a situação com falha.	134
Figura 5.16 – Impedância elétrica obtidas com o MIBC e com o HP 4192A.	134
Figura 5.17 – Falha métrica calculada para as impedâncias elétricas obtidas com o MIBC (a), e com o HP analyzer (b).	135
Figura A.1 – Equipamento HP 4192A acoplado a um microcomputador.	147
Figura A.2 – Circuito para medida aproximada da impedância no PZT.	148
Figura A.3 – Circuito para medição da impedância elétrica com amplificador.	149
Figura A.4 – Circuito do MIBC.	150
Figura A.5 – Medidor de Impedância de Baixo Custo.	150
Figura A.6 – Esquema da cadeia de medição.	151
Figura A.7 – Cadeia de medição utilizada.	151

# Lista de Tabelas

---

Tabela 2.1 – Propriedades físicas do PZT e do PVFD. _____	38
Tabela 4.1 – Propriedades dos elementos com e sem falha. _____	91
Tabela 4.2 – Cinco primeiras frequências naturais para a estrutura de aço engastada, sem falha e com a falha fl. _____	91
Tabela 4.3 – Topologias testadas e seus respectivos erros para os dados de verificação _____	97
Tabela 4.4 – Erro gerado pela RNA escolhida na localização. _____	98
Tabela 4.5 – Característica das falhas no elemento 5. _____	99
Tabela 4.6 - Redes testadas para a quantificação. _____	100
Tabela 4.7 – Severidade da falha e erro devido ao valor gerado pela RNA. _____	101
Tabela 4.8 – Propriedades dos elementos com e sem falha. _____	102
Tabela 4.9 – Cinco primeiras frequências para a estrutura de alumínio na condição livre-livre sem falha e com a falha fl. _____	102
Tabela 4.10 – Topologias testadas e seus respectivos erros para os dados de verificação. _____	107
Tabela 4.11 – Erro gerado pela RNA na identificação da localização da falha. _____	108
Tabela 4.12 – Característica das falhas no elemento 120. _____	109
Tabela 4.13 - Redes testadas para a quantificação. _____	109
Tabela 4.14 – Severidade da falha e erro obtido na quantificação. _____	110
Tabela 4.15 – Resposta da RNA (5 16 1) treinada para a viga de alumínio na condição livre-livre, para localização de falhas nas vigas de alumínio e de aço na condição livre-livre. _____	113
Tabela 4.16 – Resposta da RNA (5 14 1), treinada para a viga de aço na condição engastada-livre, para localização de falhas nas vigas de aço e de alumínio na condição engastada-livre. _____	117
Tabela 5.1 – Características das falhas introduzidas na estrutura do tipo virabrequim. _____	127
Tabela 5.2 – Resposta da rede neural na quantificação da falha. _____	131

## Lista de Abreviações e Símbolos

---

ADALINE	=	ADaptive LInear NEuron
$d$	=	saída desejada de um neurônio genérico
$comp$	=	número de componentes do vetor, (dimensão)
$E$	=	função energia
$n$	=	índice para o vetor do conjunto de treinamento
$N$	=	número de vetores do conjunto de treinamento
$neu$	=	número de neurônios
RNA	=	Rede Neural Artificial
$rfn_i$	=	diferença entre as frequências naturais da estrutura com e sem defeitos para o modo $i$
$nrfn$	=	normalização para o parâmetro $rfn_i$
$t$	=	índice para iteração
$T$	=	operador transposto
$x$	=	entrada líquida de um neurônio
XOR	=	OR exclusivo
$y$	=	saída de um neurônio
$\delta_j$	=	erro no neurônio $j$
$\gamma$	=	coeficiente do termo momento
$\mu$	=	taxa de aprendizagem
$\theta$	=	limiar da função de transferência
$w_{ji}$	=	peso sináptico entre o neurônio $i$ e $j$
$w_{j0}$	=	peso aplicado a entrada bias
$\Delta w_{ji}$	=	atualização de um peso $w_{ji}$
$\omega_i$	=	frequência natural referente ao $i$ -ésimo modo de vibrar da estrutura com defeitos

$\omega_i^u$  = frequência natural referente ao  $i$ -ésimo modo de vibrar da estrutura sem defeitos

### **Vetores e matrizes**

$K$  = matriz de rigidez da estrutura

$M$  = matriz de massa da estrutura

$W0$  = vetor de peso para a entrada bias

$W$  = matriz de pesos

$X$  = vetor de entrada

$D$  = vetor de saída esperada

$Y$  = vetor de saída da rede

# CAPÍTULO 1

## INTRODUÇÃO

### 1.1 Motivação

Cada vez mais a manutenção preditiva vem fazendo parte de nosso cotidiano, sendo aplicada nas indústrias, em empresas, nas construções, no monitoramento de máquinas, etc. Sua utilização se justifica devido a necessidade de reduzir gastos e aumentar a confiabilidade e segurança das estruturas e equipamentos. Existem algumas técnicas de manutenção preditiva baseadas nos ensaios não-destrutivos (END) que já são largamente aplicadas, dentre elas temos: análise de óleo, partículas magnéticas, líquidos penetrantes, métodos baseados na análise de vibrações, etc. A exigência cada vez maior dessas técnicas e sua utilização nas mais diversas situações, levam a constantes pesquisas envolvendo novos materiais e o desenvolvimento de novas técnicas.

Na área de projetos, geralmente, estas técnicas são empregadas no diagnóstico e monitoramento de danos estruturais. A capacidade de avaliação de danos pode ser pensada de duas maneiras: (1) monitoramento das mudanças de sua condição e, se necessário, parar a operação do equipamento antes de piorar as condições; e (2) garantir que o dano iniciado não se estenda para uma situação de risco. As técnicas de obtenção de (1) estão melhores definidas que as de (2).

Análise dos sinais de vibração para máquinas rotativas utilizando a técnica de *Order Tracking*, são apresentadas por Idehara (Idehara, 2003). Neste trabalho, o autor realiza análise de componentes rotativos expondo seus sinais em função da velocidade de rotação.

A utilização da ferramenta das redes neurais artificiais e da transformada de wavelet no diagnóstico de falhas em máquinas rotativas, pode ser encontrada em Santiago (Santiago, 2004). Estas duas técnicas alternativas aplicadas no diagnóstico de máquinas, mostra o dinamismo presente na área que estuda a manutenção preditiva.

A caracterização de danos, para melhor entendimento, pode ser classificada por níveis. Doebling et al. (Doebling et al., 1998) usam quatro níveis de classificação:

- Nível 1 – Detecta a existência da falha;
- Nível 2 – Detecta e localiza a falha;
- Nível 3 – Detecta, localiza e quantifica a falha;
- Nível 4 – Detecta, localiza e quantifica a falha e então estima a vida útil restante do equipamento.

Inman (Inman, 2001) adiciona mais três níveis. Todos incorporando a utilização de materiais inteligentes:

- Nível 5 – Combina o nível 4 com estruturas inteligentes para auto-diagnóstico de falhas estruturais;
- Nível 6 – Combina o nível 4 com estruturas inteligentes e controle para formar um sistema de auto-reparo estrutural;
- Nível 7 – Combina o nível 1 com controle ativo e estruturas inteligentes para obtenção de um sistema simultâneo de controle e monitoramento.

Este trabalho propõe uma técnica de manutenção preditiva utilizando materiais inteligentes e redes neurais artificiais para detecção e monitoramento de danos estruturais. Assim, seria uma técnica que abrangeria o nível 3 apresentado por Doebling e o nível 7, de maneira parcial, apresentado por Inman.

## 1.2 Estruturas Inteligentes

Embora existam diversas definições para o termo inteligente (*Smart*), a comunidade de engenharia tem adotado o termo de estruturas inteligentes (*Smart Structures*). Desde o início da

década de 90 para descrever estruturas ou componentes estruturais com habilidades extraordinárias, que não são encontradas em materiais/estruturas convencionais. Um melhor detalhamento destas propriedades será apresentado nos capítulos seguintes. No entanto, a figura (1.1), mostra de uma maneira sucinta a analogia entre estruturas inteligentes e os seres vivos. (Egawa, 1997).




Figura 1.1 – Conceitos prevaletentes de estruturas inteligentes.

Materiais inteligentes têm a habilidade de converterem uma forma de energia em outra. Exemplos incluem a conversão de energia mecânica em elétrica e vice-versa pelos materiais piezelétricos, calor para energia mecânica, através das ligas de memória de forma que em inglês tem a sigla SMA (*Shape Memory Alloys*), magnética para energia mecânica em fluidos magnetorelógico e uma variedade de outros materiais. As duas formas de energia oriundas dos materiais inteligentes podem trazer uma série de vantagens para as estruturas e dispositivos que têm estes materiais incorporados. Estes materiais são fabricados de várias formas e tamanhos, propiciando assim sua utilização em diversas aplicações, incluindo lugares de difícil acesso. Além do que, estes materiais podem ser usados como sensores e atuadores permitindo assim o monitoramento e ação de controle nas estruturas em que estão agregados (Peairs, 2002).

Diversos materiais vêm sendo empregados na construção de estruturas inteligentes, dentre estes chamam a atenção às estruturas que utilizam os materiais com propriedades piezelétricas, tais como as cerâmicas *PZT* (*Titanato Zirconato de Chumbo*) e os filmes plásticos *PVDF* (*Fluorido de Polivinilideno*). Estas propriedades conferem ao material a característica de quando submetido a uma tensão mecânica gerar um campo elétrico, efeito direto (*sensor*), enquanto um campo elétrico aplicado neste material gera uma tensão mecânica, efeito inverso (*atuador*). Descobertos por *Jaffet et al.* em 1954 (Clark, Saunders e Gibbs, 1998), os PZTs são

constituídos principalmente de óxido de chumbo, zircônio e titânio. Uma das vantagens do PZT reside no fato de apresentar grande rigidez, sendo idealmente indicados na confecção de atuadores. Já o PVDF, cujas propriedades piezelétricas foram descobertas por *Kawai* após 1960, (Lima e Arruda, 1999), é um polímero piezelétrico robusto e maleável. Devido suas propriedades, o PVDF é indicado para construção de sensores.

Uma técnica promissora que vem sendo empregada no monitoramento de estruturas é a técnica da impedância elétrica. Esta técnica emprega materiais inteligentes, sendo mais utilizada a cerâmica de PZT. O princípio da técnica envolve excitações em alta frequência (tipicamente acima de 10kHz) com o objetivo de monitorar sub-regiões da estrutura baseadas nas mudanças na impedância mecânica. Estas mudanças são relacionadas com o dano e podem ser identificadas em sua fase inicial. Isto é possível utilizando os materiais piezelétrico sensor/atuador, pois a impedância elétrica é diretamente relacionada à impedância estrutural mecânica.

A ciência de estruturas inteligentes é recente e nesta conjuntura podemos ter uma visão desta tecnologia como uma oportunidade para resultados em longo prazo, ou podemos examinar os impactos que as estruturas inteligentes terão na habilidade do sistema para exibir adaptação em curto-prazo. O estudo da tecnologia de estruturas inteligentes é importante devido ao potencial demonstrado para estruturas convencionais em várias aplicações. Pode-se citar por exemplo:

- ✓ A presença de algoritmo de controle adaptativo que fornece um crítico mecanismo de adaptação em curto-prazo em resposta a mudanças em uma variedade de parâmetros do sistema, (Silcox et al., 1992);
- ✓ Aplicações para controle ativo, que tipicamente fornece supressão de vibração para faixas de frequências mais baixas se comparado a métodos passíveis disponíveis, (Clark, Saunders e Gibbs, 1998);
- ✓ Sistemas de auto-monitoramento das condições de máquinas ou estruturas “self-health monitoring”, (Lopes Jr. et al., 2001).

Um dos primeiros trabalhos, apresentando o uso de atuadores piezelétricos como elementos de estruturas inteligentes, foi abordado por (Crawley ed Luis 1987). Neste trabalho foram construídas três estruturas inteligentes. Em uma das estruturas os atuadores piezelétricos foram colados na superfície de uma viga de alumínio, nas outras duas o material foi imerso no interior da viga, uma confeccionada com grafita/epoxy e outra com fibra de vidro/epoxy. Um dos

primeiros trabalhos que utilizou o M.E.F. (método dos elementos finitos) para análise estática e dinâmica de estruturas piezelétricas foi apresentado por *Allik e Hughes* (Allik e Hughes, 1970). O uso do conceito de materiais inteligentes em aplicações de controle, supressão de vibrações, monitoramento das condições de máquinas e outros é relativamente novo.

A característica que torna extremamente vantajoso o uso dos materiais piezelétricos é a possibilidade de construção de sensores e atuadores distribuídos ao longo de superfícies relativamente amplas, o que tem importantes implicações no tocante à sensibilidade dos sensores, à capacidade de aplicação de cargas dos atuadores e à potência requerida para a atuação.

Algumas das características destes materiais são:

Cerâmicas piezelétricas. Em particular, as cerâmicas PZT têm sido extensivamente utilizadas como elementos atuadores distribuídos, aplicados sob a forma de placas, com espessuras típicas da ordem de 0,1 a 0,2 mm.

Polímeros piezelétricos. O PVDF tem sido largamente utilizado como sensores distribuídos, aplicados sob a forma de filmes finos, com espessura típica da ordem de 40 a 120 $\mu$ m.

Os materiais piezelétricos têm sido utilizados em diversas aplicações de engenharia, principalmente aquelas requerendo atuações de alta precisão e velocidade, tais como: sistemas de rastreamento óptico, microposicionadores para robôs, impressoras a jato de tinta e alto-falantes. Pesquisas recentes têm sido dedicadas ao uso de atuadores de PZT em sistemas de controle ativo de vibrações e ruído e de controle de danos estruturais. São também numerosas as aplicações de materiais piezelétricos como sensores de temperatura (explorando o efeito piroelétrico), deformação e pressão.

Giurgiutiu (Giurgiutiu, 2000) apresenta uma aplicação deste material para monitoramento de falhas (fadiga e corrosão) em estruturas aeroespaciais onde o princípio da impedância elétrica e “wave propagation” são utilizados. Lopes Jr. et al. (2001) utilizam o princípio da impedância elétrica e técnicas de otimização hierárquica para detecção de falhas estruturais.

Um modelo de estrutura eletro-mecânica utilizando o método dos elementos finitos é apresentado por Pereira (Pereira, 2003). As posições dos atuadores piezelétricos ao longo da estrutura são determinadas através do método de otimização baseado nos algoritmos genéticos, métodos clássicos são empregados para obtenção dos valores dos ganhos para os controladores.

Com isto, procura-se minimizar os esforços de controle aplicados na estrutura, enquanto um determinado nível de vibração é atingido.

A identificação da faixa de frequência para o monitoramento de estruturas flexíveis baseada na técnica da impedância elétrica, é apresentada por Moura e Steffen (Moura Jr. e Steffen Jr., 2004). Neste trabalho, o sensor é avaliado para a detecção de falha e a superfície de resposta é calculada utilizando-se meta-modelo.

Por apresentarem um comportamento aproximadamente linear, sob baixos campos elétricos, relativa insensibilidade à variação de temperatura e flexibilidade como sensores e atuadores, os elementos piezelétricos são utilizados mais frequentemente em aplicações aeroespaciais e automotivas. Pelo exposto, podemos traçar um paralelo entre as vantagens e desvantagens destes materiais:

**Vantagens:** Relativa insensibilidade à temperatura, resposta linear a baixos níveis de excitação, baixo peso, flexibilidade para serem usados como sensores e atuadores em uma larga variedade de aplicações e ampla faixa de resposta.

**Desvantagens:** Significante perda por histerese para grandes campos elétricos, rigidez e baixa tenacidade dos PZT's, baixas propriedades eletromecânicas nos PVDF's e o efeito piezelétrico gerado pode deteriorar e conduzir a efeitos de envelhecimento e degradação da performance.

### 1.3 Organização da Dissertação

Ao contrário das técnicas tradicionais baseadas em ensaios não-destrutivos, que fornecem informações sobre a natureza do dano como por exemplo seu tamanho e localização, a técnica da impedância elétrica é qualitativa, ou seja, fornece informações limitadas sobre a natureza do dano. Desta maneira, uma outra ferramenta deve ser utilizada quando o objetivo é obter uma informação quantitativa do dano, formando assim uma técnica híbrida. É neste sentido que propomos a técnica da impedância elétrica para detecção e localização da falha e a técnica de redes neurais artificiais para quantificar a severidade do dano.

Para estudo e validação da proposta, são apresentadas simulações numéricas empregando redes neurais artificiais e testes experimentais utilizando a técnica da impedância elétrica e, por final, a utilização das duas técnicas em testes experimentais.

Nos capítulos iniciais são apresentados os conceitos básicos de piezeletricidade, do método da impedância elétrica e uma abordagem mais aprofundada sobre redes neurais artificiais, para que o leitor possa, além de compreender o tipo de rede utilizada, reproduzi-la utilizando o algoritmo apresentado. Finalizamos o texto com os capítulos de resultados numéricos e experimentais e o capítulo de considerações finais.

No capítulo de resultados numéricos são apresentadas simulações para vigas com material, condições de contorno e dimensões distintas. As vigas são submetidas a duas condições de contorno: engasta-livre e livre-livre. Redes neurais foram utilizadas para localizar e quantificar as falhas, utilizando para isto, uma normalização da variação das frequências naturais.

Em testes experimentais, aplicamos a técnica da impedância elétrica para realizar a detecção e localização de falhas em uma barra de alumínio.

Posteriormente, aplicamos a técnica da impedância elétrica e a ferramenta das redes neurais para realizar a detecção, localização e quantificação de falhas inseridas em uma estrutura relativamente complexa, com seu formato assemelhando-se ao de um virabrequim.

Finalizando, realizamos a detecção de uma falha em uma barra de aço. Na medição da impedância elétrica para as estruturas anteriores, utilizamos o equipamento HP Analyzer 4192A, já para o caso da barra de aço, apresentamos um aparelho batizado de “MIBC”, Medidor de Impedância de Baixo Custo que foi confeccionado em conjunto com membros do grupo “GMSINT”, Grupo de Materiais e Sistemas Inteligentes. No apêndice A são apresentados detalhes desde equipamento.

## CAPÍTULO 2

### CONCEITOS BÁSICOS UTILIZADOS NA METODOLOGIA

#### 2.1 Conceitos Básicos de Piezeletricidade

Alguns sólidos, notavelmente certos cristais, têm polarização elétrica permanente. Outros cristais se tornam eletricamente polarizados quando sujeitos a uma tensão (*Stress*). Piezeletricidade (literalmente "eletricidade de pressão") é observada se uma deformação é aplicada a um sólido, por exemplo, dobrando, torcendo, ou comprimindo esse sólido. O quartzo é um material que exhibe propriedades piezelétricas. Se comprimirmos um cristal de quartzo entre dois eletrodos, uma diferença de potencial é notada, reciprocamente, se o cristal de quartzo é inserido em um campo elétrico, a tensão elétrica resultante altera suas dimensões. A Piezeletricidade é responsável pela grande precisão de relógios equipados com osciladores de quartzo. Alguns dos exemplos de suas aplicações são os transdutores de pressão, acelerômetros, em violões elétricos e vários outros instrumentos musicais para transformar vibrações mecânicas em sinais elétricos que são então amplificados e convertidos em sons através de amplificadores.

O surgimento de eletricidade devido ao aquecimento do cristal turmalina já era conhecida desde o século XVIII. Em 1824, Brewster observou o efeito em vários tipos de cristais, chamando este fenômeno de "piroeletricidade". Lord Kelvin notou que a piroeletricidade era devida a polarização permanente. De acordo com sua teoria, o efeito piroelétrico é simplesmente a manifestação do coeficiente de temperatura desta polarização. Por isso, este efeito ficou conhecido como a interação entre o sistema elétrico e térmico (Ikeda, 1996).

O efeito piezelétrico foi descoberto em 1880 por Pierre and Jacques Curie. Pierre Curie tinha previamente estudado a relação entre piroeletricidade e cristal simétrico. Este estudo levou os irmãos não somente a notar a eletrificação devido a pressão mas também prever em qual direção a pressão deveria ser aplicada e em qual classe de cristal o efeito era esperado. O mesmo fenômeno foi encontrado em outros cristais, como os de turmalina. Hankel propôs o nome “piezeletricidade”. Piezeletricidade é a interação entre o sistema elétrico e mecânico (Ikeda, 1996).

Como já foi dito, alguns materiais naturais exibem o efeito *piezo*, tal como quartz, turmalina, etc. Pesquisas com pequenos materiais cerâmicos policristalinos ferroelétricos, tal como Titanato Zirconato de Chumbo (PZT), têm sido desenvolvidas nos últimos anos. Estas cerâmicas ferroelétricas se tornam piezelétricas quando polarizadas.

Cerâmicas de PZT estão disponíveis em muitas variações e atualmente são amplamente empregadas como atuadores. Abaixo da *Temperatura de Curie* ou *Ponto Curie*, temperatura para a qual a estrutura do cristal muda de não-simétrica para uma estrutura simétrica, expresso em graus Celsius, cristais PZT exibem estrutura tetragonal. Devido permanente assimetria elétrica e mecânica, estes tipos de células unitárias exibem espontânea polarização e deformação. Grupos de células unitárias com a mesma orientação de polarização e deformação são chamados domínios. Devido a distribuição aleatória da orientação desses domínios no material cerâmico, um processo de polarização ferroelétrico é necessário para se obter anisotropia macroscópica associada às propriedades piezelétricas, figura (2.1).




Figura 2.1 – Célula unitária de PZT: 1) Tipo Perovskite Titanato Zirconato de Chumbo (PZT), célula unitária no estado de simetria cúbica acima da temperatura de *Curie*. 2) Célula unitária distorcida tetragonalmente após a temperatura de *Curie*.

Se submetido a uma temperatura acima da temperatura de *Curie*, a célula unitária do PZT apresenta uma estrutura cúbica isotrópica. Quando resfriada, os domínios modificam, mas devido a orientação aleatória, o material não apresenta macroscopicamente propriedades piezoelétricas.

O arranjo assimétrico dos íons positivos e negativos fornece o comportamento permanente de dipólo elétrico para os cristais. Antes do tratamento de polarização, os domínios estão orientados aleatoriamente no PZT. Durante a polarização, um intenso campo elétrico (acima de 2000 V/mm) é aplicado na *piezo* cerâmica. Com o campo aplicado, o material expande ao longo do eixo do campo e contrai na direção perpendicular para que o eixo do domínio fique para cima. Quando o campo é removido, os dipólos elétricos ficam direcionados, mas não completamente alinhados. O material agora tem uma polarização remanescente a qual pode ser degradada pelo excesso dos limites mecânico, térmico ou elétrico do material.

Consequentemente, quando uma tensão elétrica é aplicada no pólo do material piezoelétrico, os íons da célula unitária são trocados e, adicionalmente, os domínios mudam o grau de alinhamento, figura (2.2). O resultado é a correspondente mudança de dimensão (expansão, contração) do material PZT.




Figura 2.2 – Dipolos elétricos nos domínios: 1) cerâmica ferroelétrica não-polarizada, 2) durante a polarização e 3) após a polarização (cerâmica piezoelétrica)

### 2.1.1 Equações Constitutivas da Piezeletricidade

A tensão mecânica, a deformação, o campo elétrico e o deslocamento elétrico, dentro do material piezelétrico, podem ser completamente descrito por um par de equações eletromecânica. Existem vários pares de equações eletromecânicas; a melhor escolha depende do problema a ser abordado. Usando a notação padrão IEEE 176-1987, a relação constitutiva linear do material piezelétrico pode ser descrita pelas equações (2.1) e (2.2). As letras nos colchetes indicam as unidades das variáveis no Sistema Internacional de Unidades, com Newton (N), metro (m), Volt (V) e Coulomb (C).

$$S_{ij} = s_{ijkl}^E T_{kl} + d_{kij}^t E_k \quad (2.1)$$

$$D_i = d_{ikl} T_{kl} + \varepsilon_{ik}^T E_k \quad (2.2)$$

sendo:

O sobrescrito  $t$  indica matriz transposta

$i, j, k, l$  representam os valores 1, 2, 3 (ou x, y, z)

$S_{ij}$  = tensor deformação [m/m]

$T_{kl}$  = tensor de tensão [N/m<sup>2</sup>]

$E_k$  = campo elétrico [V/m; N/C]

$d_{kij}$  = constante piezelétrica [C/N]

$D_i$  = deslocamento elétrico ou indução [C/m<sup>2</sup>]

$s_{ijkl}$  = tensor de compliança [m<sup>2</sup>/N]

$\varepsilon_{ik}^T$  = permissividade dielétrica [C<sup>2</sup>/Nm<sup>2</sup>]

Na forma matricial obtém-se:

$$\begin{bmatrix} S \\ D \end{bmatrix} = \begin{bmatrix} s^E & d^t \\ d & \varepsilon^T \end{bmatrix} \begin{bmatrix} T \\ E \end{bmatrix} \quad (2.3)$$

sendo,

$$D = \begin{bmatrix} D_1 \\ D_2 \\ D_3 \end{bmatrix}, \quad E = \begin{bmatrix} E_1 \\ E_2 \\ E_3 \end{bmatrix}, \quad \varepsilon = \begin{bmatrix} \varepsilon_{11} & \varepsilon_{12} & \varepsilon_{13} \\ \varepsilon_{12} & \varepsilon_{22} & \varepsilon_{23} \\ \varepsilon_{13} & \varepsilon_{23} & \varepsilon_{33} \end{bmatrix}, \quad S = \begin{bmatrix} S_1 \\ S_2 \\ S_3 \\ S_4 \\ S_5 \\ S_6 \end{bmatrix},$$

$$T = \begin{bmatrix} T_1 \\ T_2 \\ T_3 \\ T_4 \\ T_5 \\ T_6 \end{bmatrix}, \quad S = \begin{bmatrix} S_{11} & S_{12} & S_{13} & S_{14} & S_{15} & S_{16} \\ S_{12} & S_{22} & S_{23} & S_{24} & S_{25} & S_{26} \\ S_{13} & S_{23} & S_{33} & S_{34} & S_{35} & S_{36} \\ S_{14} & S_{24} & S_{34} & S_{44} & S_{45} & S_{46} \\ S_{15} & S_{25} & S_{35} & S_{45} & S_{55} & S_{56} \\ S_{16} & S_{26} & S_{36} & S_{46} & S_{56} & S_{66} \end{bmatrix}, \tag{2.4}$$

$$d = \begin{bmatrix} d_{11} & d_{12} & d_{13} & d_{14} & d_{15} & d_{16} \\ d_{21} & d_{22} & d_{23} & d_{24} & d_{25} & d_{26} \\ d_{31} & d_{32} & d_{33} & d_{34} & d_{35} & d_{36} \end{bmatrix}$$

Assim,

$$\begin{bmatrix} S_1 \\ S_2 \\ S_3 \\ S_4 \\ S_5 \\ S_6 \\ D_1 \\ D_2 \\ D_3 \end{bmatrix} = \begin{bmatrix} s_{11} & s_{12} & s_{13} & s_{14} & s_{15} & s_{16} & d_{11} & d_{21} & d_{31} \\ s_{12} & s_{22} & s_{23} & s_{24} & s_{25} & s_{26} & d_{12} & d_{22} & d_{32} \\ s_{13} & s_{23} & s_{33} & s_{34} & s_{35} & s_{36} & d_{13} & d_{23} & d_{33} \\ s_{14} & s_{24} & s_{34} & s_{44} & s_{45} & s_{46} & d_{14} & d_{24} & d_{34} \\ s_{15} & s_{25} & s_{35} & s_{45} & s_{55} & s_{56} & d_{15} & d_{25} & d_{35} \\ s_{16} & s_{26} & s_{36} & s_{46} & s_{56} & s_{66} & d_{16} & d_{26} & d_{36} \\ d_{11} & d_{12} & d_{13} & d_{14} & d_{15} & d_{16} & \varepsilon_{11} & \varepsilon_{12} & \varepsilon_{13} \\ d_{21} & d_{22} & d_{23} & d_{24} & d_{25} & d_{26} & \varepsilon_{12} & \varepsilon_{22} & \varepsilon_{23} \\ d_{31} & d_{32} & d_{33} & d_{34} & d_{35} & d_{36} & \varepsilon_{13} & \varepsilon_{23} & \varepsilon_{33} \end{bmatrix} \begin{bmatrix} T_1 \\ T_2 \\ T_3 \\ T_4 \\ T_5 \\ T_6 \\ E_1 \\ E_2 \\ E_3 \end{bmatrix} \quad (2.5)$$

Em alguns trabalhos é comum usar a relação  $k = \varepsilon/\varepsilon_0$ , sendo  $\varepsilon_0 = 8.5 \times 10^{-12} \text{ C}^2/\text{Nm}^2$  a permissividade no vácuo. Os sobrescritos  $E$  e  $T$  indicam que as quantidades foram obtidas com campo elétrico ou tensão constante, respectivamente.

As equações (2.1) e (2.2) representam, respectivamente, o efeito inverso e direto do PZT. O efeito inverso normalmente é associado à utilização do PZT como atuador, pois aplicando uma tensão elétrica alternada no PZT, obtém-se também uma deformação alternada, gerando assim um estado vibratório. Por outro lado, aplicando uma tensão mecânica no PZT é possível notar a presença de uma tensão elétrica, efeito direto. A técnica baseada na impedância elétrica utiliza o PZT como atuador e sensor. A figura (2.3) mostra as direções principais de uma estrutura piezelétrica.




Figura 2.3 – Direções dos materiais piezelétricos.

### 2.1.2 Sensores e Atuadores Piezelétricos

Os tipos mais comuns de materiais piezelétricos que normalmente são encontrados em estruturas inteligentes, são os PZT's e os PVDF's. Os PZT's já foram discutidos anteriormente, já os PVDF's (*polyvinylidene fluoride*) são piezopolímeros que normalmente são empregados como sensores em estruturas. Ambos são confeccionados em lâminas finas, o PZT na espessura da ordem de 0,1 a 0,2 mm, já o PVDF é mais fino com espessura da ordem de 40 a 120  $\mu\text{m}$ . Uma película metálica é depositada nas faces opostas para formar um eletrodo. A tabela (2.1) apresenta algumas propriedades físicas do PZT e do PVDF, geralmente utilizados para aplicações estruturais.

Tabela 2.1 – Propriedades físicas do PZT e do PVDF.

Propriedade	PZT (PC5H) Tipo V1	PVDF
Temperatura de Curie [ $^{\circ}\text{C}$ ]	210	100
Módulo de Young Longitudinal [ $\text{Nm}^{-2}$ ]	$59,5 \times 10^9$	$3 \times 10^9$
Constante Dielétrica $d_{31}$ [ $\text{mV}^{-1}$ ]	$212 \times 10^{-12}$	$23 \times 10^{-12}$
Campo Elétrico Maximo [ $\text{Vm}^{-1}$ ]	$0,4 \times 10^6$	$40 \times 10^6$

Observando o módulo de Young longitudinal na tabela acima, notamos que o PZT é cerca de 20 vezes mais rígido de que o PVDF. Este fato ressalta a utilização do PZT como atuador, pois sua rigidez relativamente alta quando comparada com a do PVDF, leva a um melhor acoplamento mecânico. Por outro lado, a pequena rigidez do PVDF torna-o atraente na utilização como sensor, pois baixa rigidez é uma característica importante para os sensores, uma vez que, o sensor deve interferir de forma mínima na estrutura, não alterando de maneira acentuada a rigidez local. Nota-se também que o PVDF suporta um campo elétrico de aproximadamente cem vezes maior que o PZT, fato este que o torna atraente para utilização como sensor, principalmente quando utilizado em camadas.

### 2.1.3 Atuadores Piezelétricos

O material piezelétrico quando submetido a um campo elétrico alternado, produz uma deformação alternada (*efeito inverso*). Considerando este elemento colado em uma estrutura, podemos modelar seu esforço como sendo uma força  $F$  ou um momento  $M$  aplicado em suas extremidades. O esforço considerado dependerá da forma de ligação do material piezelétrico. Supondo dois elementos piezelétricos colados em lados opostos, como mostram as figuras (2.4) e (2.5), temos duas opções de excitação na estrutura: esforços na direção longitudinal e de flexão. Por exemplo, se colarmos em uma estrutura os materiais piezelétricos com a direção da superfície de polarização em contato com a superfície da estrutura, ligando estes materiais em fase, figura (2.6), obtemos os esforços longitudinais apresentados na figura (2.4). Entretanto, ao excitarmos estes elementos em antifase, figura (2.7) obtemos os esforços de flexão apresentados na figura (2.5).




Figura 2.4 – Tensão elétrica aplicada em fase, gerando movimento longitudinal.




Figura 2.5 – Tensão elétrica aplicada em antifase, gerando movimento de flexão.




Figura 2.6 – Elementos piezelétricos ligados em fase.




Figura 2.7 – Elementos piezelétricos ligados em anti-fase.

No caso de um atuador piezelétrico estar excitando a estrutura no modo de flexão, a equação (2.6) apresenta uma maneira de estimar o valor do momento aplicado, (Brennan, 1994).

$$M = \frac{t_b^2 Y_b b_b (1 + T)}{6 + \psi + 12T + 8T^2} \Lambda \tag{2.6}$$

sendo  $T = \frac{t_p}{t_b}$ ,  $\psi = \frac{Y_b b_b t_b}{Y_p b_p t_p}$  e  $\Lambda = \frac{d_{31} V}{t_p}$

$b$  e  $t$  são, respectivamente, a largura e a espessura e os subíndices  $b$  e  $p$  se referem a viga e ao PZT, respectivamente,  $V$  é a tensão elétrica aplicada, e  $Y$  é o módulo de elasticidade.

Realizando a ligação em fase, o par de material piezelétrico excitará a estrutura com esforços longitudinais, desta maneira o valor da força aplicada pode ser estimado através da equação (2.7) (Brennan, 1994).

$$F = \frac{2t_b E_b b_b}{6 + \Psi} \Lambda \tag{2.7}$$

sendo,  $\Psi = \frac{Y_b b_b t_b}{Y_p b_p t_p}$  e  $\Lambda = \frac{d_{31} V}{t_p}$

### 2.1.4 Sensores Piezelétricos

Como apresentado no item 2.1.2, o PVDF é recomendado para ser utilizado na forma de sensores devido suas características apresentadas na tabela (2.1). A tensão elétrica obtida pelo sensor é proporcional a deformação espacialmente integrada pela área que ele ocupa. Este sensor pode ser modelado através de um modelo elétrico simples, constituído de um gerador de carga em paralelo com um capacitor, ou um gerador de tensão elétrica em série com um capacitor, como mostra a figura (2.8). A relação entre estas variáveis é dada por (Brennan, 1994),

$$Q = CV \quad (2.8)$$

sendo  $V$  a tensão elétrica gerada em circuito aberto,  $Q$  a carga elétrica e  $C$  a capacitância do sensor.

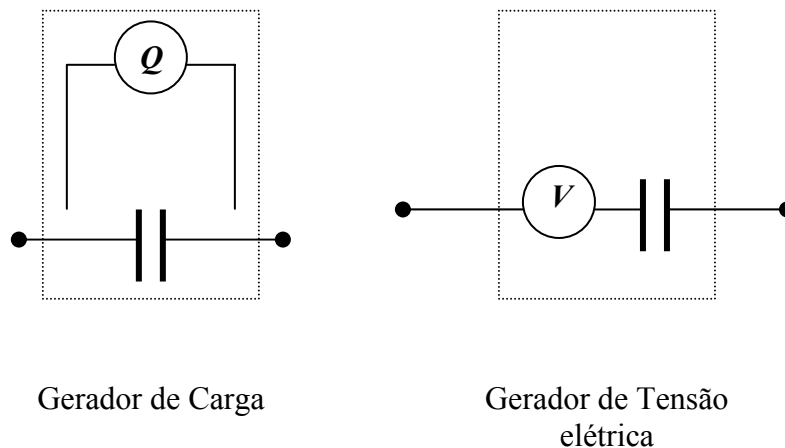


Figura 2.8 – Modelos equivalentes de um sensor piezelétrico.

## 2.2 A Técnica da Impedância Elétrica

Danos como trincas, corrosão, cortes, etc, causam alterações na massa, rigidez e amortecimento das estruturas. Conseqüentemente, estas mudanças causam reflexos nos parâmetros modais das estruturas, tais como: frequências naturais, modos de vibrar e fator de amortecimento. Existem técnicas bastante difundidas utilizando parâmetros modais para

avaliação de falhas estruturais. Demarchi (Demarchi, 2001) utiliza a variação das frequências naturais em uma estrutura do tipo barra para localizar e quantificar a falha através de redes neurais.

Embora existam diversos trabalhos apresentando a utilização de parâmetros modais na detecção e localização de falhas estruturais, o emprego desta metodologia não é trivial e apresenta alguns obstáculos. Um exemplo é o fato da falha ser um fenômeno local enquanto as informações modais refletem as informações globais do sistema. Neste sentido, utilizamos o método da impedância elétrica para detectar e localizar as falhas em uma estrutura. O método emprega atuadores/sensores piezelétricos (PZT) para excitar/medir a impedância elétrica em altas faixas de frequência (tipicamente acima de 10kHz). Esta faixa de frequência permite trabalhar com os modos locais, avaliando, assim, apenas as informações correspondentes à área de atuação de cada PZT. O princípio básico consiste em monitorar a variação da impedância mecânica, causada devido a presença de uma mudança estrutural (falha), através da impedância elétrica.

Um modelo simples, como mostrado na figura (2.9), pode descrever a interação entre um PZT e a estrutura a ele vinculada. O PZT é considerado como uma barra fina exposta a uma vibração axial em resposta a aplicação de tensão elétrica alternada. Uma extremidade é fixada e a outra é conectada na estrutura, representada por um sistema de um grau de liberdade.

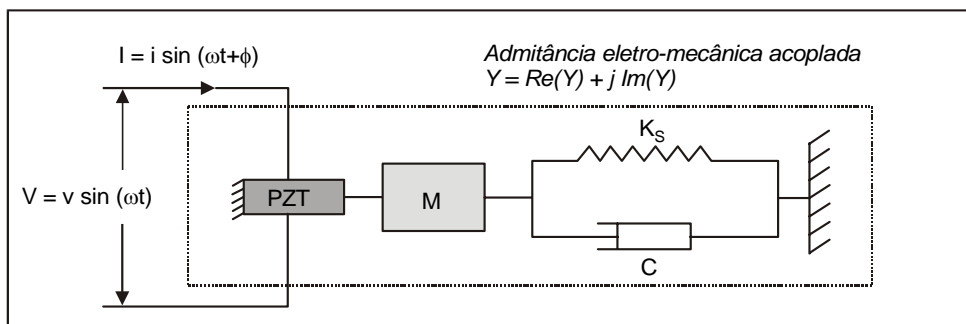


Figura 2.9 – Modelo usado para representar o acoplamento de um PZT com a estrutura base.

A impedância elétrica é definida como sendo a razão entre a tensão elétrica de entrada e a corrente resultante. A impedância mecânica, equação (2.9), é definida como a razão entre a força aplicada e a velocidade resultante no domínio da frequência (Ewins, 1991). O transdutor eletromecânico acopla as impedâncias elétrica e mecânica. Sendo mais fácil medir a impedância elétrica do que a mecânica, esta característica pode ser utilizada com vantagens para muitas

aplicações, como por exemplo, em situações onde a FRF (Função de Resposta em Frequência) poderia ser de difícil obtenção.

$$Z(\omega) = \frac{F(\omega)}{\dot{X}(\omega)} \quad (2.9)$$

$$Y(\omega) = \frac{1}{Z(\omega)} \quad (2.10)$$

sendo  $Z(\omega)$  a impedância mecânica,  $F(\omega)$  a transformada de Fourier da força de entrada,  $\dot{X}(\omega)$  a transformada de Fourier da velocidade e  $Y(\omega)$  a admitância, a qual é o inverso da impedância. A impedância mecânica da estrutura depende da frequência de excitação e para um sistema massa-mola amortecedor é dada por:

$$Z(\omega) = c + m \frac{\omega^2 - \omega_n^2}{\omega} i \quad (2.11)$$

sendo  $c$  o coeficiente de amortecimento,  $m$  a massa,  $\omega$  a frequência de excitação e  $\omega_n$  a frequência de ressonância do sistema. A relação força-deslocamento para o sensor/atuador PZT e a estrutura é, (Sun, 1996):

$$F = k_A (x - x_{in}) \quad (2.12)$$

$$k_A = \bar{Y}_{22}^E \frac{w_A h_A}{l_A} \quad (2.13)$$

$$x_{in} = d_{32} E l_A \quad (2.14)$$

$$\bar{Y}_{22}^E = Y_{22}^E (1 + i\eta) \quad (2.15)$$

sendo  $x$  o deslocamento,  $F$  a força exercida pelo atuador,  $k_A$  a rigidez estática do PZT,  $w_A$ ,  $h_A$  e  $l_A$  a largura, a espessura e o comprimento do PZT, respectivamente,  $x_{in}$  o deslocamento do atuador sem indução,  $Y_{22}^E$  módulo complexo do PZT para campo elétrico zero,  $\eta$  o fator de perda mecânica do PZT,  $E$  é o campo elétrico e  $d_{32}$  é a constante piezoeletrica. Para aplicações dinâmicas, como no caso do monitoramento de condição baseado na impedância, a relação força-deslocamento é fundamentada no conceito da impedância mecânica. Assumindo um estado harmônico de excitação constante e usando a equação (2.11):

$$F = -Z\dot{x} = -\left( c + m \frac{\omega^2 - \omega_n^2}{\omega} i \right) (i\omega x) \quad (2.16)$$

ou

$$F = -k_D x = -(ic\omega - m(\omega^2 - \omega_n^2))x \quad (2.17)$$

sendo  $k_D$  a rigidez dinâmica. A relação força-deslocamento dinâmico pode agora ser determinada pelas equações (2.12) e (2.17), como:

$$F = -\frac{k_D k_A}{k_D + k_A} x_{in} \quad (2.18)$$

Para aplicação estrutural, as equações eletromecânicas (2.1) e (2.2) são reduzidas para duas equações escalares. Considerando que o campo elétrico é aplicado na direção  $z$  e que o PZT expande e contrai apenas na direção  $y$ , a relação constitutiva é:

$$S_2 = s_{22}^E T_2 + d_{32} E_3 \quad (2.19)$$

$$D_3 = d_{32} T_2 + \varepsilon_{33}^T E_3 \quad (2.20)$$

ou, na forma matricial

$$\begin{Bmatrix} S_2 \\ D_3 \end{Bmatrix} = \begin{bmatrix} s_{22}^E & d_{32} \\ d_{32} & \varepsilon_{33}^T \end{bmatrix} \begin{Bmatrix} T_2 \\ E_3 \end{Bmatrix} \quad (2.21)$$

Aqui é assumido que  $D_3$  é medido,  $E_3$  é determinado a partir do campo elétrico aplicado no material piezocerâmico e  $s_{22}^E$ ,  $d_{32}$ ,  $\varepsilon_{33}^T$  são constantes.  $S_2$  é a deformação e  $T_2$  é a tensão no PZT ao longo do eixo  $y$ . A primeira equação é chamada de equação do atuador e a segunda, de equação do sensor. Nestas condições, existem duas variáveis desconhecidas,  $S_2$  e  $T_2$ , as quais podem ser determinadas pelas equações acima. A solução das equações eletromecânicas, no caso escalar, é a base teórica do auto-sensoriamento do atuador piezelétrico. A equação de movimento para um PZT com deslocamento na direção  $y$  pode ser expresso como:

$$\rho \frac{\partial^2 v}{\partial t^2} = \bar{Y}_{22}^E \frac{\partial^2 v}{\partial y^2} \quad (2.22)$$

sendo  $v$  o deslocamento na direção  $y$  e  $\rho$  a densidade do PZT. Separando o deslocamento nos domínios do tempo e espacial e aplicando as condições de contorno, a solução da equação acima pode ser escrita como

$$v = \bar{v} e^{i\omega t} = (A \cos(k.y) + B \sin(k.y)) e^{i\omega t} \quad (2.23)$$

com

$$k = \omega^2 \frac{\rho}{\bar{Y}_{22}^E} \quad (2.24)$$

o deslocamento do atuador PZT, a deformação, o campo de tensão e o campo de deslocamento elétrico podem então ser determinados (Ayres, 1996). O fluxo de corrente no PZT é a taxa de tempo da carga elétrica total entre os dois eletrodos, podendo ser expressa como:

$$I = \iint_{\sigma} i\omega D_3 d\sigma \quad (2.25)$$

sendo  $\sigma$  a área do eletrodo. A admitância elétrica é dada por  $Y = I/V$ , que após algumas substituições, para um PZT retangular como mostrado na figura (2.3) pode ser encontrada como (Sun, 1996):

$$Y(\omega) = i\omega \frac{w_A l_A}{h_A} \left( \bar{\epsilon}_{33}^T - (d_{32})^2 \bar{Y}_{22}^E + \frac{Z_A(\omega)}{Z_S(\omega) + Z_A(\omega)} (d_{32})^2 \bar{Y}_{22}^E \frac{\tan(k l_A)}{k l_A} \right) \quad (2.26)$$

Em que  $Z_A$  é a impedância mecânica do atuador ao longo da direção  $y$  e  $Z_S$  é a impedância mecânica da estrutura.

### 2.2.1 Área de atuação do PZT

A técnica da impedância elétrica utiliza faixas de frequências relativamente altas, isto faz com que a resposta em frequência seja dominada pelos modos locais, delimitando desta forma, a área de atuação de cada PZT. Falhas estruturais tais como: trincas e perda de conexão, produzem variação nas características dinâmicas do sistema e essas mudanças podem ser medidas. Os modos locais são mais sensíveis à presença de uma falha do que os modos globais, neste sentido, monitorando o valor da impedância elétrica de cada PZT é possível isolar o local onde a falha está presente, obtendo-se assim, a posição geométrica do dano.

Para monitorar as condições da estrutura, a técnica utiliza uma faixa de frequência para excitar a estrutura. No caso de uma falha incipiente, cuja presença não causa mudanças mensuráveis através das técnicas globais, é necessário um comprimento de onda para excitação menor do que o comprimento da falha para que a mesma possa ser detectada (Stokes, 1993). Neste sentido, a faixa de frequência geralmente empregada é algo abaixo de 100kHz. A faixa de frequência utilizada é encontrada na base da tentativa e erro, sendo escolhida a região onde se encontram o maior número de ressonâncias (picos), isto normalmente indica que existe uma

grande interação dinâmica. Deve ser notado que altas frequências limitam a área de sensibilidade de cada PZT (Raju, 1998).

Como já foi dito, o PZT excita os modos locais, sendo assim, esta técnica é sensível apenas às alterações ocorridas próxima a região onde o PZT está colado. Portanto, no monitoramento de uma estrutura é necessário a colagem de PZT's nas regiões que se deseja monitorar, ou seja, nas regiões mais propícias de ocorrer falhas.

### 2.2.2 Características da Resposta Medida em Frequência

Para realizarmos a medida da impedância elétrica foram utilizados dois tipos de aparelhos. Primeiramente utilizamos o “HP impedance analyzer – HP 4192A”, onde podem ser medidas dois componentes independentes da impedância, simultaneamente. Esta combinação entre os componentes representa ambas as características resistivas e reativas da amostra. No total estão disponíveis quinze tipos de parâmetros que podem ser medidos; destes, dois são utilizados neste trabalho:

- 1) Função “R – X”, (R: real e X: imaginário); unidades: R, ohms e X, ohms.
- 2) Função “Z –  $\theta$ ”, (Z: impedância e  $\theta$ : graus); unidades: Z, ohms e  $\theta$ , radianos.

O segundo aparelho utilizado na medida da impedância elétrica foi batizado de MIBC (Medidor de impedância de Baixo Custo), neste caso as medidas foram obtidas com os componentes real e imaginário da impedância.

No caso da medida utilizando a função “R – X” (R é real ou a parte resistiva e X é imaginário ou a parte capacitiva) foram plotados dois tipos de gráficos: um sendo “R vs. Frequência” e outro sendo “X vs. Frequência”. A impedância absoluta ou a fase podem ser obtidas através das equações:

$$Z = \sqrt{R^2 + X^2} \quad (2.27)$$

$$\theta = \tan^{-1}\left(\frac{X}{R}\right) \quad (2.28)$$

sendo,

$Z$  = Impedância absoluta

$R$  = Resistência

$X$  = reatância

$\theta$  = ângulo de fase.

O componente que é mais sensível à presença de uma falha é a parte real  $R$ , isto deve-se ao fato de que uma mudança na impedância medida é atribuída a uma mudança na impedância estrutural devido a presença da falha. Esta característica é devida a parte resistiva da impedância medida (componente  $R$ ). A parte reativa  $X$  permanece com uma desprezível mudança, qualquer mudança neste componente é devido a variação nas condições de contorno, tais como: temperatura, e comprimento do fio de teste (Raju, 1998).

### 2.2.3 Falha Métrica

A técnica da impedância elétrica fornece informações qualitativas a respeito da falha. Neste sentido, a falha métrica é definida como um valor escalar para monitorar a variação da impedância elétrica em tempo real. Deve-se definir um valor mínimo, “threshold”, acima do qual um sinal de alarme deve ser acionado para alertar o surgimento de falhas.

Existem alguns tipos de falha métrica que são empregadas. A mais simples pode ser definida como:

$$M = \sum_{i=1}^n [\text{Re}(Z_{i,1}) - \text{Re}(Z_{i,2})]^2 \quad (2.29)$$

sendo  $M$  a falha métrica,  $\text{Re}(Z_{i,k})$  a parte real da impedância elétrica,  $Z_{i,1}$  a impedância elétrica medida para a estrutura na condição normal (medida de referência) e  $Z_{i,2}$  a impedância elétrica que será comparada com a medida de referência para cada intervalo de frequência  $i$  (Lopes Jr. et al., 2001). A mudança da impedância elétrica para a medida de  $Z_{i,2}$  ao longo de toda a curva, e não somente em uma região qualquer, pode indicar a presença de uma falha.

## CAPÍTULO 3

### CONCEITOS BÁSICOS DE REDES NEURAIS ARTIFICIAIS

Em nosso trabalho, as redes neurais artificiais foram utilizadas na segunda etapa da metodologia empregada. A primeira etapa está a cargo do método da impedância elétrica que é responsável pela detecção e localização da falha na estrutura. A segunda etapa compreende a fase da quantificação da severidade da falha. Assim, as medidas da impedância elétrica são padronizadas de forma a representar cada condição de falha. Desta maneira, após o treinamento, para cada situação de dano, espera-se que a rede apresente uma boa capacidade de generalização.

Esta técnica exige o treinamento de uma rede neural para cada PZT colado na estrutura. Portanto, a fase de treinamento de cada rede define o sucesso da metodologia empregada. Utilizamos uma rede com treinamento supervisionado do tipo “Multilayer Perceptron” com algoritmo de aprendizado por retropropagação (Backpropagation). Alguns conceitos sobre as redes neurais artificiais são descritos neste capítulo, bem como o tipo de rede e o algoritmo de aprendizado utilizado.

#### 3.1 Introdução e o Modelo Biológico

Existem estudos que indicam inteligência em outros animais, entretanto, nenhuma delas é comparada a inteligência humana. Esta inteligência “irracional” proveniente dos outros seres está associada a necessidade de adaptação ao meio. Desta maneira, pode-se utilizar este conceito para

uma máquina definindo-se a *inteligência de máquina*. Esta inteligência seria a *capacidade genética* de um instrumento se adaptar ao meio. Entendendo-se por *capacidade genética* o conhecimento embutido a nível de hardware, que associado a software pode proporcionar vários estados possíveis de trabalho para uma determinada máquina. A inteligência de máquina seria um tipo de inteligência construída pelo homem, portanto, uma Inteligência Artificial (IA). Redes Neurais Artificiais (RNAs) são técnicas computacionais inspiradas nos organismos vivos e que fazem parte de um ramo da inteligência artificial que envolvem técnicas como: Algoritmos Genéticos (AG), Colônia de Formigas, Lógica Nebulosa, etc. (Coelho L. S., 2000).

As redes neurais são modelos computacionais ou sistemas de processamento de informações que, de um modo geral, podem ser tratados como um dispositivo "caixa preta" que aceita uma entrada e produz uma saída. Existem algumas situações nas quais o emprego das redes neurais é vantajoso:

- Situações onde se requer poucas decisões e que envolvam grandes quantidades de dados por exemplo, (processamento de imagens, etc.);
- Situações onde as não-linearidades são fundamentais e predominantes no modelo (controle de robôs, etc.);
- Situações onde soluções muito próximas do ótimo devem ser fornecidas rapidamente (sistema de aero-navegação automática, etc.).

As redes neurais, potencialmente, podem ser utilizadas para as mais diversas finalidades, dentre as quais se destacam:

- Classificação: a rede neural fornece como saída uma classe representativa de um dado padrão fornecido como entrada;
- Reconhecimento de padrões: se um determinado padrão é fornecido à rede, esta será capaz de reproduzi-lo como saída;
- Complementação de padrões: um padrão incompleto é fornecido à rede neural e esta reproduzirá o mesmo padrão completando as partes faltantes;
- Remoção de ruído: um padrão contaminado é apresentado à rede neural e ela será capaz de reproduzir o sinal removendo a maior parte, senão a totalidade, do ruído;

- Otimização: um conjunto de condições iniciais de um específico problema de otimização é apresentado à rede neural que, produzirá como saída um conjunto de condições que representa a solução ótima para o problema;

- Controle: um padrão representativo do estado atual do sistema e da resposta desejada é fornecido à rede neural que produzirá como saída uma seqüência de comandos que possibilitará a obtenção da resposta desejada.

Uma rede neural se compõe, basicamente, dos seguintes elementos:

- Um conjunto de unidades de processamento, também chamadas de células ou neurônios, agrupados em camadas;

- Uma regra de propagação, que determinará como as informações provenientes da camada anterior se comporão numa entrada efetiva  $i$  para os neurônios;

- Uma função de ativação,  $F_i$ , que produzirá o nível de ativação  $y_i$  do neurônio, a partir da entrada efetiva  $i$ ,

- Uma entrada externa (bias  $W_0$ ) para cada neurônio e

- Um método de armazenamento de informações.

Uma rede neural artificial consiste de uma arquitetura de processamento de informações baseadas nas redes neurais biológicas e possui habilidades de identificação de funções e classificação de padrões. Similarmente às redes neurais biológicas, as RNA assimilam informações pela técnica de tentativa e erro. Isto significa que podem aprender mediante a apresentação de exemplos. A figura (3.1) apresenta um modelo de neurônio biológico e seus componentes.




Figura 3.1 – Modelo de um neurônio biológico.

Os dendritos têm como função receber os estímulos nervosos provenientes de outros neurônios, enquanto o corpo celular ou soma, é responsável por coletar e gerar os impulsos nervosos. O axônio é responsável por transmitir os impulsos nervosos para as outras células, ele é constituído por uma fibra tubular que pode medir cerca de 0,1 milímetro podendo chegar a alguns metros. Próximo do seu final ele divide-se em vários ramos que se interconectam com os demais neurônios através das sinapses. Sinapse é o ponto de encontro entre o final do axônio de um neurônio e o dendrito de outro neurônio. Funciona como válvula sendo capaz de controlar a transmissão de impulsos (fluxo de informação) entre os neurônios.

### 3.2 Breve Histórico Sobre Redes Neurais Artificiais

Alan Turing foi um dos primeiros pesquisadores a inspirar-se no cérebro para configurar um paradigma computacional, em 1936 (Nelson e Illingworth, 1991). Um modelo, que possui aplicações no aprendizado das RNAs, foi proposto por Donald Hebb, no trabalho *The Organization of Behavior*, em 1949. Suas idéias não eram completamente novas, mas Hebb foi o primeiro a propor uma lei de aprendizagem específica para as sinapses dos neurônios.

Um dos trabalhos pioneiros na área foi o de Warren S. McCulloch e Walter Pitts, *A Logical Calculus of the Ideas Immanent in Nervous Activity*, em 1943, quando propuseram um

modelo para o neurônio, demonstrando que as associações de neurônios artificiais implementam qualquer função lógica finita. O primeiro modelo de unidade de processamento foi proposto por McCulloch e Pitts, figura (3.2) onde o objetivo era modelar o comportamento de células nervosas (Coelho L. S., 2000).

O primeiro neuro computador a obter sucesso foi “Mark I Perceptron” que surgiu em 1957 e 1958, tendo como mentor Frank Rosenblatt, Charles Wightman e outros. O *perceptron* consegue aprender a classificação de padrões a partir de exemplos. Assim, pela primeira vez, tinha-se a configuração de um modelo de aprendizado e percepção com resultados concretos.

Em 1959, Bernard Widrow e Marcian Hoff, com a ajuda de alguns estudantes, desenvolveram os modelos de RNAs denominados *ADALINE* (*ADaptive LINEar Elements*) e *MADALINE* (*Multiple ADALINE*). Estes modelos se utilizam de uma poderosa lei de aprendizado e, diferente do Perceptron, ainda permanece em uso. Esta foi a primeira aplicação de RNAs, em problemas reais, constituindo-se de filtros adaptativos para eliminação de ruídos em linhas telefônicas.

Após um entusiasmo inicial se seguiu uma grande crise com a descoberta das limitações do *perceptron*. No livro *Perceptrons*, Minsky e Papert (1969) mostram as deficiências do *perceptron* e provam que as RNAs de uma camada, então em utilização, são incapazes de resolver problemas simples, incluindo a execução de uma função *ou exclusivo*. O problema detectado aponta que uma única camada é incapaz de resolver problemas linearmente não-separáveis. No trabalho citado, as limitações apontadas são acompanhadas de uma declaração de uma crença pessoal (e errônea) dos autores, na qual a extensão do modelo neural seria inútil. Este fato marca uma diminuição das pesquisas em RNAs na década de 70. Entretanto, deve ser mencionado que Minsky e Papert (1969) apontam a solução do *ou exclusivo*, através de alguma transformação pela adição de uma camada ao *perceptron* conectando todas as entradas.

Em 1974 Paul J. Werbos lançou as bases para o algoritmo de retropropagação (backpropagation). O ressurgimento do interesse em RNAs ocorre com a utilização do algoritmo de treinamento por retropropagação de erro, por um grupo de pesquisadores denominado *PDP* (*Parallel Distributed Processing*), em 1986. Suas pesquisas resultam na extensão do *perceptron* para várias camadas de neurônios e, assim, superam as dificuldades daquele modelo (Rumelhart et al., 1986). A partir deste marco, observa-se uma explosão de aplicações de RNAs nos mais variados campos do conhecimento.

Em 1987 ocorreu em São Francisco a primeira conferência de redes neurais em tempos modernos, a IEEE International Conference on Neural Networks, e também foi formada a International Neural Networks Society (INNS). A partir destes acontecimentos surgiram o INNS journal em 1989, seguido do Neural Computation e do IEEE Transactions on Neural Networks, em 1990.

### 3.3 Modelo Neural Artificial

O primeiro modelo de neurônio artificial foi proposto por McCulloch – Pitts em 1943, figura (3.2), tendo como inspiração o modelo de um neurônio biológico. Atualmente sabemos que o modelo proposto está distante da realidade. Entretanto, ele norteou o desenvolvimento de outros modelos mais realísticos, que ainda se baseiam no modelo inicialmente proposto.




Figura 3.2 – Modelo de neurônio de McCulloch – Pitts

Podemos dividir o neurônio artificial em duas regiões. Na primeira se encontra a *função de base* ou *função de rede*, que pode ser uma função linear, ou não-linear. Após a apresentação de um vetor de entrada  $X_n$ , que pode ser chamado de padrão, é realizada uma multiplicação vetorial com a matriz de pesos  $W$  da primeira camada, resultando em um vetor de resposta  $S_n$ . Normalmente no cálculo de  $S_n$  é adicionado um vetor de peso *bias*  $W_0$ , ponderado com uma entrada fixa igual a  $\pm 1$ . Este artifício desempenha o papel de controle de nível na saída do neurônio, aumentando assim a capacidade da rede. Pode-se representar uma função linear, para

um neurônio  $j$  com o comprimento do vetor de entrada igual a  $comp$  através da equação (3.1) abaixo.

$$s_j = \sum_{i=1}^{comp} w_{ji}x_i + w_{j0} \tag{3.1}$$

sendo

$x_i$  = vetor de entrada na posição  $i$ ;

$w_{ji}$  = matriz de peso, que relaciona a entrada  $i$  e o neurônio  $j$ ;

$i$  = índice do número de entrada;

$j$  = índice do número do neurônio.

Abaixo apresentamos os componentes de cada entidade para o caso particular da primeira camada ativa de neurônios, sendo as variáveis  $neur$  e  $comp$  o número de neurônios da primeira camada ativa e o número de componentes do vetor de entrada respectivamente.

$$\mathbf{X}_n = \left\{ \begin{matrix} x_{1n} \\ x_{2n} \\ \vdots \\ x_{comp\ n} \end{matrix} \right\}_{comp \times 1}$$

$$\mathbf{W} = \begin{bmatrix} w_{11} & \cdots & w_{1j} \\ w_{21} & \cdots & w_{2j} \\ \vdots & \ddots & \vdots \\ w_{i1} & \cdots & w_{ij} \end{bmatrix}_{neur \times comp}$$

$$\mathbf{W}_0 = \left\{ \begin{matrix} w_{10} \\ w_{20} \\ \vdots \\ w_{neur0} \end{matrix} \right\}_{neur \times 1}$$

$$\mathbf{S}_n = \left\{ \begin{matrix} s_{1n} \\ s_{2n} \\ \vdots \\ s_{neur\ n} \end{matrix} \right\}_{neur \times 1}$$

Assim em notação vetorial tem-se :

$$\mathbf{S}_n = \mathbf{W}\mathbf{X}_n + \mathbf{W}_0 \tag{3.2}$$

O índice  $n$  indica o índice do vetor apresentado à rede correspondente a matriz de dados utilizada que contém  $N$  vetores, pois tanto na fase de treinamento como na de verificação são apresentados um conjunto de dados (vetores) que constituem a matriz de treinamento e verificação respectivamente.

Observa-se que:

$$S_n = WX_n + W_0 \quad \text{ou} \quad S_n = (X_n^T W^T)^T + W_0 \quad (3.3)$$

O sobrescrito  $T$  indica operação transposta. Embora a combinação linear seja a mais aplicada existem outras funções que também podem ser utilizadas nesta fase como, por exemplo a função *produtório* (3.4), *máximo* ou *mínimo* (3.5) e *soma cumulativa* (3.6). Pode-se observar que na equação (3.6) a entrada líquida é obtida utilizando não somente o vetor de entrada e os pesos, mas também o valor da entrada líquida numa iteração anterior (Kaminski, 1997).

$$s_j = \prod_{i=1}^{comp} w_{ji} x_i \quad (3.4)$$

$$s_j = \max\{w_{ji} x_i\} \quad i = 1, 2, \dots, comp \quad (3.5)$$

$$s_j^t = s_j^{t-1} + \sum_{i=1}^{comp} w_{ji} x_i \quad (3.6)$$

Após a fase de treinamento da rede, a matriz de pesos representa a influência de cada conexão na resposta final do neurônio, ou seja, conexões que apresentam um valor alto nos pesos têm grande influência na resposta daquele neurônio. Similarmente, conexões que apresentam baixos valores nos pesos têm pouca influência na resposta do referido neurônio.

A segunda região do neurônio artificial é chamada de *função de ativação* ou *função de transferência* do neurônio ou até mesmo *função do neurônio*, equação (3.7). Esta região é a parte responsável pela característica de não-linearidade da rede, embora possa ser utilizada uma função linear. Na maioria das vezes a função utilizada é não-linear, uma vez que uma das características mais atraentes das RNAs é seu emprego em casos onde a não-linearidade está

presente. O neurônio de McCulloch – Pitts emprega a função de transferência degrau (Threshold). Outras funções podem ser utilizadas e a escolha depende da aplicação da rede, cada uma ressaltando determinada característica.

$$y_n = f(s_n) \quad (3.7)$$

As *funções de transferência* convertem um domínio infinito em um domínio finito e os tipos mais comuns de funções utilizadas são apresentadas a seguir:

### Função linear

A função linear apresentada na figura (3.3.a) produz uma saída linear para uma entrada  $s$  obedecendo a seguinte equação:

$$y = f(s) = Ks \quad (3.8)$$

sendo  $K$  uma constante escalar, que neste caso é positiva.

### Função degrau

A função tipo degrau apresentada na figura (3.3.b) produz somente dois valores,  $-A$  ou  $B$ , escalares. Se o valor do sinal de entrada  $s$  é igual ou maior que um dado valor de referência  $\theta$ , então a função de ativação produz o valor  $B$ , caso contrário o valor será  $-A$ . Matematicamente esta função pode ser descrita como:

$$y = f(s) = \begin{cases} B & \text{se } s \geq \theta \\ -A & \text{se } s < \theta \end{cases} \quad (3.9)$$

### Função rampa

A função de ativação tipo rampa apresentada na figura (3.3.c) produz valores que variam linearmente entre dois pontos de saturação simetricamente dispostos em torno da origem. Fora dessa faixa a função produz valores constantes.

$$y = f(s) = \begin{cases} \xi & \text{se } s \geq \xi \\ s & \text{se } |s| < \xi \\ -\xi & \text{se } s \leq -\xi \end{cases} \quad (3.10)$$

sendo  $\xi$  o valor de saturação da função. Os pontos  $s = \xi$  e  $s = -\xi$ , são descontinuidades na função  $f$ .

### Função sigmoidal

A função de ativação sigmoidal é uma função não-linear. A função sigmoidal mais comum é matematicamente definida como:

$$y = f(s) = \frac{1}{1 + e^{-\lambda s}} \quad (3.11)$$

sendo  $\lambda \neq 0$  (geralmente  $\lambda = 1$ ) responsável pela inclinação da curva. Esta função promove um valor da saída na faixa ente 0 e 1. Existem outros tipos de função alternativa à função sigmoidal, como por exemplo a função tangente hiperbólica apresentada na figura (3.3.d), que produz valores na faixa de +1 a -1.

$$y = f(s) = \frac{1 - e^{-\lambda s}}{1 + e^{-\lambda s}} \quad (3.12)$$

### Função gaussiana

A função de ativação gaussiana apresentada na figura (3.3.e) é simétrica em relação a origem e requer um valor predefinido de variância  $v > 0$ .

$$y = f(s) = e^{-\frac{(s - \bar{s})^2}{v}} \quad (3.13)$$

sendo  $\bar{s}$  o valor médio da entrada e  $v$  é a variância previamente definida.

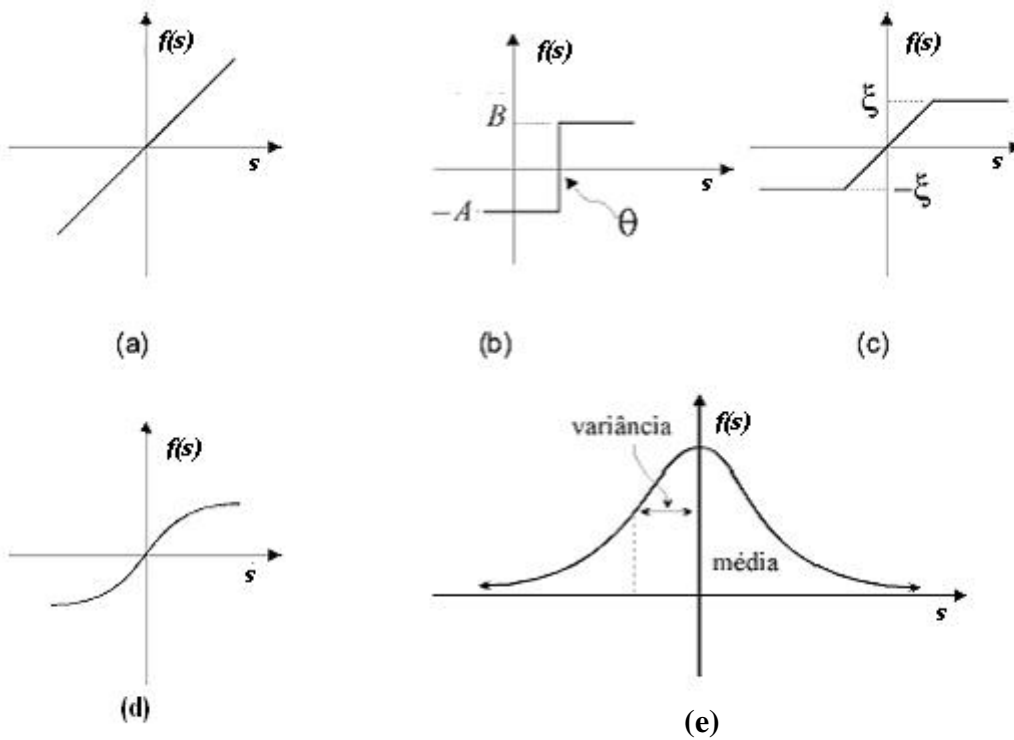


Figura 3.3 – Funções de ativação. (a) Função linear. (b) Função degrau. (c) Função rampa. (d) Função sigmóide. (e) Função gaussiana.

A utilização de funções de transferência como a sigmoidal tendem a amenizar o problema que a rede neural tem em lidar com valores de entradas altos e baixos ao mesmo tempo. Grossberg apresenta um dos primeiros trabalhos propondo a utilização de funções de transferência onde o ganho (entendendo-se *ganho* como sendo a derivada da função de transferência calculada para o valor da entrada) entre a entrada e a saída fosse variável. Desta maneira, entradas pequenas ficam sujeitas a valores maiores de ganho quando comparado com entradas com maior magnitude. A função de transferência do tipo rampa com saturação apresenta características similares a função sigmóide no que tange a propriedade do ganho. Entretanto, a função não é diferenciável em todos os pontos e pode se tornar um problema, uma vez que esta propriedade normalmente é utilizada em alguns tipos de treinamento.

A propriedade de variação do ganho pode ser facilmente verificada observando a derivada da função sigmóide, uma vez que o ganho é dado justamente por esta (Kaminski, 1997).

$$f(s) = \frac{1}{1 + e^{-s}} \quad (3.14)$$

$$f'(s) = \frac{e^{-s}}{(1 + e^{-s})^2} = f(s)(1 - f(s)) \quad (3.15)$$

Para valores de entrada  $s$  positivos e elevados,  $f(s) \approx 1$ . Logo,  $f'(s) \approx 0$  e por conseguinte o ganho é mínimo. O mesmo pode ser dito para valores de  $s$  menores que zero, mas de valor absoluto bastante elevado. Para este caso  $f(s) \approx 0$  e  $f'(s) \approx 0$ . Para valores próximos a zero  $f(s) \approx 1/2$  e  $f'(s) \approx 1/4$  e este será o ganho máximo.

Cada neurônio produz uma única saída, que posteriormente é enviada a outros neurônios. O valor de saída é o mesmo, entretanto, ele pode ser ponderando por valores diferentes de pesos.

### 3.4 Estrutura da Rede Neural Artificial

Comumente, as redes neurais são dispostas em *camadas*, figura (3.4), as quais se dividem em *camada de entrada*, *camadas intermediárias ou ocultas (hidden layers)* e *camada de saída*. No cálculo do número de camadas de uma rede são consideradas apenas as camadas com propriedade de processamento. Assim, a camada de entrada não é computada, sendo utilizada apenas para distribuir para todos os neurônios da camada posterior os componentes do vetor de entrada. Desta maneira a rede da figura (3.4) apresenta três camadas de processamento, com duas camadas ocultas, que ficam entre a camada de entrada e a camada de saída. Uma outra maneira de contar as camadas de uma RNA é considerar as camadas de pesos  $w_{ij}$ . Desta forma, evita-se uma eventual confusão na contagem de camadas devido as características especiais dos neurônios da camada de entrada. A forma utilizada para apresentar a topologia da rede utilizada neste trabalho é (2 4 4 1), sendo os números a quantidade de neurônios em cada camada.




Figura 3.4 – Rede neural multicamada com duas camadas ocultas.

Como será visto adiante o número de camadas de uma rede neural é uma característica importante, pois ela tem forte influência na representação do problema. Os perceptrons eram redes com apenas uma camada de neurônios, similar ao do tipo McCulloch – Pitts, e com função de transferência degrau com valores 0 ou 1. Devido sua configuração de uma única camada este tipo de rede tinha a limitação de não conseguir empregar a função booleana OU Exclusivo (“XOR”).

Considerando-se a propagação dos dados de uma rede neural, tem-se dois tipos de divisões (Lopes, 2000).

- **Redes Diretas (Feedforward)** – São redes onde os dados fluem da camada de entrada para a camada de saída no processo *feedforward*, ou seja, não existe um ciclo. A saída de um neurônio é transmitida para camadas posteriores, não havendo realimentação da mesma camada ou de camadas anteriores figura (3.4). Estas são as redes mais populares, principalmente por existirem algoritmos de aprendizados bastante difundidos e de fácil implementação. Um método muito utilizado e eficiente é o “backpropagation” ou retropropagação, por esta razão alguns autores chegam a chamar impropriamente este tipo de rede de “backpropagation”.
- **Rede Recorrentes (feedback)** – Ao contrário das redes diretas as redes recorrentes possuem um ciclo de alimentação, ou seja, a saída de um neurônio além de ser transmitida para as camadas subseqüentes alimenta neurônios da

mesma camada ou até mesmo neurônios de camadas anteriores, figura (3.5). Um exemplo importante deste tipo de rede é encontrado na rede proposta por Hopfield.




Figura 3.5 – Exemplo de uma rede recorrente.

Este último tipo de rede desenvolve uma memória em longo prazo nos neurônios internos, pois sua saída depende da resposta que ela apresentou, ao contrário da rede *feedforward* onde a entrada da rede é função somente da saída dos neurônios da camada anterior ponderada pelos pesos, saída esta que não depende de nenhum neurônio de camadas subsequentes.

### 3.5 Generalização e Representação

Uma das grandes propriedades das redes neurais é sua capacidade de aprender. O processo pelo qual a rede aprende é chamado de treinamento e é realizado através de um processo iterativo de ajustes de seus pesos. O aprendizado é alcançado quando a rede neural atinge uma solução generalizada para uma classe de problemas.

A capacidade de generalização pode ser compreendida quando a rede apresenta soluções satisfatórias nas situações para as quais não houve aprendizado; crianças reconhecem números num relógio digital embora tenham aprendido os algarismos arábicos na forma manuscrita. Outra característica das RNA é a de não perder a informação já armazenada caso ocorra a destruição

parcial da rede. Isto pode ser verificado no funcionamento normal do sistema nervoso humano, caso alguns milhões de neurônios sejam anulados (Oliveira, 1999).

A capacidade de representação de uma rede está associada a sua capacidade de implementar uma determinada função. Como exemplo, considera-se uma rede que consegue identificar alguns tipos diferentes de flores tendo como informação para esta identificação o número de pétalas e sépalas. Será possível representar esta função usando uma rede neural? Será possível ajustar os pesos desta rede neural de tal forma que a classificação possa ser feita? Se possível, então diz-se que a rede neural representa a função desejada (Kaminski, 1997).

### 3.5.1 Representação com uma Camada de Neurônios

Seja um neurônio de McCulloch – Pitts com duas entradas binárias.




Figura 3.6 – neurônio com duas entradas.

$$\begin{aligned}
 s_j &= w_{j1}x_1 + w_{j2}x_2 \\
 y &= 1 \quad \text{se } s_j > 0,5 \\
 y &= 0 \quad \text{se } s_j < 0,5
 \end{aligned}
 \tag{3.16}$$

Podemos notar que o neurônio acima divide o espaço em duas regiões. Uma onde as entradas contidas no vetor  $\mathbf{X} = \{x_1, x_2\}$  provocam saída igual a 1 e outra onde as entradas provocam saída igual a 0, conforme mostrado na figura (3.7).




Figura 3.7 – Separação em duas categorias.

A reta cuja equação é dada pela equação (3.17) separa a figura (3.7) em duas regiões.

$$x_1 w_{j1} + x_2 w_{j2} = cte \quad (3.17)$$

Podemos dizer que um neurônio de McCulloch – Pitts funciona como um *discriminador linear*, isto é, consegue distinguir se conjuntos de dados pertencem a classes distintas, desde que estas classes sejam linearmente separáveis.

Podemos entender como classes linearmente separáveis, classes que podem ser separadas por intermédio de um hiperplano linear. A figura (3.8.a) apresenta uma ilustração de uma classe que pode ser separada linearmente, no caso por uma reta (caso especial de hiperplano), já no caso da figura (3.8.b) isto já não é possível.




Figura 3.8 – (a) Classes linearmente separáveis; (b) Classes não-separáveis linearmente

Para o caso de três entradas no neurônio, o hiperplano seria um plano no espaço euclidiano. A separação linear é característica de perceptrons com uma camada de neurônios quando este tem função de rede linear e função de transferência tipo degrau (Kaminski, 1997).

### 3.5.2 Representação de Duas ou mais Camadas de Neurônios

As limitações das RNA's com uma camada de neurônios podem ser superadas pela adição de mais camadas na rede. Rede com mais de uma camada de neurônios pode ser entendida como uma combinação de redes com uma camada.

Portanto, podemos entender a capacidade de representação de uma rede com duas camadas de neurônios como uma combinação das capacidades de representação de cada rede individualmente. Esta combinação dependerá dos pesos associados às conexões entre a primeira e a segunda camada, bem como da função de rede e de transferência dos neurônios na segunda camada.

Para uma RNA com unidades de processamento binárias e duas camadas de neurônios é possível, por exemplo, separar pontos contidos em regiões convexas abertas ou fechadas. Entende-se por região convexa toda aquela onde dois pontos quaisquer podem ser unidos por uma reta que não deixa a região. Uma região fechada tem todos os seus pontos contidos por um contorno. Na figura (3.9) vê-se exemplos de regiões abertas e fechadas.




Figura 3.9 – Superfícies convexas. (a) e (b) fechadas; (c) aberta

Considerando uma rede neural com duas camadas de neurônios e duas entradas distintas é possível separar uma classe da outra somente se uma delas for representada por uma região convexa. Este artifício aumenta a capacidade da rede quando comparada com uma rede com apenas uma camada. Entretanto, ainda representa uma restrição a sua utilização em problemas onde não é possível a divisão de uma classe desta forma. A figura (3.10) ilustra esta restrição.




Figura 3.10 – (a) Classes separáveis por curva convexa; (b) classes não separáveis por curva convexa.

As restrições apresentadas para uma rede com duas camadas podem ser superadas com a adição de mais uma camada. As limitações de uma rede com três camadas ficam restritas ao número total de neurônios e, por conseguinte, ao número de pesos.

A rede com três camadas pode ser entendida como sendo uma combinação de duas redes de duas camadas. Esta combinação depende apenas dos pesos entre a penúltima e a última camada de neurônios. No entanto, esta combinação não leva a restrição de uma região convexa. Na verdade, esta combinação de duas superfícies convexas pode levar a uma superfície não convexa.

A figura (3.11) representa uma combinação de duas superfícies convexas. A combinação entre as duas superfícies consiste, neste caso, numa união das regiões, resultando numa região não-convexa. Pode-se desta maneira, isto é, combinando regiões de representação convexas, obter regiões de qualquer representação.




Figura 3.11 – Superfícies de representação convexas resultando numa não-convexa.

As vantagens das redes com mais de uma camada de neurônios só são válidas se pelo menos a função de transferência dos neurônios for não-linear. Caso a função de rede e a função de transferência sejam lineares não há vantagem alguma em se ter uma rede com mais de uma

camada de neurônios. Neste último caso, as camadas podem ser reduzidas a uma única, que é a combinação linear das outras.

### 3.6 Treinamento da Rede Neural

Aprender se refere ao ato de produzir certo comportamento diante de novas situações causadas por estímulos externos. Este comportamento é influenciado por excitações recebidas no passado e de certa forma caracteriza a aquisição de conhecimento. É comum em IA falar sobre aprendizado de máquinas e de certa forma o aprender é considerado um comportamento inteligente. RNAs possuem a capacidade de aprendizagem através de exemplos e têm a capacidade de fazer interpolações do que aprendem.

Os algoritmos de aprendizado nada mais são do que um conjunto de regras bem definidas para a atualização dos pesos. Existem muitos tipos de algoritmos de aprendizado específicos. Estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

A rede neural se baseia nos dados para extrair um modelo geral. Portanto, a fase de aprendizado deve ser rigorosa e verdadeira, a fim de se evitar modelos falsos. Todo o conhecimento de uma rede neural está armazenado nas sinapses, ou seja, nos pesos atribuídos às conexões entre os neurônios. De 50 a 90% do total de dados deve ser separado para o treinamento da rede neural, dados estes escolhidos aleatoriamente, a fim de que a rede "aprenda" as regras e não "decore" exemplos. O restante dos dados só é apresentado à rede neural na fase de testes a fim de que ela possa "deduzir" corretamente o inter-relacionamento entre os dados.

Os dois tipos de treinamentos mais difundidos são o treinamento supervisionado e o treinamento não supervisionado.

- **Treinamento Supervisionado** – É o tipo mais comum de treinamento, neste tipo de treinamento é apresentado um conjunto de entrada e seu respectivo conjunto de saída desejado. Após a apresentação do conjunto de entrada a rede produzirá um conjunto de saída, que inicialmente pode ser diferente do conjunto de saída desejado. Assim, de posse do erro entre a saída desejada e a saída que a rede produz se pode iterativamente atualizar os pesos. O objetivo é minimizar este erro

atingindo padrões aceitáveis. Dentre os algoritmos de cálculo para os pesos destaca-se o “backpropagation”. Uma ilustração dessa forma de treinamento é apresentada pela figura (3.12).

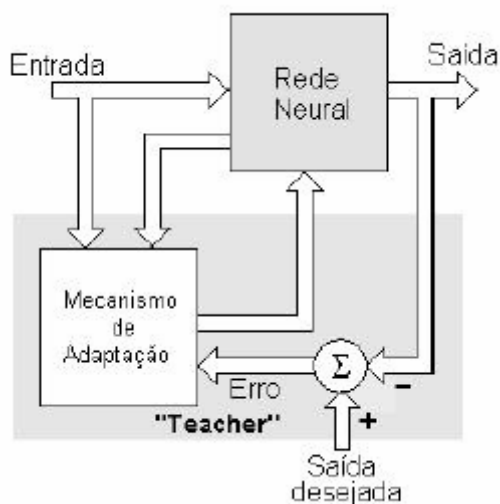


Figura 3.12 – Treinamento supervisionado.

- **Treinamento Não-supervisionado** – Este tipo de treinamento não utiliza um agente externo “Teacher” indicando a resposta desejada para os padrões de entrada. A rede recebe apenas um conjunto de entrada e, espera-se que a rede seja capaz de agrupar esses dados em categorias semelhantes. É portanto um tipo de treinamento auto-organizável que tem como um dos primeiros precursores Kohonen (Demarchi, 2001). A figura (3.13) apresenta uma ilustração desse tipo de treinamento.

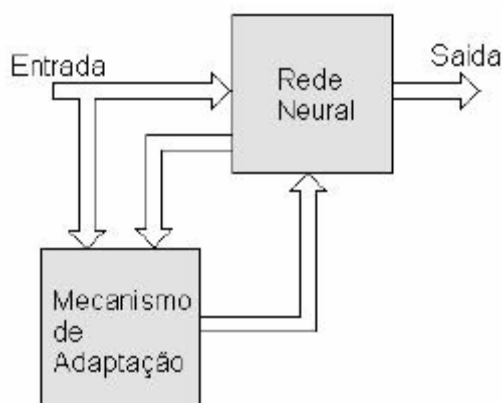


Figura 3.13 – Treinamento não-supervisionado.

Podemos denominar ainda ciclo como sendo uma apresentação de todos os  $N$  pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos num ciclo pode ser executado de dois modos:

*Modo Padrão:* A correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos se baseia somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem  $N$  correções.

*Modo Batch:* Apenas uma correção é feita por ciclo. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro são feitas as correções dos pesos.

### 3.6.1 *Aprendizado Hebbiano*

Os fundamentos teóricos sobre os processos de treinamento de RNAs datam de fins da década de 40. Em 1949 Donald Hebb propôs a primeira teoria neurofisiológica sobre a modificação das sinapses em neurônios reais (processo de determinação de aprendizagem do cérebro). Em sua teoria “se um neurônio A é repetidamente estimulado por outro neurônio B, ao mesmo tempo que ele está ativo, ele ficará mais sensível aos estímulos de B e a conexão sináptica de B para A será mais eficiente. Deste modo, B achará mais fácil estimular A para produzir uma saída”. Esse procedimento de ajuste de pesos proposto por Hebb, frequentemente chamado de regra de Hebb, tem sido adotado de formas diferentes em algoritmos de aprendizagem para RNAs baseadas no modelo de McCulloch – Pitts (Haykin, 1994).

Esta forma de aprendizado aplicada a um modelo de neurônio de McCulloch – Pitts, pode ser escrita como:

$$w^{t+1} = w^t + \Delta w \tag{3.18}$$

$$\Delta w = \mu \cdot \delta \cdot x$$

Este é um tipo de treinamento supervisionado, assim a atualização do peso  $\Delta w$  depende do erro  $\delta$  entre a resposta esperada e a saída obtida pelo neurônio, da entrada  $x$  e de um parâmetro  $\mu$  que significa a taxa de aprendizado. O sobrescrito  $t$  indica o índice da iteração.

### 3.6.2 Os Perceptrons e seu Treinamento

Os perceptrons foram uma das primeiras redes neurais proposta no final da década de 50 por Rosenblatt. Eles eram compostos por neurônios similares ao de McCulloch-Pitts. Uma de suas características era a existência de um algoritmo de treinamento para determinação dos pesos. No modelo inicialmente proposto por McCulloch-Pitts não havia um algoritmo para determinação dos mesmos, portanto, este algoritmo é considerado hoje como sendo o primeiro método de treinamento das redes neurais artificiais. O modelo perceptron com uma camada de processamento é formado por uma camada de entrada, a qual não realiza qualquer processamento e uma camada de saída, onde os pesos são atualizados, não existindo camada oculta. A entrada é formada por um conjunto de números binários e sua saída também, sua função de ativação é linear com função de transferência do tipo degrau (relé  $\{-1,1\}$  ou degrau unitário  $\{0,1\}$ ), como pode ser observado na figura (3.14) (Haykin, 1994).




Figura 3.14 – Exemplo de um perceptron com uma camada.

Como foi observado no item 3.5.1 a representação com uma camada de neurônios apresenta certas limitações; o exemplo mais utilizado para apresentar estas limitações é o da

função booleana OU Exclusivo (“XOR”), que não pode ser implementada por um perceptron de simples camada. Mesmo com as limitações de suas aplicações os perceptrons têm sido estudados e seus princípios básicos ainda são utilizados como ponto inicial para estudos de RNA’s. Assim, o trabalho de Rosenblatt merece destaque nas pesquisas sobre RNA’s.

No treinamento dos perceptrons os pesos são ajustados de forma que para um conjunto de entradas se obtenha a saída desejada. Assumindo um vetor de entrada  $X$  com componentes  $x_1, x_2, \dots, x_{comp}$  e uma matriz de pesos  $W$  composta pelos componentes  $w_{11}, w_{12}, \dots, w_{neur\ comp}$ , realiza-se uma multiplicação vetorial  $S$ . Caso o valor obtido atinja um determinado valor  $\theta$ , a saída  $Y$  assume o valor 1, caso contrário assume o valor 0. Esta operação é representada na equação (3.19), onde a função  $f(.)$  indica a função degrau apresentada na equação (3.9).

$$\begin{aligned} S &= WX \\ Y &= f(.) \end{aligned} \tag{3.19}$$

A saída  $Y$  é comparada com a saída desejada, caso o valor obtido seja o esperado nada é modificado. Entretanto, se a saída for incorreta os pesos são modificados, objetivando-se a minimização do erro. Este processo é realizado iterativamente até que um valor fixo de iterações seja atingido ou o erro pré-estabelecido seja alcançado. Os passos a seguir apresentam o processo.

**Passo 1** – Aplicar uma entrada padrão e calcular a saída  $Y$ .

**Passo 2** – Se a saída estiver correta, ir para o passo 1.

- Se a saída estiver incorreta e for 0, adicionar a cada peso suas respectivas entradas.

- Se a saída estiver incorreta e for 1, subtrair a cada peso suas respectivas entradas.

**Passo 3** – Ir para o passo 1.

Caso os conjuntos de entradas sejam linearmente separáveis, após um número finito de passos, a rede aprenderá através dos ajustes dos pesos a identificar os padrões corretamente.

### 3.6.3 Regra Delta

Após o desenvolvimento dos perceptrons, Widrow (Widrow, 1990) desenvolveu a ADALINE (ADaptive LINEar Element) que como o próprio nome sugere é composta por uma unidade de processamento com função de ativação linear. O algoritmo de aprendizado da ADALINE foi desenvolvido por Widrow e Hoff, chamada de regra delta (“delta rule”). A regra delta posteriormente foi adaptada para outros tipos de rede neural, sendo a base da regra de treinamento do “backpropagation” ou retropropagação do erro, que atualmente é a mais difundida para redes com múltiplos neurônios. O desenvolvimento da ADALINE levou a MADALINE, que é constituída por vários elementos ADALINE. O modelo ADALINE possui saídas binárias bipolares  $[-1,1]$  e tem seus pesos adaptados em função do erro de sua saída linear  $(y = \sum_i w_i x_i)$  antes da aplicação da função de transferência, daí o nome adaptive linear neuron. A figura (3.15) ilustra uma ADALINE.

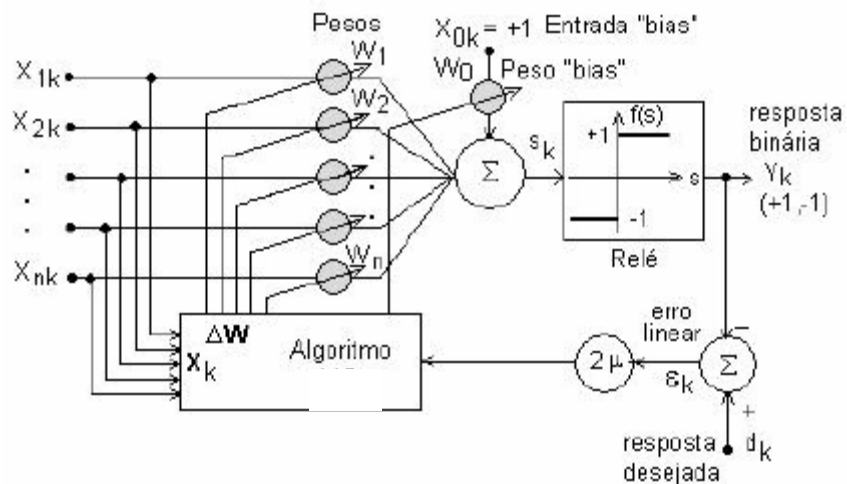


Figura 3.15 – Rede neural ADALINE.

O tipo de treinamento proposto por Widrow e Hoff tem como objetivo minimizar uma função critério, em geral o erro quadrático entre as saídas esperadas e aquelas calculadas pela rede. No caso dos perceptrons, qualquer conjunto de pesos que levassem a saída desejada podia ser adotado, entretanto na ADALINE existe um único conjunto de pesos que é procurado (Kaminski, 1997).

A ADALINE é uma rede neural com função de ativação linear passando por uma função de transferência do tipo relé. Pelo fato da função de transferência não ser diferenciável, seus pesos são adaptados em função do erro de sua saída linear, assim podemos assumir que:

$$\mathbf{Y} = \mathbf{WX} \quad (3.20)$$

A função objetivo é o erro quadrático médio a ser minimizado

$$E(\mathbf{W}) = \frac{1}{2} \sum_{n=1}^N (\mathbf{Y}_n - \mathbf{D}_n)^2 \quad (3.21)$$

sendo  $N$  o total de componentes do conjunto de treinamento, composto por vetores de entrada  $\mathbf{X}_n$  que produzem saídas  $\mathbf{Y}_n$  e composto também pelas saídas esperadas,  $\mathbf{D}_n$ .

Nota-se que  $E(\mathbf{W})$  é uma função convexa em  $\mathbf{W}$  e, portanto, existe um mínimo, dado pelo vetor de pesos  $\mathbf{W}^*$ . Se calcularmos o gradiente de  $E(\mathbf{W})$  e igualarmos este a zero, podemos encontrar este vetor de pesos. O vetor  $\mathbf{W}^*$  que anula o gradiente corresponde aquele que fornece o mínimo erro (Kaminski, 1997).

$$\begin{aligned} \text{grad } E(\mathbf{W}) &= \frac{1}{2} \cdot \frac{d}{d\mathbf{W}} \sum_{n=1}^N (\mathbf{W} \cdot \mathbf{X}_n - \mathbf{D}_n)^2 \\ &= \sum_{n=1}^N \mathbf{X}_n \cdot (\mathbf{W} \cdot \mathbf{X}_n - \mathbf{D}_n) = 0 \\ &= \left[ \sum_{n=1}^N \mathbf{X}_n \cdot \mathbf{X}_n^T \right] \cdot \mathbf{W} - \sum_{n=1}^N \mathbf{X}_n \cdot \mathbf{D}_n = 0 \end{aligned} \quad (3.22)$$

Para obtermos o vetor  $\mathbf{W}^*$  que minimiza o erro quadrático é necessário invertemos a matriz dada por:

$$\mathbf{A} = \left[ \sum_{n=1}^N \mathbf{X}_n \cdot \mathbf{X}_n^T \right] \quad (3.23)$$

Realizar a inversão de uma matriz não é uma operação trivial, além de que sendo esta matriz inversa obtida por meios numéricos sempre existe a possibilidade de se obter uma matriz malcondicionada e surgirem erros devido as imprecisões do processo numérico adotado.

O algoritmo proposto por Widrow dispensa o cálculo desta matriz, partindo-se da idéia de que a partir de um ponto inicial se pode seguir caminhando no sentido contrário do gradiente de  $E(\mathbf{W})$  e, assim, encontrar o mínimo da função erro, ou seja.

$$\mathbf{W}^{(t+1)} = \mathbf{W}^{(t)} - \mu \cdot \text{grad} (E(\mathbf{W})^t) \quad (3.24)$$

sendo:

$$\begin{aligned} \text{grad} E(\mathbf{W}) &= \sum_{n=1}^N \mathbf{X}_n \cdot (\mathbf{W}_n \cdot \mathbf{X}_n - \mathbf{D}_n) \\ &= \sum_{n=1}^N \mathbf{X}_n \cdot (\mathbf{Y}_n - \mathbf{D}_n) \end{aligned} \quad (3.25)$$

$$\begin{aligned} \Rightarrow \mathbf{W}^{t+1} &= \mathbf{W}^t + \mu \cdot \sum_{n=1}^N \mathbf{X}_n \cdot (\mathbf{Y}_n - \mathbf{D}_n) \\ \Rightarrow \mathbf{W}^{t+1} &= \mathbf{W}^t + \mu \cdot \sum_{n=1}^N \mathbf{X}_n \cdot \delta_n \end{aligned} \quad (3.26)$$

$$\delta_n = \mathbf{Y}_n - \mathbf{D}_n \quad (3.27)$$

O parâmetro  $\mu$  chamado de taxa de aprendizado, indica o tamanho do passo quando se caminha no sentido oposto do gradiente. Ele tem um papel importante na rede, uma vez que, para valores pequenos de  $\mu$  são necessárias muitas iterações durante o treinamento, já valores elevados de  $\mu$  podem levar a rede a instabilidade, prejudicando o treinamento. Como os pesos são ajustados de forma iterativa, é necessário um critério de parada para a rede. O número de iterações para o treinamento pode ser utilizado como critério de parada. Outro critério pode ser a comparação entre o valor do erro médio quadrático da rede e um valor de erro preestabelecido.

Como será observado, esta técnica de aprendizado, desenvolvida por Widrow, serviu como fonte de inspiração para o desenvolvimento de outras técnicas como, por exemplo, o treinamento backpropagation, que atualmente é um dos mais difundidos.

### 3.6.4 Algoritmo Backpropagation

Minsky e S. Papert (Minsky e S. Papert, 1969) mostraram que as redes unidirecionais com mais de duas camadas poderiam superar muitas restrições, mas não apresentaram a solução para o problema de como ajustar os pesos das sinapses a partir da camada de entrada para as camadas invisíveis. A resposta para esta questão foi apresentada por Rumelhart (Rumelhart, Hinton e Williams 1986), baseado no trabalho de Werbos em 1974.

A idéia central desse algoritmo é que o erro de cada camada invisível é determinado retrocedendo os erros a partir da camada de saída. Por essa razão, este algoritmo é denominado *backpropagation learning rule*. O algoritmo backpropagation pode ser considerado uma generalização da regra delta para funções de ativação não-lineares e rede neural multicamadas.

Para exemplificarmos o algoritmo de treinamento, utilizaremos a figura (3.16) a qual apresenta um neurônio  $j$  para uma rede neural “multilayer perceptrons”. O modo de treinamento apresentado é o modo padrão, que como já citado, faz a atualização dos pesos após a apresentação de um par entrada/saída. Considerando um conjunto de treinamento com  $N$  pares, após uma apresentação do conjunto de treinamento teremos  $N$  atualizações dos pesos.




Figura 3.16 – Detalhes do sinal que percorre um neurônio  $j$ .

Durante o processo de treinamento da rede neural, o fluxo de informação tem duas direções figura (3.17). A direção “forward” ocorre quando é apresentado um par de treinamento à rede. Assim, após a apresentação do vetor de treinamento o sinal flui da entrada da rede, através dos neurônios, até a saída. O valor de saída da rede é comparado com o valor desejado, se existir um erro os pesos são ajustados camada por camada partindo da camada de saída até chegar a camada de entrada, direção “backward”. Sendo concluída a fase de treinamento da rede, a fase “backward” é retirada restando apenas a fase “forward” que é responsável pelo valor de saída da rede (Haykin,1994).




Figura 3.17 – Ilustração dos dois tipos básicos de sinais de uma rede neural, sinal “forward” e sinal “backward” (sinal do erro).

Para realizarmos o treinamento da rede é necessário calcularmos o erro da rede. Considerando  $e_j(n)$  o erro para o neurônio  $j$  alocado na camada de saída da rede referente a apresentação do par de treinamento  $n$  do conjunto de treinamento contendo  $N$  pares,  $d_j(n)$  a saída desejada para o neurônio  $j$ , e  $y_j(n)$  a saída do neurônio  $j$ . Temos:

$$e_j(n) = d_j(n) - y_j(n) \quad (3.28)$$

Considerando como erro instantâneo, o somatório quadrático do erro  $e_j(n)$  para todos os neurônios na última camada.

$$E(n) = \frac{1}{2} \sum_{j=1}^c e_j^2(n) \quad (3.29)$$

sendo  $c$  o número de neurônios na última camada.

O valor do erro médio quadrático é obtido pela relação entre os  $N$  pares do conjunto de treinamento e o número de neurônios da última camada e a somatória do valor do erro instantâneo  $E(n)$ .

$$E_m = \frac{1}{N * c} \sum_{n=1}^N E(n) \quad (3.30)$$

O erro instantâneo e, conseqüentemente, o erro médio são funções de todos os parâmetros da rede. O erro médio,  $E_m$ , representa uma função custo, onde podemos medir o desempenho da rede. Assim, o processo de treinamento tem como objetivo ajustar os parâmetros da rede de forma a minimizar este erro  $E_m$ .

Observando a figura (3.16) podemos calcular a função de rede linear do neurônio, que servirá de entrada para a não-linearidade associada ao neurônio  $j$ .

$$s_j(n) = \sum_{i=0}^p w_{ji}(n) y_i(n) \quad (3.31)$$

Sendo  $p$  o total de entradas que estão relacionadas ao neurônio  $j$ . A entrada  $y_0$  diz respeito ao valor adotado para o bias ( $\pm 1$ ), e o peso  $w_{j0}$  corresponde ao peso que pondera esta entrada do bias. Portanto, podemos calcular a saída do neurônio  $j$  após a não linearidade, dada por  $y_j$ .

$$y_j(n) = f(s_j(n)) \quad (3.32)$$

Sendo  $f(\cdot)$  a função não-linear associada ao neurônio  $j$ .

O algoritmo backpropagation aplica a correção  $\Delta w_{ji}$  nos pesos  $w_{ji}$  com o objetivo de minimizar a função custo,  $E_m$ . Para isto aplica a regra do gradiente descendente, cujo objetivo é minimizar a função caminhando no sentido contrário do seu gradiente e adotando para isto um valor  $\mu$  para o tamanho do passo. Desta maneira, a correção dos pesos adotando o método do gradiente descendente é dado da seguinte maneira:

$$\begin{aligned} w_{ji}^{(t+1)} &= w_{ji}^{(t)} + \Delta w_{ji}^{(t)} \\ \Delta w_{ji}^{(t)} &= -\mu \frac{\partial E(n)}{\partial w_{ji}(n)} \end{aligned} \quad (3.33)$$

De acordo com a regra da cadeia, o gradiente do erro em relação aos pesos pode ser obtido da seguinte maneira:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial s_j(n)} \frac{\partial s_j(n)}{\partial w_{ji}(n)} \quad (3.34)$$

O gradiente  $\partial E(n)/\partial w_{ji}(n)$  representa o fator de sensibilidade, determina a direção do vetor de procura no espaço dos pesos  $w_{ji}$ .

Derivando ambos os lados da equação (3.29), em relação ao erro  $e_j(n)$ , temos:

$$\frac{\partial E(n)}{\partial e_j(n)} = e_j(n) \quad (3.35)$$

Derivando ambos os lados da equação (3.28), em relação a  $y_j(n)$ , temos:

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (3.36)$$

Derivando ambos os lados da equação (3.32), em relação a  $s_j(n)$ , temos:

$$\frac{\partial y_j(n)}{\partial s_j(n)} = f'(s_j(n)) \quad (3.37)$$

Sendo  $f'(\cdot)$  a derivada a função  $f(\cdot)$  em relação ao argumento. Finalmente, derivando a equação (3.31), em relação a  $w_{ji}(n)$ , temos:

$$\frac{\partial s_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (3.38)$$

Portanto, substituindo as equações de (3.35) até (3.38) na equação (3.34) temos:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n) f'(s_j(n)) y_j(n) \quad (3.39)$$

A correção  $\Delta w_{ji}$  aplicada em  $w_{ji}$  utilizando a regra do gradiente descendente é:

$$\Delta w_{ji}(n) = -\mu \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (3.33)$$

sendo  $\mu$  o tamanho do passo, também chamado de coeficiente de aprendizado. O sinal negativo representa a direção contrária ao gradiente. Podemos escrever também:

$$\Delta w_{ji} = \mu \delta_j(n) y_i(n) \quad (3.40)$$

sendo:

$$\begin{aligned} \delta_j(n) &= -\frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial s_j(n)} \\ &= e_j(n) f'(s_j(n)) \end{aligned} \tag{3.41}$$

O gradiente local é utilizado na mudança dos pesos. De acordo com a equação (3.41), o gradiente local  $\delta_j(n)$ , para o neurônio  $j$  localizado na saída da rede, é igual ao produto entre o erro  $e_j(n)$  e a derivada da função de transferência associada ao neurônio,  $f'(s_j(n))$ .

Observando as equações (3.40) e (3.41) notamos que um dos fatores que está envolvido no ajuste dos pesos  $\Delta w_{ji}(n)$  é o erro  $e_j(n)$  obtido na saída do neurônio  $j$ . Neste sentido, podemos destacar dois casos distintos, dependendo da localização do neurônio  $j$ . No primeiro caso o neurônio  $j$  está alocado na camada de saída da rede, desta maneira se torna fácil calcular o erro para o referido neurônio, uma vez que, para a camada de saída, se tem o valor desejado equação (3.28). No segundo caso o neurônio  $j$  está na camada intermediária (hidden layer). Deve-se encontrar uma maneira de penalizar o referido neurônio dependendo da resposta da rede. Este problema foi resolvido de forma elegante pelo algoritmo de treinamento retropropagação.

Quando o neurônio  $j$  está alocado em uma camada intermediária da rede, também chamada de camada oculta, não existe uma forma específica de penalizar este neurônio. Desta forma, o valor do erro para o “neurônio escondido” é determinado em termos dos erros de todos os neurônios os quais ele está diretamente conectado. Esta é a parte onde o algoritmo backpropagation apresenta uma pequena complexidade. Consideremos a situação da figura (3.18), na qual o neurônio  $j$  está na camada oculta da rede.




Figura 3.18 – Detalhes do sinal de saída de um neurônio  $k$  conectado a um neurônio  $j$  localizado na camada intermediária.

De acordo com a equação (3.41), podemos redefinir o gradiente local  $\delta_j(n)$  para o neurônio  $j$  na camada oculta como:

$$\begin{aligned}\delta_j(n) &= -\frac{\partial E(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial s_j(n)} \\ &= -\frac{\partial E(n)}{\partial y_j(n)} f'(s_j(n))\end{aligned}\quad (3.42)$$

Para calcular a derivada parcial  $\partial E(n)/\partial y_j(n)$ , nós podemos proceder da seguinte forma. Da figura (3.18), vemos que:

$$E(n) = \frac{1}{2} \sum_{k=1}^c e_k^2(n) \quad (3.43)$$

A qual é a equação (3.29) reescrita com o índice  $k$  ao invés do  $j$ . Para não confundirmos, o índice  $k$  refere-se ao neurônio na camada de saída, já o índice  $j$  ao neurônio na camada oculta. Derivando a equação (3.43) em relação à  $y_j(n)$ , temos:

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (3.44)$$

Utilizando a regra da cadeia para calcular a derivada parcial  $\partial e_k(n)/\partial y_j(n)$ , podemos reescrever a equação (3.44) da seguinte forma:

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial s_k(n)} \frac{\partial s_k(n)}{\partial y_j(n)} \quad (3.45)$$

Portanto, da figura (3.18), notamos que:

$$\begin{aligned}e_k(n) &= d_k(n) - y_k(n) \\ &= d_k(n) - f(s_k(n))\end{aligned}\quad (3.46)$$

Então

$$\frac{\partial e_k(n)}{\partial s_k(n)} = -f'(s_k(n)) \quad (3.47)$$

Notamos da figura (3.18), que a função de base para o neurônio  $k$  é dada pela seguinte expressão:

$$s_k(n) = \sum_{j=0}^q w_{kj}(n) y_j(n) \quad (3.48)$$

Sendo  $q$  o número total de entradas que estão relacionadas com o neurônio  $k$ . Aqui, novamente, a entrada  $y_0$  representa a entrada do bias ( $\pm 1$ ) e o peso  $w_{k0}$  corresponde ao peso que pondera o valor de entrada do bias. Derivando ambos os lados da equação (3.48) em relação a  $y_j(n)$ , temos:

$$\frac{\partial s_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (3.49)$$

Assim, usando as equações, (3.47) e (3.49) na equação (3.45) obtemos:

$$\begin{aligned} \frac{\partial E(n)}{\partial y_j(n)} &= -\sum_k e_k(n) f'(s_k(n)) w_{kj}(n) \\ &= -\sum_k \delta_k(n) w_{kj}(n) \end{aligned} \quad (3.50)$$

Sendo que na segunda linha, nós usamos a definição de gradiente local  $\delta_k(n)$  dado pela equação (3.41) com o índice  $k$  substituindo o índice  $j$ .

Finalmente, utilizando as equações (3.50) e (3.42) obtemos o gradiente local  $\delta_j(n)$  dado para o neurônio  $j$  alocado na camada oculta da rede através da equação:

$$\delta_j(n) = f'(s_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (3.51)$$

O fator  $f'(s_j(n))$  envolvido no cálculo de  $\delta_j(n)$  na equação (3.51), depende somente da função de transferência do neurônio  $j$ . Enquanto o termo,  $\delta_k(n)$  depende do erro  $e_k(n)$ , que é obtido pela última camada da rede, os pesos  $w_{kj}(n)$  são todos os pesos que chegam aos neurônios alocados na saída partindo do neurônio  $j$ . Daí vem o nome do algoritmo backpropagation ou retropropagação do erro, pois o erro calculado na camada de saída é utilizado para calcular o erro nas demais camadas, partindo da saída em direção a entrada.

Agora podemos relacionar o algoritmo backpropagation com a regra delta para atualização dos pesos. Para atualização do peso  $w_{ji}(n)$  conectado do neurônio  $i$  ao neurônio  $j$ , tem-se:

$$\begin{pmatrix} \text{atualização} \\ \text{do peso} \\ \Delta w_{ji}(n) \end{pmatrix} = \begin{pmatrix} \text{fator de} \\ \text{aprendizagem} \\ \mu \end{pmatrix} \cdot \begin{pmatrix} \text{gradiente} \\ \text{local} \\ \delta_j(n) \end{pmatrix} \begin{pmatrix} \text{entrada do} \\ \text{neurônio } j \\ y_i(n) \end{pmatrix} \quad (3.52)$$

Sendo que o gradiente local  $\delta_j(n)$  depende da localização do neurônio. Se ele estiver na camada de saída, utiliza-se a equação (3.41), caso contrário, se ele estiver localizado nas camadas ocultas, utiliza-se a equação (3.51).

As funções de transferência usualmente utilizadas nos neurônios da rede neural são funções do tipo sigmóide. Os dois tipos de funções normalmente utilizadas são as funções do tipo logística, equação (3.53) que produzem saídas entre os valores (0,1) e as funções do tipo tangente hiperbólica (3.54), que produzem valores de saída entre (-1,+1).

$$y_i = \frac{1}{1 + e^{(-\lambda s_i)}} \quad (3.53)$$

$$y_i = \frac{1 - e^{(-\lambda s_i)}}{1 + e^{(-\lambda s_i)}} \quad (3.54)$$

sendo  $\lambda$  a constante que determina a inclinação da curva  $y_i$ . As respectivas derivadas em relação a entrada são dadas pelas equações (3.55) e (3.56).

$$\begin{aligned} \frac{\partial y_i}{\partial s_i} &= \frac{\partial}{\partial s_i} \left\{ \frac{1}{1 + e^{-\lambda s_i}} \right\} \\ &= \frac{\lambda e^{-\lambda s_i}}{(1 + e^{-\lambda s_i})^2} \\ &= \lambda \left\{ \frac{(1 + e^{-\lambda s_i}) - 1}{(1 + e^{-\lambda s_i})^2} \right\} = \lambda \left\{ \frac{1}{(1 + e^{-\lambda s_i})} - \frac{1}{(1 + e^{-\lambda s_i})^2} \right\} \\ &= \lambda y_i (1 - y_i) \end{aligned} \quad (3.55)$$

$$\begin{aligned} \frac{\partial y_i}{\partial s_i} &= \frac{\partial}{\partial s_i} \left\{ \frac{1 - e^{-\lambda s_i}}{1 + e^{-\lambda s_i}} \right\} \\ &= \frac{2 \lambda e^{-\lambda s_i}}{(1 + e^{-\lambda s_i})^2} \\ &= \frac{1}{2} \lambda \left\{ \frac{(1 + e^{-\lambda s_i})^2}{(1 + e^{-\lambda s_i})^2} - \frac{(1 - e^{-\lambda s_i})^2}{(1 + e^{-\lambda s_i})^2} \right\} \\ &= 0.5 \lambda (1 - y_i^2) \end{aligned} \quad (3.56)$$

### 3.6.5 Algoritmo Backpropagation com Momento

Um dos artificios utilizados para tornar o algoritmo backpropagation convencional mais rápido computacionalmente é a inclusão do termo *momento*. Este termo é utilizado para evitar a oscilação quando se utiliza valores altos para a taxa de treinamento,  $\mu$ . Desta forma, utiliza-se uma variação no peso dependente da variação do peso passado acrescentando o termo momento. Para o caso onde se utiliza o termo momento,  $\gamma$ , a adaptação dos pesos pode ser formulada como se segue (Haykin,1994):

$$\Delta w_{ji}(n) = \gamma \Delta w_{ji}(n-1) + \mu \delta_j(n) y_i(n) \quad (3.53)$$

A influência do termo momento é apresentada na figura (3.19). Quando o termo não é utilizado é necessário um maior número de iterações para que se possa atingir o mínimo quando se utiliza um baixo valor de aprendizagem. Entretanto, se for utilizado um alto valor na taxa de aprendizagem o ponto de mínimo talvez possa nunca ser alcançado devido as oscilações. Inserindo o termo momento, pode-se utilizar altas taxas de aprendizagem sem que ocorra grandes oscilações, assim o mínimo pode ser alcançado com um número menor de iterações (Oliveira,1999).




Figura 3.19 – Ajuste dos pesos. (a)-para pequenas taxas de aprendizagem. (b)-para grandes taxas de aprendizagem. (c)-para grandes taxas de aprendizagem com o termo momento.

A figura (3.20) apresenta uma ilustração de como se pode realizar o treinamento da rede neural *feedforward* de 3 camadas (2 2 1), via “backpropagation” sem o termo de momento.

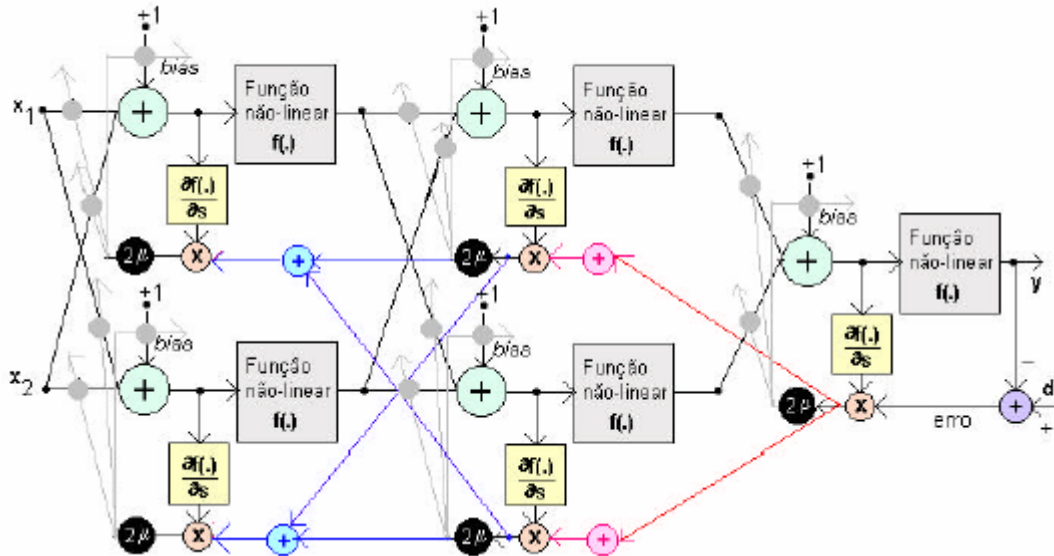


Figura 3.20 – Desenho ilustrativo do treinamento via backpropagation

### 3.6.6 Vantagens do Backpropagation

Sendo os padrões corretamente selecionados e com uma escolha correta da configuração, geralmente se obtém uma rede bem treinada. As redes apresentam uma certa robustez, ou seja, mesmo que os dados utilizados na rede após o treinamento apresentem alguma variação a rede responderá de forma satisfatória, dentro de certa tolerância.

Outra vantagem é a característica das redes neurais de aproximar e classificar problemas associados com não-linearidades. Se os padrões de entradas de dados representam adequadamente as falhas, que são processos não-lineares, esta formulação pode ser aplicada e evitar a complexidade que seria introduzida por métodos computacionais convencionais. Além do mais, a capacidade de aprendizado de redes neurais é adequada a processos com grande número de entradas, o que é fundamental para aplicações em estruturas inteligentes, que é o objetivo principal do projeto em desenvolvimento neste trabalho.

### 3.6.7 *Desvantagens do Backpropagation*

O tempo de treinamento das redes via backpropagation geralmente é longo e quando os parâmetros como: número de neurônios; taxa de aprendizado e o termo momento não estão devidamente corretos, dificilmente a rede atingirá um mínimo. A maioria dos métodos avançados de treinamento baseados no backpropagation tem algum dispositivo automático de ajuste da taxa de treinamento. Outros dois problemas que normalmente ocorrem é a paralisia e pontos de mínimos locais (Lopes, 2000).

**Paralisia da rede:** Em consequência do próprio treinamento os valores dos pesos podem ser ajustados para valores muito grandes, o que torna o sistema fortemente instável e o processo de aprendizagem não entra em rota de convergência. Com os altos valores, em módulo, dos pesos nas camadas da rede, para o caso da função sigmoideal, a ativação atinge valores muito próximos de zero ou de um. Consecutivamente, os pesos ajustados estarão próximos de zero e o processo de treinamento pode sofrer uma paralisação (ou efeito de paralisia).

**Mínimos Locais:** A superfície da função erro é muito irregular, cheia de picos e vales; isto leva os métodos de minimização de erros se tornarem refém de um mínimo local, não atingindo o mínimo global. Alguns métodos probabilísticos podem ajudar a evitar esses mínimos, entretanto, eles tendem a ser lentos. Uma alternativa é aumentar o número de camadas, desta forma aumentará a dimensionalidade do espaço de erro, como consequência, haverá um aumento do número de mínimos locais e para determinadas taxas de aprendizagens o gradiente descendente poderá se tornar robusto o suficiente para sair dos vales menores.

## *CAPÍTULO 4*

### **METODOLOGIA PROPOSTA E APLICAÇÕES NUMÉRICAS**

#### **4.1 Metodologia Proposta**

O esquema de identificação de falha proposto é baseado na sensibilidade da impedância elétrica, para a localização da falha, e o uso de redes neurais para quantificar a severidade do defeito. A proposta apresentada consiste em dois passos, conforme descreve a figura (4.1). No primeiro passo, o método da impedância elétrica é utilizado para detectar e localizar a falha estrutural. A técnica de impedância elétrica é baseada na aplicação de baixa tensão elétrica em altas faixas de frequências, excitando assim os modos locais. Devido a estas características a área de influência de cada PZT atuador é pequena. Alterações estruturais fora da área de influência não causam mudanças significativas no sinal de impedância elétrica e, isto possibilita o monitoramento das regiões de influência de cada PZT. Se a falha é detectada, o segundo passo da metodologia é automaticamente acionado. Nesta etapa, as redes neurais são treinadas para as situações de falhas nas regiões específicas. O objetivo desta etapa é a estimativa da severidade da falha. Devido as características de independência de cada região do PZT atuador, o número de redes neurais utilizadas deve ser igual ao número de PZT's colado na estrutura.

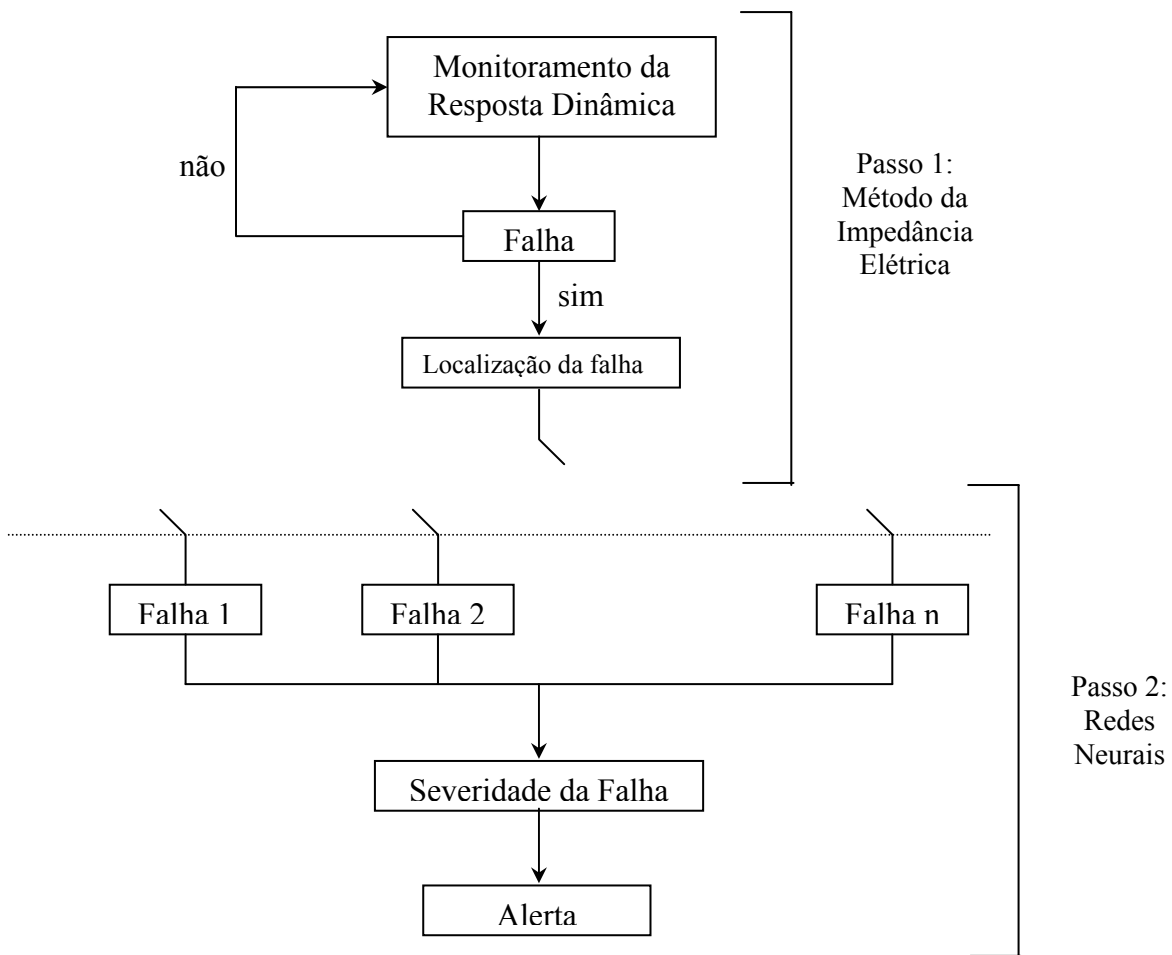


Figura 4.1 – Diagrama do esquema de identificação da falha.

A impedância elétrica é medida em altas faixas de frequências, o que garante grande sensibilidade para as variações da estrutura. Após a aquisição, os sinais devem ser processados e normalizados, para que representem todas as condições de falhas que se deseja monitorar. Uma das maiores vantagens deste método é que a variação do sinal é local e não afeta os outros sensores (PZT). Portanto, falhas simultâneas, que são dificilmente identificadas por métodos convencionais, podem ser tratadas como se ocorressem independentemente.

Teoricamente, pode-se usar uma infinidade de dados como padrão de entrada para o treinamento da rede. Entretanto, a exatidão e a capacidade de generalização da rede neural é fortemente dependente da escolha do tipo de entrada. Nos exemplos apresentados a seguir se utilizou o algoritmo da retropropagação com momento para o processo de treinamento.

## 4.2 Aplicações Numéricas

O trabalho proposto tem como objetivo a caracterização de falhas estruturais, ou seja, a detecção, a localização e a quantificação do dano. Entende-se por detecção a determinação da existência ou não da falha; por localização sua descrição geométrica na estrutura; e por quantificação uma avaliação da severidade existente. Tanto a detecção quanto a localização são estimadas através da técnica da impedância elétrica, enquanto a quantificação da falha é estimada usando redes neurais artificiais.

Na etapa de treinamento da rede neural o ideal seria que todo o banco de dados fosse obtido experimentalmente e que abrangesse toda a faixa de atuação. Entretanto, na maioria das vezes isto se torna muito oneroso ou às vezes impraticável. Sendo assim, em alguns casos, utiliza-se a modelagem para simular tais condições, gerando, assim, um banco de dados que é utilizado no treinamento e na fase de verificação da capacidade de generalização da rede. O método dos elementos finitos tem sido largamente utilizado para modelagem devido sua versatilidade, sua aplicação em uma infinidade de problemas e relativo baixo custo, se comparado às montagens experimentais.

Para a validação da rede neural como ferramenta desta metodologia, foram realizadas simulações de falhas em quatro diferentes tipos de vigas. O software comercial ANSYS<sup>®</sup> e um programa próprio foram utilizados para obtenção das frequências naturais, através do método dos elementos finitos, para os quatro casos estudados. A frequência natural foi o parâmetro escolhido como variável do problema. No entanto, outros parâmetros, ou funções, podem ser utilizados como padrão de entrada nas redes. Nos exemplos apresentados as falhas são simuladas através de uma redução no momento de inércia de área do elemento com falha.

O tipo de rede neural utilizada, foi uma rede multilayer perceptrons, com treinamento via “backpropagation”, ou retropropagação. Com relação à topologia da rede empregada, utilizamos uma rede de duas camadas, com funções de transferência diferentes em cada camada. Na camada intermediária, “hidden”, utilizamos a função de transferência do tipo sigmoial, que pode ser observada através da figura (3.3.d) e equação (3.12). Enquanto, na camada de saída, utilizamos a função de transferência do tipo linear, que pode ser observada através da figura (3.3.a) e equação (3.8). Dependendo do caso estudado, variamos a quantidade de neurônios na camada intermediária.

### 4.2.1 Pré - Processamento

A utilização direta das frequências naturais ou da curva da resposta em frequência não representam a melhor opção para se alcançar o objetivo proposto. Este fato foi observado durante o trabalho de iniciação científica do aluno (Furtado, 2001). Sendo assim, um pré-processamento é necessário para melhorar a eficácia da rede. Como veremos, existem normalizações ou pré-processamentos que ressaltam certas características dos dados; isto é importante uma vez que a rede neural utilizada tem como principal objetivo o reconhecimento de padrões. Assim existem normalizações que ressaltam as características que buscamos, enquanto outras não são tão sensíveis a estas variações.

A variação da frequência natural pode ser obtida pela equação (4.1), com  $\omega^u$  sendo a frequência natural sem falha,  $\omega$  a frequência natural do sistema que se deseja analisar e  $i$  o índice para a ordem da frequência natural. Neste caso foram realizados testes simulados no ANSYS®.

$$\Delta\omega_i = \omega_i^u - \omega_i \quad (4.1)$$

Uma normalização que pode ser empregada é a *redução da frequência natural rfn<sub>i</sub>* da estrutura. Esta redução foi proposta por Kaminski (Kaminski,1997). Esta normalização é função da localização do dano  $r$  e das alterações nos parâmetros de rigidez ( $\Delta K$ ) e inércia ( $\Delta M$ ).

$$rfn_i = \frac{\Delta\omega_i}{\omega_i^u} = g_i(r) \cdot f_i(\Delta K, \Delta M) \quad (4.2)$$

Realizando a expansão da função  $f_i$  em torno do estado não-perturbado ( $\Delta K=0$  e  $\Delta M=0$ ) e tomando apenas os termos de primeira ordem:

$$\frac{\Delta\omega_i}{\omega_i^u} \cong g_i(r) \cdot \left[ f_i(0,0) + \Delta M \frac{\partial f_i(0,0)}{\partial \Delta M} + \Delta K \frac{\partial f_i(0,0)}{\partial \Delta K} \right] \quad (4.3)$$

Como não existe alteração da frequência natural se não houver mudança nos parâmetros estruturais, podemos assumir que  $f_i(0,0) = 0$ . Assim,

$$\frac{\Delta\omega_i}{\omega_i^u} \cong g_i(r) \cdot \left[ \Delta M \frac{\partial f_i(0,0)}{\partial \Delta M} + \Delta K \frac{\partial f_i(0,0)}{\partial \Delta K} \right] \quad (4.4)$$

As derivadas parciais da função  $f_i$  calculadas no ponto ( $\Delta K = 0$  e  $\Delta M = 0$ ) são funções constantes. Assim,

$$\frac{\Delta\omega_i}{\omega_i^u} \cong \Delta M . m_i(r) + \Delta K . n_i(r) \quad (4.5)$$

Como neste trabalho as falhas simuladas representam defeitos do tipo trincas, podemos assumir que as perturbações devido a inércia são bem menores que as devido a rigidez, assim como hipótese tem-se  $\Delta M \approx 0$ ,

$$\frac{\Delta\omega_i}{\omega_i^u} \cong \Delta K . n_i(r) \quad (4.6)$$

Analisando a equação (4.6) podemos observar que esta normalização destaca as alterações na rigidez e na posição das falhas. Desta maneira, especificando o local da falha, podemos treinar a rede para diferentes condições de severidades.

Para a localização da falha existe outra normalização que é sensível apenas ao parâmetro da posição, também proposta por Kaminski (Kaminski,1997). Esta normalização é obtida através da  $rfn_i$  chamada de *normalização da frequência natural*  $nrfn_i$ .

$$nrfn_i = \frac{rfn_i}{\sum_{j=1}^q rfn_j} = \frac{\Delta K . n_i(r)}{\Delta K . \sum_{i=1}^q n_i(r)} = f(l_i(r)) \quad (4.7)$$

sendo  $q$  o número de frequências naturais consideradas.

O aprendizado da rede neural está fortemente ligado ao tipo e a qualidade dos padrões de entrada. Estes padrões quando bem estruturados e devidamente selecionados levam, geralmente, a uma solução do problema. Neste sentido, esta etapa é importante para o desenvolvimento do trabalho e validação numérica da metodologia. Como se pode notar, as normalizações apresentadas focam ora a intensidade da falha ( $rfn$ ), ora sua localização ( $nrfn$ ), assim, estes dados serão utilizados para a verificação da intensidade e localização da falha, respectivamente.

### 4.3 Exemplo – 1: Viga de Aço Engastada

Neste exemplo é utilizado uma viga de aço com 500 mm de comprimento e seção retangular de lados 30x10 mm, figura (4.2). A viga se encontra na condição engastada-livre e foi discretizada com 250 elementos do tipo BEAM3 (2D) no software ANSYS®. O detalhamento do

elemento utilizado pode ser observado na figura (4.3). As propriedades do material empregado, utilizando o sistema internacional de unidades (SI), são: módulo de elasticidade,  $E = 210\text{GPa}$ ; coeficiente de Poisson,  $\nu = 0,3$  e; densidade em massa,  $\gamma = 7810\text{kg/m}^3$ .




Figura 4.2 – Viga de aço engastada simulada.

Na figura (4.2), nota-se que a falha ocorre na posição  $l_i$ , enquanto o comprimento é  $l$ . Isto foi feito para que a falha inserida pudesse ter sua posição representada na forma adimensional  $l_i/l$ . Este artifício foi utilizado buscando estender a análise para qualquer outro tipo de viga, sob as mesmas condições de contorno.




Figura 4.3 – Elemento de viga utilizado.

Como se pode observar, o elemento utilizado BEAM3 é um elemento bidimensional com dois nós e três graus de liberdade por nó, deslocamento nas direções X e Y e rotação em torno do eixo Z. Este é um elemento elástico aplicado na solução de problemas estruturais.

A falha foi simulada através da redução do momento de inércia de área, com o intuito de simular a presença de uma trinca. Sendo assim, para cada posição da falha existem quatro situações distintas, a situação sem falha e as falhas  $f1$ ,  $f2$  e  $f3$ , que consideram as profundidades de 1, 2 e 3 mm, respectivamente. A tabela (4.1) apresenta os valores dos momentos de inércia para os elementos com e sem falha.

Tabela 4.1 – Propriedades dos elementos com e sem falha.

<i>Situação</i>	<i>Momento de Inércia (m<sup>4</sup>)</i>
Sem falha	25,00 x 10 <sup>-10</sup>
Falha 1 ( $f1$ )	18,22 x 10 <sup>-10</sup>
Falha 2 ( $f2$ )	12,80 x 10 <sup>-10</sup>
Falha 3 ( $f3$ )	8,575 x 10 <sup>-10</sup>

A tabela (4.2) mostra as cinco primeiras frequências naturais da estrutura sem falha e com a falha  $f1$ , variando a posição do elemento com falha ao longo da viga. Optamos por apresentar somente os valores das frequências relativas a falha  $f1$  pelo fato de se tornar muito extensa a tabela contendo todas as cinco frequências para as três condições de falha.

Tabela 4.2 – Cinco primeiras frequências naturais para a estrutura de aço engastada, sem falha e com a falha  $f1$ .



<b>Frequências</b>					
	Frequência 1 (Hz)	Frequência 2 (Hz)	Frequência 3 (Hz)	Frequência 4 (Hz)	Frequência 5 (Hz)
<b>Sem falha</b>	<b>33,4181</b>	<b>209,3306</b>	<b>585,6944</b>	<b>1146,4776</b>	<b>1892,5359</b>
Distância Normalizada ( $li/l$ )					
0,0040	33,3197	208,7259	584,0317	1143,2822	1887,3583
0,0200	33,3239	208,8153	584,4272	1144,3229	1889,4746
0,0400	33,3292	208,9172	584,8459	1145,3343	1891,3350
0,0600	33,3342	209,0077	585,1795	1146,0209	1892,3258
0,0800	33,3392	209,0869	585,4277	1146,3913	1892,5258
0,1000	33,3439	209,1547	585,5923	1146,4762	1892,1235
0,1200	33,3486	209,2111	585,6779	1146,3312	1891,3994
0,1400	33,3530	209,2562	585,6925	1146,0333	1890,6657
0,1600	33,3573	209,2902	585,6476	1145,6716	1890,1886
0,1800	33,3615	209,3136	585,5572	1145,3337	1890,1210
0,2000	33,3655	209,3269	585,4375	1145,0928	1890,4705
0,2200	33,3693	209,3307	585,3053	1144,9965	1891,1088
0,2400	33,3730	209,3260	585,1771	1145,0603	1891,8181

0,2600	33,3766	209,3137	585,0675	1145,2671	1892,3596
0,2800	33,3799	209,2949	584,9881	1145,5717	1892,5485
0,3000	33,3831	209,2710	584,9469	1145,9106	1892,3123
0,3200	33,3862	209,2431	584,9476	1146,2138	1891,7155
0,3400	33,3890	209,2125	584,9893	1146,4186	1890,9391
0,3600	33,3918	209,1806	585,0670	1146,4818	1890,2232
0,3800	33,3943	209,1487	585,1719	1146,3877	1889,7893
0,4000	33,3967	209,1180	585,2927	1146,1518	1889,7713
0,4200	33,3990	209,0895	585,4163	1145,8178	1890,1746
0,4400	33,4011	209,0643	585,5295	1145,4483	1890,8751
0,4600	33,4030	209,0431	585,6199	1145,1134	1891,6568
0,4800	33,4048	209,0267	585,6775	1144,8767	1892,2780
0,5000	33,4065	209,0154	585,6955	1144,7830	1892,5457
0,5200	33,4080	209,0095	585,6711	1144,8506	1892,3770
0,5400	33,4094	209,0091	585,6055	1145,0670	1891,8257
0,5600	33,4106	209,0141	585,5040	1145,3915	1891,0649
0,5800	33,4117	209,0241	585,3754	1145,7627	1890,3323
0,6000	33,4127	209,0388	585,2311	1146,1096	1889,8559
0,6200	33,4136	209,0573	585,0839	1146,3652	1889,7842
0,6400	33,4144	209,0792	584,9468	1146,4790	1890,1408
0,6600	33,4151	209,1034	584,8319	1146,4274	1890,8161
0,6800	33,4157	209,1293	584,7488	1146,2172	1891,5992
0,7000	33,4162	209,1558	584,7045	1145,8847	1892,2430
0,7200	33,4166	209,1823	584,7020	1145,4879	1892,5412
0,7400	33,4170	209,2078	584,7406	1145,0960	1892,3936
0,7600	33,4172	209,2317	584,8161	1144,7762	1891,8362
0,7800	33,4175	209,2535	584,9208	1144,5817	1891,0271
0,8000	33,4177	209,2726	585,0449	1144,5427	1890,1966
0,8200	33,4178	209,2889	585,1776	1144,6613	1889,5770
0,8400	33,4179	209,3022	585,3077	1144,9121	1889,3353
0,8600	33,4180	209,3125	585,4256	1145,2481	1889,5265
0,8800	33,4180	209,3201	585,5242	1145,6110	1890,0806
0,9000	33,4180	209,3252	585,5992	1145,9442	1890,8297
0,9200	33,4181	209,3284	585,6500	1146,2052	1891,5689
0,9400	33,4181	209,3301	585,6795	1146,3745	1892,1308
0,9600	33,4181	209,3308	585,6928	1146,4587	1892,4445
0,9800	33,4181	209,3310	585,6966	1146,4849	1892,5513
1,0000	33,4181	209,3310	585,6970	1146,4876	1892,5631

Para a localização da falha foi utilizada a normalização referente a equação (4.7), *normalização da frequência natural*,  $nrfn$ . Já para a quantificação da severidade da falha foi utilizada a equação (4.2), *redução da frequência natural*,  $rfn$ , que é sensível à severidade do dano.

A figura (4.4) mostra a variação das três primeiras frequências naturais quando a falha varia da posição 0 (lado engastado) a posição 1 (extremidade livre). A figura (4.5) apresenta as

normalizações,  $nrfn_1$ ,  $nrfn_2$  e  $nrfn_3$ , para as frequências naturais em função da distância normalizada. Os dados foram obtidos numericamente através do método dos elementos finitos para as três condições de falhas,  $f1$ ,  $f2$  e  $f3$ .







Figura 4.4 – Três primeiras freqüências naturais, em função da distância da viga normalizada.



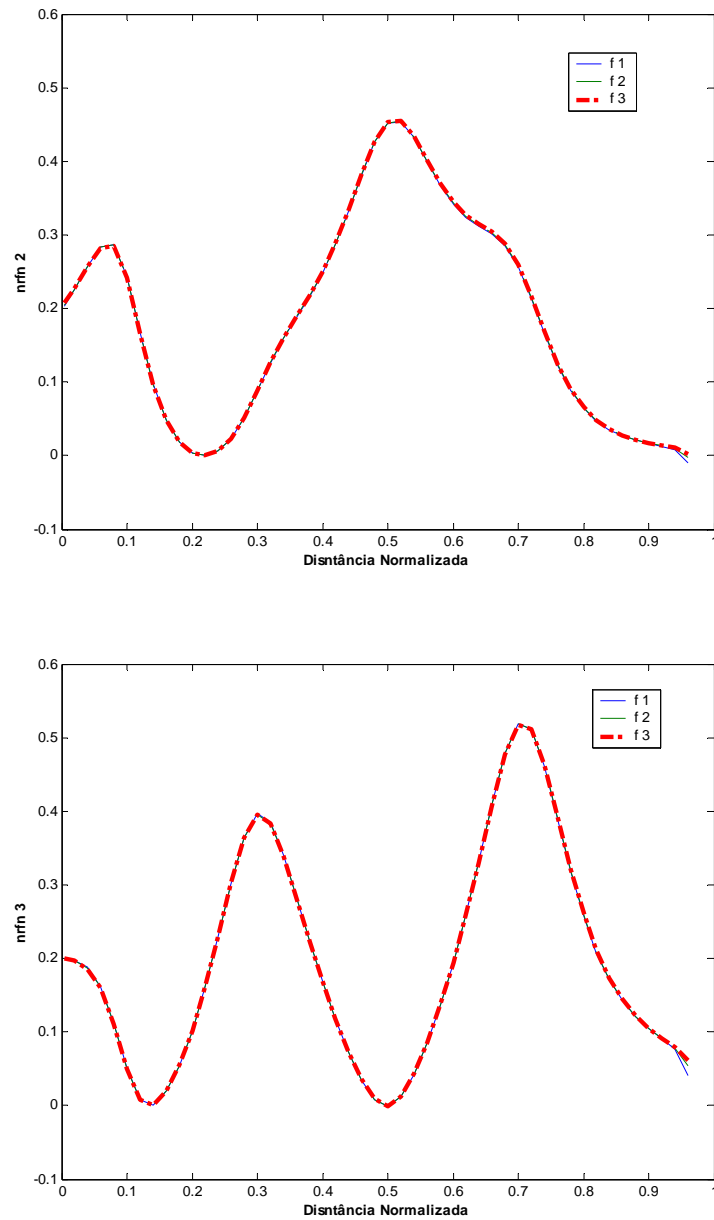


Figura 4.5 –  $nrfn_1$ ,  $nrfn_2$  e  $nrfn_3$ , em função da distância da viga normalizada.

### 4.3.1 Localização da falha

Observa-se nas figuras (4.5) que para diferentes intensidades de falha as curvas são praticamente as mesmas. Elas teriam que dar iguais. A diferença é de arredondamento do

computador. Portanto, a normalização  $nrfn$  é bastante adequada para localização da falha, pois independe da severidade do dano. Pode-se notar também que para uma determinada frequência, um mesmo valor de  $nrfn_i$  pode ser associado a diferentes posições. Assim, uma maior quantidade de curvas de frequência com a normalização  $nrfn$ , deve ser utilizada para que seja possível associar os padrões de entrada a determinada posição da falha, neste trabalho utilizamos cinco. A figura (4.6) apresenta as normalizações  $nrfn_i$  ( $i = 1$  a 5), para as cinco primeiras frequências naturais, em função da distância normalizada da viga.




Figura 4.6 – Normalização  $nrfn_i$  para as cinco primeiras frequências em função da distância normalizada.

Para a validação da rede, os dados foram separados aleatoriamente formando dois grupos. O primeiro grupo foi utilizado durante o treinamento da RNA. Nesta etapa é necessário grande quantidade de dados, para que as condições que se deseja avaliar estejam adequadamente representadas e a rede tenha grande capacidade de generalização. Assim, quanto maior for este grupo de dados melhor será o desempenho da rede após o treinamento. O segundo grupo, chamado de verificação, contém os dados não utilizados na fase de treinamento. Nesta etapa o objetivo é verificar a capacidade de generalização da rede, ou seja, avaliar o comportamento da RNA durante sua utilização. As quantidades de dados utilizados nos dois grupos foram:

- Treinamento 98 dados
- Verificação 49 dados

Os dados utilizados na fase de treinamento e na fase de verificação não foram separados em categorias de severidade de falha, pois como vimos anteriormente, na fase de localização a severidade da falha não tem influência quando empregamos a normalização  $nrfn_i$ , equação (4.7).

A escolha da melhor topologia da rede teve como critério o menor erro absoluto obtido para os dados de verificação. O erro absoluto foi calculado pela equação (4.8) sendo,  $E$  o erro absoluto,  $\hat{Y}_j$  o valor desejado para o padrão  $j$ ,  $Y_j$  o valor obtido pela rede devido a apresentação deste padrão e  $N$  o número de dados do conjunto de verificação.

$$E = \frac{\left| \sum_{j=1}^N \hat{Y}_j - Y_j \right|}{N} \quad (4.8)$$

Uma escolha concomitante entre o menor erro absoluto e menor quantidade de neurônios seria a melhor opção, visto que quanto maior a quantidade de neurônios de uma rede neural maior é seu tempo de treinamento. A tabela (4.3) mostra o erro absoluto para os dados de verificação para determinadas topologias utilizadas. Na coluna da topologia, como já adotado no capítulo de redes neurais, a posição e o algarismo do número representam, respectivamente, a camada e o número de neurônios da referida camada.

Tabela 4.3 – Topologias testadas e seus respectivos erros para os dados de verificação

<i>Topologia</i>	<i>Erro Absoluto</i>
5 14 1	0,0002
5 15 1	0,0007
5 16 1	0,0008
5 17 1	0,0014

A figura (4.7) apresenta o resultado da localização para a rede escolhida (5 14 1). Nota-se que o valor ideal esperado da rede seria a diagonal do retângulo, contudo a resposta obtida não está distante do que se esperava. Os pontos no formato de asteriscos (\*) simbolizam a resposta da rede neural, a linha pontilhada é a resposta esperada. Analisando um ponto de resposta da rede, no eixo das ordenadas obtém-se o valor da saída da rede, já no eixo das abscissas está representada a distância da viga normalizada esperada.




Figura 4.7 – Resposta da rede escolhida (5 14 1).

A tabela (4.4) mostra o valor do erro em porcentagem para cada padrão dos dados de verificação, comparando-se o valor obtido pela RNA escolhida e o valor esperado. O erro é a diferença entre o valor da distância real e o valor da distância apresentado pela rede neural.

Tabela 4.4 – Erro gerado pela RNA escolhida na localização.

RNA					
Distância Real	Distância Estimada	Erro (x 100)	Distância Real	Distância Estimada	Erro (x 100)
0,0040	0,0062	<b>0,22</b>	0,5000	0,4978	<b>0,22</b>
0,0200	0,0192	<b>0,08</b>	0,5200	0,5141	<b>0,59</b>
0,0400	0,0422	<b>0,22</b>	0,5400	0,5355	<b>0,45</b>
0,0600	0,1112	<b>5,12</b>	0,5600	0,5572	<b>0,28</b>
0,0800	0,0792	<b>0,08</b>	0,5800	0,5787	<b>0,13</b>
0,1000	0,0787	<b>2,13</b>	0,6000	0,6034	<b>0,34</b>
0,1200	0,1206	<b>0,06</b>	0,6200	0,6280	<b>0,80</b>
0,1400	0,1370	<b>0,30</b>	0,6400	0,6448	<b>0,48</b>
0,1600	0,1578	<b>0,22</b>	0,6600	0,6550	<b>0,50</b>
0,1800	0,1904	<b>1,04</b>	0,6800	0,6731	<b>0,69</b>
0,2000	0,2087	<b>0,87</b>	0,7000	0,7040	<b>0,40</b>
0,2200	0,2142	<b>0,58</b>	0,7200	0,7264	<b>0,64</b>
0,2400	0,2287	<b>1,13</b>	0,7400	0,7371	<b>0,29</b>
0,2600	0,2632	<b>0,32</b>	0,7600	0,7527	<b>0,73</b>
0,2800	0,2950	<b>1,50</b>	0,7800	0,7768	<b>0,32</b>
0,3000	0,3103	<b>1,03</b>	0,8000	0,8016	<b>0,16</b>
0,3200	0,3100	<b>1,00</b>	0,8200	0,8235	<b>0,35</b>

0,3400	0,3241	<b>1,59</b>	0,8400	0,8430	<b>0,30</b>
0,3600	0,3594	<b>0,06</b>	0,8600	0,8610	<b>0,10</b>
0,3800	0,3916	<b>1,16</b>	0,8800	0,8782	<b>0,18</b>
0,4000	0,3954	<b>0,46</b>	0,9000	0,8948	<b>0,52</b>
0,4200	0,3979	<b>2,21</b>	0,9200	0,9109	<b>0,91</b>
0,4400	0,4285	<b>1,15</b>	0,9400	0,9289	<b>1,11</b>
0,4600	0,4667	<b>0,67</b>	0,9600	0,9624	<b>0,24</b>
0,4800	0,4879	<b>0,79</b>			

### 4.3.2 Quantificação da Falha

Após a localização da falha, o ideal seria que tivéssemos uma rede treinada para quantificar a severidade em cada posição. Porém, isso seria oneroso e trabalhoso. Assim, analisando a estrutura, podemos sugerir que a região mais sensível à ocorrência de falhas seria a região próxima ao engaste, pelo fato das maiores solicitações mecânicas ocorrerem neste local. Desta forma, a título de validar a metodologia de quantificação de falhas através das redes neurais, treinou-se uma rede para diferentes intensidades de falha no elemento 5, ou seja, localizado a 10 mm do engaste. A quantificação de falhas para outros elementos é feita de maneira similar. A tabela (4.5) apresenta as profundidades utilizadas para gerar as falhas no elemento 5.

Tabela 4.5 – Característica das falhas no elemento 5.

<i>Falha</i>	<i>Profundidade (mm)</i>	<i>Momento de Inércia (m<sup>4</sup>)</i>	<i>Falha</i>	<i>Profundidade (mm)</i>	<i>Momento de Inércia (m<sup>4</sup>)</i>
sem falha	0,0	25,000 x 10 <sup>-10</sup>	F 6	3,0	8,575 x 10 <sup>-10</sup>
F 1	0,5	21,434 x 10 <sup>-10</sup>	F 7	3,5	6,866 x 10 <sup>-10</sup>
F 2	1,0	18,220 x 10 <sup>-10</sup>	F 8	4,0	5,400 x 10 <sup>-10</sup>
F 3	1,5	15,353 x 10 <sup>-10</sup>	F 9	4,5	4,159 x 10 <sup>-10</sup>
F 4	2,0	12,800 x 10 <sup>-10</sup>	F 10	5,0	3,125 x 10 <sup>-10</sup>
F 5	2,5	10,547 x 10 <sup>-10</sup>			

A normalização sensível a variações no parâmetro de rigidez é a *redução da frequência natural, rfn*, equação (4.2). Observando a tabela (4.5) notamos que dispomos de 11 padrões, ou

seja, 11 situações distintas que podem ser apresentadas à rede neural. O treinamento se caracterizou pela utilização de 5 destes padrões escolhidos aleatoriamente. Todos os padrões, incluindo os de testes, foram utilizados na verificação da rede.

A escolha da melhor topologia seguiu o mesmo critério utilizado na localização da falha, calculando-se o erro absoluto pela equação (4.8) e selecionando a RNA que apresentou o menor erro. A tabela (4.6) mostra as RNAs testadas e seus respectivos erros. Os testes foram repetidos várias vezes, para que se pudesse avaliar a convergência das redes.

Tabela 4.6 - Redes testadas para a quantificação.

<i>Topologia</i>	<i>Erro Absoluto</i>
5 5 1	0,0006
5 6 1	0,0003
5 7 1	0,0012
5 8 1	0,0004
5 9 1	0,0007
5 10 1	0,0003

Como já mencionado, deve-se selecionar a RNA que apresentar menor erro absoluto. Entretanto, a quantidade de neurônios também é um fator importante visto que, um grande número de neurônios exige um maior tempo de processamento e a possibilidade de sobreajustes, se a quantidade de padrões de entrada for insuficiente. Assim, uma escolha otimizada entre estes dois fatores deve ser feita. Desta maneira a RNA (5 6 1) foi escolhida para realizar a quantificação da falha, com 6 neurônios na camada intermediária. A saída desejada foi padronizada com o valor 0 na saída para a situação da estrutura sem falha e o valor 1 na saída para a situação de falha máxima. Os demais valores de saída foram obtidos calculando a porcentagem que determinado padrão  $rfn_i$  tem em relação ao padrão com maior falha, padrão  $rfn_{10}$ .

O valor obtido pela quantificação da RNA escolhida pode ser observado pela tabela (4.7), bem como o erro gerado pela mesma.

Tabela 4.7 – Severidade da falha e erro devido ao valor gerado pela RNA.

RNA		
Saída Desejada	Saída RNA	Erro (x 100)
0,0000	0,0008	<b>0,08</b>
0,0293	0,0293	<b>0,00</b>
0,0650	0,0658	<b>0,08</b>
0,1089	0,1101	<b>0,12</b>
0,1633	0,1640	<b>0,07</b>
0,2316	0,2306	<b>0,10</b>
0,3180	0,3160	<b>0,20</b>
0,4284	0,4275	<b>0,09</b>
0,5710	0,5728	<b>0,18</b>
0,7567	0,7606	<b>0,39</b>
1,0000	0,9991	<b>0,09</b>

#### 4.4 Exemplo – 2: Viga de Alumínio Livre-Livre

Neste exemplo, é utilizado uma viga de alumínio com 500 mm de comprimento e seção retangular de lados 25x3 mm, figura (4.8). A viga, na condição livre-livre, foi discretizada da mesma maneira do exemplo anterior, utilizando 250 elementos do tipo BEAM3 (2D) no software ANSYS®. As propriedades físicas do alumínio empregado na simulação, utilizando o sistema internacional de unidades (SI), são: módulo de elasticidade,  $E = 70\text{GPa}$ ; coeficiente de Poisson,  $\nu = 0,3$  e; densidade em massa,  $\gamma = 2710\text{kg/m}^3$ .




Figura 4.8 – Viga de alumínio livre-livre simulada.

Como pode ser observado na figura (4.8), o comprimento total utilizado nos testes  $l$  foi atribuído apenas até a metade da viga, isto se deve ao fato da presença de simetria nesta

condição. Assim, para uma posição encontrada  $l_i / l = 0,1$  podemos concluir que a falha está a uma posição de 10% do comprimento de  $l$  em qualquer uma das duas extremidades.

Para simularmos a falha procedemos da mesma maneira que o caso anterior, reduzindo apenas o momento de inércia de área. Sendo assim, temos quatro situações distintas de falhas para cada posição, a situação sem falha e as falhas  $f1$ ,  $f2$  e  $f3$  com profundidades de 0,5 , 1 e 1,5 mm, respectivamente. A tabela (4.8) apresenta os valores dos momentos de inércia para os elementos com e sem falha.

Tabela 4.8 – Propriedades dos elementos com e sem falha.

<i>Situação</i>	<i>Momento de Inércia (<math>m^4</math>)</i>
Sem falha	$5,625 \times 10^{-11}$
Falha 1 ( $f1$ )	$3,255 \times 10^{-11}$
Falha 2 ( $f2$ )	$1,667 \times 10^{-11}$
Falha 3 ( $f3$ )	$0,703 \times 10^{-11}$


Na tabela (4.9) podemos observar as cinco primeiras freqüências naturais da estrutura sem falha e com a falha  $f1$  variando a posição do elemento com falha ao longo da viga. Nota-se uma pequena alteração no valor da freqüência natural para o caso onde a falha se encontra perto da extremidade. Deve ser lembrado que o valor  $l$  foi atribuído apenas até a metade do comprimento da viga.

Tabela 4.9 – Cinco primeiras freqüências para a estrutura de alumínio na condição livre-livre sem falha e com a falha  $f1$ .

<b>Freqüências</b>					
	Freqüência 1 (Hz)	Freqüência 2 (Hz)	Freqüência 3 (Hz)	Freqüência 4 (Hz)	Freqüência 5 (Hz)
<b>Sem falha</b>	<b>62,6863</b>	<b>172,7818</b>	<b>338,6818</b>	<b>559,7762</b>	<b>836,0618</b>
Distância Normalizada ( $l_i / l$ )					
0,0400	62,6863	172,7818	338,6816	559,7744	836,0549
0,0800	62,6862	172,7803	338,6710	559,7311	835,9246
0,1200	62,6859	172,7741	338,6314	559,5809	835,5113
0,1600	62,6850	172,7594	338,5451	559,2874	834,8056
0,2000	62,6833	172,7329	338,4056	558,8775	834,0094
0,2400	62,6804	172,6927	338,2207	558,4394	833,4377
0,2800	62,6761	172,6388	338,0130	558,0907	833,3442

0,3200	62,6700	172,5731	337,8141	557,9352	833,7869
0,3600	62,6622	172,4995	337,6580	558,0248	834,5970
0,4000	62,6524	172,4234	337,5736	558,3414	835,4481
0,4400	62,6407	172,3512	337,5778	558,8014	835,9882
0,4800	62,6272	172,2890	337,6724	559,2780	835,9900
0,5200	62,6121	172,2429	337,8432	559,6371	835,4624
0,5600	62,5958	172,2172	338,0622	559,7761	834,6577
0,6000	62,5786	172,2149	338,2923	559,6570	833,9547
0,6400	62,5609	172,2367	338,4939	559,3207	833,6777
0,6800	62,5432	172,2811	338,6317	558,8759	833,9486
0,7200	62,5260	172,3447	338,6819	558,4640	834,6403
0,7600	62,5098	172,4219	338,6364	558,2137	835,4376
0,8000	62,4951	172,5062	338,5055	558,2017	835,9758
0,8400	62,4823	172,5900	338,3153	558,4306	836,0051
0,8800	62,4719	172,6657	338,1032	558,8290	835,5091
0,9200	62,4641	172,7263	337,9100	559,2735	834,7161
0,9600	62,4592	172,7662	337,7728	559,6257	833,9912
1,0000	62,4573	172,7817	337,7175	559,7751	833,6653

As figuras (4.9) e (4.10) apresentam as variações das frequências naturais  $w_2$  e  $w_3$  e as normalizações  $nrfn_2$  e  $nrfn_3$  em função da distância da viga normalizada, para as três condições de falhas,  $f1$ ,  $f2$  e  $f3$ .







Figura 4.9 – Variações das 2<sup>o</sup> e 3<sup>o</sup> frequências naturais, em função da distância da viga normalizada.






Figura 4.10 –  $nrfn_2$  e  $nrfn_3$ , em função da distância da viga normalizada.

#### 4.4.1 Localização da falha

Como já mencionado, podemos notar nas figuras (4.10) que para diferentes valores de intensidade de falha as curvas são praticamente coincidentes, assim a normalização  $nrfn$  é adequada para a localização da falha, pois independe da severidade da falha. Pode-se notar também que para uma determinada frequência um mesmo valor de  $nrfn_i$  pode ser associado a diferentes posições. Assim, uma maior quantidade de curvas de frequências naturais com a normalização  $nrfn$ , deve ser utilizada para que seja possível associar os padrões de entrada a determinada posição de falha, neste trabalho utilizamos cinco. A figura (4.11) apresenta as curvas para as normalizações  $nrfn_i$  ( $i = 1$  a 5), para a falha  $f1$ , em função da distância normalizada da viga.




Figura 4.11 – Normalizações  $nrfn_i$  para as cinco primeiras frequências naturais, em função da distância da viga normalizada.

Na fase de treinamento da rede os dados foram selecionados aleatoriamente formando um banco com 50 padrões, entendendo-se como padrão o par entrada e resposta desejada. Nesta fase, a maioria dos padrões devem ser utilizados para que a rede aprenda e tenha grande capacidade de generalização, sugere-se que cerca de 80% de todos os padrões disponíveis sejam aplicados nesta fase. Na etapa de verificação, foram selecionados 25 padrões de forma a testar toda a posição relativa da viga. Desta maneira temos:

- Treinamento 50 dados
- Verificação 25 dados

Como critério de escolha para a melhor topologia da rede utilizamos o menor erro absoluto obtido para os dados de verificação. O erro absoluto,  $E$ , foi calculado utilizando a equação (4.8).

A tabela (4.10) apresenta o erro absoluto obtido através dos dados de verificação para as três topologias testadas, tendo como principal variante o número de neurônios na camada intermediária.

Tabela 4.10 – Topologias testadas e seus respectivos erros para os dados de verificação.

<i>Topologia</i>	<i>Erro Absoluto</i>
5 12 1	0,0031
5 14 1	0,0025
5 16 1	0,0016

A figura (4.12) apresenta o resultado da localização para a rede com a topologia escolhida (5 16 1). Nota-se que o valor ideal esperado da rede seria a diagonal do retângulo, contudo a resposta obtida não está distante do que se esperava. Os pontos no formato de asteriscos (\*) simbolizam a resposta da rede neural, a linha pontilhada é a resposta esperada. Analisando um ponto de resposta da rede, no eixo das ordenadas obtém-se o valor da saída da rede, já no eixo das abscissas esta representada a distância da viga normalizada esperada.




Figura 4.12 – Resposta da rede escolhida (5 16 1).

A tabela (4.11) apresenta o erro, em porcentagem, obtido pela rede selecionada em relação ao valor real esperado.

Tabela 4.11 – Erro gerado pela RNA na identificação da localização da falha.

<b>RNA</b>		
<b>Distância Real</b>	<b>Distância Estimada</b>	<b>Erro (x 100)</b>
0,0400	0,0200	<b>2,00</b>
0,0800	0,0929	<b>1,29</b>
0,1200	0,1201	<b>0,01</b>
0,1600	0,1524	<b>0,76</b>
0,2000	0,1920	<b>0,80</b>
0,2400	0,2373	<b>0,27</b>
0,2800	0,2846	<b>0,46</b>
0,3200	0,3294	<b>0,94</b>
0,3600	0,3680	<b>0,80</b>
0,4000	0,4010	<b>0,10</b>
0,4400	0,4354	<b>0,46</b>
0,4800	0,4777	<b>0,23</b>
0,5200	0,5253	<b>0,53</b>
0,5600	0,5697	<b>0,97</b>
0,6000	0,6054	<b>0,54</b>
0,6400	0,6389	<b>0,11</b>
0,6800	0,6785	<b>0,15</b>
0,7200	0,7237	<b>0,37</b>
0,7600	0,7685	<b>0,85</b>
0,8000	0,8066	<b>0,66</b>
0,8400	0,8382	<b>0,18</b>
0,8800	0,8783	<b>0,17</b>
0,9200	0,9315	<b>1,15</b>
0,9600	0,9745	<b>1,45</b>
1,0000	0,9910	<b>0,90</b>

#### 4.4.2 *Quantificação da Falha*

Após a localização da falha, o ideal seria que tivéssemos uma rede treinada para quantificar a severidade em cada posição. Porém isso seria oneroso e trabalhoso. Assim, analisando a estrutura, podemos sugerir que a região mais sensível a ocorrência de falhas seria a região próxima ao centro da viga. Desta forma, a título de validar a metodologia de quantificação de falhas através das redes neurais, treinou-se uma rede para diferentes intensidades de falha no elemento 120, ou seja, localizado a 240 mm de uma das extremidades da viga. A quantificação de falhas para outros elementos é feita de maneira similar. A tabela (4.12) apresenta as

profundidades utilizadas para gerar as falhas neste elemento. Da mesma maneira que o exemplo anterior, a falha foi simulada alterando somente o momento de inércia de área.

Tabela 4.12 – Característica das falhas no elemento 120.

<i>Falha</i>	<i>Profundidade (mm)</i>	<i>Momento de Inércia (m<sup>4</sup>)</i>	<i>Falha</i>	<i>Profundidade (mm)</i>	<i>Momento de Inércia (m<sup>4</sup>)</i>
sem falha	0,00	$5,625 \times 10^{-11}$	F 5	1,25	$1,116 \times 10^{-11}$
F 1	0,25	$4,333 \times 10^{-11}$	F 6	1,50	$7,031 \times 10^{-12}$
F 2	0,50	$3,255 \times 10^{-11}$	F 7	1,75	$4,069 \times 10^{-12}$
F 3	0,75	$2,373 \times 10^{-11}$	F 8	2,00	$2,083 \times 10^{-12}$
F 4	1,00	$1,667 \times 10^{-11}$			

A *redução da frequência natural*, *rfn* equação (4.2), foi o padrão de entradas empregado para quantificar a falha. Observando a tabela (4.12) notamos que dispomos de 9 padrões, ou seja, para as nove condições acima (resposta desejada) temos os referidos vetores. O treinamento se caracterizou pela utilização de 5 destes padrões escolhidos aleatoriamente. Todos os padrões, incluindo os de testes, foram utilizados na verificação da rede.

A escolha da melhor topologia seguiu o mesmo critério utilizado na localização da falha, calculando-se o erro absoluto pela equação (4.8) e selecionando a RNA que apresentou o menor erro. A tabela (4.13) mostra as RNAs testadas e seus respectivos erros. Os testes foram repetidos varias vezes, para que se pudesse avaliar a convergência das redes.

Tabela 4.13 - Redes testadas para a quantificação.

<i>Topologia</i>	<i>Erro Absoluto</i>
5 5 1	0,0034
5 6 1	0,0042
5 7 1	0,0010
5 8 1	0,0039
5 9 1	0,0011
5 10 1	0,0051

Podemos observar que a rede que apresentou menor erro absoluto foi a RNA com a topologia (5 7 1), ou seja, cinco neurônios na camada de entrada, sete neurônios na camada intermediária e um neurônio na camada de saída. Assim, esta foi a RNA selecionada para a quantificação do dano. Deve ser ressaltado que os neurônios na camada de entrada não possuem

poder de cálculo, sendo utilizados apenas para apresentar os padrões, assim, podemos dizer que esta rede possui duas camadas de cálculo, ou como normalmente é empregado, diz-se rede de duas camadas.

A saída desejada foi padronizada com o valor 0 na saída para a situação da estrutura sem falhas e o valor 1 na saída para a situação de falha máxima. Os demais valores de saída foram obtidos calculando a porcentagem que determinado padrão  $rfn_i$  tem em relação ao padrão com maior falha, padrão  $rfn_8$ .

O valor obtido pela quantificação da RNA escolhida pode ser observado pela tabela (4.14), bem como o erro gerado pela mesma.

Tabela 4.14 – Severidade da falha e erro obtido na quantificação.

RNA		
Saída Desejada	Saída RNA	Erro (x 100)
0,0000	0,0021	<b>0,21</b>
0,0153	0,0153	<b>0,00</b>
0,0371	0,0354	<b>0,17</b>
0,0693	0,0670	<b>0,23</b>
0,1186	0,1172	<b>0,14</b>
0,1975	0,1977	<b>0,02</b>
0,3303	0,3312	<b>0,09</b>
0,5656	0,5775	<b>1,19</b>
1,0000	0,9995	<b>0,05</b>

## 4.5 Generalização

### 4.5.1 Viga de Aço Livre-Livre

O primeiro exemplo apresentou a localização e a quantificação da falha para uma viga de aço na condição engastada-livre. Com o objetivo de avaliar o comportamento da mesma viga na

condição livre-livre, foi realizada uma nova simulação, com as mesmas condições de falha, ou seja,  $f1$ ,  $f2$  e  $f3$  representando as profundidades de 1, 2 e 3mm respectivamente, porém na condição livre-livre. As curvas das variações da 2ª e 3ª frequências naturais em função da localização do elemento com falha e sua severidade são apresentadas na figura (4.13). As curvas para a normalização da frequência natural,  $nrfn$ , da 2ª e 3ª frequências naturais são apresentadas na figura (4.14). A exemplo da seção 4.4, para o caso da viga de alumínio na condição livre-livre, nesta seção os dados são apresentados para valores até o centro da viga de aço. Assim, o valor da distância normalizada igual a 1 indica a posição central da viga, a uma distância de 250 mm em relação a sua extremidade.

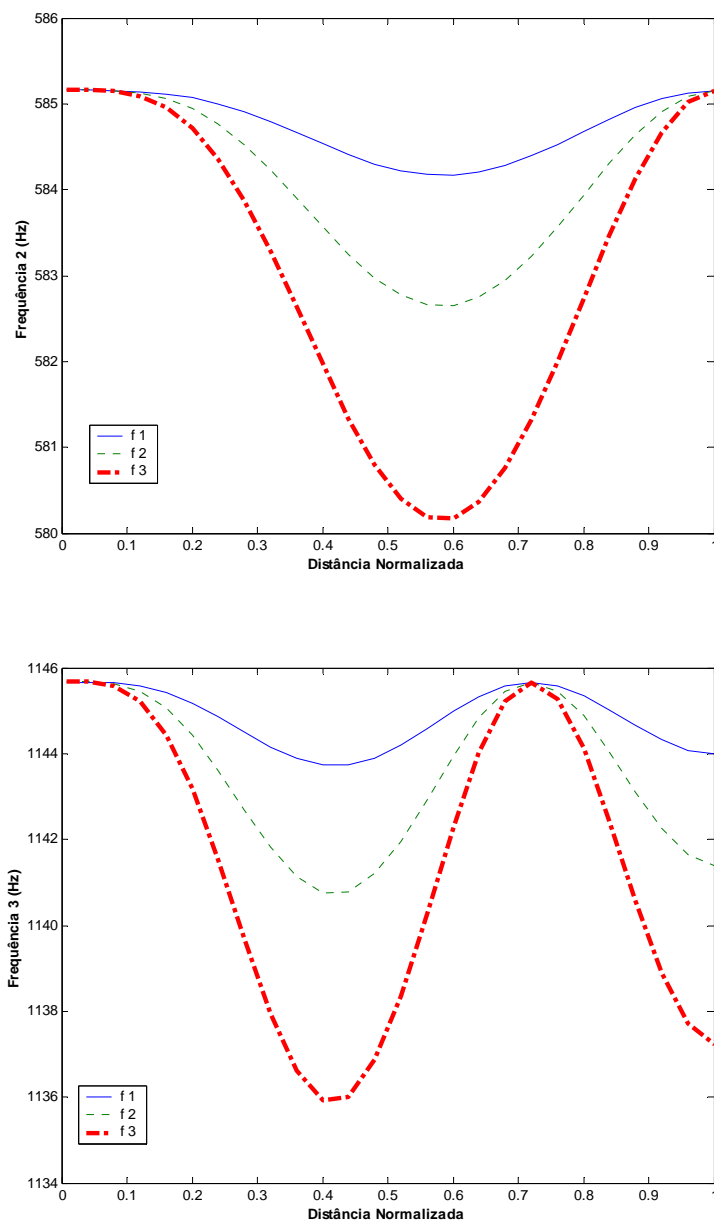


Figura 4.13 – Variações das 2º e 3º frequências naturais para a viga de aço livre-livre.





Figura 4.14 –  $nrfn_2$  e  $nrfn_3$  para a viga de aço livre-livre.

Mesmo tratando-se de materiais e dimensões diferentes, notamos a similaridade entre as figuras (4.13) e (4.9) e entre as figuras (4.14) e (4.10). Nota-se que nas figuras (4.13) e (4.9) os eixos das ordenadas apresentam os valores das frequências naturais, que são diferentes para os dois sistemas. No entanto, depois da normalização, as curvas são similares, sugerindo uma generalização para cada condição de contorno, independentemente do material da viga e de suas

dimensões. Sua similaridade nos leva à concluir que mesmo se tratando de materiais diferentes e com dimensões diferentes, estas curvas podem ser utilizadas para localização de falhas em qualquer tipo de viga sob as mesmas condições de contorno, tornando esta etapa da metodologia bastante robusta para localização de falhas.

No sentido de realizarmos estudos à respeito da generalização da rede, apresentamos a tabela (4.15), onde podemos observar o comportamento da RNA (5 16 1) que foi selecionada na seção 4.4, para monitorar falhas na viga de alumínio na condição livre-livre. Esta tabela apresenta também a resposta da referida RNA para localização de falhas para a viga de aço na condição livre-livre. Deve ser ressaltado que a presente RNA foi treinada apenas com os padrões oriundos da viga de alumínio na condição livre-livre.

Tabela 4.15 – Resposta da RNA (5 16 1) treinada para a viga de alumínio na condição livre-livre, para localização de falhas nas vigas de alumínio e de aço na condição livre-livre.


<b>RNA</b>				
<b>Distância Real</b>	<b>Viga Aço</b>	<b>Erro Aço (x 100)</b>	<b>Viga Alumínio</b>	<b>Erro Alumínio (x 100)</b>
0,0400	0,0200	<b>2,00</b>	0,0195	<b>2,05</b>
0,0800	0,0929	<b>1,29</b>	0,0748	<b>0,52</b>
0,1200	0,1201	<b>0,01</b>	0,1121	<b>0,79</b>
0,1600	0,1524	<b>0,76</b>	0,1495	<b>1,05</b>
0,2000	0,1920	<b>0,80</b>	0,1904	<b>0,96</b>
0,2400	0,2373	<b>0,27</b>	0,2361	<b>0,39</b>
0,2800	0,2846	<b>0,46</b>	0,2837	<b>0,37</b>
0,3200	0,3294	<b>0,94</b>	0,3288	<b>0,88</b>
0,3600	0,3680	<b>0,80</b>	0,3677	<b>0,77</b>
0,4000	0,4010	<b>0,10</b>	0,4006	<b>0,06</b>
0,4400	0,4354	<b>0,46</b>	0,4349	<b>0,51</b>
0,4800	0,4777	<b>0,23</b>	0,4772	<b>0,28</b>
0,5200	0,5253	<b>0,53</b>	0,5248	<b>0,48</b>
0,5600	0,5697	<b>0,97</b>	0,5691	<b>0,91</b>
0,6000	0,6054	<b>0,54</b>	0,6047	<b>0,47</b>
0,6400	0,6389	<b>0,11</b>	0,6381	<b>0,19</b>
0,6800	0,6785	<b>0,15</b>	0,6777	<b>0,23</b>
0,7200	0,7237	<b>0,37</b>	0,7231	<b>0,31</b>
0,7600	0,7685	<b>0,85</b>	0,7682	<b>0,82</b>
0,8000	0,8066	<b>0,66</b>	0,8063	<b>0,63</b>
0,8400	0,8382	<b>0,18</b>	0,8380	<b>0,20</b>
0,8800	0,8783	<b>0,17</b>	0,8781	<b>0,19</b>
0,9200	0,9315	<b>1,15</b>	0,9315	<b>1,15</b>
0,9600	0,9745	<b>1,45</b>	0,9745	<b>1,45</b>
1,0000	0,9910	<b>0,90</b>	0,9904	<b>0,96</b>

Em geral, o erro obtido para a localização da falha na viga de aço foi, praticamente, da mesma ordem de grandeza do que o erro obtido na localização da falha para a viga de alumínio. Isto justifica a normalização adotada e a utilização de uma mesma rede para monitoramento de qualquer tipo de viga sob as mesmas condições de contorno.

#### 4.5.2 Viga de Alumínio Engastada-Livre

Seguindo a mesma metodologia, foram realizadas simulações na mesma viga de alumínio apresentada na seção 4.4, entretanto, para a condição engastada-livre. Esta simulação pretende avaliar o comportamento desta viga na condição engastada-livre e, se possível, traçar um paralelo para a viga estudada na seção 4.3 que aborda a viga de aço na condição engastada-livre. Neste sentido, o tipo de elemento empregado e o número de elementos utilizados na discretização foram os mesmos para todos os casos apresentados. A severidade da falha simulada é semelhante à apresentada na seção 4.4, ou seja,  $f1$ ,  $f2$  e  $f3$  representam 0,5 , 1 e 1,5 mm de profundidade respectivamente.

As variações das 2º e 3º frequências naturais, em função da posição e da severidade do elemento com falha, são apresentadas na figura (4.15). O valor da *normalização da frequência natural*,  $nrfn$ , das 2º e 3º frequências naturais, são apresentados na figura (4.16).







Figura 4.15 – Variações das 2º e 3º frequências naturais para a viga de alumínio engastada-livre.






Figura 4.16 –  $nrfn_2$  e  $nrfn_3$  para a viga de alumínio engastada-livre.

Observando as figuras (4.15) e (4.16), nota-se a similaridade com as curvas (4.4) e (4.5) que foram obtidas na seção 4.3 para a viga de aço na condição engastada-livre. As figuras (4.15) e (4.4) apresentam valores diferentes quando tomamos como base o eixo das ordenadas pelo fato de representar as frequências naturais de cada caso, o que já era esperado. Entretanto, o comportamento da curva é semelhante. Já para as figuras (4.16) e (4.5) a semelhança está presente em sua totalidade.

Esta similaridade de comportamento nos leva à concluir que mesmo se tratando de materiais diferentes e com dimensões diferentes, estas curvas podem ser utilizadas para localização de falhas em qualquer tipo de viga sob as mesmas condições de contorno, tornando esta etapa da metodologia bastante robusta para localização da falha. O mesmo comportamento havia sido observado para a viga de alumínio e a viga de aço na condição livre-livre. Desta maneira, é possível treinar apenas uma RNA para cada condição de contorno e expandir sua utilização para qualquer tipo de viga, evitando, assim, repetidas fases de treinamento e verificação das redes.

Para a quantificação, as curvas das frequências apresentam o mesmo comportamento, no entanto, o valor absoluto é diferente. Similarmente ao caso anterior, é possível generalizar o uso de uma rede para quantificar a severidade das falhas de vigas com dimensões e materiais

diferentes sob as mesmas condições de contorno. No entanto, deve-se notar que para cada posição da falha exige-se uma rede.

A tabela (4.16) apresenta os resultados da localização da falha para a rede escolhida na seção 4.3, ou seja configuração (5 14 1) para o caso da viga de aço na condição engastada-livre. A referida tabela apresenta, também, a resposta da rede para o caso da viga de alumínio na condição engastada-livre. Deve ser ressaltado que na fase de treinamento, esta rede recebeu apenas os padrões oriundos da viga de aço na condição engastada-livre.

Tabela 4.16 – Resposta da RNA (5 14 1), treinada para a viga de aço na condição engastada-livre, para localização de falhas nas vigas de aço e de alumínio na condição engastada-livre.

Distância Real	RNA			
	Viga Aço	Erro Aço (x 100)	Viga Alumínio	Erro Alumínio (x 100)
0,0040	0,0062	<b>0,22</b>	0,0009	<b>0,31</b>
0,0200	0,0192	<b>0,08</b>	0,0174	<b>0,26</b>
0,0400	0,0422	<b>0,22</b>	0,0483	<b>0,83</b>
0,0600	0,1112	<b>5,12</b>	0,1109	<b>5,09</b>
0,0800	0,0792	<b>0,08</b>	0,0777	<b>0,23</b>
0,1000	0,0787	<b>2,13</b>	0,0786	<b>2,14</b>
0,1200	0,1206	<b>0,06</b>	0,1207	<b>0,07</b>
0,1400	0,1370	<b>0,30</b>	0,1369	<b>0,31</b>
0,1600	0,1578	<b>0,22</b>	0,1570	<b>0,30</b>
0,1800	0,1904	<b>1,04</b>	0,1891	<b>0,91</b>
0,2000	0,2087	<b>0,87</b>	0,2087	<b>0,87</b>
0,2200	0,2142	<b>0,58</b>	0,2175	<b>0,25</b>
0,2400	0,2287	<b>1,13</b>	0,2353	<b>0,47</b>
0,2600	0,2632	<b>0,32</b>	0,2702	<b>1,02</b>
0,2800	0,2950	<b>1,50</b>	0,3022	<b>2,22</b>
0,3000	0,3103	<b>1,03</b>	0,3109	<b>1,09</b>
0,3200	0,3100	<b>1,00</b>	0,3085	<b>1,15</b>
0,3400	0,3241	<b>1,59</b>	0,3218	<b>1,82</b>
0,3600	0,3594	<b>0,06</b>	0,3573	<b>0,27</b>
0,3800	0,3916	<b>1,16</b>	0,3876	<b>0,76</b>
0,4000	0,3954	<b>0,46</b>	0,3906	<b>0,94</b>
0,4200	0,3979	<b>2,21</b>	0,3938	<b>2,62</b>
0,4400	0,4285	<b>1,15</b>	0,4255	<b>1,45</b>
0,4600	0,4667	<b>0,67</b>	0,4645	<b>0,45</b>
0,4800	0,4879	<b>0,79</b>	0,4863	<b>0,63</b>
0,5000	0,4978	<b>0,22</b>	0,4975	<b>0,25</b>
0,5200	0,5141	<b>0,59</b>	0,5131	<b>0,69</b>
0,5400	0,5355	<b>0,45</b>	0,5345	<b>0,55</b>
0,5600	0,5572	<b>0,28</b>	0,5558	<b>0,42</b>
0,5800	0,5787	<b>0,13</b>	0,5770	<b>0,30</b>
0,6000	0,6034	<b>0,34</b>	0,6014	<b>0,14</b>
0,6200	0,6280	<b>0,80</b>	0,6258	<b>0,58</b>

0,6400	0,6448	<b>0,48</b>	0,6426	<b>0,26</b>
0,6600	0,6550	<b>0,50</b>	0,6529	<b>0,71</b>
0,6800	0,6731	<b>0,69</b>	0,6712	<b>0,88</b>
0,7000	0,7040	<b>0,40</b>	0,7027	<b>0,27</b>
0,7200	0,7264	<b>0,64</b>	0,7263	<b>0,63</b>
0,7400	0,7371	<b>0,29</b>	0,7361	<b>0,39</b>
0,7600	0,7527	<b>0,73</b>	0,7510	<b>0,90</b>
0,7800	0,7768	<b>0,32</b>	0,7748	<b>0,52</b>
0,8000	0,8016	<b>0,16</b>	0,7998	<b>0,02</b>
0,8200	0,8235	<b>0,35</b>	0,8221	<b>0,21</b>
0,8400	0,8430	<b>0,30</b>	0,8417	<b>0,17</b>
0,8600	0,8610	<b>0,10</b>	0,8599	<b>0,01</b>
0,8800	0,8782	<b>0,18</b>	0,8772	<b>0,28</b>
0,9000	0,8948	<b>0,52</b>	0,8936	<b>0,64</b>
0,9200	0,9109	<b>0,91</b>	0,9086	<b>1,14</b>
0,9400	0,9289	<b>1,11</b>	0,9221	<b>1,79</b>
0,9600	0,9624	<b>0,24</b>	0,9347	<b>2,53</b>

Em geral, o erro obtido para a localização da falha na viga de alumínio foi da mesma ordem de grandeza do erro obtido na localização da falha para a viga de aço. Isso comprova a generalização proposta na seção anterior.

## *CAPÍTULO 5*

### **RESULTADOS EXPERIMENTAIS**

Neste capítulo, apresentaremos os resultados experimentais obtidos nos laboratórios da Faculdade de Engenharia de Ilha Solteira, visando demonstrar o potencial da metodologia através de exemplos práticos. Os testes foram realizados em diferentes tipos de estruturas, com diferentes materiais, para que pudéssemos avaliar o comportamento da técnica empregada.

As medidas experimentais são basicamente as medidas de impedância elétrica dos materiais piezelétricos colados nas estruturas. Grande parte das medidas de impedância elétrica foram realizadas no laboratório de caracterização elétrica do departamento de Física e Química da Faculdade de Engenharia de Ilha Solteira, através do equipamento HP Analyzer 4192A. Este aparelho está acoplado a um microcomputador que comanda todo equipamento. Desta maneira, parâmetros como: faixa de frequência; resolução da frequência; número de médias e tipo de medidas podem ser ajustados através do microcomputador. A figura (5.1) mostra detalhes do equipamento utilizado.




Figura 5.1 – Microcomputador e aparelho HP Analyzer 4192A.

No último exemplo apresentamos um aparelho alternativo para medidas de impedância elétrica, batizado de “MIBC” (Medidor de Impedância de Baixo Custo). O equipamento da HP foi utilizado para validar o aparelho desenvolvido e construído pelo grupo de Materiais e Sistemas Inteligentes, GMSINT. A construção deste aparelho tem, também, a função de viabilizar a metodologia para o caso onde não se tem acesso a medidores de impedância comerciais. Maiores detalhes podem ser obtidos no apêndice A.

A detecção, a localização e a quantificação das falhas são obtidas através das medidas de impedância elétrica e estimadas por meio do cálculo da falha métrica. A falha métrica facilita a interpretação da variação da impedância e fornece informações quantitativas a respeito das curvas. Utilizando a falha métrica, apresentada na seção 2.2.3, podemos obter uma maneira automática de inspeção da estrutura.

$$M = \sum_{i=1}^n [\operatorname{Re}(Z_{i,1}) - \operatorname{Re}(Z_{i,2})]^2 \quad (2.29)$$

As faixas de frequência escolhidas para cada caso dependem da quantidade de ressonâncias (picos) que aparecem no gráfico da impedância elétrica. Quanto maior a quantidade destes picos melhor é a faixa, pois as variações estruturais e, conseqüentemente, as variações da impedância elétrica serão facilmente monitoradas.

Para demonstrarmos a aplicabilidade da metodologia dividimos este capítulo em três partes: inicialmente apresentamos a localização de múltiplas falhas em uma barra de alumínio;

na seqüência é realizada a localização e a quantificação de falhas em uma estrutura de aço no formato de um virabrequim e finalizando; foi feita a validação do aparelho MIBC através de medidas realizadas em uma viga de aço. Estas medidas foram validadas comparando o resultado obtido com o MIBC com o resultado obtido pelo medidor de impedância HP Analyzer 4192A.

## 5.1 Barra de Alumínio

O objetivo deste exemplo é demonstrar a capacidade da técnica em detectar e localizar falhas simultâneas em estruturas. Para isso, utilizamos uma barra de alumínio com dimensões 600 x 25 x 5 mm que correspondem ao comprimento, a largura e a espessura, respectivamente. Nas regiões próximas de cada extremidade colamos os PZT's, que estão numerados como mostra a figura (5.2). O número 1 está localizado a 60 mm de uma extremidade, e o número 2 está localizado a 100 mm da outra extremidade. Ambos foram colados do mesmo lado da superfície. Cada PZT tem formato quadrado com lados de 20 mm e espessura de 0,267 mm. Foram utilizados PZT's de denominação PSI-5A-S4, (Piezo System), com as seguintes propriedades: Módulo de Elasticidade  $E = 63 \text{ GPa}$ ; Constante Dielétrica  $d_{31} = -190 \text{e-}12 \text{ m.V}^{-1}$ .




Figura 5.2 – Barra de alumínio utilizada.

### 5.1.1 Localização da Falha

Inserimos dois tipos de falhas em regiões distintas. A primeira foi feita próxima ao PZT número 1 a uma distância de 45 mm da extremidade da viga na mesma superfície onde os PZT's estão colados, indicado na figura (5.2) como P1. A segunda está localizada próxima ao PZT número 2 a uma distância de 25 mm da extremidade da viga na superfície oposta onde estão colados os PZT's, indicado na figura (5.2) como P2.

A posição da falha próxima ao PZT 1 foi chamada de “posição 1 da falha”. Esta falha foi inserida por meio de uma serra circular com 1,5 mm de espessura, ao longo da largura da viga. Nesta posição foram feitas três profundidades de falha, 0,5, 1,0 e 1,5 mm, que foram especificadas por falha 1, falha 2 e falha 3, respectivamente. A faixa de frequência adotada neste exemplo foi de 43kHz a 53kHz. Inicialmente realizamos as medidas da impedância elétrica na condição sem falha para os dois PZT's. Estas medidas serviram como referência para a condição sem falha. Em seguida inserimos as falhas na posição 1 com as três profundidades descritas acima. Após a inserção de cada profundidade de falha medimos a impedância elétrica dos dois PZT's e, por meio do cálculo da falha métrica, comparamos com a medida de referência.

A figura (5.3) apresenta o valor absoluto da impedância elétrica e do componente real para o PZT 1, nas condições sem falha e com a falha de 1,5 mm de profundidade na posição 1. Note que o gráfico apresenta apenas parte da faixa de frequência estudada; isto foi empregado para facilitar a visualização da diferença entre as curvas.

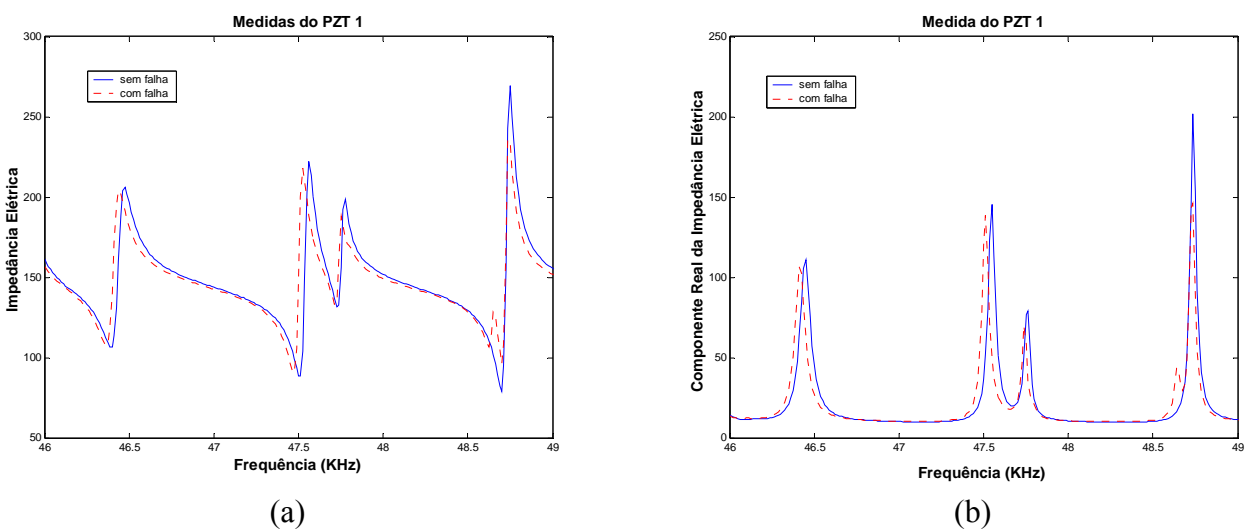


Figura 5.3 – Medidas do PZT 1 com e sem falha na posição 1: (a) impedância elétrica; (b) componente real da impedância elétrica.

Comparando a falha métrica obtida para cada condição de falha entre os dois PZT's e normalizando este valor em relação ao maior valor, podemos localizar em qual região dos dois PZT's a falha está mais próxima, ou seja, em qual região ela está tendo forte influência. A figura (5.4) apresenta os valores da falha métrica para os dois PZT's, calculadas para cada profundidade de falha inserida na posição 1. Neste exemplo e nos demais, a componente real da impedância elétrica, seção 2.2.2, foi empregada no cálculo da falha métrica, por se tratar do componente que apresenta maior sensibilidade em relação à mudança estrutural, quando comparada com a componente imaginária, (Raju, 1998).




Figura 5.4 – Localização da falha inserida na posição 1.

O gráfico acima apresenta o valor da falha métrica normalizada, em relação ao maior valor de falha métrica obtido, que neste caso foi para o PZT 1 com a profundidade de 1,5 mm. A barra 1 corresponde a situação sem falha, já as demais estão em ordem crescente das falhas. Como podemos notar, o valor da falha métrica para o PZT 1 foi maior do que para o PZT 2. Utilizando esta metodologia, podemos localizar a região onde a falha está presente. Entretanto, o valor da falha métrica apresentada pelo PZT 2 também é alto, assim podemos afirmar que área de influência do PZT 2 também engloba a posição 1 de falha.

A segunda posição onde a falha foi inserida, próxima ao PZT 2, foi adotada como “posição 2 da falha”. As falhas inseridas nesta região foram feitas por meio de uma serra circular com 0,3 mm de espessura, ao longo da largura da viga. Nesta posição foram feitas três falhas com profundidade distintas, as profundidades são as mesmas empregadas na posição 1. Como dito anteriormente, esta falha foi feita na superfície oposta onde estão colados os PZT's. Esta

decisão foi tomada visando analisar o comportamento da técnica diante de uma falha relativamente pequena e localizada na face oposta.

Para podermos localizar a falha inserida na posição 2, temos de utilizar como referência não mais a situação sem falha para os dois PZT's mas sim a situação de falha máxima na posição 1. Portanto, será utilizado como medida de referência para localizar a falha na posição 2 a medida da impedância elétrica para os dois PZT's na condição de falha máxima na posição 1, com profundidade de 1,5 mm. O cálculo da falha métrica expressa uma comparação entre as diferenças de curvas e o fato de utilizarmos a curva com a falha na posição 1 como referência não vai influenciar no cômputo das falhas inseridas na posição 2.

Comparando a falha métrica obtida para cada condição de falha entre os dois PZT's e normalizando este valor em relação ao maior valor, podemos localizar a região da falha, ou seja, em qual região ela está tendo maior influência. A figura (5.5) apresenta o valor da falha métrica para os dois PZT's, calculada para cada profundidade de falha inserida na posição 2.




Figura 5.5 – Localização da falha inserida na posição 2.

O gráfico acima apresenta o valor da falha métrica normalizada, em relação ao maior valor de falha métrica obtido, que neste caso foi para o PZT 2 com a profundidade de 1,5 mm. A barra 1 corresponde a situação sem falha, já as demais estão em ordem crescente das falhas. Observando a figura acima, podemos notar que em todos os casos o valor da falha métrica para o PZT 2 foi maior do que para o PZT 1. Desta maneira podemos localizar a região onde a falha

está presente. Porém, o valor da falha métrica apresentada pelo PZT 1 também é alto, assim podemos afirmar que área de influência do PZT 1 também engloba a posição 2 de falha.

O monitoramento da estrutura poderia ser realizado para as duas situações utilizando como referência a situação sem falhas. Neste caso teríamos sete situações: sem falha; falha 1, falha 2 e falha 3 na posição 1 e; falha 1, falha 2 e falha 3 na posição 2. A figura (5.6) mostra o valor da falha métrica para os dois PZT's.




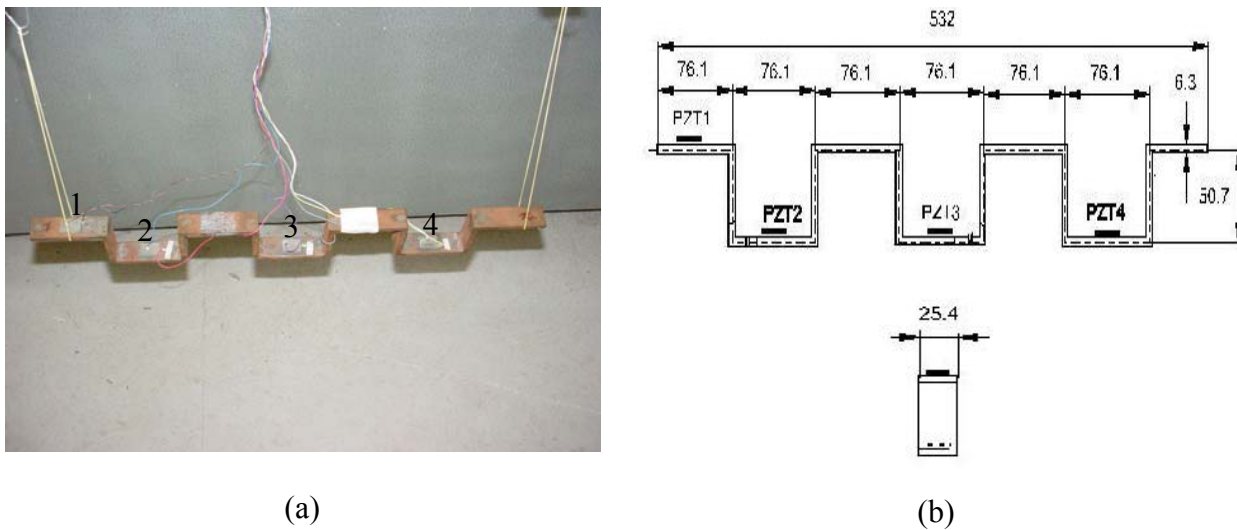
Figura 5.6 – Localização das falhas inseridas na viga.

De posse das medidas para os tipos de falhas, seria possível treinarmos uma RNA para quantificar o valor dessas falhas, entretanto, optamos apenas em detectar e localizar a região da falha nesta fase. Posteriormente, as RNA's serão utilizadas para quantificar falhas.

## 5.2 Estrutura do Tipo Virabrequim

Neste exemplo utilizamos uma estrutura do tipo virabrequim, figura (5.7.a), confeccionada de aço. As dimensões da estrutura em milímetros estão mostradas na figura (5.7.b). A estrutura em questão, foi previamente utilizada para quantificar danos através de um método de otimização hierárquica, (Lopes Jr. et al., 2000).

Para esta estrutura foi monitorado a detecção, a localização e quantificação da severidade da falha introduzida. Durante a localização da falha, utilizamos as medidas da impedância elétrica de cada PZT para cada condição de falhas no cálculo da falha métrica. Na fase de quantificação utilizamos, também, as redes neurais artificiais, que foram treinadas e avaliadas tendo como padrão de entradas os valores da falha métrica.



(a)

(b)

Figura 5.7 – Estrutura do tipo virabrequim.

Na figura (5.7.a), podemos notar quatro PZT's colados ao longo da estrutura, numerados de 1 a 4, cada PZT tem formato quadrado com lados de 20 mm e espessura de 0,267 mm. Estes PZT's delimitam a área de estudo para localização das falhas. As propriedades físicas dos PZT's são as mesmas apresentadas na seção anterior.

### 5.2.1 Localização da falha

A falha foi inserida na estrutura no lado oposto e em baixo do quarto PZT, indicado na figura (5.7.a) pelo numero quatro, através de um corte realizado por uma serra circular com 0,3 mm de espessura ao longo da largura da estrutura, como mostra a figura (5.8).



Figura 5.8 – Detalhe da falha introduzida.

Para cada PZT, foram realizadas seis medidas de impedância elétrica na faixa entre 45kHz e 55kHz; a situação padrão sem falha, referência, e as cinco demais com falhas. As falhas introduzidas e as respectivas profundidades podem ser observadas na tabela (5.1).

Tabela 5.1 – Características das falhas introduzidas na estrutura do tipo virabrequim.

<i>Tipo de falhas</i>	<i>Profundidade (mm)</i>
Falha 1	0,2
Falha 2	0,6
Falha 3	1,0
Falha 4	1,2
Falha 5	1,4

A figura (5.9) apresenta os valores da falha métrica para os quatro PZT's em cada condição de falha. O componente real da impedância elétrica, seção 2.2.2, foi empregado no cálculo da falha métrica. Note que os valores estão normalizados em relação ao maior valor e que em todos os casos foi obtido no PZT\_4. Mesmo tratando-se de uma falha incipiente, 0,3 mm de largura e 0,2 mm de profundidade, a técnica foi capaz de detectar e localizar a região onde a falha está presente.

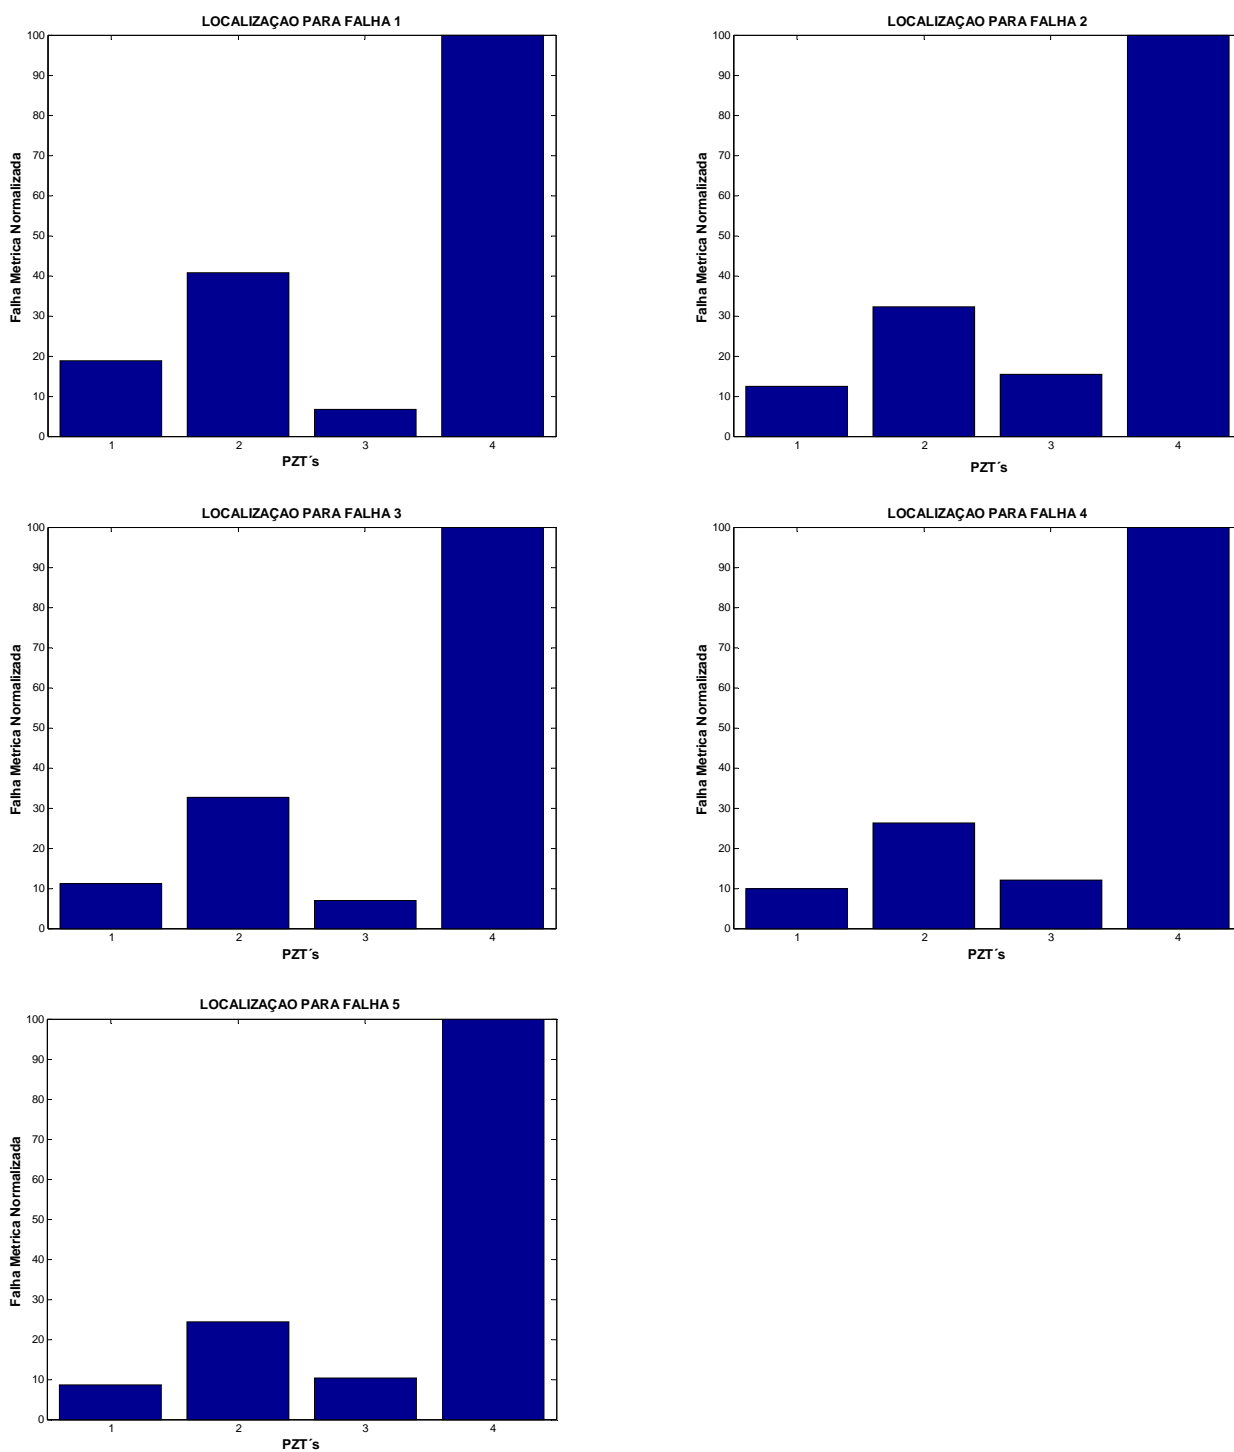


Figura 5.9 – Falha métrica para os quatro PZT's em cada condição de falha.

### 5.2.2 Quantificação da Falha

Na fase de quantificação da falha, utilizamos os dados da evolução da falha métrica para o PZT\_4 como padrões de treinamento e de avaliação da rede neural. A metodologia exige uma rede neural para cada PZT, ou seja, após a localização da região onde a falha está presente deve ser utilizada a rede neural específica treinada para o referido PZT para quantificar a severidade da falha naquela região. A figura (5.10) apresenta a evolução da falha métrica obtida para o PZT\_4. Note que os valores estão normalizados em relação ao valor máximo.




Figura 5.10 – Evolução da falha métrica para o PZT\_4

As barras apresentadas na figura acima representam o valor da falha métrica calculada para cada profundidade de falha no PZT\_4. As falhas estão em ordem crescente, partindo da condição sem falha, barra 1, até a falha máxima, barra 6, que representa a falha com 1,4 mm de profundidade. A figura (5.11) apresenta o gráfico do componente real da impedância elétrica no PZT\_4 para a condição sem falha e com a falha de 1,4 mm de profundidade. Pode-se notar claramente a diferença entre as curvas.




Figura 5.11 – Componente real da impedância elétrica no PZT\_4 nas condições sem falha e com falha máxima.

Para quantificarmos a falha, utilizamos uma rede neural multilayer perceptron com treinamento via backpropagation com duas camadas de processamento. Nos neurônios intermediários empregamos a função de transferência do tipo sigmoideal, equação (3.11). Já para o neurônio de saída a função de transferência empregada foi do tipo linear, equação (3.8). Por se tratar de um problema relativamente simples e com um pequeno número de padrões, utilizamos uma rede neural relativamente pequena com topologia (1 5 1).

Os padrões utilizados na fase de treinamento foram as falhas métricas referentes às profundidades descritas na tabela (5.1). Entretanto, na fase de avaliação, além de utilizarmos os mesmo padrões que foram utilizados na fase de treinamento, utilizamos também os padrões referentes as profundidades de 0,4 e 0,8 mm. Esses dados não foram apresentados a rede neural durante a fase de treinamento, desta maneira podemos avaliar o comportamento da rede diante de um padrão desconhecido (generalização). A tabela (5.2) mostra os padrões fornecidos à rede e as respostas obtidas.

Tabela 5.2 – Resposta da rede neural na quantificação da falha.

Falha Métrica (%)	Profundidade da falha (mm)	Resposta da rede profundidade (mm)	Erro (x 100)
0,0000	0,0	0,0032	0,32
0,1613	0,2	0,2133	1,33
0,2081	0,4	0,3791	2,09
0,7329	0,6	0,6309	3,09
0,7602	0,8	0,7745	2,55
0,8072	1,0	1,0049	0,49
0,9227	1,2	1,2014	0,14
1,0000	1,4	1,3991	0,09

Como podemos notar, a rede apresentou um bom resultado na quantificação da profundidade das falhas, mesmo não sendo treinada para as profundidades de 0,4 e 0,8 mm. O maior erro apresentado na verificação da rede,  $3,09 \times 10^{-2}$ , não prejudica em muito a estimativa da profundidade da falha. Neste sentido, obtivemos êxito na quantificação da severidade da falha através das redes neurais.

Cabe observar que a faixa de frequência adotada exibe apenas um pico de ressonância. Os resultados poderiam ser melhorados se fosse adotada uma faixa de frequência com maior quantidade de picos. A técnica da impedância elétrica, como proposto neste trabalho, pressupõe análise independente para cada região de influência do PZT. Portanto, cada sinal, originário dos PZT's, pode ser adquirido em uma faixa diferente de frequências.

### 5.3 Barra de Aço

Nos exemplos anteriores, nós apresentamos a localização e a quantificação de falhas em alguns tipos de estruturas. A utilização da técnica da impedância elétrica empregada na localização da falha apresentou bons resultados e o emprego das redes neurais artificiais aliada à técnica da impedância elétrica possibilitou quantificar a severidade da falha.

Contudo, em ambos os casos a medida da impedância elétrica foi obtida por meio do medidor de impedância HP Analyzer 4192A. Este equipamento, embora tenha apresentado bons resultados, é um aparelho que tem um custo alto e algumas outras funções, podendo portanto,

inviabilizar esta técnica de detecção de falhas estruturais. Além do mais, é um equipamento pesado e muito sensível, o que dificulta seu emprego durante medidas realizadas nos locais de trabalho. Esses locais, normalmente, são lugares de difícil acesso e que nem sempre oferecem boas condições de limpeza. Neste sentido, o emprego de um aparelho de menor porte, menos sensível a danos e com um custo menor, é algo de grande interesse. Dessa forma, o grupo GMSINT (Grupo de Materiais e Sistemas Inteligentes) confeccionou um aparelho com as características desejadas para um medidor de impedância elétrica que pudesse ser utilizado nas medidas em “campo”. Maiores detalhes sobre este aparelho podem ser encontrados no apêndice A.

Este exemplo visa a validação desse aparelho chamado de MIBC (Medidor de Impedância de Baixo Custo). Sendo assim, utilizamos uma barra de aço com um PZT colado em sua superfície. A espessura da barra é de 3 mm e as demais dimensões podem ser observadas na figura (5.12). O PZT colado tem formato quadrado com lados de 10 mm e espessura de 0,267 mm. As propriedades do PZT são as mesmas definidas na seção anterior.




Figura 5.12 – Viga de aço com PZT colado.

Para validarmos o MIBC como um aparelho confiável a ser utilizado na técnica da impedância elétrica inserimos duas falhas na barra de aço a 170 mm da extremidade, com profundidades de 2 e 4 mm na seção transversal e largura de 1,5mm. A figura (5.13) mostra os equipamentos utilizados para as medidas, onde além do MIBC, podemos ver o filtro analógico passa-banda da marca robotron modelo 01017, o amplificador de tensão elétrica da marca PCB modelo 494A e o microcomputador com o sistema de aquisição ACE.




Figura 5.13 – Sistema de aquisição de dados.

O objetivo desse estudo é observar se o MIBC é capaz de detectar a existência dessas falhas, e mais, avaliar se o sinal obtido é o mesmo obtido pelo HP analyser. Neste sentido, a figura (5.14) mostra as curvas da impedância elétrica obtidas através do MIBC e pelo HP 4192A. Essas medidas foram obtidas com a barra sem a falha, medida de referência. A faixa de frequência utilizada foi de 13kHz a 20 kHz; esta faixa foi determinada devido a limitações que encontramos no sistema de aquisição de dados empregado no MIBC (sistema ACE), que permite uma frequência máxima de excitação de 20kHz.




Figura 5.14 – Impedância elétrica obtida através do MIBC e do HP 4192A, para a situação sem falha.

Podemos observar certa diferença entre as curvas, entretanto, o comportamento das mesmas é semelhante. O fato das curvas não serem coincidentes, não acarreta problemas durante o monitoramento da estrutura por meio da técnica da impedância elétrica, visto que a técnica trabalha com a diferença entre as curvas, ou seja, utiliza a diferença entre as curvas de referência, sem falha, e o sinal da situação que se deseja analisar.

A figura (5.15) apresenta as curvas obtidas com o MIBC e com o HP 4192A para a situação com a segunda falha, 4 mm de profundidade. Como podemos observar mesmo não sendo coincidentes, as curvas apresentam o mesmo comportamento.

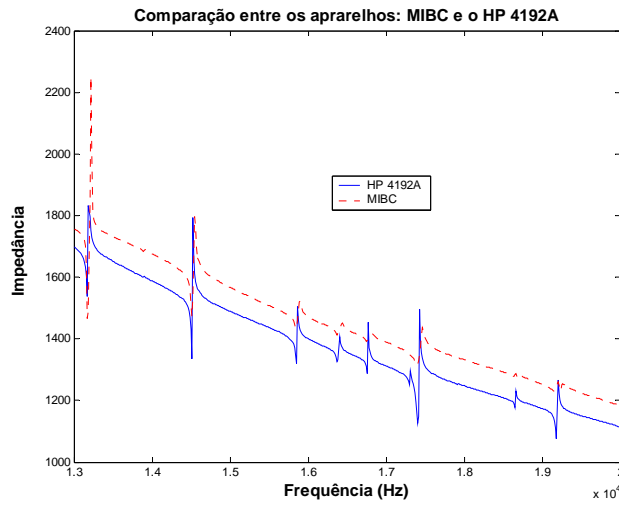


Figura 5.15 – Impedância elétrica obtida através do MIBC e do HP 4192A, para a situação com falha.

No sentido de estudar o comportamento das curvas diante da presença das falhas, a figura (5.16) mostra as curvas de referência e as curvas com falha a de 4 mm de profundidade obtidas com o MIBC, figura (5.16.a), e com o HP 4192A, figura (5.16.b). Notamos claramente que ambos os aparelhos foram capazes de detectar a variação.




Figura 5.16 – Impedância elétrica obtidas com o MIBC e com o HP 4192A.

Para avaliarmos a capacidade do MIBC em quantificar as falhas inseridas, os valores da falha métrica foram normalizados para as duas condições de falhas. A figura (5.17.a) apresenta a falha métrica obtida por meio da impedância elétrica medida através do MIBC e a figura (5.17.b) mostra a falha métrica obtida por meio da impedância elétrica medida através do HP 4192A.

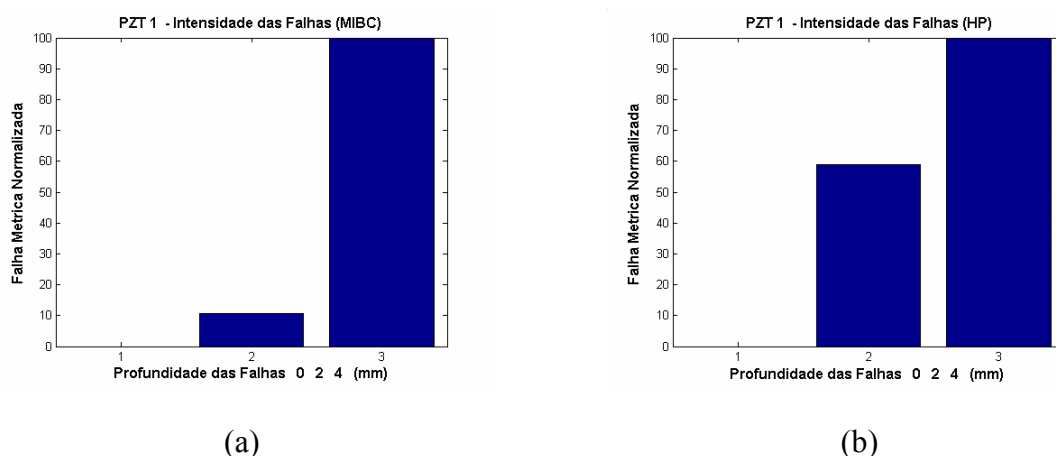


Figura 5.17 – Falha métrica calculada para as impedâncias elétricas obtidas com o MIBC (a), e com o HP analyzer (b).

Nos dois gráficos os valores que correspondem as barras 1, 2 e 3, representam as falhas métricas para o caso sem falha e com as falhas de 2 e 4 mm de profundidade, respectivamente. Notamos que os dois gráficos apresentam maiores valores para o caso da falha com 4 mm de profundidade. Embora os gráficos não sejam idênticos, ambos foram capazes de apresentar a diferença entre as duas intensidades de falha. Sendo assim, podemos concluir que o MIBC é um aparelho capaz de ser empregado na técnica da impedância elétrica como medidor de impedância. Outros testes foram realizados e as medidas foram similares. Cabe destacar que com o aumento do dano o comportamento dos padrões se aproximam de curvas exponenciais. Esta tendência foi melhor verificada com as medidas realizadas com o aparelho MIBC.

## CAPÍTULO 6

### CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

#### 6.1 Considerações Finais

Procuramos com este trabalho, apresentar uma técnica relativamente nova aplicada no monitoramento de falhas em estruturas. Já existem diversas técnicas de manutenção preditiva bem difundidas, cada uma com suas potencialidades e limitações. A técnica da impedância elétrica tem como ponto positivo a localização da região onde a falha está presente, entretanto, uma de suas limitações é a informação apenas qualitativa a respeito do dano. Uma das formas encontradas para obter informações quantitativas a respeito da falha utilizando a técnica da impedância elétrica foi o emprego das redes neurais artificiais. Simulações numéricas e ensaios experimentais foram utilizados para demonstrar a potencialidade da metodologia empregada.

As simulações numéricas tiveram como principal objetivo o estudo e a avaliação das redes neurais artificiais. Utilizamos exemplos de estruturas simples, como vigas, que foram simuladas através do método dos elementos finitos por meio do software ANSYS<sup>®</sup>. Utilizando a normalização apresentada na equação (4.7), organizamos os dados obtidos por meio das frequências naturais, padrões, que foram utilizados na fase de localização da falha. Observamos que o maior erro obtido foi em torno de  $5 \times 10^{-2}$  para a localização da falha para os casos onde as vigas estavam na condição engastada-livre. Notamos também que utilizando a normalização empregada, a localização da falha se tornou robusta para condições de falhas com severidades diferentes e para estruturas com materiais e dimensões distintas, respeitando-se somente o tipo de estrutura e a condição de contorno a qual ela está submetida. Isto pode ser confirmado quando

avaliamos os dados apresentados na tabela (4.15), que mostra os valores da localização das falhas para as vigas de alumínio e de aço, na condição livre-livre porém com a rede treinada apenas com os dados para o primeiro caso. O mesmo pode ser notado com a tabela (4.16), que apresenta os valores da localização das falhas para as vigas de alumínio e de aço, na condição engastada-livre porém com, a rede treinada apenas com os dados para o segundo caso.

A fase de quantificação também apresentou bons resultados, pois empregando a normalização apresentada pela equação (4.2) o maior erro obtido foi para a quantificação da falha para a viga de alumínio na condição livre-livre e foi de aproximadamente  $1,2 \times 10^{-2}$ . Este dado é um valor satisfatório, visto que, o banco de dados foi extraído das frequências naturais das respectivas estruturas em determinada condição de operação e como podemos notar nas tabelas (4.2) e (4.9), estes valores apresentam pequena variação entre uma condição e outra. De posse desses resultados, optamos por empregar as RNA's como ferramenta para quantificação da falha.

No capítulo 5 foi possível observar alguns exemplos experimentais onde se empregou técnica da impedância elétrica para localizar a região da falha e as RNA's para quantificar a severidade da falha. Este capítulo chama a atenção pelo resultado apresentado na seção 5.3 *Barra de Aço*, onde foram apresentadas medidas da impedância elétrica obtidas com dois equipamentos distintos. Um dos aparelhos que pode ser empregado para este tipo de medida, é o medidor de impedância da empresa HEWLETT PACKARD. No nosso caso utilizamos o HP Analyzer 4192A. No entanto, apresentamos um sistema alternativo que também pode ser empregado para medir a impedância elétrica. Este aparelho foi batizado de MIBC e analisando a figura (5.14) notamos que este sistema alternativo foi capaz de reproduzir de maneira satisfatória o sinal obtido pelo aparelho comercial da HP. Notamos também que é possível utilizá-lo em substituição ao aparelho comercial, uma vez que, na figura (5.17) podemos observar a variação da falha métrica que foi calculada a partir dos dados obtidos por meio do MIBC e do HP Analyser 4192A. Em ambos os casos foi possível distinguir as severidades das falhas. Maiores detalhes sobre o sistema alternativo de medida de impedância elétrica, podem ser obtidos através do apêndice A.

A seção 5.2 apresenta a localização e quantificação de falhas em uma estrutura do tipo virabrequim. Com quatro PZT's distribuídos ao longo da estrutura, figura (5.7.a), localizamos a região onde a falha foi inserida, figura (5.9), mesmo tratando-se de uma falha relativamente pequena, 0,3 mm de largura e 0,2 mm de profundidade. Em seguida realizamos a quantificação

de diferentes profundidades de falhas inseridas na estrutura. A tabela (5.2) apresenta os resultados obtidos por meio das RNA's. O erro máximo obtido foi de aproximadamente  $3,1 \times 10^{-2}$ , um valor satisfatório para a estimativa da severidade do dano.

Acredita-se que os objetivos almejados para esta dissertação foram alcançados. Discutiuse a potencialidade de duas técnicas, as redes neurais artificiais e a técnica da impedância elétrica, que não são baseadas em modelos matemáticos e que juntas formaram uma técnica híbrida para localização e quantificação de falhas estruturais. A maior vantagem desta metodologia é, sem dúvidas, a possibilidade de identificação de falhas simultâneas, pois as áreas de influência de cada PZT são analisadas independentemente. A análise de falhas simultâneas aparece em um número bastante reduzido de referências, na literatura básica desta área.

Espera-se também, que este trabalho sirva de base para pesquisadores e engenheiros que queiram adquirir um conhecimento aprofundado a respeito das duas técnicas e que possam compreender seu potencial por meio dos exemplos apresentados. Destaca-se o apêndice A que apresenta um sistema alternativo de medição da impedância elétrica, o que pode viabilizar o emprego desta metodologia nos locais onde o aparelho comercial não está disponível. Além disso, o algoritmo da RNA, aqui empregado, será disponibilizado para outros membros do grupo para ser aprimorado e utilizado em outras pesquisas.

## 6.2 Sugestões para Trabalhos Futuros

Este trabalho procurou apresentar noções básicas e exemplos onde esta técnica híbrida pudesse ser empregada. Como no início tivemos dificuldades em encontrarmos o aparelho comercial para realizarmos as medidas da impedância elétrica, fomos obrigados a procurar uma alternativa para obtenção da medida. Isto norteou o desenvolvimento de um sistema alternativo de medição da impedância elétrica, o que culminou no desenvolvimento do MIBC. Neste sentido, apresentamos apenas conceitos básicos de cada tópico de modo que pesquisas mais aprofundadas possam ser realizadas. A seguir apresentamos algumas sugestões para trabalhos futuros:

- Estudo da área de influência de cada PZT, avaliando assim as variáveis mais importantes na delimitação da área de influência. De posse de uma técnica de

otimização, estudar a distribuição de cada PZT de forma a monitorar a estrutura como um todo.

- Aplicação da técnica da impedância elétrica em outros materiais não-metálicos, como por exemplo materiais compósitos e polímeros.
- Aprimoramento da rede neural, utilização de uma técnica para estimar a quantidade de neurônios e/ou o valor da taxa de aprendizado. Sugerimos a lógica nebulosa como maneira de estimar esses parâmetros.
- Verificação da cadeia de medidas utilizada na medição da impedância elétrica por meio do aparelho de baixo custo MIBC. Obtenção de um sistema próprio para geração e aquisição de dados para medidas em altas faixas de frequência, o que viabilizaria a utilização desse sistema para qualquer estrutura.

## CAPÍTULO 7

### REFERÊNCIAS

AYRES, J.W. **Qualitative health monitoring and incipient damage inspection/ evaluation.** Blacksburg-VA, 1996. (Master Thesis) - Virginia Polytechnic Institute and State University – CIMSS.

ALLIK, H.; HUGHES, T. J. R. Finite element method for piezoelectric vibration. **International Journal for Numerical Methods in Engineering**, Sussex, v 2, p.151-157, 1970.

AYRES, J.W.; LALANDE, F.; CHAUDHRY, Z.; ROGERS, C.A. Qualitative health monitoring of a steel bridge structure via piezoelectric actuator/sensor patches. **Proceedings, SPIE Nondestructive Evaluation Techniques for Aging Infrastructure & Manufacturing**, Scottsdale, AZ, v. 2946, p. 211-218, 1996.

ANSYS® Theory Reference Release 7.0, 2002, SAS IP, Inc.

BRENNAN, M.J.; DAY, M.J.; ELLIOTT, S. J.; PINNINGTON R.J. Piezoelectric actuators and sensors. IUTAM SYMPOSIUM OF THE ACTIVE CONTROL OF VIBRATION, 1994, Bath. **Proceedings...** Bath: S.n., 1994. p. 1-7.

CLARK, R.L.; SAUNDERS, W.R.; GIBBS, G.P. **Adaptive structures: dynamics and control.** New York: John Wiley & Sons, 1998. 467p.

COELHO, L. S. **Identificação e controle de processos multivariáveis via metodologias avançadas e inteligência computacional.** Florianópolis-SC, 2000. Tese (Doutorado em Engenharia Elétrica) - Universidade Federal de Santa Catarina.

CRAWLEY, E. F.; DE LUIS, J. Use of piezoelectric actuators as elements of intelligent structures. **AIAA Journal**, New York, v.25, n.10, p.1373-1385, 1987.

DEMARCHI, D. **Técnicas não-destrutivas de monitoramento e detecção de falhas estruturais utilizando redes neurais**. Ilha Solteira, 2001. 117p. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Estadual Paulista.

DOEBLING, S. W.; FARRAR, C. R.; PRIME, M. B. A summary review of vibration-based damage identification methods . **The Shock and Vibration Digest**, Thousand Oaks, v.30, n.2, p.91-105, 1998.

DOSCH, J. J.; INMAN, D. J.; GARCIA, E. A self-sensing piezoelectric actuator for collocated control. **Journal of Intelligent Material Systems and Structures**, Lancaster, v.3, n.1, p.166-185, 1992.

EGAWA, K. A new Concept of Maintenance Inspection. In: INTERNATIONAL WORKSHOP ON STRUCTURAL HEALTH MONITORING. **Structural health monitoring: Currents Status and Perspectives: proceedings of the ...** Lancaster: Technomic Pub., 1997. p.603 – 614.

EWINS, D.J. **Modal testing: theory and practice**. New York: John Wiley & Sons, 1991. 269p.

FURTADO, R. M. **Localização de falhas estruturais usando sensores e atuadores piezoelétricos e redes neurais artificiais**. Ilha Solteira, 2001. Relatório de Iniciação Científica, FAPESP Processo 00/12387-7, Faculdade de Engenharia, Universidade Estadual Paulista.

FURTADO, R. M.; LOPES JR., V. Localização de falhas estruturais usando sensores e atuadores piezoelétricos e redes neurais artificiais In: CONGRESSO NACIONAL DE ENGENHARIA MECÂNICA- CONEM, 2002, 2, João Pessoa. **Anais...João Pessoa: Abcm, 2002. (CD-ROM)**

FURTADO, R. M.; TEBALDI, A.; LOPES JR., V. Fault identification in smart structures using genetic algorithms and artificial neural networks In: INTERNATIONAL MODAL ANALYSIS CONFERENCE – IMAC, 21, 2003. **Conference on Structural Dynamics**. Kissimmee: S.n., 2003. (CD-ROM).

GIURGIUTIU, V. Active sensors for health monitoring of aging aerospace structures *SPIE's INTERNATIONAL SYMPOSIUM ON SMART STRUCTURES AND MATERIALS*, 7, INTERNATIONAL SYMPOSIUM ON NONDESTRUCTIVE EVALUATION AND HEALTH MONITORING OF AGING INFRASTRUCTURE, 5, 2000, Newport Beach. **SPIERs...** Newport Beach : S.n., 2000. p.3985-32

HAYKIN, S. **Neural networks: a comprehensive foundation**. New York : Macmillan, 1994. 696p.

IDEHARA, S. J. **Aplicação de técnicas de Order Tracking para análise de máquinas e componentes rotativos**. Campinas, 2003. 132p. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Estadual de Campinas.

IEEE Standard on Piezoelectric (1978). **IEEE Transactions on Sonics and Ultrasonic**, New York, v. 31, n. 2, 1984.

IKEDA, T. **Fundamentals of piezoelectricity**. Oxford: Oxford University Press, 1996. 263p.

INMAN, D.J. Control/Structure interaction: effects of actuator dynamics. JUNKINS, J.L. (Ed.) **Mechanics and control of large flexible structures**. Washington, DC : American Institute of Aeronautics and Astronautics, c1990. p. 507-533. (Progress in astronauts and aeronautics, 129) pp.507 – 533, 1990.

INMAN, D. J. Control/Structure interaction: effect in PZT based control design. In: WORKSHOP ON SMART STRUCTURE, 3, 1997, Blacksburg. **Workshop...** Blacksburg: S.n., 1997.

INMAN, D.J. **Engineering vibration**. Englewood Cliffs: Prentice Hall, 1996. 560p.

INMAN, D. J. Smart structures: examples and new problems. CONGRESSO BRASILEIRO DE ENGENHARIA MECÂNICA – COBEM, 16, 2001, Uberlândia. **Anais...** Uberlândia: ABCM, 2001. p.26-30, 2001.

INMAN, D. J. Smart structures solutions to vibration problems. **Proceedings of ISMA**, Leuven, v.23, p.1-12, 1998.

KAMINSKI, P.C. **Um sistema de diagnóstico de falhas estruturais baseado em redes neurais artificiais e frequências naturais**. São Paulo, 1997. 139p. Tese (Livre Docência) – Escola Politécnica, Universidade de São Paulo.

LIMA JUNIOR., J. J.; ARRUDA, J. R. F. Viga ativa usando sensores piezelétricos incorporados. CONGRESSO BRASILEIRO DE ENGENHARIA MECÂNICA-COBEM, 15, Águas de Lindóia . **Anais...** Águas de Lindóia: ABCM, 1999.

LOPES, M. L. M. **Desenvolvimento de um sistema previsor de cargas elétricas via redes neurais**. Ilha Solteira, 2000. 82p. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista.

LOPES JUNIOR., V.; MÜLLER-SLANY, H.; BRUNZEL F.; INMAN, D.J. Damage detection in structures by electrical impedance and optimization technique. In: IUTAM SYMPOSIUM ON SMART STRUCTURES AND STRUCTRONIC SYSTEMS, 89, 2000, Magdeburg. **Proceedings...** Dordrecht: Kluwer Academic Publishers, 2001. p.239-246.

LOPES JÚNIOR, V.; TURRA, A.E.; MÜLLER-SLANY, H.; BRUNZEL F.; INMAN, D. J. A new methodology of damage detection by electrical impedance and optimization technique. In: INTERNATIONAL SYMPOSIUM ON DYNAMIC PROBLEMS OF MECHANICS-DINAME, 9, 2001,- Florianópolis. **Proceedings...** Rio de Janeiro: ABCM, 2001. p.311-316.

MCCULLOCH, W. S. E PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, New York, v. 5, p.115-119. 1943.

MINSKY, M. E.; PAPERT, S. **Perceptrons: an introduction to computational geometry**. Cambridge: MIT Press, 1969. 258p.

MOURA JUNIOR, J. R. V.; STEFFEN JUNIOR, V. Impedance-based health monitoring: frequency band evaluation In: INTERNATIONAL MODAL ANALYSIS CONFERENCE – IMAC, 22, 2004. **Conference on Structural Dynamics**. Dearborn: S.n., 2004. (CD-ROM).

NELSON, M. M.; ILLINGWORTH, W. T. **A practical guide to neural nets**. Reading, : Addison-Wesley, c1991. 344p.

OLIVEIRA, A. G. **Técnicas de caracterização de excitações em máquinas rotativas**, Uberlândia, 1999. Tese (Doutorado em Engenharia Mecânica) - Universidade Federal de Uberlândia.

PEAIRS, D. M. **Development of a self-sensing and self-healing bolted joint**. Blacksburg-VA, 2002. Master's thesis (Master's thesis) - Virginia Polytechnic, Institute and State University.

PEREIRA, C. B. **Técnicas de otimização discreto-continuas aplicadas ao controle de vibração de estruturas inteligentes**. Uberlândia, 2003. 95p. Dissertação (Mestrado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Federal de Uberlândia.

RAJU, V. **Implementing impedance-based health monitoring**, Blacksburg-VA, 1998. Master's thesis (Master's thesis) - Virginia Polytechnic Institute and State University.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Parallel distributed processing: explorations in the microstructure of cognition**. Cambridge: v. 1, The MIT Press, 1986.

SANTIAGO, D. F. A. **Diagnóstico de falhas em máquinas rotativas utilizando transformada de wavelet e redes neurais artificiais**. Campinas, 2004. 117p. Tese (Doutorado em Engenharia Mecânica) - Faculdade de Engenharia, Universidade Estadual de Campinas.

SILCOX, R.J.; LEFEBVRE, S.; METCALF, V.L.; FULLER, C.R. Evaluation of piezoceramic actuators for control of aircraft interior noise. PROCEEDING OF DGLR/AIAA, 14, 1992, **Proceedings...** Aachen: Aeroacoustic Conf., 1992.

STROKES, J. P.; CLOUD, G. L. The application of interferometric techniques to the nondestructive inspection of fiber-reinforced materials. **Experimental Mechanics**, St. Bethel, v. 33, p.314-319, 1993.

SUN, F. **Piezoelectric active sensor and electric impedance approach for structural dynamic measurement**. Blacksburg-VA, 1996. Master Thesis (Master Thesis) - CIMSS, Virginia Polytechnic Institute and State University.

WIDROW, B.; LEHR, M.A. 30 Years of adaptive neural networks: perceptron, madaline, and backpropagation, **Proceedings of the IEEE**, New York, v.78, n.9, p.1415-1442, 1990.

## *APÊNDICE – A*

### **MEDIDAS DE IMPEDÂNCIA ELÉTRICA COM APARELHO DE BAIXO CUSTO**

Medidas de impedância elétrica, que é um dos passos utilizados neste trabalho e em muitos outros que envolvem técnicas de monitoramento via PZT, utilizam altas faixas de frequências, geralmente de 10kHz até 100kHz. As medidas de impedância elétrica para estes valores de frequência é realizada através de um medidor de impedância, como o HP 4194A. Infelizmente, este equipamento é caro, com valor estimado em torno de US\$ 30.000,00. Outra desvantagem desde aparelho é seu tamanho e peso relativamente grandes, que dificultam as sessões de medidas para o monitoramento dos equipamentos, pois estas são periódicas e devem ser realizadas de maneira ágil e com um pequeno número de pessoas. A técnica de monitoramento de falha através da impedância elétrica utiliza apenas uma pequena parcela das funções que este aparelho dispõe e sua relativa complexidade de peças e sensibilidade das mesmas não possibilita a utilização desde equipamento em qualquer local.

Desta maneira, o desenvolvimento de um equipamento com baixo preço, portátil e de fácil manuseio seria algo atraente e que auxiliaria, e às vezes até possibilitaria, a utilização desta técnica. Nesta ótica, esta seção apresenta um aparelho com estas características que foi desenvolvido durante este trabalho com a ajuda do grupo (GMSINT) e um aluno do curso de Engenharia Elétrica desta unidade. O modelo deste aparelho foi inspirado em trabalho semelhante desenvolvido na Virginia Polytechnic Institute and State University, Daniel M. Peairs (Peairs 2002).

## A.1 Medida de Impedância Convencional

Normalmente o método de realizar a medida da impedância elétrica através do HP 4194A é medindo o ganho e a fase, que são medidos simultaneamente. A combinação destes parâmetros representa ambas as características de resistência e reação da impedância elétrica 15 tipos de parâmetros podem ser avaliados. Entretanto, apenas a função  $R-X$  é geralmente utilizada no monitoramento. A letra  $R$  representa o componente real da impedância em ohms e  $X$  o componente imaginário em ohms. Em um circuito em série equivalente esta impedância é igual a  $Z=R+jX$ , sendo:

$$j = \text{operador imaginário} = \sqrt{-1}$$

A impedância  $Z$  pode ser expressa por representação polar (magnitude e ângulo), equação (A.1) :

$$Z = |Z| \angle \theta \quad (\text{A.1})$$

sendo:

$|Z|$  = magnitude ou módulo da impedância  $Z$ .

$\theta$  = ângulo de fase.

O módulo da impedância,  $Z$ , e o ângulo de fase,  $\theta$ , podem ser calculados pelas equações (A.2) e (A.3).

$$Z = \sqrt{R^2 + X^2} \quad (\text{A.2})$$

$$\theta = \tan^{-1} \left( \frac{X}{R} \right) \quad (\text{A.3})$$

Em vez de se utilizar a magnitude ( $Z$ ) e fase ( $\theta$ ), o componente  $R$  é geralmente empregado no monitoramento estrutural. Isto se deve ao fato do componente  $R$  ser mais sensível à falha ou mudanças na integridade estrutural, enquanto  $X$  é mais sensível a mudanças devido a temperatura (Raju 1998).

Outros dispositivos já foram sugeridos para serem utilizados na medida da impedância elétrica para monitoramento de falhas, mas não são comumente empregados. Raju sugere o uso de um computador portátil conectado ao equipamento HP 4192A via PCMCIA-GPIB com um

barramento remoto de controle de análise e simula a função *sweep* com o Visual Basic através de um software desenvolvido por ele próprio. Infelizmente, isto ainda requer a compra de equipamentos caros, que não são comuns na maioria dos laboratórios de engenharia.

Uma alternativa, semelhante à sugerida por Raju, foi adotada neste trabalho. Em uma das fases, os sinais de impedância elétrica foram obtidos pelo HP Analyzer, HP 4192A gerenciado por um software desenvolvido em linguagem C. Nele é possível ajustar parâmetros como: tipo de medida, frequência inicial, frequência final, tamanho do intervalo de medida, número de médias de medida, e outros. A figura (A.1) mostra o equipamento utilizado.




Figura A.1 – Equipamento HP 4192A acoplado a um microcomputador.

## A.2 Circuito Alternativo para a Medição da Impedância Elétrica

Como alternativa aos métodos de medição de impedância apresentados, sugerimos um novo método utilizando um pequeno circuito que possibilita a obtenção da impedância elétrica do PZT. O procedimento desenvolvido utiliza um software comercial de análise modal, o ACE<sup>®</sup>, que é encarregado de gerar o sinal de excitação no PZT e de medir sua resposta. A utilização do software acima é baseada apenas na disponibilidade do laboratório; qualquer outro sistema de aquisição de sinal e software poderiam ser usados. Portanto, havendo disponibilidade destes esta técnica pode ser aplicada sem o desprendimento de grande quantia de dinheiro, uma vez, que o aparelho desenvolvido teve em custo de R\$ 200,00 (aproximadamente U\$ 70,00).

A impedância elétrica de um PZT vinculado a estrutura é igual à tensão elétrica aplicada no PZT dividido pela corrente que atravessa o mesmo. Uma aproximação para a impedância elétrica gerada é a razão entre a tensão elétrica aplicada pelo programa ACE<sup>®</sup> no circuito,  $V_i$ , e a corrente que atravessa o PZT. Considerando uma resistência  $R_s$  em série com o PZT, podemos medir a tensão elétrica de saída  $V_o$ , como mostra a figura (A.2).




Figura A.2 – Circuito para medida aproximada da impedância no PZT.

A tensão elétrica de saída é proporcional à corrente que atravessa o resistor. Temos que a corrente que atravessa o PZT é a mesma que passa pelo resistor, utilizando a lei de Kirchoff podemos encontrar a corrente que atravessa o PZT. O circuito é descrito pelas equações abaixo.

$$V_i - Z(\text{PZT}) * I - R_s * I = 0 \quad (\text{A.4})$$

$$V_o = R_s * I \Rightarrow I = \frac{V_o}{R_s} \quad (\text{A.5})$$

Sendo  $I$  a corrente que atravessa o resistor e o PZT. Podemos encontrar a impedância elétrica  $Z$  do PZT utilizando as equações (A.4) e (A.5). Assim:

$$Z = \frac{V_i - V_o}{I} = \left( \frac{V_i - V_o}{V_o} \right) * R_s = \frac{V_i}{V_o} * R_s - R_s \quad (\text{A.6})$$

Utilizando uma resistência  $R_s$  com pequeno valor, podemos estimar o valor da impedância elétrica  $Z$  do PZT, como:

$$Z \cong \frac{V_i * R_s}{V_o} \quad (\text{A.7})$$

Como os PZT's são elementos com propriedades capacitivas, a corrente que o atravessa muda em função da frequência. Assim, um aumento de frequência causa um aumento da corrente, diminuindo a impedância. Contrariamente, para valores baixos de frequência têm-se altos valores de impedância, equação (A.8).

$$|Z_{\text{capacitivo}}| = \left| \frac{1}{\omega * c} \right| \quad (\text{A.8})$$

Sendo:

$\omega$  = frequência de excitação

$c$  = constante capacitiva

Neste caso, um amplificador inverso para o circuito pode provocar uma larga faixa de saída. O circuito para medição aproximada de impedância com amplificador é apresentado na figura (A.3).

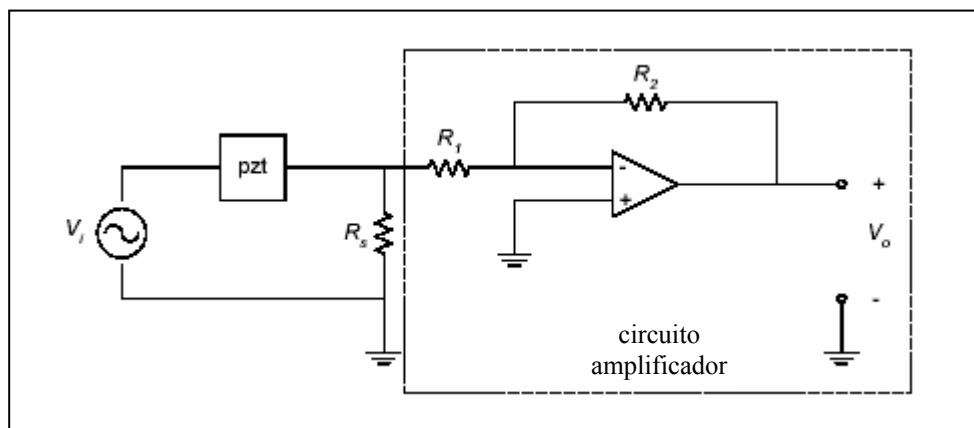


Figura A.3 – Circuito para medição da impedância elétrica com amplificador.

Utilizando este amplificador, a tensão elétrica de saída,  $V_o$ , é dada pela equação (A.9); sendo  $G$  o ganho do circuito amplificador. Como o amplificador apresentado é do tipo inversor, seu ganho é negativo.

$$V_o = G * V_i$$

$$G = -\frac{R_2}{R_1} \quad (\text{A.9})$$

O circuito e os componentes empregados na construção do MIBC podem ser observados pela figura (A.4). A letra R representa resistência e a letra C representa constante capacitiva. Todas as unidades estão no sistema internacional de medidas, SI.

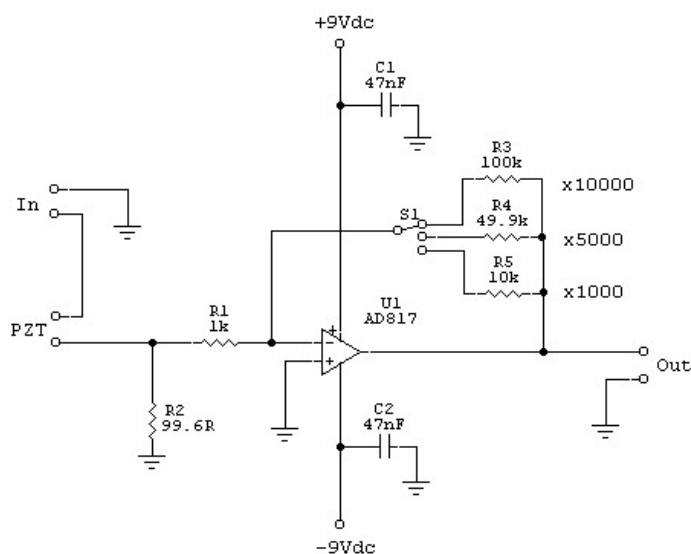


Figura A.4 – Circuito do MIBC.

A figura (A.5) mostra o aparelho confeccionado, tendo como base o circuito descrito. Este aparelho foi batizado pelo grupo de MIBC (Medidor de Impedância de Baixo Custo). Além de ser de fácil manuseio e prático, o aparelho possui uma chave seletora onde é possível escolher o ganho na saída. Pode-se selecionar o fator 1000, 5000 e 10.000. O aparelho ainda possui as entradas para os terminais do PZT, o terminal de entrada (excitação) e o de saída (medição), além de uma chave para ligar e desligar o aparelho, pois o mesmo é alimentado por duas baterias comuns de 9 volts cada uma.




Figura A.5 – Medidor de Impedância de Baixo Custo.

### A.3 Cadeia de Medição

No capítulo de resultados experimentais podemos encontrar uma aplicação do MIBC para localizar falhas estruturais. Porém, como já mencionado, o MIBC é apenas um circuito que possibilita a medição da impedância elétrica, sendo necessário outros equipamentos para realizar a medida. Para realizarmos as medidas de impedância elétrica através do MIBC necessitamos, basicamente, de um microcomputador, responsável pelo gerenciamento da medida, um sistema de geração de sinal, uma vez que devemos excitar a estrutura, e um sistema de aquisição de sinal, além de filtros, condicionadores e amplificadores. A figura (A.6) mostra os equipamentos de uma cadeia de medição.




Figura A.6 – Esquema da cadeia de medição.

A cadeia de medição sugerida acima, foi utilizada na obtenção da impedância elétrica através do MIBC apresentado no exemplo do capítulo 5. Utilizamos um microcomputador, um sistema de geração e aquisição de sinal, que ficou ao encargo do software ACE<sup>®</sup>, um filtro passa banda da marca robotron modelo 01017 e um amplificador de tensão elétrica da marca PCB modelo 494A. Todos esses equipamentos são normalmente encontrados em um laboratório de análise de vibrações. A figura (A.7) apresenta a cadeia de medição utilizada.




Figura A.7 – Cadeia de medição utilizada.

Com o desenvolvimento deste aparelho é possível consolidar a utilização do método da impedância elétrica para o monitoramento de falhas em estruturas, sem o desprendimento de grande quantia de dinheiro. Isto é de suma importância pelo fato de um medidor comercial, como por exemplo o HP 4194A, ser relativamente caro. Além da vantagem de ser mais acessível devido a questão financeira como já mencionado, a questão da praticidade também tem seu ponto interessante, uma vez que, em situações práticas, os locais onde são realizadas as medidas são de difícil acesso, dificultando a utilização do aparelho comercial que é espaçoso e sensível. A utilização do MIBC facilita, portanto, em muito o procedimento de manutenção proposto, tornando a metodologia sugerida uma proposta atraente.