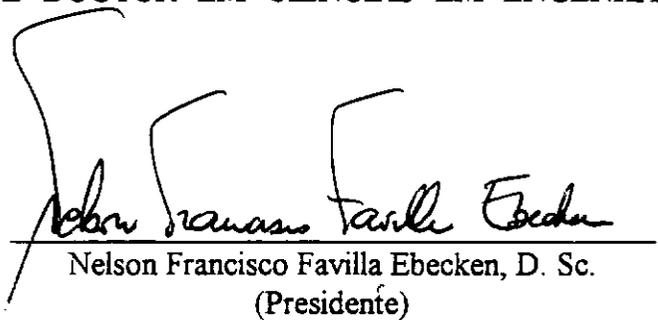


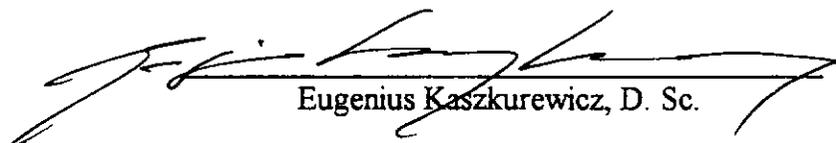
AVALIAÇÃO DO DANO DE FADIGA EM PLATAFORMAS DE PETRÓLEO EM TEMPO REAL

Tiago Alberto Piedras Lopes

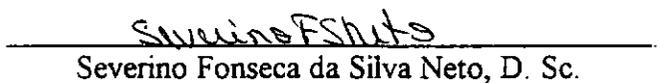
TESE SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS EM ENGENHARIA CIVIL.

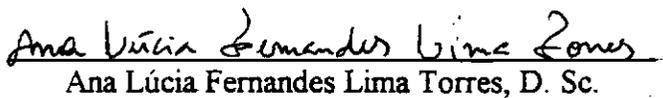
Aprovada por:

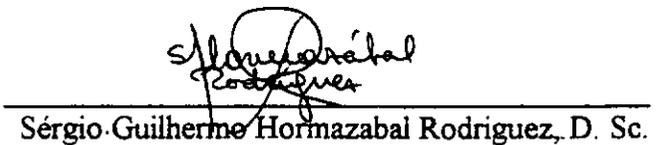

Nelson Francisco Favilla Ebecken, D. Sc.
(Presidente)


Eugenius Kaszkurewicz, D. Sc.


Ney Roitman, D. Sc.


Severino Fonseca da Silva Neto, D. Sc.


Ana Lúcia Fernandes Lima Torres, D. Sc.


Sérgio Guilherme Hormazabal Rodriguez, D. Sc.

RIO DE JANEIRO, RJ - BRASIL

JUNHO de 1995

LOPES, TIAGO ALBERTO PIEDRAS

Avaliação do Dano de Fadiga em Plataformas de Petróleo em Tempo Real
[Rio de Janeiro] 1995.

X, 158 p. 29,7 cm (COPPE/UFRJ, D.Sc., Engenharia Civil, 1995)

Tese - Universidade Federal do Rio de Janeiro, COPPE

1. Fadiga 2. Plataformas 3. Redes Neurais

I. COPPE/UFRJ II. Título (série)

*Far better an approximate answer to the right question,
which is often vague,
than an exact answer to the wrong question,
which can always be made precise.*

John W. Tuckey, 1962.

Dedico esta tese aos meus pais e aos meus filhos, pelo
muito que aprendi e tenho aprendido com eles.

AGRADECIMENTOS

À Lúcia, amada e companheira no infinito de nós dois.

À memória de Inco, um *cocker spaniel* muito especial.

Ao professor Lobo Carneiro, grande mestre, pela sabedoria inerente aos grandes homens e pela capacidade de motivação, sempre presentes ao longo de muitos anos de convivência.

Ao professor Nelson Ebecken, sempre um exemplo de dinamismo e competência, pela sugestão do tema e impecável orientação.

Ao amigo e professor Severino, exemplo maior de excelência profissional e humana, com quem tenho compartilhado, desde 1979, todos os momentos importantes na COPPE.

Ao amigo Troyman, que sempre tratou a computação com grande intimidade, tornando possível colocar em prática as nossas idéias, ao longo desses 18 anos de convivência.

Aos amigos Frederico, Vileti e Sarasa, companheiros de muitos anos, que muito têm contribuído para a excelência do nosso Laboratório de Estruturas Navais, e ao amigo José Lopes, que durante um grande período, participou com entusiasmo das atividades do Laboratório.

Ao professor Selasco, que me incentivou a ser professor e a permanecer na Universidade.

Ao professor Ripper, pela orientação que me foi concedida, por ocasião da criação do Laboratório, em 1975.

Ao professor Caloba, pela iniciação neste incrível universo das redes neurais.

À Beth, da secretaria do Programa de Engenharia Civil, pelo apoio administrativo.

A todos que, fazendo parte do Laboratório, da COPPE e da UFRJ, alunos, docentes e técnico-administrativos, em algum momento e de alguma forma, contribuíram para o meu crescimento profissional e humano.

À COPPETEC, setor indispensável para a transformação das idéias em fatos concretos.

À COPPE, em particular à atual diretoria, pelo estímulo transmitido em todos os momentos.

Ao engenheiro Mourão, da PETROBRAS, pelo grande apoio para a implementação de linhas de pesquisa experimentais em estruturas offshore.

Ao CENPES/PETROBRAS e diversos setores desta excepcional empresa, à Indústria de Construção Naval e a Marinha do Brasil, que ao longo destes últimos vinte anos, sempre valorizaram as atividades do Laboratório de Estruturas Navais.

Ao Laboratório de Estruturas da Ishikajima-Harima, Japão, em particular ao sensei Mano, por ter auxiliado a concretizar a decisão mais importante da minha carreira profissional.

Ao FINEC/Banco do Brasil, à CAPES e ao CNPq, pelo apoio constante que sempre me concederam.

A esta FORÇA SUPERIOR, por muitos denominada DEUS, que está presente em tudo o que acontece.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

AVALIAÇÃO DO DANO DE FADIGA DE PLATAFORMAS DE PETRÓLEO EM TEMPO REAL

Tiago Alberto Piedras Lopes

Junho de 1995

Orientador : Nelson Francisco Favilla Ebecken
Programa : Engenharia Civil

O objetivo desta tese é avaliar, através de um modelo numérico simplificado, a proposta de um sistema para a monitoração de fadiga em tempo real para plataformas fixas de produção de petróleo. Este sistema tem como finalidade realizar o cálculo do dano de fadiga acumulado em juntas selecionadas, através dos esforços que estão realmente atuando na estrutura: ele irá operar na plataforma. A partir das informações do deslocamento do convés inferior da plataforma e de um procedimento de cálculo baseado em redes neurais, a estimativa de dano de fadiga é realizada imediatamente após a aquisição dos sinais. Esta informação, em conjunto com informações provenientes da inspeção, irá possibilitar uma definição mais precisa da prioridade da inspeção e do reparo.

As metodologias referentes à análise dinâmica aleatória, à aquisição de dados experimentais, à fadiga de estruturas metálicas e às redes neurais tipo *feedforward* com treinamento pela técnica de *backpropagation* são apresentadas de forma resumida, acompanhadas de exemplos baseados na experiência do autor e na literatura disponível.

O modelo simplificado considera, da melhor forma possível, as condições dinâmicas da estrutura de uma plataforma fixa de produção de petróleo instalada na Bacia de Campos, RJ, possibilitando que as conclusões alcançadas neste trabalho possuam uma estreita ligação com a situação real.

Abstract of Thesis presented to COPPE/UFRJ as partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

REAL TIME FATIGUE ANALYSIS OF FIXED OFFSHORE STRUCTURES

Tiago Alberto Piedras Lopes

June, 1995

Chairman : Nelson Francisco Favilla Ebecken
Program : Civil Engineering

This thesis aims at evaluating, for a simplified structural numerical model, a new methodology for fatigue monitoring of fixed offshore structures. The accumulated fatigue damage on selected joints, caused by actual loading condition, will be assessed through a data acquisition and processing system installed onboard. Based on measurements of upward jacket displacements and neural networks, the calculation of fatigue damage is performed in real time. This information, along with inspection reports, could be used to improve further inspection and repair of the platform jacket.

The main aspects of random dynamic analysis, data acquisition, fatigue of offshore structures and feedforward backpropagation neural networks are presented, with some selected examples from author experience and available literature.

The simplified model takes into account, as much as possible, the dynamical structural conditions of a platform installed on Campos Basin, RJ, Brasil, in order to match the thesis's conclusions to the actual behaviour of offshore structures.

Índice

	Pág.
I. INTRODUÇÃO	1
II. ANÁLISE DINÂMICA ALEATÓRIA DE ESTRUTURAS OFFSHORE	6
II.1. Introdução	6
II.2. Densidade Espectral	6
II.3. Excitação do Meio Ambiente	8
II.4. Influência das Fundações	11
II.5. Resposta às Excitações Aleatórias	13
II.5.1. <u>Análise de Sistemas com 1 Grau de Liberdade</u>	13
II.5.2. <u>Análise de Sistemas com Vários Graus de Liberdade</u>	16
II.6. Concentração de Tensões e Tensões de <i>Hot Spot</i>	19
II.7. O Programa ANSYS	21
III. DADOS EXPERIMENTAIS	24
III.1. Introdução	24
III.2. Aquisição de Dados Experimentais	26
III.3. Identificação de Parâmetros	29
III.3.1. <u>Introdução</u>	29
III.3.2. <u>O Método da Máxima Entropia</u>	30
III.3.3. <u>Estimador da Frequência Natural pelo MEM</u>	32
III.3.4. <u>Estimador do Coeficiente de Amortecimento pelo MEM</u>	33
III.3.5. <u>Aplicação a um Caso Real</u>	34
III.3.6. <u>Estimativa dos Deslocamentos Relativos</u>	38
III.4. Atualização do Modelo Dinâmico	39
III.4.1. <u>Introdução</u>	39
III.4.2. <u>Correlação Teórico-Experimental</u>	41
III.4.3. <u>Técnicas para Atualização do Modelo Dinâmico</u>	42
IV. FADIGA EM ESTRUTURAS OFFSHORE	46
IV.1. Introdução	46
IV.2. Conceito de Fadiga	47

IV.3. Modelo Estocástico de Falha por Fadiga	49
IV.3.1. <u>Distribuição das Amplitudes de Tensão</u>	49
IV.3.2. <u>Estimativa do Dano de Fadiga pela Regra de Miner</u>	52
IV.3.3. <u>Estimativa do Dano de Fadiga pela Regra de Paris</u>	56
IV.3.4. <u>Equivalência entre Mecânica da Fratura e Curva S-N</u>	59
IV.3.5. <u>Variabilidade dos Parâmetros</u>	60
V. REDES NEURAIS	61
V.1. Introdução	61
V.2. Breve Histórico	61
V.3. Conceito de Rede Neural	63
V.4. Conceito de <i>Backpropagation</i>	66
V.5. Treinamento	68
V.5.1. <u>Minimização da Função Erro</u>	69
V.5.2. <u>Atualização dos Pesos</u>	71
V.5.3. <u>Métodos para Aceleração do Treinamento</u>	72
V.5.4. <u>Reforço de Treinamento</u>	73
V.5.5. <u>Sugestões Práticas para o Treinamento</u>	73
V.6. Conceito de <i>Recurrent Backpropagation</i>	78
V.7. O Programa <i>Neuroshell 2</i>	80
VI. AVALIAÇÃO DE FADIGA EM TEMPO REAL	83
VI.1. Introdução	83
VI.2. Modelo da Plataforma	85
VI.3. Frequências e Modos Naturais de Vibração	87
VI.4. Excitação do Mar	87
VI.5. Resposta em Deslocamento	89
VI.6. Resposta em Tensão	91
VI.7. Dano de Fadiga	92
VI.8. Redes Neurais na Simulação do Dano de Fadiga	96
VI.8.1. <u>Introdução</u>	96
VI.8.2. <u>Avaliação Preliminar do Desempenho das Redes Neurais de Fadiga</u>	98
VI.8.3. <u>Avaliação Definitiva do Desempenho das Redes Neurais de Fadiga</u>	102
VI.9. Redes Neurais na Atualização do Modelo Dinâmico	132

VI.10. Dano de Fadiga em Tempo Real	135
VII. CONCLUSÕES E SUGESTÕES	141
APÊNDICE A - Teoremas	145
BIBLIOGRAFIA	147
LISTA DE SÍMBOLOS	156

Capítulo I

INTRODUÇÃO

A ruptura de um membro estrutural submetido a esforços variáveis e repetidos, num nível de tensão inferior à tensão máxima admissível do material, é denominada **colapso por fadiga**. Este fenômeno ocorre, principalmente, em estruturas metálicas soldadas, submetidas a carregamento variável, assumindo significativa importância nas estruturas offshore, pois as plataformas apresentam um aumento nos períodos naturais com o acréscimo da lâmina d'água, ficando mais sensíveis aos efeitos dinâmicos provocados por ações ambientais.

A fadiga do material é decorrente do dano cumulativo produzido pela ação repetitiva de cargas cíclicas, variáveis no tempo, que são resultantes da ação de máquinas em operação ou de efeitos ambientais. Esta variação do carregamento produz flutuações cíclicas de tensões nos membros da estrutura, induzindo à propagação de **trincas** e, provavelmente, ao conseqüente colapso, que ocorre mesmo que as tensões não tenham atingido a tensão máxima admissível do material.

No caso de juntas tubulares, há uma probabilidade maior de ocorrência deste fenômeno devido, principalmente, aos seguintes aspectos [Vughts,1976]:

⇒ as juntas soldadas são as mais sensíveis ao aparecimento e desenvolvimento de trincas, pois os próprios processos de fabricação podem ocasionar defeitos de soldagem que atuam como início das trincas;

⇒ a geometria da junta influencia na concentração das tensões na região onde a trinca está iniciando. Estas regiões são denominadas *hot spot*. Verifica-se que o colapso por fadiga ocorre, com maior frequência, na interseção entre *brace* e *chord*, que são os elementos tubulares que compõem a jaqueta de uma plataforma fixa de produção de petróleo. Na figura I.1 [UEG/CIRIA,1985], que corresponde a um ensaio de resistência à fadiga de uma junta típica, a falha ocorrida na raiz do cordão de solda está perfeitamente identificada.

⇒ as plataformas offshore estão submetidas a carregamentos variáveis no tempo, de ação repetitiva, causados principalmente por fenômenos ambientais (ventos, correntes, ondas), que produzem flutuações cíclicas de tensões em seus membros, ocasionando a propagação das trincas.

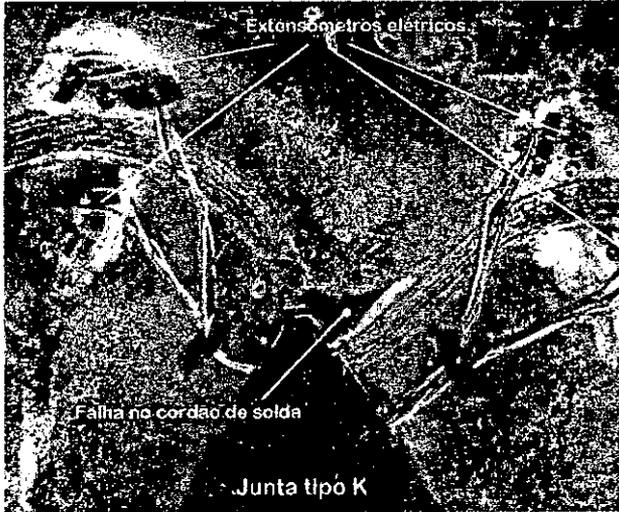


Figura I.1 - Colapso por fadiga de uma junta soldada

Em estruturas offshore constituídas de membros tubulares soldados, o efeito da fadiga deve ser devidamente considerado no dimensionamento, o que não é muito simples de ser realizado, pois o cálculo do dano é muito complexo, dependendo de uma série de fatores, dentre os quais podemos destacar [Department of Energy, 1982]:

- 1) a correta determinação do carregamento atuante na estrutura sendo, no caso da ação do meio ambiente, necessário realizar uma análise aleatória;
- 2) o modelo estrutural, que deve representar convenientemente os detalhes estruturais, o que implica no aumento do número de graus de liberdade para uma representação adequada por elementos finitos;
- 3) o método de análise, que deve ser bastante preciso na determinação dos esforços e tensões nas regiões críticas da estrutura;
- 4) a história completa da flutuação de tensões durante toda a sua vida útil;
- 5) a qualidade do processo de soldagem;

As técnicas atuais de análise estrutural, apesar de toda as ferramentas numéricas e computacionais disponíveis, ainda não são plenamente satisfatórias no que diz respeito ao cálculo da fadiga, devido à complexidade do fenômeno em si [Akyurek, 1992], [Yao,1986].

As **incertezas** existentes na previsão do dano de fadiga tornam os procedimentos de **inspeção** de estruturas em operação extremamente importantes para a garantia da sua integridade estrutural. No caso particular de jaquetas de plataformas fixas de produção de petróleo, o processo de inspeção implica na utilização de equipes de mergulho ou de equipamentos operados remotamente, que são utilizados para verificar a existência de trincas e, caso localizadas, as suas características geométricas [Jiao,1992]. O plano de inspeção, que define os locais da estrutura a serem inspecionados, é atualmente baseado em critérios de confiabilidade e considera, sob o aspecto de atualização, as informações originadas na própria inspeção [Madsen,1987]. Em virtude da complexidade deste tipo de estrutura, conforme pode ser verificado na figura I.2 (uma plataforma semisubmersível também está sendo apresentada para efeito de comparação), o tempo e o custo envolvidos nos procedimentos de inspeção são elevados.

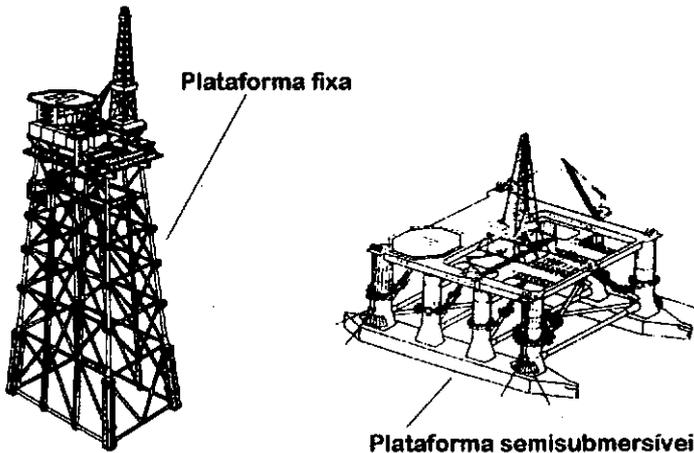


Figura I.2 - Plataformas usadas na produção de petróleo no mar.

Sob um ponto de vista analítico, a **confiabilidade** de uma estrutura, ou de um componente a ela pertencente, pode ser considerada como a probabilidade de ser ultrapassado um determinado nível de segurança [Benjamin,1991], [Subia,1991], [Beyko,1992]. Em um sistema desenvolvido para acessar o dano estrutural em tempo real, é essencial a determinação do tipo e quantidade de defeitos iniciais, pois esta informação irá permitir a avaliação adequada da vida remanescente da estrutura [Virkler,1979].

Geralmente, considera-se que a avaliação da estrutura em operação pode ser realizada continuamente (através de simulações em computador) enquanto que testes e inspeções são feitos periodicamente. A partir desta concepção, uma estratégia para reparo e inspeção de estruturas foi desenvolvida, baseada na hipótese de que o custo total da

inspeção e do reparo podem ser minimizados com a restrição dos níveis aceitáveis de confiabilidade do sistema e seus componentes [Thoft-Christensen,1986], [Rodriguez,1991], [Fujimoto,1992]. Esta estratégia pode ser utilizada em qualquer tipo de sistema onde a inspeção e o reparo sejam necessários.

A utilização de técnicas de Inteligência Artificial tem permitido um tratamento mais abrangente para esta classe de problema. Sob o aspecto da forma de tratar o conhecimento, estas técnicas podem ser divididas em Sistemas Especialistas, Sistemas *Fuzzy* e **Redes Neurais**. Os Sistemas Especialistas armazenam informação e tomam decisões a partir de regras lógicas, usando uma descrição simbólica estruturada do conhecimento. Os Sistemas *Fuzzy* possuem a mesma capacidade, mas operam com uma descrição numérica estruturada do conhecimento. As redes neurais permitem a obtenção de uma descrição numérica do conhecimento por meio da avaliação de conjuntos de dados de entrada e saída. Conforme exemplificado em [Kosko,1992], uma rede neural não assimila diretamente a regra “se o tráfego está intenso em uma direção, mantenha o sinal verde aceso por mais tempo naquela direção”. A rede neural deverá ser apresentada a uma série de exemplos, formados por combinações numéricas referentes a intensidade de tráfego e duração do sinal verde, para decidir.

A teoria e a aplicação prática de redes neurais têm apresentado um grande desenvolvimento nos últimos quinze anos. Em particular, na área de Identificação de Falhas, a utilização de redes neurais tem mostrado resultados promissores, em conjunto com a maior compreensão dos processos dinâmicos não lineares [Pouliezos,1994]. Em diversas áreas do conhecimento tem sido reportados aplicações específicas de redes neurais, tais como monitoração de falhas em motores de indução [Chow,1991], diagnose de falhas em equipamentos [Ray,1991], monitoração de centrais nucleares [Kim,1992] e Diagnóstico de falha em servo-válvula [Yamashima, 1990]. No caso particular de estruturas offshore, pode ser destacado o trabalho descrito em [Wu,1992], no qual é proposto um sistema, baseado em redes neurais, capaz de identificar danos em jaquetas de plataformas offshore.

Uma alternativa que pode ser viabilizada com a utilização de redes neurais é a otimização dos procedimentos de inspeção, que seria feita através do estabelecimento da prioridade das regiões da plataforma não só pelos métodos atuais, mas também pela identificação das juntas mais críticas de uma jaqueta por um sistema de monitoração de fadiga instalado a bordo da plataforma.

No capítulo II é feita uma revisão dos conceitos normalmente utilizados na Análise Estrutural Dinâmica Aleatória. São apresentados, de forma resumida, os conceitos de densidade espectral, de carregamento das ondas, de análise aleatória para sistemas com 1

e vários graus de liberdade e algumas características do programa *ANSYSv5.0*, baseado no método dos elementos finitos, que foi usado para gerar os exemplos desta tese.

No capítulo III são apresentadas as técnicas usadas na aquisição e processamento de dados experimentais e na identificação de parâmetros dinâmicos de plataformas fixas sob a ação das ondas do mar. Neste capítulo é comentada a experiência do autor na instalação e operação de sistemas automáticos de aquisição de dados em estruturas offshore. Neste capítulo também são descritas as principais técnicas para a atualização numérico-experimental de estruturas. Estas técnicas são utilizadas para atualizar as matrizes de massa e rigidez consideradas na fase de projeto da estrutura, de forma que o erro entre frequências e modos naturais medidos e calculados seja mínimo.

No capítulo IV, a teoria referente à fadiga de estruturas metálicas é apresentada de forma resumida, com ênfase para excitação aleatória. As principais formulações existentes são mencionadas, de forma não extensiva e com exemplos baseados na experiência do autor e na literatura disponível, e apresentados os procedimentos que são aplicados neste trabalho.

No capítulo V é feita uma introdução ao conceito de redes neurais, que são modelos computacionais baseados na estrutura e forma de processamento de informações do cérebro humano. As redes neurais têm capacidade de aprender a realizar um determinado conjunto de procedimentos, a partir de informações referentes às variáveis de entrada e saída do processo que estiver sendo simulado, fato este que caracteriza o treinamento supervisionado. Nesta tese, as redes neurais serão utilizadas para a atualização numérico-experimental e estimativa do dano de fadiga em tempo real. Neste capítulo é também apresentado o programa *Neuroshell 2*, que foi utilizado para gerar os resultados numéricos deste trabalho.

No capítulo VI é proposto e avaliado, através de modelo simplificado, um sistema para a monitoração de fadiga em tempo real para plataformas fixas de produção de petróleo. Este sistema tem como objetivo permitir realizar o cálculo do dano de fadiga a partir dos esforços que estão realmente atuando na estrutura: ele irá operar na estrutura. A partir das informações do deslocamento do convés inferior da plataforma e de um procedimento de cálculo baseado em redes neurais, a estimativa de dano de fadiga é realizada em tempo real. Esta informação, em conjunto com informações provenientes da inspeção, irá possibilitar uma definição mais precisa da prioridade da inspeção e do reparo.

Finalmente, no Capítulo VII são expostas as conclusões do presente trabalho, bem como sugestões para a sua continuidade.

Capítulo II

ANÁLISE DINÂMICA

ALEATÓRIA DE ESTRUTURAS OFFSHORE

II.1 INTRODUÇÃO

A análise dinâmica aleatória permite a avaliação da resposta de sistemas estruturais submetidos a solicitações de caráter aleatório, bem como considerar as incertezas no conhecimento das propriedades dinâmicas da estrutura.. A resposta de estruturas submetidas a ação do mar, como as estruturas offshore, deve ser avaliada através de uma análise aleatória, pois os resultados obtidos são bem mais realistas devido à representação mais adequada dos estados de mar, principalmente para grandes profundidades de lâmina d'água [Torres,1984].

II.2 DENSIDADE ESPECTRAL

Uma função $x(t)$, continuamente diferenciável por partes e periódica, pode ser sempre expressa através de uma série infinita de funções trigonométricas: a série de Fourier. No entanto, o registro no tempo $x(t)$ de uma função de um processo aleatório não é periódico e, portanto, não pode ser representado por séries discretas de Fourier. Além disso, para um processo aleatório $x(t)$ prossegue indefinidamente e a condição $\int_{-\infty}^{\infty} |x(t)| dt < \infty$, que deve ser satisfeita para possibilitar a aplicação da integral de Fourier, não é verificada. Não seria possível, à princípio, avaliar a transformada de Fourier de $x(t)$ com o objetivo de se obter informações sobre a composição de frequências do processo aleatório. Esta dificuldade pode ser superada fazendo-se uma análise de Fourier, não das funções de amostragem ou registros mas, da função de auto-correlação $R_x(\tau)$. Isto é possível porque a função de auto-correlação fornece informações sobre as frequências presentes num processo aleatório indiretamente.

Verifica-se que $R_x(\tau)$ atinge os valores máximos para valores de τ para os quais $x(\tau)$ e $x(t+\tau)$ estão em fase e os valores mínimos para valores de τ para os quais $x(t)$ e $x(\tau+t)$ estejam em anti-fase [Newland,1975]. Se o processo aleatório $x(t)$ é ajustado de tal forma que o seu valor médio - $E[x(t)]$ - seja zero e supondo-se que $x(t)$ não tenha componentes periódicas, tem-se que:

$$R_x(\tau \rightarrow \infty) = 0 \quad (\text{II.1})$$

Portanto, é satisfeita a condição:

$$\int_{-\infty}^{\infty} |R_x(\tau)| d\tau < \infty \quad (\text{II.2})$$

Desta forma, a transformada de Fourier de $R_x(\tau)$ e sua inversa são expressas por:

$$S_x(\omega) = \frac{1}{2\pi} \int_{-\infty}^{\infty} R_x(\tau) e^{-i\omega\tau} d\tau \quad (\text{II.3})$$

e

$$R_x(t) = \int_{-\infty}^{\infty} S_x(\omega) e^{i\omega\tau} d\omega \quad (\text{II.4})$$

onde $S_x(\omega)$ é a densidade espectral de potência do processo aleatório em função de ω .

Fazendo-se $\tau = 0$ e substituindo-se em (II.4), tem-se que:

$$R_x(\tau = 0) = \int_{-\infty}^{\infty} S_x(\omega) d\omega \quad (\text{II.5})$$

A partir daí, pode-se demonstrar que:

$$E[x^2] = \int_{-\infty}^{\infty} S_x(\omega) d\omega \quad (\text{II.6})$$

O valor médio quadrático de um processo aleatório estacionário é, portanto, dado pela área sob o gráfico de densidade espectral $S_x(\omega)$.

Na prática, a função autocorrelação é truncada, pois se considera uma série temporal com duração limitada, não só pela limitação de um processamento digital, mas também pela necessidade de garantir a propriedade do sinal ser estacionário. O tipo de truncamento influencia nas características da função densidade espectral de potência.

Um processo cuja densidade espectral ocupa apenas uma faixa estreita de frequências é denominado de banda estreita. Um processo de banda larga é aquele cuja densidade espectral corresponde a uma larga banda de frequências. As séries temporais e correspondentes a estes tipos de densidades espectrais são indicadas na figura II.1.

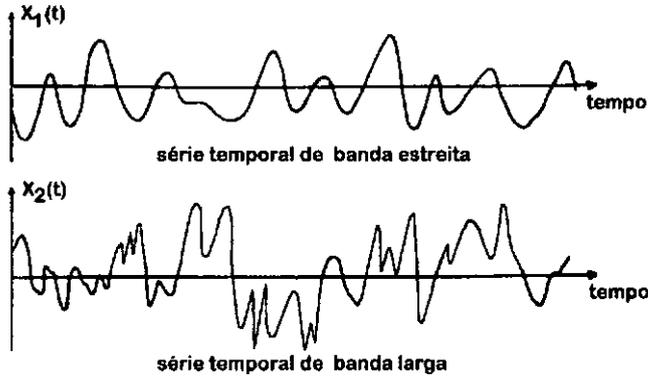


Figura II.1 - Processos de banda estreita e banda larga

Conhecendo-se a densidade espectral de potência $S_x(\omega)$ de um processo aleatório estacionário $x(t)$, é possível calcular seu valor médio quadrático através da equação (II.6), e também a densidade espectral dos processos obtidos através de diferenciação de $x(t)$, que vão corresponder a sua velocidade e aceleração.

A densidade espectral cruzada, de um par de processos aleatórios, é definida como a transformada de Fourier da função de correlação cruzada correspondente aos dois processos. Sendo $R_{xy}(\tau)$ e $R_{yx}(\tau)$ as duas funções de correlação cruzada, tem-se que [Bendat,1986]:

$$S_{xy}(\omega) = \frac{1}{2\pi} \int_{-\infty}^{\infty} R_{xy}(\tau) e^{-i\omega\tau} d\tau \quad (\text{II.7})$$

e

$$S_{yx}(\omega) = \frac{1}{2\pi} \int_{-\infty}^{\infty} R_{yx}(\tau) e^{-i\omega\tau} d\tau \quad (\text{II.8})$$

II.3 EXCITAÇÃO DO MEIO AMBIENTE

A excitação do meio ambiente, no caso de estruturas offshore fixas, origina-se na ação do vento, corrente e ondas e terremotos. Os terremotos são considerados como

importantes apenas no caso da plataforma ser instalada nas proximidades de uma placa tectônica. A ação do vento, de acordo com [Watt,1978], representa somente 5% da carga ambiental e a ação da corrente normalmente não é considerada, pois o seu conteúdo em frequência não excita as estruturas fixas. A carga devido às ondas é a ação mais importante do meio ambiente com relação à resposta dinâmica das estruturas offshore fixas.

Basicamente, podemos identificar três tipos de mar, de acordo com a forma da sua densidade espectral, conforme indicado na figura II.2 [Haver,1985].

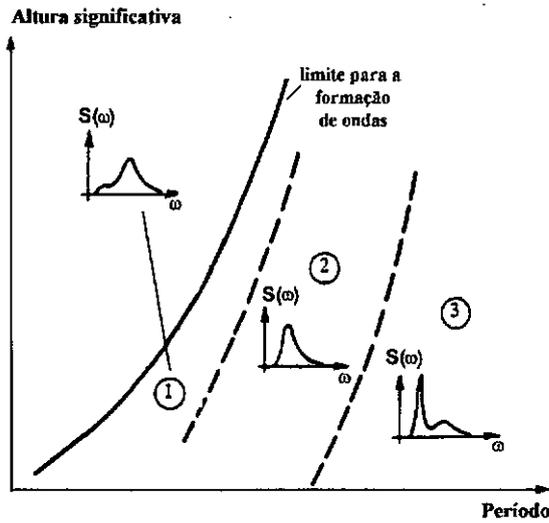


Figura II.2 - Tipos básicos de estado de mar

Na região 1, o estado de mar corresponde a ondas geradas na região pelo vento local (denominadas *sea*), com alguma influência das ondas geradas em região distante do local (denominadas *swell*).

Na região 2, o estado de mar tem predominância de ondas tipo *sea*.

Na região 3, o estado de mar corresponde à predominância de ondas tipo *swell*, com alguma influência de ondas tipo *sea*.

A representação de mar sob a forma de densidade espectral de potência é amplamente utilizada na análise das estruturas offshore [Bishop,1979]. Os dados disponíveis referentes às medidas de onda, realizadas em diversos locais do mundo, indicam que, para períodos curtos de tempo, a elevação da superfície do mar pode ser considerada como um processo Gaussiano estacionário. Várias expressões são utilizadas para a representação do estado de mar, sendo a densidade espectral de Pierson-Moskowitz modificada correspondente dada por [Almar-Naess,1985]:

$$S_{\text{mar}}(\omega) = \frac{4\pi^3 A_s^2}{\omega^5 T_z^4} \exp\left(-\frac{16\pi^3}{\omega^4 T_z^4}\right) \quad (\text{II.9})$$

onde A_s é a altura significativa e T_z é o período de cruzamento ascendente do nível médio.

Normalmente, também é considerado um fator de dispersão na definição do espectro, que leva em conta o fato da linha formada pela crista de uma onda não ser uma reta. A variação típica da densidade espectral do mar em função de A_s e T_z está apresentada na figura II.3, onde observa-se que a forma do espectro se modifica conforme o valor do período diminui, surgindo uma maior concentração de energia na região correspondente às frequências naturais das plataformas fixas.

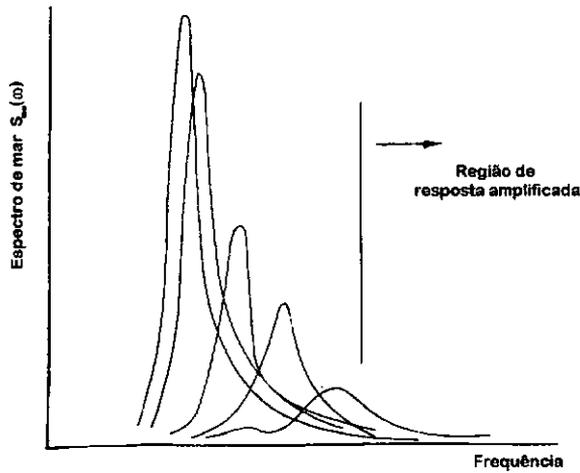


Figura II.3 - Variação típica da densidade espectral do mar

A densidade espectral do carregamento deve ser determinada a partir da densidade espectral das elevações da superfície do mar. As relações entre estas funções irá depender da teoria utilizada para avaliar a cinemática das partículas da onda e da formulação usada para determinar as pressões e integrá-las ao longo dos tubos que compõem a jaqueta de uma plataforma fixa [Sigbjornsson,1979].

Para estados de mar de curta duração, é utilizada a formulação linear desenvolvida por Airy para o cálculo da densidade espectral das velocidades das partículas da onda [Borgman,1972]. A expressão para as velocidades é (para as acelerações a expressão é semelhante):

$$S_v(\omega) = \omega^2 \frac{\cosh^2(k_{\text{ond}}(z_{\text{ref}} + d_{\text{prof}}))}{\sinh^2(k_{\text{ond}} d_{\text{prof}})} S_{\text{mar}}(\omega) \quad (\text{II.10})$$

onde $S_v(\omega)$ é a densidade espectral da velocidade horizontal das partículas, z_{ref} é a referência de águas tranquilas, d_{prof} é a profundidade e k_{ond} é número de onda. Em diversos artigos técnicos e livros podem ser encontradas variações desta expressão, incluindo correções para a altura da onda, e fórmulas equivalentes para o cálculo da densidade espectral de velocidade e aceleração verticais e espectros cruzados.

As forças hidrodinâmicas atuantes na estrutura são calculadas de acordo com a equação de Morison [Sarpkaya,1981]. No desenvolvimento desta equação é assumido que o cilindro é fixado na posição vertical e que o seu movimento é muito menor do que o movimento das partículas da água. As forças são divididas em duas parcelas: a primeira parcela, proporcional à velocidade relativa do escoamento, é denominada força de Arraste, e a segunda parcela, proporcional à aceleração relativa, é denominada força de Inércia. Após as devidas simplificações, a expressão das componentes normal e tangencial destas forças combinadas é:

$$F_n = \frac{1}{2} \rho C_d A_{tub} |\dot{u}_n| \dot{u}_t + \rho C_m V_{tub} \ddot{u}_n \quad \text{e} \quad F_t = \rho V_{tub} \ddot{u}_t \quad (\text{II.11})$$

onde A_{tub} é a área seccional e V_{tub} é o volume do tubo/unidade de comprimento.

Os membros estruturais localizados nas proximidades da superfície livre estão submetidos à variação da força hidrostática e também às forças de *slamming*. De acordo com [Gupta,1986], a influência da variação da força hidrostática só se torna relevante, no cálculo do dano de fadiga, para estados de mar com altura significativa de onda superiores a 6 metros. A força de *slamming* pode ser calculada como uma força de arraste, substituindo-se o coeficiente de arraste por um coeficiente de *slamming*, que é estimado a partir de dados experimentais. Neste caso, devido à natureza da força, é necessário se considerar um fator de amplificação e o período de ocorrência do *slamming* [ARSEM,1985].

Os procedimentos numéricos envolvidos no cálculo das forças nodais, nos diversos elementos verticais, horizontais e inclinados considerados sob a ação das ondas, são complexos e exigem programas de computador desenvolvidos especificamente para esta finalidade.

II.4 INFLUÊNCIA DAS FUNDAÇÕES

A resposta de uma plataforma fixa com fundação flexível sob a ação de ondas depende muito das características de rigidez e amortecimento do material componente do solo, devido a interação das estacas com o solo onde elas estão cravadas. Na figura II.4 é

apresentado o detalhamento do solo e de uma das estacas correspondentes à plataforma PGP-1, localizada na Bacia de Campos, em lâmina d'água de 120 metros.

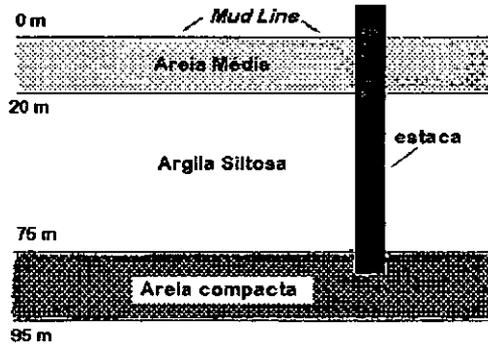


Figura II.4 - Detalhe do sistema estaca-fundação de PGP-1

Na formulação desenvolvida em [Novak,1974], para calcular as reações dinâmicas do solo, foram assumidas as seguintes hipóteses:

- o solo é formado por um meio infinito, homogêneo, isotrópico e visco-elástico, com amortecimento histerético independente da frequência;
- os deslocamentos são de pequena amplitude;
- não é permitida a separação entre a estaca e o solo.

O efeito do conjunto estaca-solo é baseado em estudos teóricos das funções de impedância deste conjunto [Gupta,1986]. O comportamento do solo pode ser representado por molas e amortecedores colocados ao longo de cada estaca da jaqueta. As funções de impedância podem ser determinadas através da teoria de uma viga contínua apoiada em base elástica, considerando-se a análise harmônica do sistema excitado por força aplicada no topo da estaca. As partes real e imaginária da função de impedância representam a rigidez e o amortecimento devido a interação da estaca com o solo, respectivamente. De acordo com uma avaliação paramétrica em [Gupta,1986], o cálculo do dano de fadiga é muito sensível aos valores considerados para o módulo de cisalhamento do solo e para a sua distribuição ao longo da estaca.

Geralmente, nos sistemas integrados para cálculo da resposta dinâmica de plataformas [ADEP,1987], a idealização das fundações é feita pela discretização do sistema estacas-solo. A estaca é modelada por elementos de viga, sendo assumido que cada elemento possui propriedades constantes, e o solo é representado por uma série de molas lineares, obtidas a partir das propriedades geofísicas do material que o compõe. Mesmo com o comportamento do solo sendo notadamente não linear, como o estudo de fadiga

envolve deslocamentos pequenos, esta hipótese pode ser adotada. Em [Meniconi,1989], o cálculo efetuado para a plataforma PGP-1, dos coeficientes de rigidez das molas colocadas na extremidade inferior de cada perna da plataforma, forneceu os seguintes resultados:

- mola vertical: 7600 N/m e molas horizontais: 370 N/m

Estes resultados serão utilizados na simulação numérica que será desenvolvida no Capítulo VI deste trabalho.

II.5 RESPOSTAS ÀS EXCITAÇÕES ALEATÓRIAS

II.5.1 Análise de Sistemas com 1 Grau de Liberdade

Considerando-se um conjunto de séries temporais, obtidos de sistemas lineares idênticos, para os quais as respostas a impulsos aplicados são $h_1(t)$ e $h_2(t)$ e as respostas em frequência são $H_1(\omega)$ e $H_2(\omega)$, a resposta para mais de duas solicitações poderá ser obtida através da solução para duas solicitações. As funções $h_1(t)$ e $H_1(\omega)$ fornecem a resposta $y(t)$ devido à solicitação $x_1(t)$ e as funções $h_2(t)$ e $H_2(\omega)$ fornecem a resposta $y(t)$ devido à solicitação $x_2(t)$ [Bendat,1986].

A resposta $y(t)$ para um registro relativo às solicitações $x_1(t)$ e $x_2(t)$ pode ser expressa por:

$$y(t) = \int_{-\infty}^{\infty} h_1(\theta)x_1(t-\theta)d\theta + \int_{-\infty}^{\infty} h_2(\theta)x_2(t-\theta)d\theta \quad (\text{II.12})$$

Para calcular o valor médio $E[y(t)]$ do conjunto de registros, é necessário calcular a média de cada uma das integrais da equação (II.12). A expressão da média é:

$$E[y(t)] = \int_{-\infty}^{\infty} h_1(\theta) E[x_1(t-\theta)]d\theta + \int_{-\infty}^{\infty} h_2(\theta) E[x_2(t-\theta)]d\theta \quad (\text{II.13})$$

Sendo as duas solicitações estacionárias, seus valores médio a $E[x_1]$ e $E[x_2]$ independem do tempo $(t-\theta)$, concluindo-se que $E[y(t)]$ também independe do tempo, o que resulta em:

$$E[y] = E[x_1] \int_{-\infty}^{\infty} h_1(\theta)d\theta + E[x_2] \int_{-\infty}^{\infty} h_2(\theta)d\theta \quad (\text{II.14})$$

A função de autocorrelação da resposta é dada por $E[y(t)y(t+\tau)]$. Substituindo-se θ por θ_1 e θ_2 , podem ser obtidas as seguintes expressões para $y(t)$ e $y(t+\tau)$:

$$y(t) = \int_{-\infty}^{\infty} h_1(\theta_1)x_1(t - \theta_1)d\theta_1 + \int_{-\infty}^{\infty} h_2(\theta_1)x_2(t - \theta_1)d\theta_1 \quad (\text{II.15})$$

e

$$y(t + \tau) = \int_{-\infty}^{\infty} h_1(\theta_2)x_1(t + \tau - \theta_2)d\theta_2 + \int_{-\infty}^{\infty} h_2(\theta_2)x_2(t + \tau - \theta_2)d\theta_2 \quad (\text{II.16})$$

Sendo o processo $x_1(t)$ estacionário, a função de autocorrelação independe do tempo absoluto t , resultando em:

$$E[x_1(t - \theta_1)x_1(t + \tau - \theta_2)] = R_{x_1}(\tau - \theta_2 + \theta_1) \quad (\text{II.17})$$

A resposta em frequência $H(\omega)$ pode ser expressa por:

$$H_1(\omega) = \int_{-\infty}^{\infty} h_1(\theta_2)e^{-i\omega\theta_2}d\theta_2 \quad \text{e} \quad H_2(\omega) = \int_{-\infty}^{\infty} h_2(\theta_1)e^{-i\omega\theta_1}d\theta_1 \quad (\text{II.18})$$

O complexo conjugado de (II.18) é dado por:

$$H_1^*(\omega) = \int_{-\infty}^{\infty} h_1(\theta_1)e^{i\omega\theta_1}d\theta_1 \quad \text{e} \quad H_2^*(\omega) = \int_{-\infty}^{\infty} h_2(\theta_2)e^{i\omega\theta_2}d\theta_2 \quad (\text{II.19})$$

A partir destas considerações, pode-se demonstrar que a expressão da densidade espectral da resposta é:

$$S_y(\omega) = H_1^*(\omega)S_{x_1}(\omega) + H_1^*(\omega)H_2(\omega)S_{x_1x_2}(\omega) + H_2^*(\omega)H_1(\omega)S_{x_2x_1}(\omega) + H_2^*(\omega)H_2(\omega)S_{x_2}(\omega) \quad (\text{II.20})$$

Para N solicitações, pode-se demonstrar que:

$$S_y(\omega) = \sum_{r=1}^N \sum_{s=1}^N H_r^*(\omega)H_s(\omega)S_{x_r x_s}(\omega) \quad (\text{II.21})$$

onde $S_{x_r x_r}(\omega) = S_{x_r}(\omega)$.

Para uma única solicitação, tem-se que:

$$S_y(\omega) = |H(\omega)|^2 S_x(\omega) \quad (\text{II.22})$$

Na figura II.5 está ilustrada a operação descrita na equação anterior. O primeiro pico que aparece no gráfico da resposta é devido à concentração da distribuição de energia da densidade espectral da excitação. O segundo pico é causado pela amplificação dinâmica

da excitação e corresponde à frequência natural da estrutura. A amplitude deste segundo pico irá depender do coeficiente de amortecimento modal da estrutura.

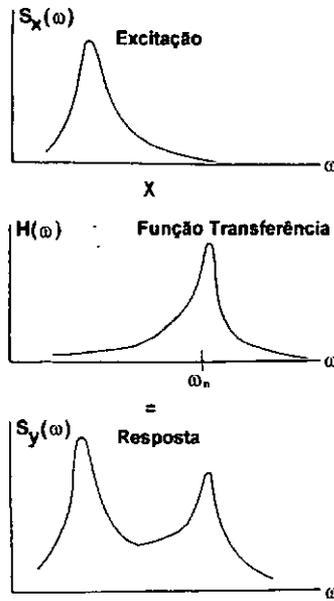


Figura II.5 - Excitação e Resposta no domínio da frequência

Para solicitações não correlacionadas, para as quais os termos relativos a densidade espectral cruzada são nulos, a equação (II.21) transforma-se em:

$$S_y(\omega) = \sum_{r=1}^N |H_r(\omega)|^2 S_x(\omega) \quad (\text{II.23})$$

O valor médio quadrático é obtido por:

$$E[y^2] = \int_{-\infty}^{\infty} S_y(\omega) d\omega \quad (\text{II.24})$$

Para uma única solicitação, tem-se que:

$$E[y^2] = \int_{-\infty}^{\infty} |H(\omega)|^2 S_x(\omega) d\omega \quad (\text{II.25})$$

Para N solicitações não correlacionadas, obtém-se:

$$E[y^2] = \sum_{r=1}^N \int_{-\infty}^{\infty} |H_r(\omega)|^2 S_x(\omega) d\omega \quad (\text{II.26})$$

Para solicitações correlacionadas, o valor médio quadrático da resposta não pode ser expresso pela soma dos valores médios quadráticos de cada resposta. Neste caso,

torna-se necessário a utilização da equação (II.21) sem simplificações, isto é, considerando-se os termos cruzados.

A relação entre a distribuição de probabilidade da resposta de um sistema linear em função da distribuição de probabilidade da solicitação é difícil de ser determinada, exceto para o caso das solicitações cuja distribuição é gaussiana. Para estes casos, aplica-se a seguinte propriedade: sendo y_1 e y_2 um par de variáveis aleatórias cuja distribuição de probabilidade é gaussiana, e y definido como

$$y = y_1 + y_2 \quad (\text{II.27})$$

a nova variável y também é gaussiana. Este resultado pode ser aplicado para mostrar que a resposta $y(t)$ de um sistema linear é gaussiana se a solicitação $x(t)$ também o for.

Grande parte dos fenômenos físicos podem ser considerados como fenômenos lineares, estacionários, ergódicos e gaussianos, sendo o comportamento gaussiano assegurado pelo Teorema do Limite Central [Clough,1975].

Este teorema afirma que, para um conjunto x_i , $i = 1, 2, \dots, n$, de variáveis aleatórias estatisticamente independentes, possuindo idênticas funções de distribuição, médias finitas m_i e variâncias finitas σ_i^2 , a distribuição de probabilidade de uma nova variável $y = \sum_{i=1}^n x_i$ aproxima-se da função de distribuição normal, ou Gauss, com média $m_y = \sum_{i=1}^n m_i$ e variância $\sigma_y^2 = \sum_{i=1}^n \sigma_i^2$, quando n tende para infinito.

Desta forma, um processo aleatório terá sua distribuição de probabilidade aproximadamente gaussiana se for gerado pela superposição de um grande número de fontes aleatórias.

II.5.2 Análise de Sistemas com Vários Graus de Liberdade

Para os sistemas estruturais com vários graus de liberdade, submetidos a solicitações aleatórias, os procedimentos para determinação da resposta são os mesmos desenvolvidos no item anterior, determinando-se médias, variâncias, densidades espectrais, etc..., dos deslocamentos e esforços que surgem na estrutura. A relação entre a densidade espectral da solicitação e da resposta é equivalente à equação (II.21), onde a resposta em frequência compreende todos os graus de liberdade da estrutura [Torres,1984]. Um procedimento para a avaliação da relação entre as densidades espectrais da solicitação e da

resposta, consiste em se aplicar a transformada de Fourier ao sistema de equações diferenciais:

$$\mathbf{M} \ddot{\mathbf{u}}(t) + \mathbf{C} \dot{\mathbf{u}}(t) + \mathbf{K} \mathbf{u}(t) = \mathbf{f}(t) \quad (\text{II.28})$$

obtendo-se:

$$\int_{-\infty}^{\infty} \left[-\omega^2 \mathbf{M} + i\omega \mathbf{C} + \mathbf{K} \right] \mathbf{u}(\omega) e^{i\omega t} d\omega = \int_{-\infty}^{\infty} \mathbf{f}(\omega) e^{i\omega t} d\omega \quad (\text{II.29})$$

onde:

$$\mathbf{u}(t) = \int_{-\infty}^{\infty} \mathbf{u}(\omega) e^{i\omega t} d\omega \quad (\text{II.30})$$

e

$$\mathbf{f}(t) = \int \mathbf{f}(\omega) e^{i\omega t} d\omega \quad (\text{II.31})$$

A equação (II.29) pode ser escrita como:

$$\left[\mathbf{K} + \mathbf{C}i\omega - \mathbf{M}\omega^2 \right] \mathbf{u}(\omega) = \mathbf{f}(\omega) \quad (\text{II.32})$$

A sua inversa é dada por:

$$\mathbf{u}(\omega) = \mathbf{H}(\omega) \mathbf{f}(\omega) \quad (\text{II.33})$$

O conjugado da transformada de Fourier é obtido através de (II.33), resultando em:

$$\left[\mathbf{K} - i\omega \mathbf{C} - \omega^2 \mathbf{M} \right] \mathbf{u}^*(\omega) = \mathbf{f}^*(\omega) \quad (\text{II.34})$$

cuja inversa é:

$$\mathbf{u}^*(\omega) = \mathbf{H}^*(\omega) \mathbf{f}^*(\omega) \quad (\text{II.35})$$

Multiplicando-se as equações (II.33) e (II.35), obtém-se:

$$\mathbf{u}(\omega) \mathbf{u}^{*t}(\omega) = \mathbf{H}(\omega) \mathbf{f}(\omega) \mathbf{f}^{*t}(\omega) \mathbf{H}^{*t}(\omega) \quad (\text{II.36})$$

Dividindo-se ambos os lados pelo período T , e fazendo-se $T \rightarrow \infty$, tem-se:

$$\lim_{T \rightarrow \infty} \frac{\mathbf{u}(\omega)\mathbf{u}^{*t}(\omega)}{T} = \lim_{T \rightarrow \infty} \mathbf{H}(\omega) \frac{\mathbf{f}(\omega)\mathbf{f}(\omega)}{T} \mathbf{H}^{*t}(\omega) \quad (\text{II.37})$$

O valor médio quadrático pode, também, ser definido como:

$$E[x^2(t)] = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x(t)x(t)dt \quad (\text{II.38})$$

Aplicando o conceito de transformada de Fourier, a equação (II.38) pode ser escrita como:

$$E[x^2(t)] = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x(t) \left[\int_{-\infty}^{\infty} x(\omega)e^{i\omega t} d\omega \right] dt = \int_{-\infty}^{\infty} x(\omega) \left[\lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x(t)e^{i\omega t} dt \right] d\omega \quad (\text{II.39})$$

O termo na segunda integral é o conjugado $x^*(\omega)$. Desta forma, obtém-se:

$$E[x^2(t)] = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-\infty}^{\infty} x(\omega)x^*(\omega)d\omega \quad (\text{II.40})$$

Comparando-se as equações (II.39) e (II.40), chega-se a:

$$\int_{-\infty}^{\infty} S_x(\omega)d\omega = \lim_{T \rightarrow \infty} \int_{-\infty}^{\infty} \frac{1}{T} x(\omega)x^*(\omega)d\omega = \lim_{T \rightarrow \infty} \int_{-\infty}^{\infty} \frac{|x(\omega)|^2}{T} d\omega \quad (\text{II.41})$$

Portanto, a densidade espectral de $x(t)$ pode ser expressa por:

$$S_x(\omega) = \lim_{T \rightarrow \infty} \frac{|x(\omega)|^2}{T} \quad (\text{II.42})$$

Aplicando-se (II.42) em (II.37), chega-se a:

$$\mathbf{S}_u(\omega) = \mathbf{H}(\omega) \mathbf{S}_f(\omega) \mathbf{H}^{*t}(\omega) \quad (\text{II.43})$$

onde

$$\mathbf{S}_u(\omega) = \lim_{T \rightarrow \infty} \frac{\mathbf{u}(\omega)\mathbf{u}^{*t}(\omega)}{T} \quad \text{e} \quad \mathbf{S}_f(\omega) = \lim_{T \rightarrow \infty} \frac{\mathbf{f}(\omega)\mathbf{f}^{*t}(\omega)}{T} \quad (\text{II.44})$$

Supondo-se que a densidade espectral da solicitação possa ser expressa por:

$$\mathbf{S}_f(\omega) = \mathbf{f}(\omega) \mathbf{S}_{ff}(\omega) \mathbf{f}^{*t}(\omega) \quad (\text{II.45})$$

Substituindo (II.45) em (II.43), tem-se:

$$\mathbf{S}_u(\omega) = \mathbf{H}(\omega) \mathbf{f}(\omega) \mathbf{S}_{ff}(\omega) \mathbf{f}^{*t}(\omega) \mathbf{H}^{*t}(\omega) \quad (\text{II.46})$$

Aplicando-se (II.29) e (II.35) em (II.46), chega-se a:

$$\mathbf{S}_u(\omega) = \mathbf{u}(\omega) \mathbf{S}_{ff}(\omega) \mathbf{u}^{*t}(\omega) \quad (\text{II.47})$$

Conhecido o valor de $\mathbf{S}_u(\omega)$ pode-se determinar o valor médio quadrático e outros dados estatísticos desejados de deslocamentos, velocidades e acelerações:

$$E[\mathbf{u}^2] = \int_{-\infty}^{\infty} \mathbf{S}_u(\omega) d\omega \quad (\text{II.48})$$

$$E[\dot{\mathbf{u}}^2] = \int_{-\infty}^{\infty} \omega^2 \mathbf{S}_u(\omega) d\omega \quad (\text{II.49})$$

$$E[\ddot{\mathbf{u}}^2] = \int_{-\infty}^{\infty} \omega^4 \mathbf{S}_u(\omega) d\omega \quad (\text{II.50})$$

A densidade espectral dos esforços nos elementos é obtida de maneira semelhante, através da matriz de rigidez de cada elemento.

Os esforços calculados por estes procedimentos não consideram os efeitos de ampliação que ocorrem nas regiões do cordão de solda, que serão abordados a seguir.

II.6 CONCENTRAÇÃO DE TENSÕES E TENSÕES *HOT SPOT*

Como já foi explicado anteriormente, a fadiga ocorre devido à variação cíclica de tensões, a uma certa frequência, nos membros da estrutura.

Nas juntas metálicas soldadas, cujos arranjos mais comuns estão mostrados na figura II.6, existem, inicialmente, tensões próximas à tensão de escoamento do material, decorrentes das tensões residuais que surgem no processo de soldagem. Portanto, a flutuação das tensões ocorre a partir da tensão de escoamento, que é o limite superior do intervalo de variação.

Estas flutuações podem ocorrer apenas dentro de limites de tensões de tração, de compressão, ou ainda podem abranger tensões de tração e compressão. O que influencia na propagação das trincas é o efeito da flutuação das tensões, as amplitudes dos intervalos

de variação e sua frequência de ocorrência (número de ciclos) durante toda a vida útil da estrutura.

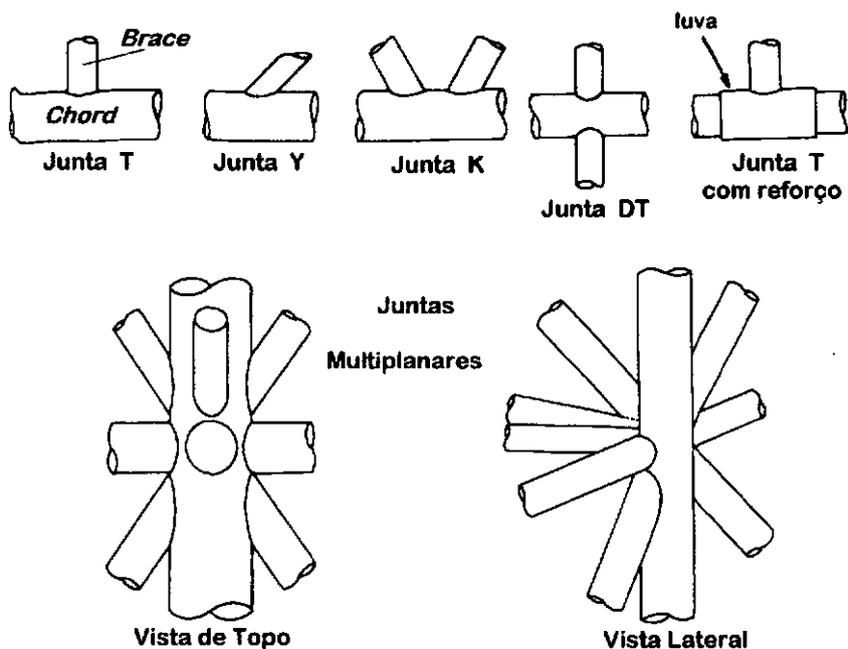


Figura II.6 - Tipos de juntas mais comuns em plataformas fixas

Nas estruturas offshore, observa-se que a geometria da junta é muito importante na concentração de tensões que ocorre nos cordões de solda. Estas tensões, chamadas de tensões *hot spot* e podem ser determinadas, basicamente, através de três métodos: uma análise através do método dos elementos finitos, ensaios experimentais de modelos físicos ou através de fórmulas paramétricas semi-empíricas.

O método mais simples de ser aplicado - fórmulas paramétricas - permite a obtenção de um fator de concentração de tensões que estabelece uma relação entre a tensão de *hot spot* e a tensão nominal obtida na extremidade dos membros da junta. São compostas de termos adimensionais que se constituem de relações entre os parâmetros geométricos de *braces* e *chords*. Existem diversos trabalhos desenvolvidos sobre o assunto, dos quais pode ser destacado [Potvin,1977]. Observa-se que há fórmulas diferentes para o *brace* e *chord*, sendo considerados três esforços que atuam no *brace* e que serão majorados pelo fator de concentração de tensões: o esforço axial, o momento que atua no plano da junta e o que atua fora do plano da junta. Na figura II.7 está apresentado um exemplo que mostra a distribuição de tensões *hot spot* na seção de uma junta tipo T.

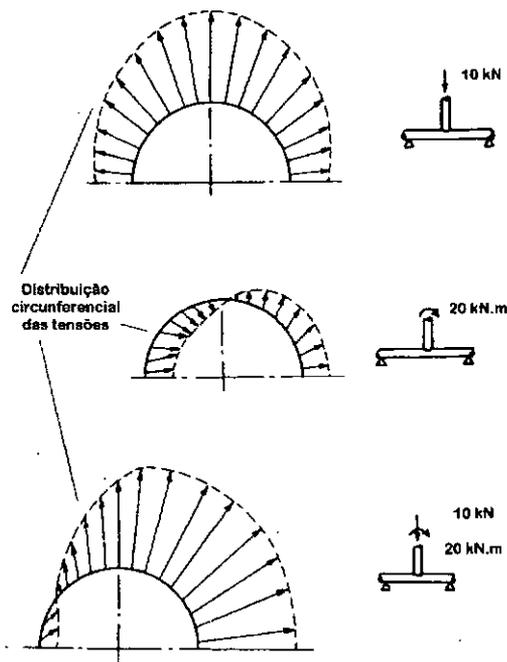


Figura II.7 - Distribuição das tensões *hot spot* em junta tipo T

As normas procuram estabelecer limites mínimos seguros para os fatores de concentração de tensões utilizados em juntas soldadas. No caso da Sociedade Classificadora Det Norske Veritas [DNV,1977], este valor é de 2.5 para juntas simples e 5.0 para juntas onde ocorre *overlapping*.

II.7 O PROGRAMA ANSYS

O programa de computador para análise estrutural por elementos finitos ANSYS versão 5.0 é basicamente composto por quatro módulos principais :

- módulo 1: Pré-processador
- módulo 2: Solução
- módulo 3: Pós-processador Geral
- módulo 4: Pós-processador no Domínio do Tempo

Através de módulo 1 são fornecidos os dados referentes à geometria, com comandos que permitem geração automática de nós, ao material e os tipos de elementos finitos que serão utilizados para a modelação da estrutura. O usuário dispõe da possibilidade de criar novos tipos de elementos.

No módulo 2 são disponíveis diversos tipos de análise, tanto estáticas quanto dinâmicas. Neste módulo as cargas são definidas, assim como os seus pontos de aplicação, e é obtida a resposta da estrutura.

Os módulos 3 e 4 são responsáveis pelo pós-processamento e operam com os resultados do módulo 2. Eles podem ser utilizados para diversos tipos de avaliações de interesse do usuário. O *ANSYSv5.0* dispõe, inclusive, de uma boa capacidade de macro-programação, que permite o desenvolvimento de rotinas de cálculo específicas no seu próprio ambiente operacional.

Na parte de Análise Espectral, o programa *ANSYSv5.0* possui a opção de Análise de Vibração Aleatória [ANSYS,1992], que permite a excitação da estrutura com até 10 funções de Densidade Espectral de Potência distintas. Estas funções podem ser parcialmente correlacionadas, totalmente correlacionadas e não correlacionadas.

Os principais comandos disponíveis para este tipo de análise são:

- PSDFRQ : Definição do conjunto de frequências do gráfico de densidade espectral, em unidade definida pelo usuário(máx. 50).
- PSDVAL : Definição das ordenadas do gráfico de densidade espectral, em unidades definidas pelo usuário (máx. 50).
- PSDUNIT : Indica o tipo de espectro de excitação.
- PSDRES : Controla o tipo de solução, que pode ser deslocamento, velocidade ou aceleração, ou tensões, forças, etc... com as suas derivadas em relação ao tempo. Controla também a característica absoluta ou relativa da solução.
- PFACT : Indica se a excitação é nodal ou de base.
- PSDWAV : Define excitações parcialmente correlacionadas a partir de um conceito de onda progressiva incidente na estrutura. A expressão usada está indicada na equação (II.51) onde o espectro de excitação $S_f(\omega)$ é corrigido ao incidir no ponto m (em relação ao ponto ℓ), tanto na intensidade quanto na fase.

$$S_{\ell m}(\omega) = S_f(\omega)(e^{\lambda\omega^{\mu+1}D_{\ell m}^{\mu+2}})(e^{-i\omega d_{\ell m}}) \quad (\text{II.51})$$

No procedimento disponível no *ANSYSv5.0* para análise dinâmica aleatória, os valores médios quadráticos e seus momentos (M_0 , M_2 e M_4) referentes aos deslocamentos e tensões, são calculados para todos os locais selecionados e armazenados em um arquivo

com terminação RST. Através de comandos específicos do módulo de pós-processamento, estes valores podem ser acessados e utilizados para a realização de procedimentos definidos pelo usuário, no próprio ambiente do *ANSYSv5.0*.

O conjunto de comandos apresentados como exemplo, a seguir, permite a localização das tensões, em oito pontos igualmente espaçados, na extremidade de um elemento previamente definido, no arquivo onde os dados foram armazenados.

ETABLE,T0,LS,33

ETABLE,T45,LS,37

ETABLE,T90,LS,41

ETABLE,T135,LS,45

ETABLE,T180,LS,49

ETABLE,T225,LS,53

ETABLE,T270,LS,57

ETABLE,T315,LS,61

PRETAB,T0,T45,T90,T135,T180,T225,T270,T315

O comando ETABLE permite a obtenção dos valores correspondentes aos diversos tipos de parâmetros calculados, para um determinado elemento. No caso deste exemplo, as tensões, que estão sendo utilizadas, representam a distribuição das tensões de flexão e axial combinadas, em locais ao longo da seção do elemento.

O programa *ANSYSv5.0* utilizado no desenvolvimento desta tese é uma versão com limite de *wavefront* em 500, denominada versão Universitária 5.0, desenvolvida para operar em microcomputares tipo PC, com sistema operacional DOS. Este programa é produzido e distribuído por Swanson Analysis Systems, Inc., localizada em Houston, PA, USA, fax no. (412) 7469494.

Capítulo III

DADOS EXPERIMENTAIS

III.1 INTRODUÇÃO

À medida que a produção petrolífera se desloca para águas cada vez mais profundas, as frequências naturais das plataformas fixas tornam-se cada vez menores, ficando mais sujeitas à excitação pelas cargas ambientais, o que mostra a grande importância do amortecimento para o cálculo do dano de fadiga das juntas destas plataformas. A complexidade destas estruturas exige uma análise numérica sofisticada e, no atual estado da arte, os métodos de modelagem aplicam técnicas de elementos finitos que discretizam e definem as matrizes de massa e rigidez. A complexidade e as incertezas destes processos implicam na necessidade de confirmação e aprimoramento dos modelos estruturais por técnicas experimentais.

Até hoje um esforço substancial tem sido feito no desenvolvimento de metodologias para a determinação dos parâmetros dinâmicos da resposta destas estruturas. Frequências naturais e coeficientes de amortecimento têm sido estimados por algumas técnicas com diferentes graus de precisão. Uma parte deste esforço foi motivada pelas pesquisas e desenvolvimento de sistemas de monitoração integrada. A viabilização destas técnicas depende particularmente da capacidade de se avaliar com precisão as frequências naturais e os modos naturais de vibração. Para fins de projeto e manutenção, no entanto, estimativas dos coeficientes de amortecimento são até mais importantes.

Para uma plataforma fixa, o amortecimento devido à energia dissipada nos elementos estruturais da jaqueta representa apenas uma parcela do amortecimento total, que compreende também os efeitos hidrodinâmicos e do solo. Esta diversidade de parâmetros torna impossível a sua previsão teórica, sendo indispensáveis, portanto, os dados experimentais. Estimativas confiáveis do amortecimento podem ser obtidas utilizando-se excitação artificial. Entretanto, para se englobar um número representativo de estados de mar, este processo se tornaria extremamente oneroso. Uma simplificação na abordagem da questão é o fato da resposta estrutural medida ser sempre interpretada em termos de

modelos lineares de amortecimento e o mesmo ser apresentado em forma de coeficiente relativo a cada modo natural de vibração.

A estimativa de coeficientes de amortecimento a partir de dados de plataformas em operação são sujeitos a grandes imprecisões ou a altos custos para se fazer os ajustes finos necessários para torná-los confiáveis. Atualmente, os métodos mais utilizados para se estimar os parâmetros dinâmicos estruturais fazem uso de medições de resposta das plataformas às excitações das ondas. Os registros de aceleração são tomados em diferentes locais e direções da plataforma e processados por algoritmos que fornecem a densidade espectral de potência da resposta da estrutura. Esta representação dos dados permite a associação de picos do espectro aos modos naturais de vibração.

Cada frequência natural e coeficiente de amortecimento são estimados a partir da frequência de pico do espectro e das características da curva de densidade espectral. Este procedimento tem se mostrado preciso para a estimativa das frequências naturais. Entretanto, em relação ao coeficiente de amortecimento, este método exige uma análise criteriosa, visto que as suas estimativas se originam da manipulação de amostras de um processo estocástico e, portanto, pode fornecer qualquer valor conforme a sua distribuição de probabilidade, não possuindo nenhum significado prático sem maiores informações [Estrella, 1995].

A obtenção de dados experimentais em plataformas de petróleo, em virtude da localização destas estruturas (normalmente instaladas em alto mar, a dezenas de quilômetros da costa) e da necessidade de dados por longos períodos de tempo (devido à natureza aleatória do carregamento dinâmico), requer a utilização de sistemas automáticos de aquisição de dados. Estes sistemas devem ter a capacidade de operar sem a presença de pessoal especializado e tomar, inclusive, decisões para que a sua operação siga os procedimentos pré-estabelecidos. As técnicas de Inteligência Artificial, notadamente, os Sistemas Especialistas, permitem o desenvolvimento de sistemas de aquisição e supervisão de dados experimentais, no qual uma base de conhecimento irá simular um técnico com experiência no assunto [Novaes, 1990].

Conhecendo-se as frequências e os modos naturais de vibração, é possível a realização de uma atualização dos dados de projeto, não só com o objetivo de diminuir as incertezas de futuros projetos mas também com a finalidade de se estabelecer uma metodologia que permita a avaliação periódica da condição de integridade estrutural da estrutura em operação. A avaliação do dano de fadiga, a partir de um modelo dinâmico no qual as matrizes de massa e rigidez tenham sido atualizadas por meio de dados experimentais, originários das condições reais de operação da plataforma, e os coeficientes

de amortecimento obtidos por critério análogo, implicará em uma sensível redução das incertezas inerentes a estas componentes do seu procedimento de cálculo [Uribe, 1988], [Meniconi, 1989].

III.2 AQUISIÇÃO DE DADOS EXPERIMENTAIS

Um sistema típico de aquisição de dados experimentais é composto pelos seguintes elementos:

- **transdutores elétricos**, que transformam a ocorrência física em um sinal de tensão ou corrente;
- **condicionadores de sinais**, responsáveis pela alimentação elétrica dos transdutores e pela filtragem analógica dos sinais por eles gerados; devem permitir o controle de suas características operacionais pelo programa de supervisão;
- **placa de conversão analógico-digital**, cujo objetivo é transformar o sinal analógico em um sinal digital para ser processado por um microcomputador; deve possuir saídas analógicas e digitais para controle dos condicionadores;
- **microcomputador e acessórios**, responsáveis pelo processamento dos sinais adquiridos e pela supervisão e controle do sistema de aquisição de dados;
- **software**, que pode ser dividido em programa supervisão/controle e programa de processamento dos sinais.

Os transdutores elétricos, no caso de plataformas fixas, são os acelerômetros, os extensômetros (*strain gages*), o ondômetro e o anemômetro. Embora o interesse seja a medida do deslocamento da plataforma devido à excitação das ondas, a faixa de frequência em que se situa a sua resposta dinâmica torna este tipo de transdutor mais apropriado. A obtenção do sinal em deslocamento é feita na fase de processamento no microcomputador. Tanto os transdutores quanto os outros componentes do *hardware* do sistema de aquisição de dados devem ter especificação apropriada para operação contínua em ambiente marinho.

O *software* de supervisão/controle é um componente extremamente importante do sistema, pois a confiabilidade e a integridade dos resultados irá depender quase que exclusivamente da sua capacidade de avaliar a qualidade dos dados armazenados. O autor, em conjunto com a sua equipe do Laboratório de Estruturas Navais da COPPE, desenvolveu um software, denominado SIAD (Sistema Inteligente de Aquisição de Dados),

para a aquisição automática de dados em plataformas de petróleo, baseado no conceito de Sistema Especialista [Charniak,1987]. O diagrama da figura III.1 fornece uma idéia básica da concepção lógica do SIAD na sua forma original [Lopes, 1989].

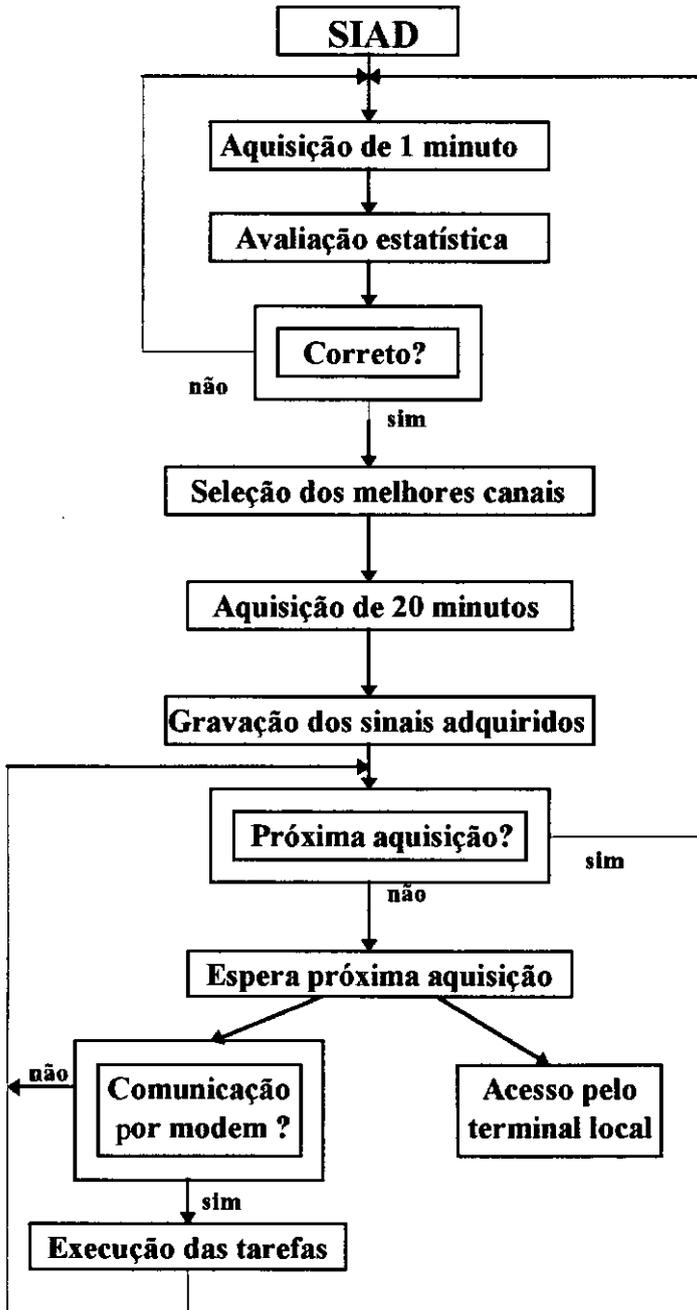


Figura III.1 - Concepção lógica do SIAD

Este sistema foi testado com êxito em uma plataforma da PETROBRAS, por um período de oito meses. O SIAD é formado pelos seguintes módulos:

- Base de Conhecimento: foram simuladas todas as hipóteses possíveis de operação do sistema, analisando-se as respostas e as providências que seriam tomadas. As bases de fatos e a base de regras foram estruturadas a partir destes testes. Na tabela 1 está apresentado um exemplo da base de regras.

Se a média de 1 min é boa
E a média quadrática de 1 min é boa
E o desvio padrão de 1 min é bom
Então o registro de 1 min é bom

Tabela 1 - Exemplo da Base de Regras

- Motor de Inferência : a partir da base de fatos e da base de regras, o objetivo do SIAD é conhecer a condição dos sinais. Na base de fatos, no objeto "sinais" e no atributo "condição", há uma série de valores que podem ser assumidos. O motor de inferência procura uma regra com "então condição dos sinais é ... ", verifica se a primeira parte da regra é um fato e, se não for, continua a procura até encontrá-lo. Como não há usuário, pergunta ao sistema se o fato é falso ou verdadeiro. Conforme a resposta, a busca prossegue ou é informado o resultado. Se o resultado indicar que a condição dos sinais não é boa, o sistema desvia a execução do programa, corrige a falha e o ciclo recomeça.

- Processamento : realiza o processamento das séries temporais adquiridas no domínio do tempo e no domínio da frequência. Os dados são armazenados em disco rígido e fita.

- Comunicação : permite o acesso de usuário autorizado via modem, através de programa que permite a execução das seguintes tarefas:

- . transmitir arquivos para o disco remoto
- . receber arquivos remotos

- . retomar transmissão ou recepção interrompidas
- . obter diretório dos arquivos remotos
- . suprimir e renomear arquivos remotos

Um refinamento que pode ser acrescentado a um planejamento dos procedimentos da aquisição de dados, no caso de excitação aleatória, é a sua otimização, através da minimização dos custos devido a falhas do sistema e o dos custos do programa de medição. As variáveis de projeto são: o número de pontos a serem medidos, a localização dos pontos e o número necessário de registros. Um exemplo deste tipo de tratamento é apresentado em [Kirkegaard,1990].

III.3 IDENTIFICAÇÃO DE PARÂMETROS

III.3.1 Introdução

A Identificação de Parâmetros é uma área extensa, com um grande número de metodologias e técnicas já disponíveis e em desenvolvimento. No caso das plataformas fixas de produção de petróleo em operação, não há possibilidade de se medir a força de excitação. A excitação artificial da sua estrutura exige condições de mar extremamente tranquilas e aparato experimental especial, o que torna este tipo de teste oneroso. Assim sendo, a metodologia que pode ser aplicada é baseada na aquisição e análise de séries temporais aleatórias, correspondentes à resposta da estrutura devido à excitação do meio ambiente, e o seu processamento por algoritmos computacionais especialmente desenvolvidos e testados para esta finalidade [Jensen,1990].

Este item apresentará, inicialmente, o método para estimativa espectral denominado Método da Máxima Entropia (MEM), identificando as suas principais características. Em seguida, apresentará a formulação para a estimativa dos parâmetros dinâmicos de interesse para o presente trabalho, que se baseiam na própria função de densidade espectral de potência MEM e na técnica da Largura de Banda a Meia-Potência. A técnica indicada será utilizada para a estimativa dos coeficientes de amortecimento modais da plataforma PGP-1, em condições reais de operação. A estimativa das frequências e modos naturais e coeficientes de amortecimento da plataforma em condições reais de operação é parte integrante da metodologia proposta neste trabalho e podem ser realizadas de forma satisfatória pelas técnicas aqui sugeridas.

III.3.2 O Método da Máxima Entropia

Considerando-se que existe uma relação entre informação e probabilidade, a entropia é uma medida das incertezas em um conjunto de probabilidades [Ables,1978]. A partir desta definição, é possível intuir que quanto maior a entropia de um sistema, maior deverá ser a quantidade de informação nele existente. Logo, um processo de máxima entropia é o processo que possui a máxima aleatoriedade possível.

Esta técnica, além de fornecer um espectro suave e de alta resolução, a partir de séries temporais de pequena duração correspondentes a sinais gaussianos estacionários, proporciona aproximações para as variâncias dos estimadores. Na estimativa espectral, os métodos convencionais partem da Transformada de Fourier das funções auto-correlação, obtidas a partir de uma série temporal finita, mostrando-se limitados na resolução devido ao truncamento da função auto-correlação e a sua extensão para o infinito com termos nulos, conforme pode ser observado na figura III.2.

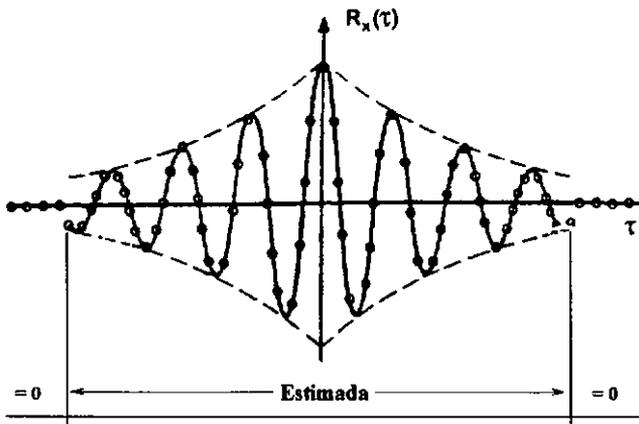


Figura III.2 - Função autocorrelação truncada

O Método da Máxima Entropia busca uma melhor resolução realizando a extensão da função autocorrelação de uma maneira consistente com o processo aleatório observado. Esta extensão é a base da estimativa espectral de entropia máxima. Na realidade, o MEM fornece meios analíticos para extrapolar, a partir de $(p-1)$ amostras da função auto-correlação conhecida, $R_x(k)$, $k = 0, 1, 2, \dots, p$, os valores remanescentes $R_x(k)$, $k = p+1, p+2, \dots, \infty$, tendo como pré-requisito o fato da sequência resultante com todos os termos ser positiva semi-definida [Ulrych,1978]. O espectro de máxima entropia $S_{\text{mem}}(f)$ é obtido pela maximização da equação (III.1) com as restrições adequadas [Marple,1987]:

$$\text{Taxa de entropia} = \int \ell_n(S_{\text{mem}}(f))df \quad (\text{III.1})$$

Nos excelentes artigos [Burg,1978a], [Burg,1978b], foi demonstrado que a extensão para infinito da função auto-correlação pode ser expressa pela seguinte equação recursiva:

$$R_x(k) = -A_1 R_x(k-1) - A_2 R_x(k-2) \dots - A_p R_x(k-p), \quad k > 0 \quad (\text{III.2})$$

onde os valores de A_i são obtidos como solução do sistema de equações:

$$\begin{bmatrix} R_x(0) & R_x(1) & \cdot & R_x(p-1) \\ R_x(1) & R_x(0) & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ R_x(p-1) & R_x(1) & R_x(0) & \cdot \end{bmatrix} * \begin{bmatrix} A_1 \\ A_2 \\ \cdot \\ \cdot \\ A_p \end{bmatrix} = \begin{bmatrix} R_x(1) \\ R_x(2) \\ \cdot \\ \cdot \\ R_x(p) \end{bmatrix} \quad (\text{III.3})$$

Portanto, para $(p-1)$ valores dados de uma função auto-correlação, é possível a determinação dos coeficientes até a p -ésima ordem e, conseqüentemente, extender-se a função auto-correlação.

Na prática, pode-se mostrar que o espectro MEM de p -ésima ordem é definido por [Haykin,1983]:

$$S_{\text{mem}}(f) = \frac{\tau_p^2 \Delta t}{\left| 1 + \sum_{k=1}^p A_k e^{-i2\pi k f \Delta t} \right|^2} \quad (\text{III.4})$$

onde:

$$- \tau_p^2 = R(0) - \sum_{k=1}^p A_k R(k) \quad (\text{III.5})$$

- Δt = incremento da amostragem

Para demonstrar praticamente a precisão na estimativa espectral pelo MEM, considerou-se como exemplo de um sistema de 1 grau de liberdade, excitado por ruído branco, e foram calculados os espectros utilizando-se o MEM e o método FFT - Transformada Rápida de Fourier, [Cooley,1965] - a partir de onze amostras referentes a intervalos de 1 segundo (resolução de 0.1 Hz). O coeficiente de amortecimento selecionado foi de 1% ($\xi = 1\%$) e a frequência natural de 0,25Hz ($f_n = 0,25\text{Hz}$). O resultado pode ser

visto na figura III.3, demonstrando claramente a precisão do MEM como estimador espectral, visto que praticamente não há diferenças em relação ao espectro exato.

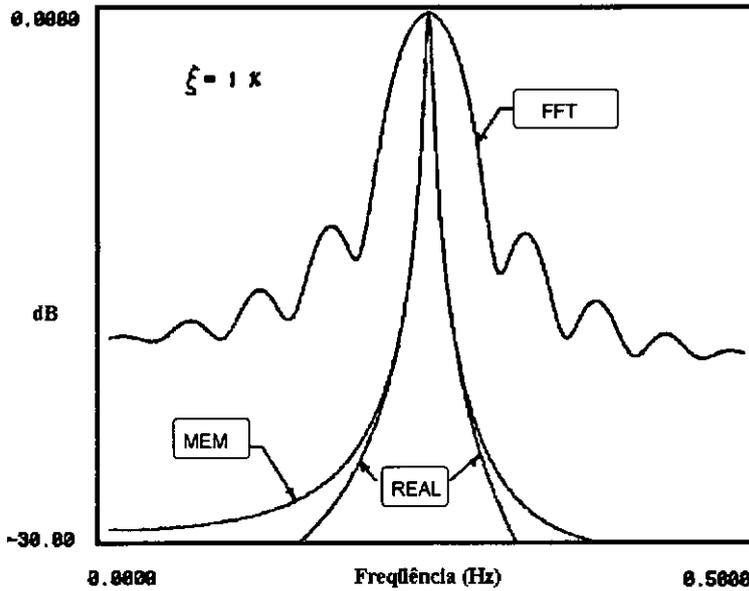


Fig. III.3 - Comparação entre espectros estimados pelo MEM e FFT

III.3.3 Estimador da Frequência Natural pelo MEM

Ao se utilizar os estimadores espectrais convencionais, que só podem ser definidos para um conjunto finito de frequências, a estimativa se reduz ao problema de escolher os picos espectrais e suas frequências correspondentes, a partir de um gráfico. A estimativa pelo MEM permite que a determinação das frequências naturais sejam feitas analiticamente, calculando-se os máximos por:

$$\frac{\partial S_{\text{mem}}(f)}{\partial f} = 0 \quad (\text{III.6})$$

Desenvolvendo-se (III.6), chega-se a seguinte expressão [Campbel,1982]

$$\sum_{k=0}^P \sum_{m=0}^P k A_k A_m \text{sen}[2\pi(m-k)f\Delta t] = 0, \quad A_0 = 1 \quad (\text{III.7})$$

na qual as frequências naturais f_n são a solução da equação, considerando-se que os coeficientes de amortecimento da estrutura são pequenos. A expressão para a estimativa da variância do estimador também está desenvolvida em [Campbel,1982].

III.3.4 Estimador do Coeficiente de Amortecimento pelo MEM

As frequências correspondentes a meia-potência do espectro são dadas pelos valores de f que satisfazem a equação:

$$S_{\text{mem}}(f) = \frac{1}{2} S_{\text{mem}}(f_n) \quad (\text{III.8})$$

cuja interpretação para um sistema com 1 grau de liberdade está mostrada na figura III.4.

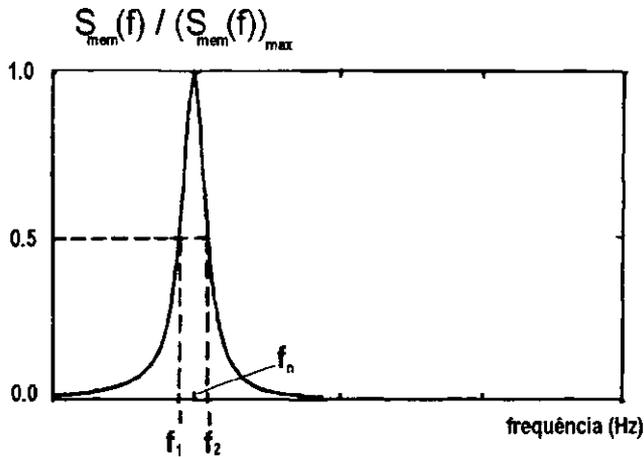


Figura III.4 - Determinação das frequências de meia-potência.

Desenvolvendo-se (III.8), obtém-se a expressão [Campbel,1982]:

$$\sum_{k=0}^P \sum_{m=0}^P A_k A_m \{ \cos[2\pi(k-m)f\Delta t] - 2 \cos[2\pi(k-m)f_n \Delta t] \} = 0, \quad A_0 = 1 \quad (\text{III.9})$$

onde a sua solução nos fornece as frequências de meia-potência f_1 e f_2 para cada frequência natural considerada.

O coeficiente de amortecimento pelo método da meia-potência, para um determinado modo natural de vibração, é definido por:

$$\xi = \frac{f_2 - f_1}{2 f_n} \quad (\text{III.10})$$

Como no caso anterior, a expressão da variância também foi desenvolvida e pode ser obtida na referência [Campbel,1982].

III.3.5 Aplicação a um Caso Real

No presente estudo, as medições foram realizadas na plataforma fixa de Garoupa, denominada PGP-1, situada na Baía de Campos - RJ, em lâmina d'água de 120m. Foram utilizados registros da Campanha de Medição 11, coletados na primeira quinzena de novembro de 1985 [Lopes,1987]. O mar incidente na plataforma foi dividido em dois tipos, conforme já definido no Capítulo II:

- predominância de *swell*, que é um estado de mar é com maior participação de ondas longas e relativamente simétricas, com períodos no entorno de 8-12 segundos, sendo produzidas por ventos e tempestades distantes do local de observação.
- predominância de *sea*, que é um estado de mar resultante da ação dos ventos atuantes na região, composto por ondas de período curto, assimétricas e agudas, com períodos na faixa corespodente a 4-10 segundos. Para períodos abaixo de 4 segundos, a densidade espectral das ondas decai continuamente, pois a altura e o período das ondas são cada vez menores, até não serem mais detectadas pelos ondômetros.

Para melhor ilustrar, são apresentados os espectros de dois registros nas figuras III.5 e III.6, um com mar predominantemente tipo *sea* (registro 23) e outro com predominância *swell* (registro 34). Estes tipos de mar ocorrem frequentemente na Baía de Campos, RJ, inclusive com ondas incidindo em direções diferentes.

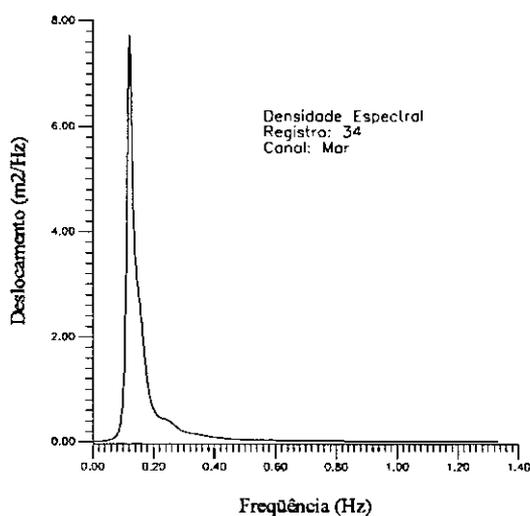


Figura III.5 - Densidade espectral de mar com predominância *swell*

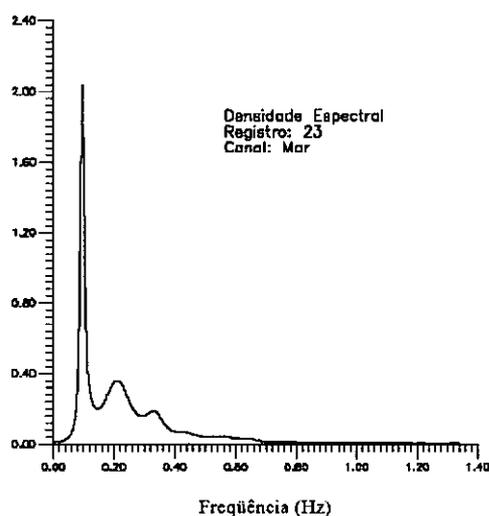


Figura. III.6 - Densidade espectral de mar com predominância *sea*

Devido a complexidade do fenômeno de geração das ondas, uma coleção de registros de altura de onda constitui um processo estocástico, sendo portanto, necessário estabelecer hipóteses simplificadoras da natureza do processo. Estas hipóteses consistem em considerá-lo estacionário e ergódico em intervalos de tempo curtos. Desta forma, as séries temporais, correspondentes a um período de tempo de aproximadamente 25 min, foram digitalizadas em registros com 4096 pontos, (frequência de amostragem = 2,67Hz).

Como o objetivo é a análise dos três primeiros modos de vibração da plataforma, foram utilizados dois pares de transdutores de aceleração, conforme ilustrado na figura III.7, sendo as séries temporais registradas em fitas magnéticas para posterior processamento.

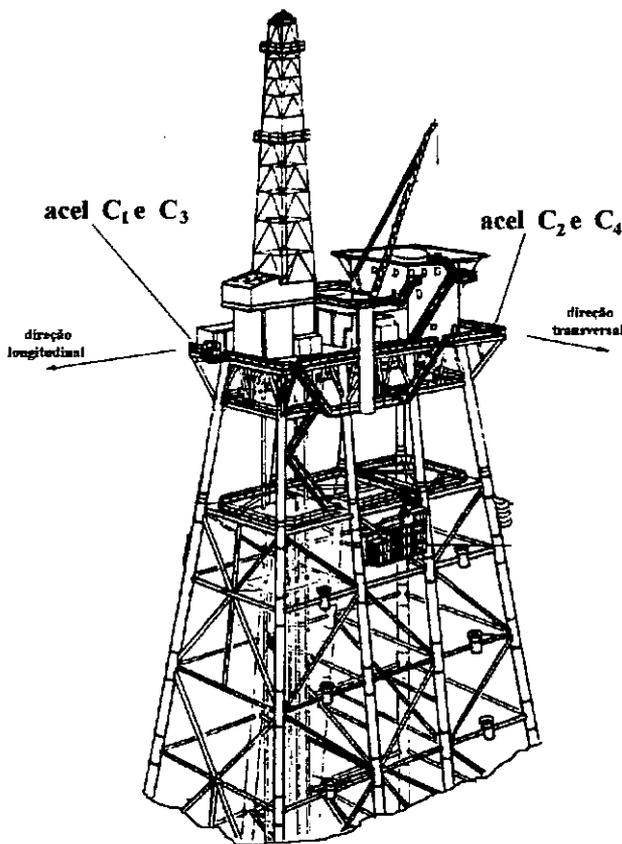


Figura III.7 - Localização dos acelerômetros

Os acelerômetros longitudinais C_1 e C_2 , detectam a menor frequência ressonante, que neste caso corresponde ao primeiro modo de flexão, direção longitudinal. Os sensores transversais C_3 e C_4 identificam a frequência ressonante seguinte, relacionada ao primeiro modo de flexão, direção transversal. Todos os sensores captam ainda um terceiro pico, correspondente ao primeiro modo de torção da jaqueta. Entretanto, os canais

transversais C_3 e C_4 identificam o modo de torção com maior clareza, uma vez que estão mais distantes do ponto central do convés da plataforma.

Observa-se, de acordo com a figura III.8, que a resposta da plataforma se divide em duas componentes. A primeira, identificada pela concentração de energia na mesma faixa de frequência do mar, é chamada de resposta direta ou quasi-estática e é registrada pelos quatro sensores. A outra é representada pelo aparecimento de picos espectrais na faixa seguinte de frequência, correspondentes às frequências naturais da estrutura. As identificações destes picos dependerá da localização do sensor, como visto anteriormente.

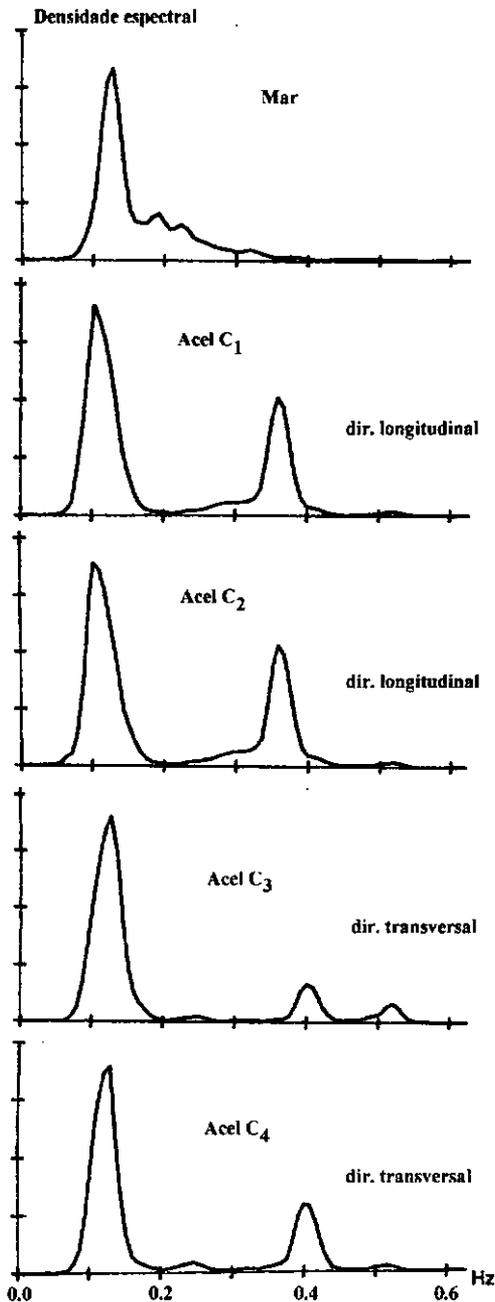


Figura III.8 - Resposta da plataforma PGP-1

A estimativa das frequências naturais e coeficientes de amortecimento foi feita utilizando-se os espectros gerados pelo MEM [Estrella,1995], com o auxílio de programas de computador desenvolvidos em [Campbell,1982]. Os resultados estão apresentados a seguir, na tabela 1.

PGP-1	Modo 1	Modo 2	Modo 3
Média	1.63	1.52	0.76
Variância	0.05	0.15	0.02

Tabela 1 - Coeficientes de amortecimento de PGP-1 (MEM) [Estrella,1995]

Em [Meniconi,1989], o cálculo do amortecimento foi feito utilizando-se o Método da Meia Potência e densidades espectrais calculadas pela FFT com janela *flat top*. Os resultados na tabela 2 mostram valores bem maiores quando comparados com a tabela 1, indicando uma estimativa pouco conservativa dos coeficientes de amortecimento (quanto maior o amortecimento, menor a tensão dinâmica), conforme esperado.

PGP-1	Modo 1	Modo 2	Modo 3
Média	4.50	4.10	3.0

Tabela 2 - Coeficientes de amortecimento de PGP-1 (FFT) [Meniconi,1989]

No trabalho desenvolvido em [Campbell,1982], é realizada uma estimativa dos coeficientes de amortecimento para a plataforma SP62C, localizada no Golfo de México, em lâmina d'água de 110 metros, com características muito semelhantes a PGP-1. Na tabela 3, são mostrados os resultados obtidos pelo MEM para os coeficientes de amortecimento. Na tabela 4, são apresentados os resultados obtidos destes coeficientes pelo método do decréscimo logarítmico, que correspondem ao ensaio em que a plataforma é excitada por força impulsiva e colocada para vibrar naturalmente, sendo então avaliado o amortecimento a partir da curva de decaimento da resposta no domínio do tempo. Embora seja um tipo de

ensaio muito difícil de ser executado para estruturas de grande porte, o seu resultado é considerado o mais preciso na prática.

SP62C	Modo 1	Modo 2	Modo 3
Média	2.10	2.0	1.30
Variância	0.60	0.60	0.40

Tabela 3 - Coeficientes de amortecimento de SP62C (MEM) [Campbell,1982]

SP62C	Modo 1	Modo 2	Modo 3
Média	1.53	1.38	1.11

Tabela 4 - Coeficientes de amortecimento de SP62C (dec. logarítmico) [Campbell,1982]

Concluimos que os valores obtidos para PGP-1 pelo MEM representam uma boa estimativa dos coeficientes de amortecimento. Estes valores serão utilizados na avaliação numérica desenvolvida no Capítulo VI deste trabalho.

III.3.6 Estimativa dos Deslocamentos Relativos

A partir das densidades espectrais, obtidas pelo MEM, é possível a obtenção de um valor proporcional à amplitude de deslocamento do ponto medido, referente a um determinado modo natural de vibração, pela seguinte expressão:

$$\text{desloc} \propto \int_{f_1}^{f_2} S_{\text{mem}}(f) df \quad (\text{III.11})$$

onde f_1 e f_2 são as frequências de meia potência.

Se esta expressão for calculada da mesma forma para todos os pontos medidos, o valor resultante poderá ser utilizado para a estimativa dos deslocamentos modais, visto que estas grandezas são, na realidade, deslocamentos relativos definidos por um

procedimento de normalização. Neste caso, considera-se sempre o quociente entre os valores calculados para o ponto em questão e o ponto de referência.

III.4 ATUALIZAÇÃO DO MODELO DINÂMICO

III.4.1 Introdução

A modelagem do comportamento dinâmico de sistemas estruturais envolveu, historicamente, duas frentes de desenvolvimento: a teórica e a experimental. Os modelos teóricos mais usuais reúnem as propriedades físicas mais relevantes do sistema (massa, rigidez e amortecimento) num conjunto de equações diferenciais de segunda ordem. Com os recursos computacionais atualmente existentes, aliados a técnicas numéricas já bem desenvolvidas, como o Método dos Elementos Finitos, tornou-se possível a modelagem de estruturas bastante complexas. Entretanto, estes modelos teóricos apresentam várias limitações, tais como: inviabilidade econômica de discretizações muito refinadas, desconhecimento parcial de propriedades físicas do sistema, etc. Tais limitações implicam em incertezas no modelo que podem torná-lo inadequado para aplicações práticas.

Do ponto de vista experimental, a obtenção do modelo dinâmico de uma estrutura se dá por meio de técnicas de Identificação de Parâmetros, sendo um exemplo específico a metodologia apresentada no item anterior. De uma forma genérica, o modelo experimental consiste, basicamente, de um conjunto de autovalores e autovetores extraídos de funções de resposta ao impulso, ou, mais comumente, de funções de resposta em frequência previamente identificadas. A estrutura passa, então, a ser representada por seus modos e frequências naturais de vibração e por coeficientes de amortecimento modais. Também, nesta área, a tarefa das equipes envolvidas com atividades experimentais tem sido bastante facilitada pelos recentes avanços da eletrônica e da informática. O contínuo desenvolvimento dos sistemas de aquisição de dados, e das técnicas de processamento digital de sinais, permite a obtenção de modelos dinâmicos experimentais cada vez mais completos, de forma rápida e a custos cada vez menores. Desta forma, uma vez garantidas condições de ensaio confiáveis, é possível representar com bastante fidelidade o comportamento dinâmico da estrutura em tese, dentro de uma faixa de frequência limitada. Ainda assim, existem várias limitações associadas a um ensaio modal: restrições de ordem prática e econômica quanto ao número de sensores utilizados, influência das condições de contorno, dificuldade matemática para a obtenção das informações a partir de uma base modal incompleta da estrutura.

As técnicas de modelagem dinâmica foram bastante aperfeiçoadas ao longo das duas últimas décadas, estando, atualmente, definitivamente incorporadas ao dia a dia de diversas indústrias e centros de pesquisa em todo o mundo. Tornou-se comum, também, a realimentação de modelos teóricos com auxílio de resultados de ensaios. Entretanto, a complexidade e as dimensões dos atuais modelos tornam praticamente impossível a compatibilização de resultados teóricos e experimentais através de simples julgamento de engenharia (experiência acumulada). Isto motivou inúmeras pesquisas com o objetivo de desenvolver algoritmos capazes de corrigir automaticamente os modelos teóricos, especialmente os modelos via Elementos Finitos, com o auxílio dos resultados da análise modal experimental. Esta abordagem é denominada Atualização de Modelos Dinâmicos.

De acordo com [Mottershead,1993], as imprecisões em um modelo teórico podem ser divididas em três categorias:

- 1) erros devido às incertezas com relação às equações que governam o comportamento físico do sistema;
- 2) erros devido à aplicação de condições de contorno inadequadas e hipóteses simplificadoras não apropriadas;
- 3) erros de discretização, em virtude da geração de malha ser deficiente para uma boa modelação da estrutura.

As técnicas de atualização dinâmica irão possibilitar a correção do modelo teórico, tendo como procedimento básico modificar as suas matrizes de massa e rigidez com o objetivo de conseguir uma boa correlação entre autovalores e autovetores calculados e medidos. Observando-se o parágrafo anterior, verifica-se que este procedimento se encaixa na segunda categoria: minimizar os erros devido às condições de contorno e às hipóteses simplificadoras. Atenção especial deve ser dada ao fato de existirem inúmeras soluções para este tipo de problema, que serão válidas apenas sob o aspecto numérico, não tendo nenhum sentido físico. Uma série de restrições deve ser aplicada ao processo de atualização, de forma que as características físicas da estrutura não sejam distorcidas [Janter,1989].

A atualização do modelo dinâmico poderia partir da hipótese de que os resultados experimentais são perfeitos, sem nenhum tipo de erro, fato este que não condiz com a realidade. Os resultados experimentais também possuem imprecisões, causadas principalmente pelo ruído (interferências eletromagnéticas) existente no ambiente em que opera um sistema digital de aquisição de sinais, que devem ser devidamente consideradas no processo de atualização das matrizes de massa e rigidez.

III.4.2 Correlação Teórico-Experimental

A partir da correlação dos resultados teóricos e experimentais, que consiste na comparação qualitativa e quantitativa entre os modelos teórico e experimental, é conduzida a atualização do modelo teórico, partindo-se da premissa que o modelo experimental é confiável. Algumas formas de proceder esta comparação são:

- **Comparação das frequências naturais:** a forma mais prática de comparar as frequências naturais é através de um gráfico teórico \times experimental. Idealmente, os pontos devem estar sobre a reta de inclinação de 45° , passando pela origem. Pontos em uma reta distinta da anterior indicam, normalmente, erros sistemáticos no modelo teórico. Pontos demasiadamente espalhados implicam, obviamente, em baixa correlação entre os modelos.
- **Comparação dos modos naturais:** a verificação da correlação entre os modos naturais e experimentais é, sem dúvida, a que permite os mais diferentes métodos de avaliação. Deformadas modais desenhadas lado a lado são as primeiras informações a respeito dos modos. Recursos gráficos computacionais, como animação e *hidden lines*, facilitam a visualização dos modos em estruturas complexas. Entretanto, torna-se necessário quantificar o grau de correlação. As técnicas mais comumente usadas com este objetivo são:

◦ MAC : esta sigla vem de *Modal Assurance Criteria* e a sua expressão, de acordo com [Allemandy,1983], é:

$$MAC_{ij}^{EC} = \frac{|(\phi_i^C)^t(\phi_j^E)|^2}{(\phi_i^C)^t(\phi_i^C) (\phi_j^E)^t(\phi_j^E)} \quad (III.12)$$

onde ϕ_i é o modo de vibração i , E \rightarrow experimental e C \rightarrow calculado.

Valores $|MAC|_{i=j} \approx 1$ e $|MAC|_{i \neq j} \approx 0$ indicam uma boa correlação entre os modos experimentais e teóricos. É importante ressaltar que esta forma de comparação pressupõe compatibilidade entre as coordenadas dos modos teórico e experimental. A situação ideal corresponde a todos os pontos da medida estarem representados como nós do modelo de elementos finitos da estrutura. Diversos métodos têm sido desenvolvidos com este fim, baseados em reduções, interpolações e expansões de modos, conforme apresentado nas referências [Kidder,1973], [Lieven,1990] e [He,1991].

° Ortogonalidade: a expressão deste indicador é:

$$\mathbf{ORT}^{EC} = (\Phi^C)^t (\mathbf{M}^C) (\Phi^E) \quad (\text{III.13})$$

onde \mathbf{M} é a matriz de massa e Φ é a matriz modal.

Para modos com normalização de massa unitária, uma indicação de boa correlação é a matriz identidade.

° COMAC: esta sigla vem de *Coordinate Modal Assurance Criterion*. É um indicador do grau de correlação de um conjunto de modos teóricos e experimentais ao longo da sua geometria. A sua expressão é [Ewins,1988]:

$$\text{COMAC}_i = \frac{\left(\sum_{k=1}^K |\phi_{ik}^C \phi_{ik}^E| \right)^2}{\sum_{k=1}^K (\phi_{ik}^C)^2 \sum_{k=1}^K (\phi_{ik}^E)^2} \quad (\text{III.14})$$

Valores de $\text{COMAC} < 0.9$ indicam discrepâncias entre os modelos nas regiões correspondentes da estrutura. Este indicador pode também ser usado para uma localização preliminar de regiões de erro na estrutura, para posterior aplicação de algoritmos de atualização do modelo (ϕ_{ik} são os elementos da matriz modal).

A análise dos indicadores para avaliação da correlação, entre os modos de vibração medido e calculado, de uma plataforma de petróleo, na qual é possível se medir apenas as três primeiras frequências naturais e os deslocamentos em poucos pontos da estrutura, permite concluir que seria difícil a sua aplicação prática. O MAC seria equivalente a uma matriz de ordem 3, da mesma forma como a matriz **ORT**. O COMAC ainda poderia dar uma informação um pouco melhor, mas o pequeno número de pontos medidos é uma restrição importante.

III.4.3 Técnicas para Atualização do Modelo Dinâmico

As técnicas para a atualização do modelo dinâmico podem ser interpretadas como uma aplicação da teoria de Estimação de Parâmetros [Natke,1988] em estruturas, onde a descrição numérica do modelo estrutural é dada pelas equações matriciais do Método dos Elementos Finitos. Uma das formas de se realizar esta atualização consiste em

se utilizar de uma função penalidade com o objetivo de maximizar a correlação entre os modelos teórico e experimental. Estes métodos permitem uma ampla seleção de parâmetros para serem atualizados, mas a otimização de funções não lineares requer procedimentos iterativos, com a possível ocorrência de problemas de convergência. Outrossim, os esquemas iterativos implicam na reavaliação do modelo teórico a cada iteração. Quando as variações nos parâmetros selecionados com as iterações torna-se pequena, uma boa estimativa do modelo teórico atualizado é alcançada. Estes métodos geralmente são baseados na utilização de uma Série de Taylor referente aos autovalores e autovetores, que é truncada para produzir a seguinte aproximação linear:

$$\delta z = S_a \delta p \quad (III.15)$$

onde δp é a perturbação nos parâmetros, δz é a perturbação na variável medida e S_a é a matriz de sensibilidade dos parâmetros.

A matriz de sensibilidade dos parâmetros contém a primeira derivada da expressão dos autovalores e autovetores com respeito aos parâmetros. O cálculo desta derivadas exige um grande esforço computacional, sendo recomendado a utilização de procedimentos numéricos eficientes para a sua obtenção. Em [Fox,1968] é desenvolvida a formulação da derivada do autovalor λ_i com respeito a o parâmetro p_j , obtendo-se:

$$\left(\frac{\partial \mathbf{K}}{\partial p_j} - \lambda_i \frac{\partial \mathbf{M}}{\partial p_j} \right) \phi_i - \frac{\partial \lambda_i}{\partial p_j} \mathbf{M} \phi_i + (\mathbf{K} - \lambda_i \mathbf{M}) \frac{\partial \phi_i}{\partial p_j} = 0 \quad (III.16)$$

Premultiplicando-se a expressão (III.16) por ϕ_i^t e usando a propriedade de ortogonalidade em relação a massa e a definição do problema de autovalor, é obtida a expressão:

$$\frac{\partial \lambda_i}{\partial p_j} = \phi_i^t \left(\frac{\partial \mathbf{K}}{\partial p_j} - \lambda_i \frac{\partial \mathbf{M}}{\partial p_j} \right) \phi_i \quad (III.17)$$

A expressão (III.17) é fácil de ser calculada, pois requer apenas 1 autovalor e o correspondente autovetor. A derivada dos autovetores é mais difícil de ser calculada e também em [Fox,1968] são apresentados dois métodos para a sua obtenção. O primeiro método envolve o uso da equação (III.16) em conjunto com uma equação baseada na condição de ortogonalidade em relação a massa, gerando $n+1$ equações com relação as n derivadas dos autovetores a serem determinadas. Este conjunto de equações é resolvido usando a técnica denominada pseudo- inversa. As características de largura de banda são alteradas e, conseqüentemente há perda de eficiência computacional. Em [Nelson,1976] é

sugerido um algoritmo semelhante, que mantém as características originais de largura de banda. No segundo método descrito em [Fox,1968], a derivada dos autovetores é expressa como uma combinação linear de todos os autovetores, onde os coeficientes são calculados usando a expressão (III.16) e a derivada da condição de ortogonalidade em relação a massa. Em [Lim,1987] é apresentado um método aproximado, que considera apenas os autovetores correspondentes às frequências mais baixas no cálculo da derivada. Existem outras formulações que também podem ser utilizadas para a obtenção da matriz de sensibilidade, conforme apresentado em [Ojalvo,1987] e [Tan,1989].

Tanto as frequências naturais quanto os modos naturais de vibração devem ser utilizados no processo de atualização, visto que os resultados deste processo serão mais precisos. Porém, os modos naturais são usados com cautela devido às imprecisões nos dados experimentais. Na obtenção das frequências naturais é possível se garantir uma precisão melhor do que 1%, mas no caso dos modos, podem ocorrer erros de até 20% em alguns componentes do vetor modal [Dascotte,1990]. Desta forma, a utilização dos modos naturais deve ser acompanhada de critérios que garantam a sua precisão.

Na expressão (III.15) o número de parâmetros e de dados medidos geralmente não é igual e, conseqüentemente, a matriz de sensibilidade S_a não é quadrada. Considerando o caso em que o número de dados medidos excede o número de parâmetros a ser utilizado, a solução é obtida pela minimização do erro quadrático e os parâmetros atualizados podem ser calculados por [Mottershead,1993]:

$$\delta p = V_p S_a^t (S_a^t V_p S_a + V_z)^{-1} \delta z \quad (III.18)$$

sendo a variância do parâmetro atualizado dada por:

$$V_p^a = V_p - V_p S_a^t (S_a^t V_p S_a + V_z)^{-1} S_a V_p \quad (III.19)$$

onde V_p é a variância dos parâmetros e V_z é a variância dos dados medidos.

Vários *softwares* comerciais [Dascotte,1989], [LMS,1991] são baseados no procedimento descritos nas equações (III.18) e (III.19). Estes procedimentos podem ser interpretados como uma Inferência Bayesiana [Tarantola,1987]. Os estimadores bayesianos são determinados pela fórmula de Bayes, que fornece a densidade de probabilidade de ocorrência dos parâmetros atualizados em função da distribuição dos parâmetros originais e dos dados medidos, considerando-se processos gaussianos. A grande dificuldade prática na aplicação deste método é a determinação das matrizes V_p e V_z , visto que só se utiliza um conjunto de dados medidos e dados calculados e, desta forma, não se conhece a sua

distribuição. Na prática, a partir da estimativa da incerteza existente nos resultados teóricos e experimentais são montadas as matrizes de variância, sendo que, em alguns casos, trata-se mais de uma questão de arte do que de ciência. Em [Blakely,1984] e [Friswell,1989] são apresentadas diretrizes para esta avaliação.

As técnicas de atualização não devem ser utilizadas para corrigir os elementos das matrizes de massa e rigidez diretamente, pois este tipo de alteração pode mascarar o significado físico do erro existente no modelo teórico e pode conduzir a matrizes de massa e de rigidez sem a devida correspondência física. Entretanto, os elementos da matriz de massa, referentes às massas concentradas nos conveses e às massas adicionadas na jaqueta (efeito hidrodinâmico), e os elementos da matriz de rigidez, correspondentes às condições de contorno, que no caso de plataformas fixas são possíveis fontes de imprecisão no modelo teórico, podem ser considerados como parâmetros específicos para atualização.

A partir desta constatação, será desenvolvida uma técnica alternativa para a atualização do modelo teórico, baseado em **redes neurais**. A rede neural irá simular a matriz de sensibilidade dos parâmetros S_p , o conjunto de dados de entrada da rede (variação de frequências e modos de vibração) corresponderá à perturbação da variável medida δz e o conjunto de dados de saída da rede (variação de massa concentrada ou condição de contorno) irá equivaler a perturbação do parâmetro δp . A avaliação numérica desta técnica alternativa está apresentada no Capítulo VI.

Capítulo IV

FADIGA EM ESTRUTURAS OFFSHORE

IV.1 INTRODUÇÃO

O processo de fadiga é um fenômeno que ainda não está perfeitamente explicado pela Engenharia. Embora a utilização intensiva de métodos computacionais e resultados experimentais permita a obtenção de estimativas com um maior ou menor grau de confiabilidade, um breve histórico referente à evolução do conhecimento sobre este fenômeno é útil para a sua melhor compreensão.

As falhas devidas às ações de cargas cíclicas foram inicialmente reportadas nas ferrovias, na década de 1940 [Fuchs,1980]. O termo fadiga surgiu, inclusive, nesta época. Na Alemanha, nas décadas de 1850 e 1860, foram desenvolvidos diversos testes de laboratório, referentes aos problemas ocorridos nas ferrovias, que são reconhecidos como a origem das curvas S-N.

Na década iniciada em 1920, foram identificadas algumas propriedades referentes à propagação das trincas, sendo o trabalho desenvolvido por [Griffith,1920] reconhecido como a origem dos conceitos de fratura mecânica. No ano de 1927, foi publicado o primeiro manual onde o processo de fadiga dos metais está apresentado de forma bem explicada [Moore,1927].

Em 1945, Miner formulou o critério da acumulação linear do dano de fadiga, a partir de estudos já iniciados por Palmgreen. Esta formulação, atualmente conhecida como **Regra de Miner**, é considerada como o método mais eficiente para a previsão do dano de fadiga [Miner,1945], [Palmgreen,1924].

Na década de 1950, com o advento do microscópio eletrônico, foi formulado o conceito do fator de intensidade de tensões ΔK [Irwin,1957], que é considerado como a base da Mecânica da Fratura Linear.

No início da década de 1960, Paris e Erdogan demonstraram que a taxa de crescimento de uma trinca - da/dN - é proporcional ao fator de intensidade de tensões ΔK . O critério desenvolvido é conhecido como **Regra de Paris** [Paris,1963].

IV.2 CONCEITO DE FADIGA

A definição de fadiga está apresentada em diversos trabalhos, podendo ser destacado o seguinte texto [ASTM,1972]:

"The process of progressive localized permanent structural change occurring in a material subject to conditons which produce fluctuating stresses and strains at some point or points and which may culminate in cracks or complete fracture after a sufficient number of fluctuations"

Conforme definido, o processo de fadiga é progressivo e localizado, o que implica que irá ocorrer ao longo de um determinado período de tempo e em algumas regiões críticas da estrutura, de acordo com os mecanismos inerentes à sua ocorrência.

Sob o enfoque destes mecanismos, são definidos três modos para identificar as formas de crescimento de uma trinca de fadiga, conforme indicado na figura IV.1. O modo I é o mais comum embora, na prática, ocorram combinações destes modos, principalmente I e III. O fator de intensidade de tensões ΔK é função do modo de crescimento da trinca e quando é usado sem referência está relacionado ao modo I.

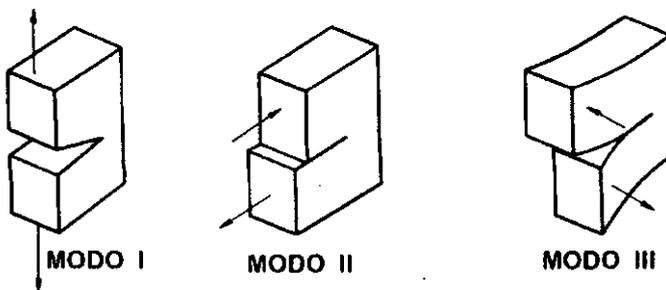


Figura IV.1 - Modos de crescimento de uma trinca

De acordo com [Almar-Naess,1985], a evolução da trinca de fadiga é dividida em três estágios: iniciação ou nucleação da trinca, crescimento estável e falha final. No caso de juntas soldadas, o processo é dominado pelo segundo estágio, que consiste no crescimento estável da trinca.

Um cordão de solda, mesmo bem executado, apresenta defeitos microscópicos tais como falta de penetração da solda e mordedura. Estes defeitos, sob a ação de solitação cíclica, podem crescer e se conectar a outros defeitos, gerando uma trinca macroscópica. Nas juntas soldadas, o estágio de nucleação da trinca representa uma parcela mínima do tempo total do processo de fadiga. A trinca só começa a crescer se os defeitos forem superiores a um tamanho crítico, dependendo também das variações das tensões atuantes. Existe um valor de tensão, denominado de limite de resistência à fadiga, abaixo do qual o fenômeno não se processa.

O crescimento de trincas de fadiga em juntas tubulares se processa no modo de fratura I, de abertura, em um plano perpendicular à direção da tensão principal máxima. Normalmente, a trinca se inicia no pé do cordão de solda e progride rapidamente junto à superfície, devido à concentração de tensões e defeitos naquela região.

A figura IV.2 mostra o gráfico da taxa de crescimento da trinca com o número de ciclos N em função da faixa de intensidade de tensões ΔK , sob forma logarítmica, onde se pode observar os três estágios já identificados.

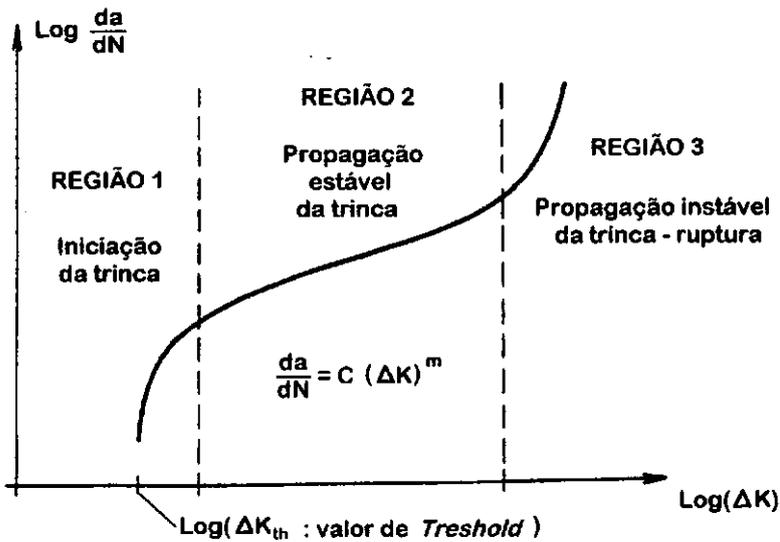


Figura IV.2 - Gráfico da taxa de crescimento de uma trinca

O trecho médio da curva, relativo ao crescimento estável da trinca, pode ser aproximado por uma linha reta, cuja expressão matemática é conhecida como Lei de Paris e está apresentada na equação (IV.1).

$$\frac{da}{dN} = C(\Delta K)^m \quad (\text{IV.1})$$

onde C e m são constantes do material.

Quando o modo de propagação da trinca é o de abertura, o seu crescimento só ocorre sob a ação de tensões de tração. As juntas soldadas das jaquetas das plataformas normalmente não sofrem tratamento térmico de alívio de tensões. No cordão de solda permanecem tensões residuais de tração elevadas, podendo chegar ao limite de escoamento do material.

Assume-se então [Gurney,1979] que, mesmo que a junta como um todo esteja sob variação de tensões compressivas, particularmente no pé do cordão da solda, haverá variação das tensões de tração. Esta hipótese implica em se considerar que a propagação das trincas irá depender apenas da variação das tensões, não importando a tensão média.

IV.3 MODELO ESTOCÁSTICO DE FALHA POR FADIGA

No caso de estruturas submetidas à ação de cargas ambientais, tais como plataformas offshore, a avaliação do dano de fadiga pode ser obtida a partir da densidade espectral das tensões, conforme demonstrado a seguir.

IV.3.1 Distribuição das Amplitudes de Tensão

Para um período curto de tempo, o estado de mar é assumido como um processo gaussiano estacionário de média zero. Utilizando-se uma formulação linear para o carregamento proveniente das ondas e modelando-se a resposta da estrutura como linear, as tensões resultantes nas juntas da plataforma poderão ser descritas por um processo que também será gaussiano estacionário de média nula.

O fator de irregularidade α , para um sinal aleatório no domínio do tempo, é definido como a relação entre o período médio da ocorrência de picos e o período médio referente ao cruzamento ascendente do nível médio. Desta forma, $1/\alpha$ será equivalente ao número de picos entre um cruzamento ascendente e o cruzamento descendente consecutivo do nível médio. Se $\alpha \approx 1$, o processo é de banda estreita, e se $\alpha \approx 0$, o processo é de banda larga.

Pode ser demonstrado que, no caso mais geral, a distribuição de amplitudes U de um processo gaussiano estacionário pode ser representada pela distribuição de densidade de probabilidade de Rice, cuja expressão é a seguinte [Lin,1967]:

$$p(\Delta S) = \sqrt{1-\alpha^2} \rho_{\text{Gauss}}\left(\frac{\Delta S}{\sigma_g \sqrt{1-\alpha^2}}\right) + \frac{\alpha \Delta S}{\sigma_g} e^{-\frac{\Delta S^2}{\sigma_g^2}} P_{\text{Gauss}}\left(\frac{\alpha \Delta S}{\sigma_g \sqrt{1-\alpha^2}}\right) \quad (\text{IV.2})$$

onde σ_g é o desvio padrão do processo e ρ_{Gauss} e P_{Gauss} são as distribuições de densidade de probabilidade e de probabilidade gaussianas, respectivamente.

Pode ser demonstrado que se $\alpha=0$ na equação (IV.2), a distribuição dos picos será a de Gauss e, se $\alpha=1$, a distribuição de picos será a de Rayleigh. Porém, verifica-se que para o caso de plataformas offshore, a distribuição de amplitudes não seguirá nenhuma destas expressões [Chaudhury,1985].

No caso da distribuição de tensões para o processo de banda larga, que é característico das plataformas offshore, a técnica utilizada para a contagem dos ciclos e identificação dos picos é extremamente importante para a precisão da estimativa do dano de fadiga.

No trabalho desenvolvido em [Sigurdson,1989] são calculadas as distribuições de picos para as técnicas de contagem denominadas *Rainflow* e *Range Counting* [Gurner,1978], comparando-as com a distribuição de Rayleigh. Um exemplo deste estudo está apresentado na figura IV.3.

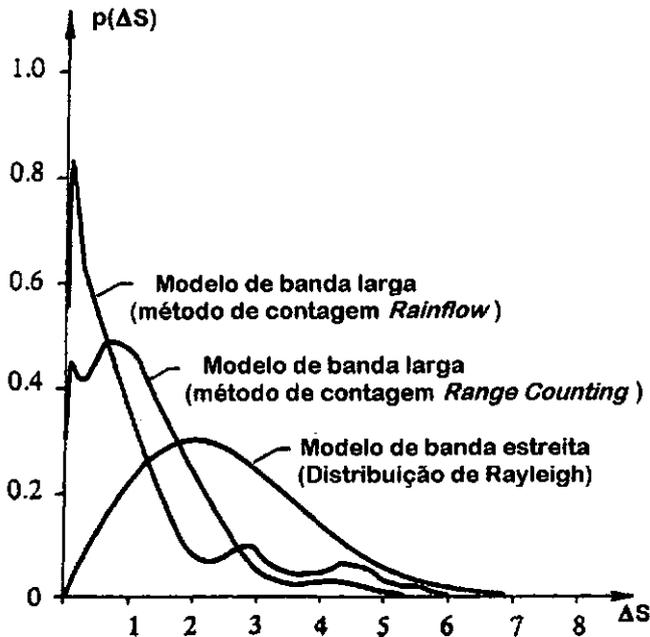


Figura IV.3 - Distribuições de amplitude de tensão em processos aleatórios

Embora o método de contagem *Rainflow* seja considerado o mais apropriado para os sinais aleatórios típicos da resposta de plataformas de petróleo à ação das ondas, não deve ser ignorada a observação de [Sigurdson,1989] de que o modelo para a estimativa de fadiga deve ser calibrado caso a caso.

A partir das expressões da densidade espectral de tensões é possível a determinação do dano de fadiga, para processos de banda larga, visto que as propriedades estatísticas destes processos são representadas de forma adequada pelos momentos de ordem n das densidades espectrais, dados por (IV.3):

$$M_n = \int_0^{\infty} \omega^n S_{ten}(\omega) d\omega \quad (IV.3)$$

onde ω é a frequência em rad/s.

A variância σ_{ten}^2 do processo é calculada por:

$$\sigma_{ten}^2 = M_0 = \int_0^{\infty} S_{ten}(\omega) d\omega \quad (IV.4)$$

O período médio de cruzamento ascendente do nível médio é [Lin,1967]:

$$T_z = 2\pi \sqrt{\frac{M_0}{M_2}} = 2\pi \sqrt{\frac{\int_0^{\infty} S_{ten}(\omega) d\omega}{\int_0^{\infty} \omega^2 S_{ten}(\omega) d\omega}} \quad (IV.5)$$

O período médio da ocorrência de picos é [Lin,1967]:

$$T_{mp} = 2\pi \sqrt{\frac{M_2}{M_4}} = 2\pi \sqrt{\frac{\int_0^{\infty} \omega^2 S_{ten}(\omega) d\omega}{\int_0^{\infty} \omega^4 S_{ten}(\omega) d\omega}} \quad (IV.6)$$

Visto que as amplitudes de tensões nas juntas variam de forma aleatória, uma questão importante a ser resolvida é a forma de considerar estas tensões. A utilização de uma faixa equivalente de tensões permite uma boa aproximação para este problema e a sua expressão é [Dover,1979]:

$$\Delta S_{eq} = \left(\sum_{i=1}^N \frac{\Delta S_i^m}{N} \right)^{\frac{1}{m}} \quad (IV.7)$$

onde N é o número total de ciclos de tensões e m uma propriedade do material.

A expressão (IV.7) não considera o efeito da sequência dos carregamentos, o que conduz a estimativas que podem ser conservativas ou não do dano de fadiga. De acordo com [Berge,1993], os efeitos da interação dos ciclos de carregamento podem acelerar ou retardar o crescimento da trinca, dependendo do ciclo imediatamente anterior.

Existem várias formulações para a determinação da expressão da faixa equivalente de tensões a partir dos parâmetros espectrais, conforme apresentado nas referências [Wirshing,1977], [Tuna,1986] e [Skjong,1987]. O tratamento dado por [Chaudhury,1985] parece o mais adequado, porque não limita as propriedades estatísticas referentes às densidades espectrais de tensões aos tipos de distribuições estatísticas geralmente adotadas neste tipo de avaliação. A expressão desenvolvida [Chaudhury,1985] para o cálculo de ΔS , apresenta resultados muito próximos dos valores obtidos pela técnica de contagem *Rainflow*.

No presente trabalho, como o cálculo da fadiga tem como objetivo identificar as juntas de plataformas offshore onde o dano de fadiga evolui mais rapidamente, isto é, é um cálculo relativo de fadiga, as possíveis diferenças nas abordagens da faixa de tensões equivalentes não irão, certamente, modificar o resultado final da avaliação.

IV.3.2 Estimativa do Dano de Fadiga pela Regra de Miner

A previsão da fadiga pela Regra de Miner é baseada nas curvas S-N. Devido à impossibilidade de avaliar a resistência à fadiga das juntas soldadas através de testes nas estruturas reais, foi necessário basear-se o cálculo da fadiga nos resultados de testes e ensaios obtidos para algumas juntas que resultaram nas curvas S-N. Estas curvas relacionam a amplitude da variação das tensões com o número de ciclos que leva ao colapso, tendo sido obtidas através de dados experimentais em laboratórios e estruturas, analisados estatisticamente, para vários tipos de juntas, situadas no ar ou expostas à água do mar, com proteção contra corrosão [UEG/CIRIA,1985].

Para cada tipo característico de junta soldada e situação de carregamento, há uma curva S-N específica, havendo ainda uma distinção entre as curvas que se referem a um tipo particular de junta, onde o fator de concentração de tensões já está implícito, e curvas mais gerais, onde o fator de concentração de tensões deve ser calculado.

Estas curvas são expressas por uma relação linear entre os logaritmos da faixa de tensões e do número de ciclos N , da forma:

$$\log N = \log C_1 - d \log \sigma - m_{sn} \log \Delta S \quad (IV.8)$$

onde ΔS é a amplitude da faixa da variação de tensões, N é o número de ciclos que produz fadiga para a faixa de tensões ΔS , C_1 é a constante relativa à curva S-N média, d é o número de desvios-padrão abaixo da média, $\log \sigma$ é o desvio padrão do $\log N$ e m_{sn} é o inverso da declividade da curva S-N.

Observa-se que, devido ao caráter exponencial das curvas S-N, uma pequena variação na avaliação do valor das tensões pode fornecer grandes variações no valor de N e conseqüentemente no dado e na vida útil. Também a escolha da curva adequada, em função do tipo de junta, qualidade da solda, carregamento e condições de exposição, influenciam na avaliação da vida útil.

A curva S-N de projeto é definida de maneira tal, que em 97.5% dos casos indique um número menor de ciclos do que o número efetivamente necessário para fadigar uma junta sujeita a uma dada variação de tensões. Existem curvas S-N propostas por diferentes Entidades, como a curva X da *American Welding Society* (AWS) e a curva T do *Department of Energy* (DoE) da Inglaterra.

As curvas S-N de juntas tubulares normalmente adotam um limite de resistência à fadiga, abaixo do qual o fenômeno não ocorre. A curva T do DoE não possui este limite, com a justificativa de que os testes realizados não são em número suficiente para corroborar aquela hipótese, pois o tempo e o custo necessários são proibitivos.

Os testes foram realizados com carregamentos cíclicos de amplitude constante, quando na realidade as juntas estão sujeitas a carregamentos randômicos. O comportamento das juntas na condição de carga variável ainda é pouco conhecido e os poucos ensaios realizados indicam que a falha da junta pelo critério do dano acumulado de Miner ocorrerá com [Ibso,1993]:

$$D = \sum_i \frac{n_i}{N_i} \leq (0.40 \approx 0.85) \quad (IV.9)$$

o que indica que o critério geralmente aplicado - $D \leq 1$ - pode conduzir a resultados não conservativos na previsão do dano de fadiga.

No presente trabalho é adotada a curva T de projeto [DoE,1984], cuja expressão é dada por:

$$N \left(\frac{\Delta S}{f_c} \right)^3 = 1.45 \times 10^{12} \quad \text{para } N \leq 10^7 \text{ ou } \Delta S \geq 53 \text{ MPa} \quad (\text{IV.10})$$

e

$$N \left(\frac{\Delta S}{f_c} \right)^5 = 4.07 \times 10^{15} \quad \text{para } N \geq 10^7 \text{ ou } \Delta S \leq 53 \text{ MPa} \quad (\text{IV.11})$$

onde o fator f_c permite corrigir as curvas para espessuras distintas do valor padrão adotado 32 mm e MPa é equivalente a N / mm^2 .

A figura IV.4 mostra o gráfico da curva T básica do DoE, podendo ser observada a mudança de inclinação na região de alto número de ciclos.

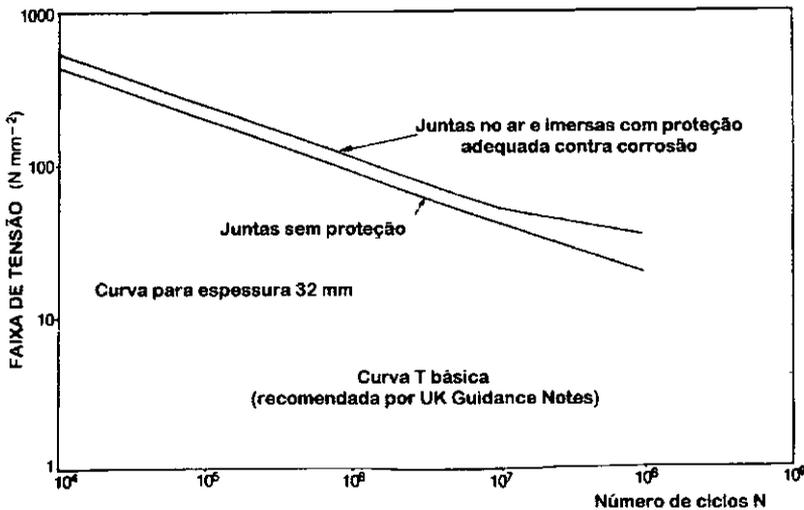


Figura IV.4 - Gráfico da Curva T básica do DoE

Se houver uma falha no sistema de proteção catódica, a corrosividade do meio marinho pode agravar os defeitos anteriormente existentes no cordão de solda. Também é possível a ocorrência de um processo de corrosão-fadiga na ponta de uma trinca. Nestes casos, adota-se uma curva ainda mais rigorosa, estendendo-a diretamente para a região de alto ciclo.

Considerando-se a densidade espectral de tensões com o um processo gaussiano estacionário de média nula, o valor esperado do dano de fadiga para um período de tempo T , é dado por [Sigurdson, 1989]:

$$E[D_T] = \frac{T}{T_{mp}} \int_0^{\infty} \left(\frac{\Delta S_i}{C_1} \right)^{m_m} p(\Delta S) dS \quad (\text{IV.12})$$

onde $p(\Delta S)$ é a função de distribuição de densidade de probabilidade de tensões.

Considerando-se [Chaudhury, 1985], a expressão para o dano de fadiga é:

$$D_T = \frac{\Gamma \sqrt{\frac{M_4}{M_2}} \left(\frac{\varepsilon^{m_{sn}+2}}{2\sqrt{\pi}} \Gamma\left(\frac{m_{sn}+1}{2}\right) + \frac{3\alpha}{4} \Gamma\left(\frac{m_{sn}+2}{2}\right) \right) (2\sqrt{2M_0})^{m_{sn}}}{A_{sn} f_c^{m_{sn}}} \quad (IV.13)$$

onde:

- α é o fator de irregularidade ($\alpha = \frac{T_z}{T_{mp}}$);
- ε é o parâmetro de largura de banda ($\varepsilon = \sqrt{1-\alpha^2}$);
- Γ é a função gama;
- A_{sn} , m_{sn} e f_c são os parâmetros da curva S-N.

A figura IV.5 mostra a função densidade espectral de tensão referente a uma série temporal de registros realizados na plataforma PGP-1, Bacia de Campos [Meniconi, 1989], confirmando que o processo é de banda larga.

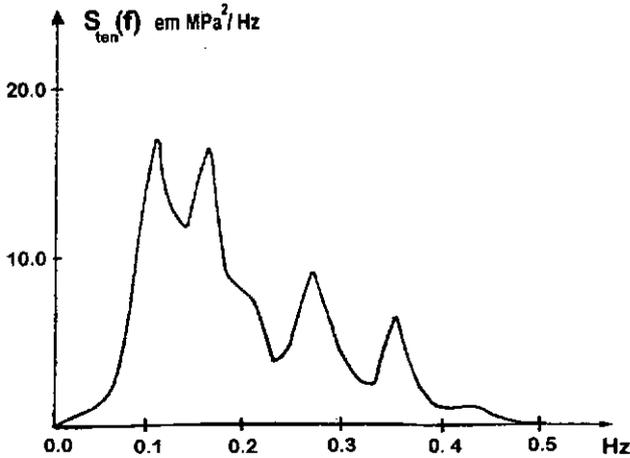


Figura IV.5 - Densidade Espectral de tensões (PGP-1)

No trabalho desenvolvido em [Meniconi,1989] foi executado o cálculo do dano de fadiga para 36 registros, considerando a série temporal, a correspondente contagem de ciclos pela técnica *Rainflow* e a expressão (IV.13). O gráfico da figura IV.6 indica a correlação entre os dois resultados, confirmando a indicação de diversos pesquisadores referente à boa concordância entre os cálculos realizados pelos dois métodos.

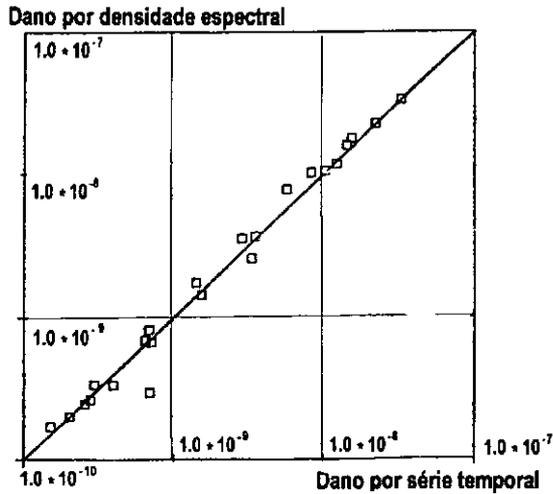


Figura IV.6 - Comparação de cálculos do dano de fadiga

IV.3.3 Estimativa do Dano de Fadiga pela Regra de Paris

A Mecânica da Fratura tem como objetivo definir as condições locais de tensão e deformação em torno de uma trinca a partir dos parâmetros de carga, geometria e outros, e prever o seu crescimento. Na mecânica da fratura linear, o parâmetro fundamental é o fator de intensidade de tensão, cuja expressão é [Paris,1963]:

$$\Delta K = Y(a) \Delta S \sqrt{\pi a} \quad (\text{IV.14})$$

onde ΔS é a amplitude de tensão, $Y(a)$ é um fator de correção e a é a profundidade da trinca.

A determinação do fator de intensidade de tensão para defeitos localizados em juntas tubulares é uma tarefa extremamente difícil, devido à complexidade inerente à forma geométrica e às características da distribuição local de tensões. Deste modo, fica evidente a necessidade de se dispor de expressões simplificadas para a determinação do fator de intensidade de tensão, de forma semelhante aos procedimentos desenvolvidos para o fator de concentração de tensões.

A expressão simplificada deveria considerar os fatores: posição da trinca, comprimento e profundidade da trinca, interação de trincas adjacentes, variação das tensões através da espessura e direções radiais e tensões residuais.

Desta forma, a expressão do fator de intensidade de tensão deveria ser :

$$\Delta K = Y_E Y_S Y_W Y_G Y_K \Delta S \sqrt{\pi a} \quad (\text{IV.15})$$

onde cada um dos coeficientes Y_i considerados estaria representando os fatores indicados. Porém, uma abordagem simplificada pode ser assumida e, de acordo com [Madsen,1987], o fator de correção a ser aplicado é uma função derivada a partir da teoria de placas com incorporação do efeito de amplificação causado pela solda. Na figura IV.7, está apresentado um gráfico de $Y(a)$ em função do quociente entre a profundidade da trinca e a espessura da chapa.

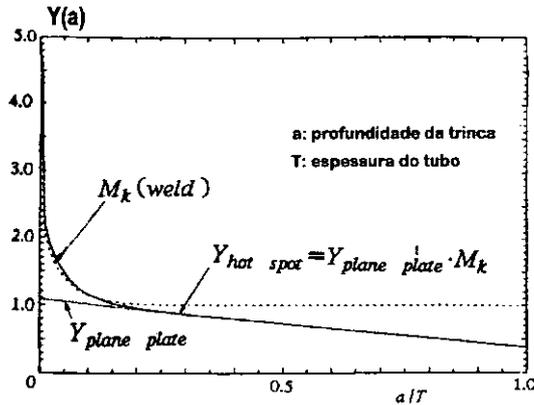


Figura IV.7 - Fator de correção $Y(a)$ [Madsen,1987]

O crescimento das trincas de fadiga pode ser representado pela expressão desenvolvida por Paris e Erdogan [Paris,1963]:

$$\frac{da}{dN} = C \left(Y(a) \Delta S \sqrt{\pi a} \right)^m \quad (IV.16)$$

onde:

$\frac{da}{dN}$ - taxa de crescimento da trinca por ciclo;

C e m - constantes do material.

Conforme pode ser observado no gráfico da figura IV.2, o conceito de fratura mecânica linear corresponde ao comportamento linear da taxa de crescimento da trinca da/dN em função da faixa de intensidade de tensão ΔK , quando esta relação é representada sob a forma de um gráfico log-log. O comportamento linear do crescimento da trinca ocorre na região II do gráfico. O fator de intensidade de tensão pode ser considerado linear nesta faixa porque, geralmente, a plastificação na ponta da trinca ocorre em uma área cujas dimensões são pequenas quando comparadas às dimensões da trinca. Na região 3 do gráfico, o comportamento é mais difícil de ser definido, pelo fato de envolver regiões plastificadas com dimensões da mesma ordem de grandeza da trinca. Nesta região é definida uma propriedade dos materiais denominada *fracture toughness*, que corresponde ao fator de

intensidade de tensão para a caso em que a trinca se propaga rapidamente e de maneira instável, sem aumento de carga, causando a ruptura da seção (*brittle fracture*).

As constantes C e m do material são obtidas por meio de ensaios, nos quais a taxa de crescimento da trinca é medida através de técnicas específicas. Nestes ensaios foi constatado que o modo 1 de crescimento da trinca é predominante. Os modos 2 e 3 produzem efeitos de segunda ordem tanto na direção quanto na taxa de crescimento das trincas.

A integração da equação (IV.16) irá conduzir à expressão:

$$\int_{a_0}^{a_i} \frac{da}{(Y(a)\sqrt{\pi a})^m} = C \Delta S^m N_i \quad (IV.17)$$

Como as amplitudes de tensão variam ao longo do tempo, considera-se o mesmo conceito de valor equivalente utilizado no método baseado na regra de Miner. Em [Kam,1987] é também proposta a mesma expressão desenvolvida em [Chaudhury,1985] para ΔS . Então, a expressão para o cálculo do dano de fadiga pela mecânica da fratura linear pode ser obtida da solução de:

$$\int_{a_0}^{a_i} \frac{da}{(Y(a)\sqrt{\pi a})^m} = C \left\{ 2\sqrt{2M_0} \left[\frac{e^{m+2}}{2\sqrt{\pi}} \Gamma\left(\frac{m+1}{2}\right) + \frac{3\alpha}{4} \Gamma\left(\frac{m+2}{2}\right) \right]^{\frac{1}{m}} \right\}^m N_i \quad (IV.18)$$

onde:

a_0 - profundidade inicial da trinca;

a_i - profundidade da trinca após N_i ciclos.

A determinação dos parâmetros a_0 , $Y(a)$, C e m é a questão a ser resolvida a seguir. Visto que estes fatores dependem, basicamente, de experiência prática, os seus valores serão obtidos a partir de recomendações de Entidades com reconhecida atuação neste assunto.

Para a_0 será utilizada a sugestão do *Det Norske Veritas* [DNV,1991], que recomenda o valor de 0.11 mm para a trinca inicial.

No caso do fator de correção $Y(a)$ será considerada a sugestão apresentada por pela [UEG/CIRIA,1985]. A expressão é:

$$Y(a) = 0.35 \left(\frac{e}{a} \right)^{0.35} \quad (\text{IV.19})$$

onde:

e - espessura da chapa.

Para C e m também foram consideradas as recomendações de [UEG/CIRIA,1985]. Os valores utilizados são:

$$C = 6.0 \times 10^{-11} \text{ e } m = 3 \text{ para } \Delta K \text{ em MPa.m}^{\frac{1}{2}} \quad (\text{IV.20})$$

IV.3.4 Equivalência entre Mecânica da Fratura e Curva S-N

A expressão genérica para a curva S-N com amplitude constante é:

$$\log N_2 = \log C_1 + m_{sn} \log \Delta S \quad (\text{IV.21})$$

Comparando-se com a expressão correspondente da regra de Paris, obtém-se:

$$N_2 = \frac{1}{C \pi^{\frac{m}{2}} \Delta S^m} \int_{a_1}^{a_2} \frac{da}{Y(a)^m a^{\frac{m}{2}}} \quad (\text{IV.22})$$

Considerando-se o logaritmo da expressão (IV.22), pode-se demonstrar que:

$$\log C_1 = \log \left(\frac{1}{C \pi^{\frac{m}{2}} \int_{a_1}^{a_2} \frac{da}{Y(a)^m a^{\frac{m}{2}}} \right) \text{ e } m_{sn} = -m \quad (\text{IV.23})$$

Uma restrição importante é o fato de a estimativa por Mecânica da Fratura Linear considerar apenas o crescimento da trinca e a estimativa pela curva S-N poder também cobrir o processo da iniciação da trinca, caso não existam defeitos incipientes nas juntas soldadas, o que não ocorre na prática.

A comparação das expressões (IV.21) e (IV.22) ilustra, de forma clara, as vantagens de se utilizar a estimativa do dano de fadiga pela Mecânica da Fratura. Enquanto o método das curvas S-N é limitado a situações semelhantes aos testes realizados em laboratório, o método da Mecânica da Fratura Linear permite:

- modificações nas condições ambientais ou no material, através da utilização das constantes C e m apropriadas;
- mudanças na geometria da junta, através da utilização do fator $Y(a)$ apropriado;
- mudanças na definição de a_0 (trinca inicial) e a_f (trinca final).

IV.3.5 Variabilidade dos Parâmetros

Os parâmetros utilizados para a estimativa do dano de fadiga não são determinísticos e, desta forma, devem ser tratados como variáveis aleatórias que possuem um determinado tipo de distribuição [Kirkegaard,1988]. Este assunto tem sido amplamente estudado, principalmente para desenvolver recomendações referentes aos intervalos de inspeções de estruturas offshore em operação e para permitir um tratamento mais apropriado na fase de projeto [Baker,1992], [Pedersen,1992].

Desenvolvendo uma análise de sensibilidade, Madsen [Madsen,1987] identificou, para um intervalo de 4 anos, a importância das diversas fontes de incerteza associadas ao processo de fadiga. Os resultados estão apresentados na Tabela IV.1.

Fontes de incerteza	Importância (%)
Identificação do meio ambiente	1
Cálculo do carregamento	19
Análise de tensão	20
Fator de intensidade de tensão	10
Parâmetros do crescimento da trinca	50

Tabela IV.1 - Importância das fontes de incerteza associadas ao processo de fadiga

Esta avaliação ilustra, de forma clara, a relevância do estudo de confiabilidade no cálculo do dano de fadiga referente ao projeto de estruturas offshore.

Pelo fato deste trabalho ser um passo inicial para o desenvolvimento de um critério numérico-experimental para a identificação de juntas críticas, sob o aspecto do dano relativo de fadiga em tempo real, não será estimado o efeito das incertezas na simulação numérica desenvolvida no Capítulo VI.

Capítulo V

REDES NEURAIS

V.1 INTRODUÇÃO

Este capítulo tem como finalidade apresentar os principais conceitos referentes ao tipo de rede neural cujo método de treinamento é supervisionado - depende da disponibilidade de um conjunto de dados contendo as variáveis de entrada e saída para ser treinada - e é baseado na técnica denominada **Regra Delta Generalizada (GDR)**, também conhecida como *backpropagation* - os erros são retropropagados dos neurônios de saída para os neurônios intermediários - cujo desenvolvimento é atribuído a Rumelhart, Hinton e Willians [Rumelhart,1986]. O estabelecimento das bases desta técnica, na verdade, foi realizado por Paul Werbos em [Werbos,1974].

O algoritmo de *backpropagation* é a extensão não linear do conhecido algoritmo de erro quadrático mínimo, desenvolvido por Widrow e Hoff [Widrow,1960], podendo também ser interpretado como um caso particular de aproximação estocástica, conforme demonstrado em [Kosko,1992].

V.2 BREVE HISTÓRICO

A computação neural é uma forma de conceber algoritmos numéricos inspirada em pesquisas referentes ao funcionamento do cérebro dos mamíferos. As redes neurais não executam programas, mas “comportam-se” face a um conjunto de dados: elas “reagem”, “se auto-organizam”, “aprendem” e “esquecem”.

Fazendo-se uma analogia com o cérebro, o neurônio é a sua unidade básica. Cada um deles pode ser considerado como um elemento processador, que recebe os impulsos elétricos e os combina no seu núcleo. Os sinais, originários de outros neurônios, são adquiridos através de estruturas denominadas dendritos. Se o estímulo resultante for suficientemente forte, o neurônio é ativado, emitindo um impulso que percorre o axônio e é

transmitido para outros neurônios por meio das sinapses. Os elementos que compõem o neurônio estão indicados na figura V.1.

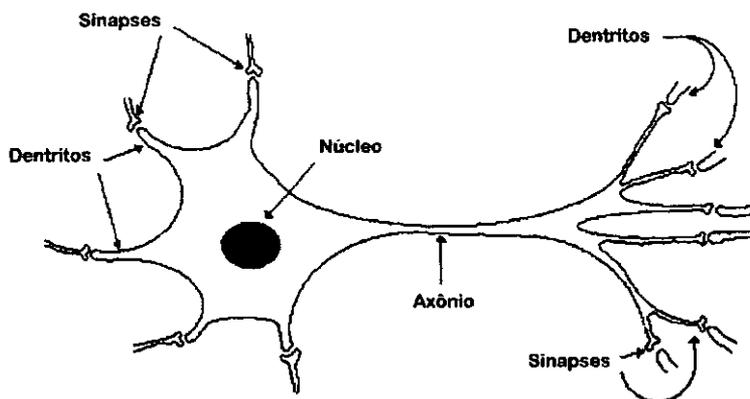


Figura V.1 - Composição de um neurônio biológico

O grande interesse que atualmente tem existido na utilização de Redes Neurais em uma série de problemas na área de monitoração, supervisão e controle de processos é, na realidade, um retorno ao entusiasmo existente nas décadas de 50 e 60. Após a solução do problema identificado na **perceptron** - a rede neural mais utilizada na época, mas que não conseguia distinguir classes de padrões não linearmente separáveis, conforme demonstrado em [Minsky,1969] - em meados da década de 80, os trabalhos de pesquisa nesta atividade aumentaram de forma significativa, originando um grande número de aplicações práticas em problemas tais como detecção de explosivos em bagagens, avaliação de segurança de crédito, comportamento de mercado financeiro, previsão de vendas, detecção de danos estruturais, interpretação de caracteres, filtragem de sinais, controle de processo em petroquímica e inúmeras outras.

O método utilizado para resolver a limitação do perceptron é uma técnica de treinamento de redes neurais que permite o ajuste de qualquer tipo de função, inclusive não linear, e foi denominado *backpropagation*. Este método pode também ser interpretado como uma técnica não paramétrica de modelação estatística, uma vez que as características da função transferência entre dados de entrada e saída é decidida pelos dados e não determinada *a priori* pelo método [Smith,1993].

O sinal de saída de um **neurônio**, que é o elemento básico de uma rede neural, pode ser considerado como uma função binária: o neurônio dispara ou não dispara. Por questões de ordem prática, contudo, considera-se a saída de um neurônio como uma função contínua, cuja variável dependente pode ser o seu nível de ativação. A função de ativação de um neurônio estabelece a sua função transferência, isto é, a relação entre os

sinais de entrada e os sinais de saída. Uma vez estabelecida e treinada a rede, esta função não se modifica mais.

Assim sendo, como pode uma rede neural **aprender**? A rede neural aprende porque os **pesos** das conexões entre os diversos neurônios pode variar. A capacidade de um neurônio excitar ou inibir outro neurônio não é constante: ela pode aumentar ou diminuir, de uma forma sistemática, baseada nos objetivos da rede. As características da conexão entre os neurônios componentes de uma rede determina o seu comportamento e como este comportamento pode ser alterado.

V.3 CONCEITO DE REDE NEURAL

O cérebro pode ser idealizado como redes de neurônios, que se comportam de acordo com o modelo matemático desenvolvido por McCulloch e Pitts [McCulloch,1943], que está indicado na figura V.2, onde a ativação só ocorrerá se o valor de u for superior a um determinado valor mínimo. Na sua concepção original, a função de ativação G é binária.

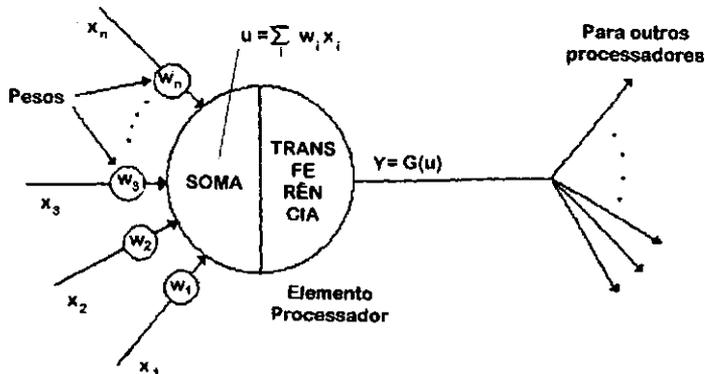


Figura V.2 - Modelo matemático de um neurônio

Um neurônio típico recebe o sinal de entrada - para excitar ou inibir - de outros neurônios. Quando o nível de excitação deste neurônio atinge um determinado valor, ele dispara. O disparo é propagado, através do axônio, para diversos neurônios a ele conectados, atuando como sinal de entrada para estes outros neurônios.

Uma rede neural ou neuronal é formada por:

a) uma camada de neurônios de entrada, que recebe os sinais de entrada para a rede;

- b) uma ou mais camadas intermediárias de neurônios, que são responsáveis pelo processamento dos sinais recebidos;
- c) uma camada de neurônios de saída, que processa e envia os sinais para fora da rede.

Deste modo, uma informação ou estímulo captado pela rede, será devidamente processado, de acordo com os objetivos desta rede, gerando um determinado padrão de resposta.

A atividade de um neurônio é determinada pela soma dos diversos sinais de entrada, recebidas através das dendrites, que são as vias de acesso para o núcleo do neurônio. No caso da saída, o sinal é enviado através das sinapses. Para um neurônio j de uma rede, esta atividade irá depender de u_j , cuja expressão é:

$$u_j = \sum_{i=1}^N w_{ij}x_i + w_{0j} \quad (\text{V.1})$$

onde :

- x_i : entrada originária do neurônio i ;
- w_{ij} : eficiência das sinapses entre os neurônios i e j ;
- w_{0j} : valor de bias.

A variável w_{0j} , associada ao neurônio j , pode ser interpretada como um valor mínimo de atividade, permitindo uma maior fidelidade ao modelo biológico (equivale a um sinal de entrada originário de um neurônio com ativação unitária), e a variável w_{ij} representa os pesos associados a cada ligação entre os neurônios (corresponde à influência de cada sinapse ij conectada aos neurônios).

A variável y_j , correspondente ao sinal de saída ou ativação do neurônio j , é dada por:

$$y_j = G(u_j) \quad (\text{V.2})$$

onde G é a função de ativação utilizada.

A rede neural mais simples, é formada por um neurônio de entrada, um neurônio intermediário e um neurônio de saída. Este tipo de rede pode ser utilizado para representar funções com uma variável dependente e uma variável independente. O neurônio situado na camada intermediária é essencial para a capacidade de processamento da rede.

O neurônio intermediário, neste caso, recebe apenas um sinal de entrada x . Ele multiplica este valor por um peso w e adiciona a este produto o valor de bias w_0 , ambos armazenados em sua memória. O resultado desta operação é:

$$u = w x + w_0 \quad (\text{V.3})$$

O gráfico desta operação é uma linha reta, no espaço bi-dimensional, e o valor w_0 corresponde ao ponto em que a reta intercepta o eixo das ordenadas.

O sinal de saída deste neurônio, como foi visto, é obtido através da função de ativação G . Considerando-se esta função como a função sigmóide logística, que é o caso mais comum, a expressão do sinal de saída é:

$$y = G(u) = \frac{1}{1 + e^{-\lambda (w x + w_0)}} \quad (\text{V.4})$$

A função logística, que é um tipo de função sigmóide, tem os seus valores compreendidos no intervalo $(0,1)$, conforme ilustrado na figura V.3. O valor de λ é geralmente unitário e a sua influência está relacionada à inclinação desta função no seu ponto médio. Outros tipos de função sigmóide também podem ser utilizados como, por exemplo, a tangente hiperbólica, que tem os seus valores compreendidos no intervalo $(-1,1)$.

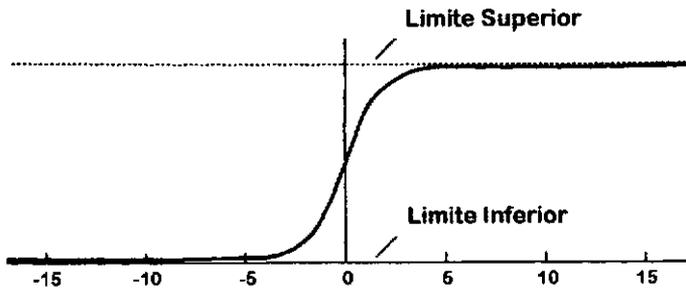


Figura V.3 - Função de ativação tipo sigmóide

A principal aplicação do conceito de redes neurais é a representação aproximada de uma função contínua. Como existem vários problemas que uma rede neural com uma camada não consegue simular, é natural considerar a possibilidade do aumento do número de camadas para resolver estes problemas. Os estudos desenvolvidos em [Sprecher,1965] e [Hetch-Nielsen,1987], cujo resumo encontra-se no Apêndice A, demonstram que redes neurais do tipo *feedforward*, que são redes em que não existe

realimentação, podem representar adequadamente qualquer função contínua. Esta propriedade está apresentada sob a forma de teoremas.

V.4 CONCEITO DE *BACKPROPAGATION*

Na figura V.4 está apresentada uma rede neural do tipo *feedforward* com três camadas, que será utilizada para ilustrar este conceito. A camada de entrada possui L neurônios, a camada intermediária M neurônios e a camada de saída foi dimensionada com N neurônios. A rede com topologia *feedforward* é geralmente estável pelo fato de não permitir realimentações.

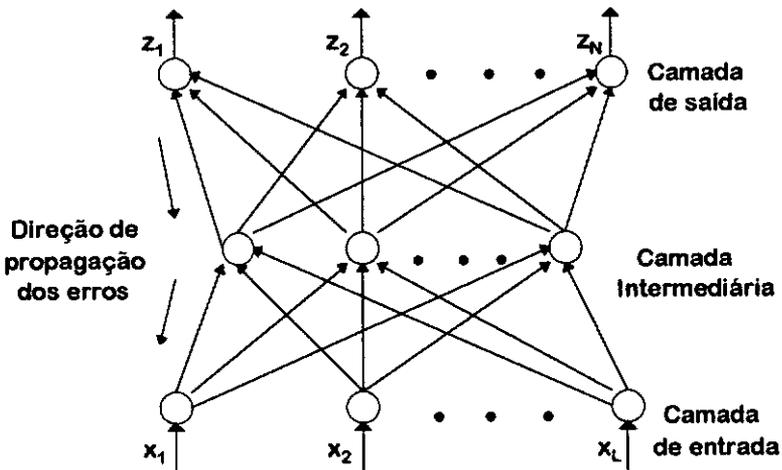


Figura V.4 - Rede neural *feedforward* com 3 camadas

Cada neurônio da camada de entrada fornece a rede o valor de uma variável independente x e cada neurônio da camada de saída corresponde a uma variável dependente z . A saída ideal da rede será denominada \hat{z} .

A principal característica da técnica *backpropagation*, fato este que permitiu o seu desenvolvimento, é a propriedade dos neurônios da camada intermediária serem capazes de determinar como modificar os pesos das suas conexões se receberem informação sobre os erros de cada neurônio pertencente à camada de saída. O nome *backpropagation*, inclusive, é derivado do processo de propagar a informação de erro de volta, dos neurônios da camada de saída para a camada intermediária.

O treinamento de uma rede com várias camadas é um processo iterativo. Cada passo envolve a determinação do erro associado a cada neurônio e, posteriormente, a modificação dos pesos nas conexões que chegam a este neurônio. O processo de

treinamento para um exemplo do conjunto de dados é denominado de **evento** ou **ciclo**. Cada evento envolve três fases intermediárias:

fase 1: - um exemplo do conjunto de dados, formado por variáveis independentes e dependentes, é fornecido à rede, sendo realizada a ativação de todos os neurônios até a camada de saída;

fase 2: - o erro na camada de saída é propagado de volta para os neurônios localizados na camada intermediária;

fase 3: - as conexões dos neurônios entre as diversas camadas têm os seus pesos modificados em função da informação de erro recebida.

Um conjunto de eventos correspondente ao número de amostras r do conjunto é denominado de **época**. O processo de treinamento de uma rede pode requerer centenas ou milhares de épocas para que todos os casos do conjunto de dados sejam mapeados com um erro inferior a um determinado valor pré-estabelecido. O método de *backpropagation* utiliza o método do gradiente descendente para a localização do erro mínimo e variações deste método, que permitem uma aceleração do processo.

A equação para o sinal de saída dos neurônios da camada intermediária da rede apresentada na figura V.4 é:

$$y_m = G_m(u_m) = G_m(w_{0m}^{int} + \sum_{\ell=1}^L w_{\ell m}^{int} x_{\ell}) \quad \forall m = 1, \dots, M \quad (V.5)$$

onde:

x_{ℓ} - sinal de entrada para o neurônio ;

$w_{\ell m}^{int}$ - peso da conexão do neurônio ℓ de entrada para o neurônio intermediário m .

Para os neurônios da camada de saída, a equação do sinal de saída é:

$$z_n = G_n(v_n) = G_n(w_{0n}^{sai} + \sum_{m=1}^M w_{mn}^{sai} y_m) \quad \forall n = 1, \dots, N \quad (V.6)$$

onde:

w_{mn}^{sai} - peso do neurônio intermediário m para o neurônio de saída n .

Recentemente, White [White,1989] demonstrou que o algoritmo de *backpropagation* pode ser interpretado como um caso especial de aproximação estocástica. A aproximação estocástica tem como objetivo determinar o valor de \mathbf{m} que satisfaz a equação:

$$E[\Psi_{\text{est}}(\mathbf{m}, \mathbf{s}, d)] = 0 \quad (\text{V.7})$$

para uma função arbitrária Ψ_{est} do vetor aleatório $\mathbf{r} = \{\mathbf{s}|d\}$.

Embora a densidade de probabilidade $p(\mathbf{r})$ não seja conhecida, a equação (V.7) pode ser resolvida numericamente a partir do conhecimento de $\mathbf{r}_1, \mathbf{r}_2, \dots$ sendo \mathbf{m} determinado iterativamente por meio da equação:

$$\mathbf{m}_{k+1} = \mathbf{m}_k + c_k \Psi_{\text{est}}(\mathbf{m}, \mathbf{r}_k) \quad (\text{V.8})$$

Se a sequência $\{c_k\}$ obedecer às condições :

$$\sum_{k=1}^{\infty} c_k = \infty \quad \text{e} \quad \sum_{k=1}^{\infty} c_k^2 < \infty \quad (\text{V.9})$$

então a sequência $\{\mathbf{w}_k\}$ converge, no sentido médio quadrático para uma solução ótima local. Estas condições correspondem a restringir $\{c_k\}$ a decrescer lentamente com respeito ao seu somatório e a decrescer rapidamente com respeito à soma de seus quadrados (por exemplo, a série harmônica $\{c_k\} = \{1/k\}$ satisfaz a estas condições).

É possível interpretar-se \mathbf{m}_k como um vetor que contem os pesos da rede neural em um tempo k . Então, $G(\mathbf{v}_k) = f_{\text{z}}(\mathbf{x}_k, \mathbf{w})$, onde \mathbf{v}_k corresponde ao estado de ativação dos neurônios da camada de saída e f_{z} é uma função não conhecida que mapeia $X \Rightarrow Z$ a partir de amostras aleatórias $(\mathbf{x}_1, \mathbf{z}_1), \dots, (\mathbf{x}_r, \mathbf{z}_r)$. White observou que:

$$\Psi_{\text{est}}(\mathbf{m}, \mathbf{r}_k) = (\hat{\mathbf{z}}_k - G(\mathbf{v}_k)) \cdot \nabla_{\mathbf{w}}(G(\mathbf{v}_k)) \quad (\text{V.10})$$

O coeficiente c_k é denominado de taxa de aprendizado (*learning rate*) ou passo de treinamento, no caso das redes neurais.

V.5 TREINAMENTO

A técnica de *backpropagation* é um método de treinamento supervisionado, composto basicamente de três fases, conforme já identificado no item anterior:

- entrada do conjunto de dados para treinamento através da camada de neurônios que compõe a entrada da rede (*feedforward of the input training pattern*) e a respectiva determinação dos erros por meio das saídas dos neurônios localizados na camada de saída ;
- retorno dos erros calculados para as camadas intermediárias (*backpropagation of associated errors to hidden layers*);
- ajuste dos pesos .

O processo de treinamento é projetado para identificar os pesos das conexões que proporcionem o melhor ajuste possível, a partir de um conceito de erro mínimo, entre a rede neural e a função conhecida através de um determinado número de amostras.

A rede com treinamento supervisionado recebe conjuntos formados pelos dados de entrada e respectivos dados de saída. O processo de treinamento consiste em encontrar um conjunto de pesos que corresponda a um erro mínimo entre os dados de saída que a rede produz e os dados de saída originais.

V.5.1 Minimização da Função Erro

Sendo $F_0(\mathbf{w})$ um funcional de erro ou função erro ou função custo, cuja função de distribuição de densidade de probabilidade é desconhecida, a aproximação estocástica estima o $\nabla E[F_0(\mathbf{w})]$ por meio de um gradiente $\nabla F_0(\mathbf{w})$, conhecido em cada iteração, através de um algoritmo estocástico:

$$\mathbf{w}_{k+1} = \mathbf{w}_k - c_k \nabla(F_0(\mathbf{w}))_k \quad (\text{V.11})$$

onde:

\mathbf{w}_k - representa os pesos das sinapses de uma rede neural após a iteração k ;

$\nabla(F_0(\mathbf{w}))_k$ - gradiente de $(F_0(\mathbf{w}))_k$ com respeito a \mathbf{w}_k .

O gradiente $-\nabla E[F_0(\mathbf{w})]$ aponta na direção mais inclinada - *steepest descent* - da superfície de erro definida por $E[F_0(\mathbf{w})]$. A minimização é realizada deslocando-se o vetor das sinapses \mathbf{w} na direção $-\nabla(F_0(\mathbf{w}))$.

A atualização de primeira ordem do peso $w_{ij(k)}$, onde (k) refere-se a uma determinada iteração, é dada pela expressão de diferenças finitas:

$$w_{ij(k+1)} = w_{ij(k)} + c_k \Delta w_{ij(k)} \quad (\text{V.12})$$

onde o coeficiente de aprendizado $\{c_k\}$ é decrescente, considerando-se o conceito de aproximação estocástica para um mínimo local [Kosko,1992]. Na abordagem convencional do processo de atualização dos pesos, o valor do coeficiente de aprendizado permanece constante.

A expressão estocástica linear, de segunda ordem, para atualizar os pesos é dada por:

$$w_{ij(k+1)} = w_{ij(k)} + c_k \Delta w_{ij(k)} + b_k \Delta w_{ij(k-1)} \quad (\text{V.13})$$

onde o termo $b_k \Delta w_{ij(k-1)}$ foi denominado por Rumelhart [Rumelhart, 1986] de *momentum*.

Denominando-se a saída ideal da rede de \hat{z} e a saída gerada pela rede de z , o erro instantâneo é definido por:

$$\epsilon_k = \hat{z}_k - z_k \quad (\text{V.14})$$

O algoritmo de backpropagation utiliza o erro quadrático instantâneo (como no caso de regressão linear e não linear, como a forma para medir o grau de ajuste dos dados). A sua expressão é :

$$E_k = \frac{1}{2} \sum_{n=1}^N [\hat{z}_{n(k)} - z_{n(k)}]^2 = \frac{1}{2} \epsilon_k \epsilon_k^t \quad (\text{V.15})$$

onde:

$z_{n(k)}$ - saída do neurônio n da camada de saída da rede para a k -ésima iteração;

$\hat{z}_{n(k)}$ - valor da função objetivo no neurônio n para a k -ésima iteração;

N - número de neurônios na camada de saída da rede.

O erro médio acumulado é dado por:

$$E_K = \frac{1}{K} \sum_{k=1}^K E_k \quad (\text{V.16})$$

onde:

K - número de iterações consideradas.

Assumindo-se que a atualização dos pesos será sempre realizada de acordo com as equações (V.12) ou (V.13) e que:

$$\frac{\partial E_K}{\partial w_{ij}} = \frac{1}{K} \sum_k \frac{\partial E_k}{\partial w_{ij}} \quad (\text{V.17})$$

justifica-se considerar o gradiente de E_k em cada iteração ao invés de se estimar o gradiente do erro médio acumulado.

A forma da superfície de erro, que pertence a um espaço cuja dimensão depende do número de pesos considerado, e a localização do ponto correspondente ao erro mínimo dependem das amostras componentes do conjunto de dados.

A técnica do gradiente descendente pode ser interpretada, de forma ilustrativa, como a colocação de uma esfera na superfície de erro, permitindo que ela se mova sem restrições. Ela irá rolar pela superfície até encontrar o seu ponto mais baixo, que representa a condição de energia potencial mínima. Caso as características da superfície impliquem na existência de vários pontos em que a esfera possa permanecer estacionada acima do ponto de energia potencial mínima global, fica caracterizado a existência de mínimos locais, que não representam a solução ótima global procurada.

Para um mínimo local existir, todos os pesos devem, simultaneamente, possuir valores tais que uma mudança em qualquer direção ocasiona um aumento do erro. Para um determinado conjunto de dados, a probabilidade da existência de mínimos locais diminui a medida que o número de pesos existentes na rede aumenta [Smith, 1993]. Esta propriedade indica, a princípio, que uma rede totalmente conectada poderia convergir para um mínimo global com maior facilidade.

V.5.2 Atualização dos Pesos

A característica fundamental da técnica de *backpropagation* é a sensibilidade do erro da rede se modificar em função da variação dos pesos. Esta sensibilidade pode ser avaliada através da determinação das derivadas parciais do erro relativas aos pesos.

Para um neurônio pertencente à camada intermediária, a expressão da atualização do seu peso é:

$$w_{\ell m}^{\text{int}(k+1)} = w_{\ell m}^{\text{int}(k)} + c_k \Delta w_{\ell m}^{\text{int}(k)} \quad (\text{V.18})$$

onde a expressão da variação dos pesos é:

$$\Delta w_{zm(k)}^{int} = \left[\sum_{m=1}^M (\hat{z}_{n(k)} - G_n(v_{n(k)})) \frac{dG_n(v_{n(k)})}{dv_{n(k)}} w_{mn(k)}^{sai} \right] G_m(u_{m(k)}) x_t \quad (V.19)$$

Caso o neurônio pertença à camada de saída, a expressão da atualização do seu peso é dada por:

$$w_{mn(k+1)}^{sai} = w_{mn(k)}^{sai} + c_k \Delta w_{mn(k)}^{sai} \quad (V.20)$$

A expressão da variação dos pesos para os neurônios localizados na camada de saída é dada por:

$$\Delta w_{mn(k)}^{sai} = (\hat{z}_{n(k)} - G_n(v_{n(k)})) \frac{dG_n(v_{n(k)})}{dv_{n(k)}} G_m(u_{m(k)}) \quad (V.21)$$

As expressões mostradas são válidas para uma rede com apenas uma camada intermediária de neurônios. No caso de mais de uma camada, expressões similares podem ser desenvolvidas.

V.5.3 Métodos para Aceleração do Treinamento

Na abordagem convencional, a modificação dos pesos é feita segundo a direção de maior declividade da superfície de erro em relação aos pesos atuais. Este procedimento, de uma maneira geral, não move o conjunto de pesos diretamente na direção ao vetor ótimo e o processo de busca do mínimo pode ser acelerado por diversos métodos, dos quais podemos citar o *adaptive learning rate* e os métodos de consideram a curvatura da superfície de erro.

O método denominado *adaptive learning rate* consiste em mudar o valor da taxa de aprendizado durante o processo. A regra denominada *DELTA-BAR-DELTA* permite que cada sinapse tenha a sua própria taxa de aprendizado e que o valor desta taxa varie ao longo do tempo [Jacobs,1988]. Duas heurísticas são usadas para as variações da taxa de aprendizado para cada peso:

- se a variação do peso ocorre na mesma direção durante várias iterações, a taxa de aprendizado da sinapse deve ser aumentada;

- se a direção da variação do peso se alterna durante várias iterações consecutivas, a taxa de aprendizado da sinapse deve ser reduzida.

Os métodos que consideram a curvatura da superfície de erro envolvem o cálculo de uma aproximação para a segunda derivada da função erro com relação à variação dos pesos. A informação da segunda derivada pode ser utilizada de diversas maneiras para fornecer uma indicação referente à mudança dos pesos, visto que fornece a taxa de variação da declividade da superfície no ponto correspondente à situação atual. Em [Fahlman,1988] é apresentada uma formulação considerando que a curva de erro x peso pode ser aproximada por uma parábola, que pode ser resumida na seguinte equação lógica:

$$(\Delta peso)_k = \frac{\left(\frac{\partial(\text{funcao erro})}{\partial \text{ peso}} \right)_k}{\left(\frac{\partial(\text{funcao erro})}{\partial \text{ peso}} \right)_{k-1} - \left(\frac{\partial(\text{funcao erro})}{\partial \text{ peso}} \right)_k} (\Delta peso)_{k-1} \quad (V.22)$$

onde k , neste caso, é interpretado como o intervalo correspondente a uma época.

V.5.4 Reforço de Treinamento

Até agora, foi assumido que há disponibilidade de um conjunto detalhado de dados de saída da rede para a realização do treinamento supervisionado. Entretanto, em algumas situações, a informação disponível não é satisfatória e a utilização de uma “crítica”, originária do “ambiente” em que a rede opera, pode trazer resultados positivos um melhor desempenho da rede. Esta realimentação de informação para a rede, durante o processo de treinamento, não fornece uma indicação de como modificar a atualização dos pesos, mas sim que determinadas informações da saída da rede estão erradas. Em [Hertz,1990] estão apresentadas algumas diretrizes e sugestões referentes a este assunto.

V.5.5 Sugestões Práticas para o Treinamento

Diversas decisões de ordem prática, ou mesmo conceitual, precisam ser consideradas antes e durante o processo de treinamento de uma rede neural. Os principais aspectos referentes a estas decisões estão apresentados a seguir:

- Dimensionamento da Rede Neural

Dado um conjunto de vetores entrada-saída $(\mathbf{x}_i, \mathbf{z}_i), i = 1, \dots, r$, e uma rede neural do tipo *feedforward*, é possível treiná-la minimizando o erro quadrático na sua saída. Entretanto, o passo inicial é o dimensionamento da rede. Se a rede for subdimensionada, apresenta pouca capacidade de generalizar ou não aprende. Se for superdimensionada, pode não conseguir atingir um mínimo satisfatório ou não generalizar da melhor forma possível, além de necessitar de um tempo de treinamento maior.

O número de neurônios da camada de entrada é igual à dimensão do vetor \mathbf{x} e o número de neurônios da camada de saída é igual à dimensão do vetor \mathbf{z} . O número de camadas intermediárias e a quantidade de neurônios em cada uma delas depende do tipo de função a ser representada e do número de pares de entrada-saída que serão utilizados. De qualquer forma, uma rede inicial necessita ser dimensionada e a técnica de tentativa-e-erro é normalmente empregada para a otimização da rede.

Uma forma de resolver este problema é a utilização de algoritmos destrutivos e algoritmos construtivos. No caso dos algoritmos destrutivos, o objetivo é eliminar automaticamente sinapses de um neurônio ou mesmo neurônios da rede, por meio de um procedimento em que se tenta minimizar a função erro acrescida de um termo de *penalty*: $E_d = E + \upsilon \sum_{ij} w_{ij}^2$, conforme demonstrado na referência [Kramer, 1989]. Os algoritmos construtivos têm como ponto de partida uma rede de configuração mínima, a qual vai sendo aumentada, na sua camada intermediária, até a função objetivo ser representada de forma adequada. Um exemplo de algoritmo construtivo é o processo denominado *Cascade Correlation* [Fahlman, 1990].

Quanto ao número de pares entrada-saída necessários, uma relação entre o número de pares r , o número total de sinapses N_{sin} da rede e a precisão v_{prec} requerida para o processo de treinamento pode ser estabelecida. Uma fórmula prática sugerida para determinar a relação entre estes parâmetros é [Baum, 1989]:

$$r = \frac{N_{\text{sin}}}{v_{\text{prec}}} \quad (\text{V.23})$$

Considerando esta expressão, em [Fausset, 1994] é apresentado o seguinte exemplo (para redes treinadas para classificar amostras): sendo $v_{\text{prec}} = 0.1$, uma rede com 80 pesos irá requerer 800 pares de entrada-saída para classificar 90% dos pares corretamente, assumindo-se que a rede foi treinada para classificar 95% dos pares corretamente.

O dimensionamento de uma rede neural também deve considerar o fato da sua capacidade de **generalizar** depender também do número de camadas intermediárias e do número de neurônios nestas camadas.

- Representação dos Dados

Em diversos tipos de problemas, os vetores de entrada e saída têm componentes que representam valores contínuos ou conjuntos de faixas. Por exemplo, a temperatura de uma refeição pode ser representada por um valor em graus *Celsius* (representação contínua) ou por cada um dos estágios: congelada, fria, temperatura ambiente ou quente. Neste último caso, serão necessários 4 neurônios na camada de saída da rede. No primeiro caso, um neurônio produz a informação. Verifica-se, entretanto, que é mais fácil fazer uma rede neural aprender um conjunto com saídas distintas do que um conjunto com saída contínua, com exceção para valores situados nas extremidades do conjunto [Fausset,1994].

Geralmente, é necessário se fazer uma transformação dos dados iniciais, utilizando-se funções logarítmicas, exponenciais e outras, de forma que a rede possa operar com os dados de forma mais conveniente.

- Pesos iniciais

A escolha dos pesos iniciais irá influenciar na capacidade da rede neural atingir um mínimo local satisfatório e também na velocidade do treinamento. A atualização da sinapse entre dois neurônios, conforme pode ser verificado em (V.19) e (V.21), depende das suas funções de ativação e derivada. Por este motivo, deve ser evitada a escolha de pesos iniciais que possam anular estas funções. Os valores dos pesos iniciais também não devem ser muito elevados, pois os sinais de entrada, para os neurônios das camadas intermediária ou de saída, poderá localizar-se na região onde a derivada da função de ativação é muito pequena. Da mesma forma, se os pesos iniciais forem muito pequenos, o sinal de entrada para as diversas camadas será próximo de zero, fato este que causa um treinamento extremamente demorado.

Um procedimento comum consiste de inicializar-se as sinapses com valores aleatórios entre -0.5 e 0.5. Em [Nguyen,1990] é apresentado um procedimento prático para a inicialização dos pesos de uma rede neural.

- Passo no treinamento (*learning rate*)

A escolha do valor de c_k é, de certa forma, uma arte, pois este fator depende da função que a rede neural irá aproximar, função esta que só é conhecida através de alguns

pares de entrada e saída. Valores muito pequenos de c_k tornam o treinamento muito lento, enquanto que valores muito grandes podem provocar a divergência do mesmo.

Para a maioria dos casos, se o vetor contendo os dados de entrada é normalizado e o maior número de sinapses que se conectam em um neurônio é N_{\max} , a convergência pode ser garantida se $c_k \leq 1/N_{\max}^2$. Como esta expressão fornece, geralmente, um valor muito conservador, um valor típico sugerido é 0.1 [Caloba,1993].

- *Momentum*

Conforme visto na equação (V.13), se o *momentum* for incluído no procedimento de atualização das sinapses, a mudança dos pesos será feita na direção correspondente à combinação do gradiente atual e do gradiente da iteração imediatamente anterior. Esta modificação da técnica convencional permite a execução de grandes ajustes de pesos ao mesmo tempo que utiliza pequenas taxas de aprendizado para prevenir valores de erro elevados devido a existência de alguma amostra espúrea no conjunto de dados.

- Mínimos locais

Como o treinamento é um processo de otimização por gradiente, possui as mesmas características destes processos. Um dos problemas é o fato da função convergir para mínimos locais.

Uma saída para esta limitação é a utilização de um esquema de *simulated annealing* [Hetch-Nielsen,1990]. Através deste esquema, é incluído no algoritmo de treinamento um ruído aleatório que provoca saltos nos valores das sinapses. Estes saltos permitem escapar dos mínimos locais, que podem ser interpretados como vales pouco profundos na superfície de erro. Ao longo do treinamento, a amplitude do ruído vai sendo reduzida e o ponto de mínimo se desloca na superfície erro para vales mais profundos, com menor probabilidade de escape.

- Paralisia

A forma da superfície de erro depende do tipo da função a ser minimizada. Valores muito elevados de $|w_{ij}|$ podem levar a valores muito grandes de $|u_i|$ ou $|v_i|$ e, devido a forma da função de ativação, $|dy_i/du_i|$ ou $|dz_i/dv_i|$ serão muito pequenos. Consequentemente, os valores do gradiente da função erro também serão muito pequenos.

Uma heurística de verificação dos valores de $|u_i|$ ou $|v_i|$ muito elevados (> 5) ou então um limite máximo para os valores de $|w_{ij}|$ são as soluções geralmente adotadas para indicar ou evitar a paralisia no treinamento [Caloba,1993].

• Tempo de Treinamento

Considerando-se que o grande interesse na utilização de redes neurais, baseadas na técnica de *backpropagation*, é o fato de ser possível um compromisso entre respostas corretas para o conjunto de dados de treino e boas respostas para novos conjuntos de dados, não utilizados no treinamento, isto é, um compromisso entre **memorização** e **generalização**, o treinamento não deve ser conduzido até o erro atingir um valor pré-selecionado de mínimo. O procedimento correto é parar o treinamento antes deste ponto.

Em [Hecht-Nielsen,1990] é sugerida a utilização de dois conjuntos de dados durante o treinamento: o conjunto de treino propriamente dito e o conjunto de teste. O ajuste dos pesos é baseado no conjunto de treino, sendo que periodicamente o erro também é computado para o conjunto de teste. Enquanto o erro do conjunto de teste estiver decrescendo, o treinamento da rede prossegue. Constatando-se que o erro do conjunto de teste começa a divergir, o treinamento é interrompido, pois a rede começa a memorizar o conjunto de treino e a perder a capacidade de generalizar.

Na figura V.5 está apresentado um exemplo onde o efeito do número de épocas na capacidade de generalização da rede fica perfeitamente evidenciada. Aumentando-se o número de épocas, embora a rede forneça resultados mais precisos para o conjunto de treino, os resultados para o conjunto de teste ficam cada vez mais imprecisos.

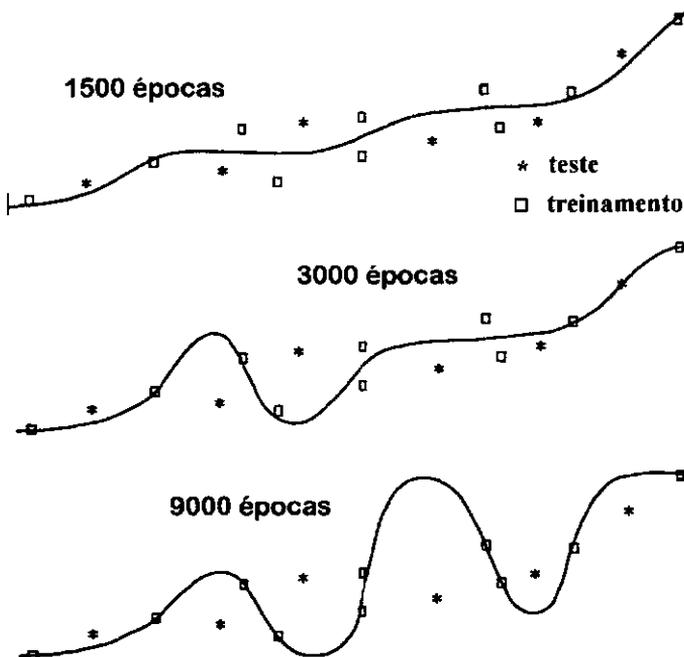


Figura V.5 - Efeito da memorização no treinamento

V.6 CONCEITO DE *RECURRENT BACKPROPAGATION*

Um tipo simples de rede neural recorrente está mostrado na figura V.6. Na realidade, esta topologia é parcialmente recorrente, visto que a maioria das conexões é *feedforward*. Um grupo específico de neurônios recebe o sinal de realimentação de neurônios localizados em camada posterior, sendo que os pesos destas conexões de realimentação podem ser fixos ou amortecidos gradualmente ao longo do treinamento. Este grupo de neurônios é denominado *context units* e o treinamento deste tipo de rede pela técnica de *backpropagation* não é mais difícil do que o processo referente a uma rede *feedforward* padrão [Fausset,1994].

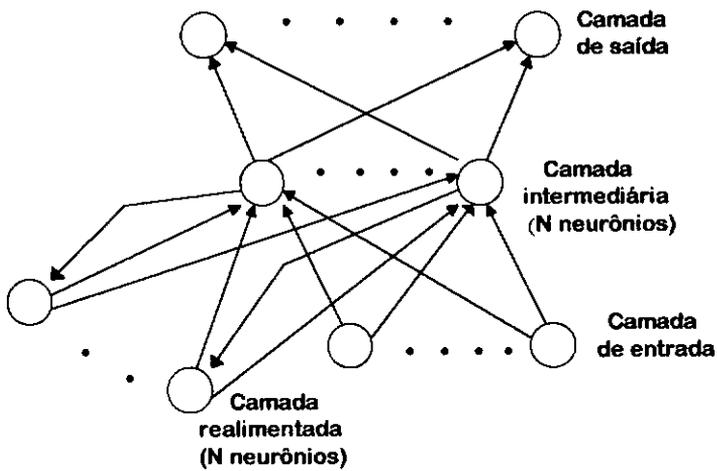


Figura V.6 - Rede recorrente simples

A técnica de *backpropagation* pode ser aplicada para o treinamento de redes recorrentes com qualquer arranjo de conexão entre os seus neurônios. A descrição apresentada a seguir é proveniente de [Fausset, 1994], que se baseou em [Hertz, 1990].

Assume-se que uma rede recorrente genérica obedece a equação de evolução dinâmica desenvolvida em [Cohen, 1983] e [Hopfield, 1984], cuja expressão é:

$$\tau_i \frac{dy_i}{dt} = -y_i + G\left(x_i + \sum_j y_j w_{ij}\right) \quad (\text{V.24})$$

onde x_i é o somatório das entradas externas do neurônio i e τ_i é uma constante no tempo.

Assumindo-se que $dy_i/dt = 0$ e que existe, pelo menos, um atrator⁽¹⁾ estável, a equação anterior transforma-se em:

$$y_i = G\left(x_i + \sum_j y_j w_{ij}\right) \quad (\text{V.25})$$

No treinamento de uma rede recorrente pela técnica da *backpropagation* considera-se o erro dado pela expressão:

$$E = \frac{1}{2} \sum_r (\hat{y}_r - y_r)^2 \quad (\text{V.26})$$

onde \hat{y}_r são os valores ideais dos neurônios definidos como saída da rede.

A técnica do gradiente descendente aplicada diretamente a esta rede produz uma expressão de atualização dos pesos que exigiria a inversão de uma matriz a cada passo. Entretanto, se a expressão da atualização dos pesos for reescrita como:

$$\Delta w_{pq} = \delta_q y_p \quad (\text{V.27})$$

onde δ_q tem a expressão abaixo (η_q inclui a matriz a ser invertida):

$$\delta_q = \left[\frac{\partial G}{\partial w_{qi}} \left(x_q + \sum_j w_{qi} y_j \right) \right] \eta_q \quad (\text{V.28})$$

é demonstrado em [Hertz,1990] que são obtidas equações que possuem a mesma forma das equações de evolução da rede original, sem ser feita a inversão da matriz.

(1)

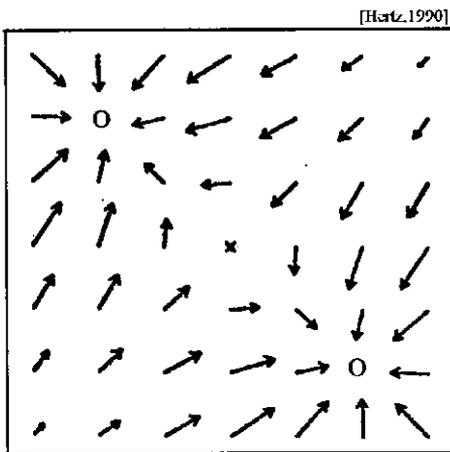


Figura V.7 - Exemplo de atrator

A figura V.7 ilustra o movimento na direção de atratores em uma rede neural com dois neurônios. Existem 2 atratores indicados pelos círculos, visto que o ponto central é um ponto de estagnação. O sistema se movimentará do seu ponto inicial nas direções das setas, sendo a sua velocidade proporcional à dimensão das setas. O sistema encontra uma posição de equilíbrio quando $dV_i/dt=0$, isto é, em um dos atratores, dependendo do ponto inicial. O lado esquerdo de (V.24) é um atrator da regra dinâmica expressa por aquela equação. As posições de equilíbrio correspondem a pontos de mínimo de um funcional de energia[Hertz,1990].

V.7 O PROGRAMA *Neuroshell 2*

O programa *Neuroshell 2* é um programa para a definição e o treinamento de redes neurais, desenvolvido para operar em ambiente Windows e microcomputadores do tipo PC. É um programa simples de ser utilizado, dispondo de uma série de opções para o usuário, mas não representa o estado na arte no assunto.

Este programa é composto por 3 estágios: **Básico**, **Avançado** e **Utilidades**. O estágio **Básico** é desenvolvido para o usuário que não tem nenhuma ou pouca experiência na utilização de redes neurais e é um subconjunto do estágio **Avançado**. O estágio **Avançado**, que foi utilizado no trabalho desta tese, é composto de várias seções específicas, conforme indicado na figura V.8.

Na seção da entrada de dados - *Problem Input* - os pares (x_i, z_i) podem ser fornecidos por digitação via teclado ou via arquivos previamente gerados por planilhas eletrônicas ou outros programas.

Na seção preliminar - *Pre-Network* - existem vários módulos. O módulo *Symbol Translate* permite que textos sejam transformados em números. O módulo *Rules* possibilita a geração de novos dados de entrada através da transformação dos dados fornecidos originalmente. O módulo *Custom* permite o acoplamento de preprocessadores específicos para determinados tipos de problemas como, por exemplo, índices do mercado financeiro. O módulo *Variable Graphics* permite ao usuário observar os dados fornecidos para a rede sob diversas formas gráficas. Como o programa opera em ambiente Windows, todos os tipos de gráficos gerados neste módulo podem ser copiados para o *Clipboard* do Windows para posterior utilização.

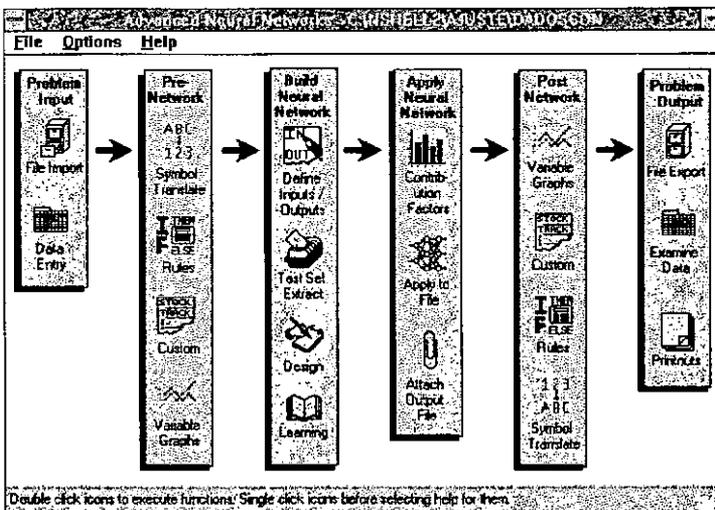


Figura V.8 - Módulo Avançado do Programa *Neuroshell 2*

Na seção seguinte - *Build Neural Network* - são preparados os dados de entrada e saída da rede neural, definida a sua topologia e executado o treinamento. Nos módulos *Define Input/Output* e *Test Set Extract* são definidos os valores máximos e mínimos do conjunto de dados de entrada e realizada a operação para dividir o conjunto original da dados em duas partes: treinamento e teste. O módulo *Design* permite a construção da rede neural a partir de 12 arquiteturas pré-estabelecidas, incluindo 6 modelos para redes neurais do tipo *feedforward backpropagation* e 3 modelos para um tipo simples de *recurrent backpropagation*, conforme ilustrado na figura V.9. Neste módulo são definidos os números de neurônios em cada camada, o número de camadas intermediárias, os tipos de função de ativação (por camada), os pesos iniciais e a técnica de treinamento: convencional, fornecendo-se valores para momentum e learning rate; *turboprop*, que acelera o processo de treinamento utilizando a técnica *adaptive learning rate* e um algoritmo exclusivo que considera a curvatura da superfície de erro.

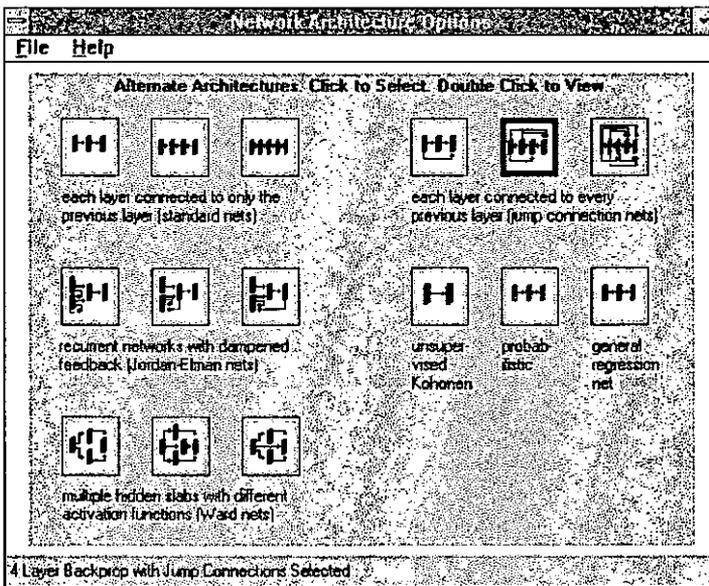


Figura V.9 - Tipos de redes neurais disponíveis

No módulo *Learning* é realizado o treinamento da rede, podendo o usuário dispor de gráficos referentes à evolução do erro durante esta fase. Esta seção fornece a rede neural treinada. O treinamento da rede é a parte mais importante da sua elaboração, visto que o objetivo principal é otimizar a sua capacidade de generalização. Para ajudar o usuário a alcançar este objetivo, o programa dispõe de uma modalidade de treinamento denominada de *Net-Perfect*, que avalia o erro de um conjunto de teste, simultaneamente com o cálculo do erro do conjunto de treinamento. O usuário pode decidir quando interromper o treinamento, de acordo com o critério assim estabelecido. Na figura V.10 é apresentada a janela correspondente a este módulo.

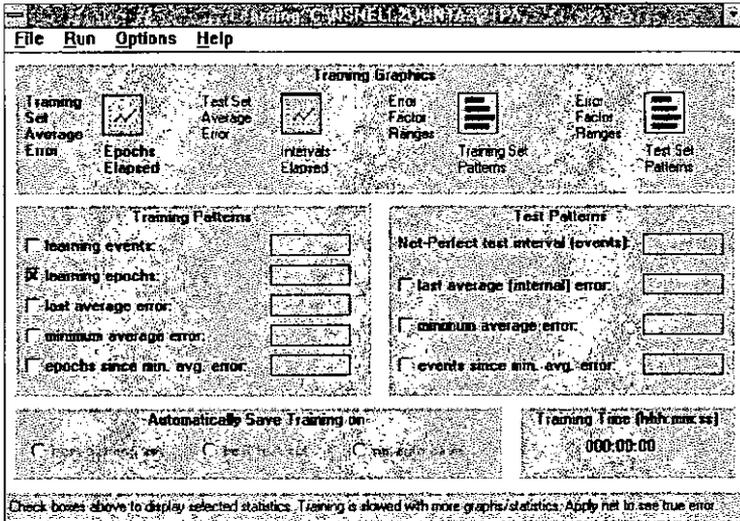


Figura V.10 - Janela do módulo *Training*

A próxima seção - *Apply Neural Network* - possui o módulo *Contribution Factors* que permite avaliar a influência dos dados de entrada da rede x_k , que através de gráficos mostra a contribuição relativa das variáveis de entrada na resposta da rede. O módulo *Apply to File* permite a utilização da rede gerada com dados de entrada provenientes de outros arquivos, que podem conter ou não os dados originalmente fornecidos à rede. O módulo *Attach Output File* possibilita ao usuário adicionar ao arquivo de entrada os resultados fornecidos pela rede neural, por meio da criação de um novo arquivo com todos os dados.

A seção *Post Network* possui módulos que realizam as mesmas funções disponíveis na seção *Pre Network*, mas para os dados de saída da rede.

A seção *Problem Output* contém procedimentos para colocar os dados utilizados pelo *Neuroshell 2* em formatos adequados para impressão de resultados e utilização por outro programas de computador.

No estágio **Utilidades**, o usuário dispõe de procedimentos para transformar a rede neural, criada pelos estágios **Básico** e **Avançado**, em códigos para serem conectados a programas desenvolvidos em compiladores C, Pascal, Visual Basic™ e Visual C™, permitindo também a sua utilização na planilha EXCEL™ ou no ACCESS™.

O programa *Neuroshell 2* é produzido e desenvolvido pela empresa Ward Systems Group, Inc., localizado em Executive Park West, 5 Hillcrest Drive, Frederick, MD, 21702, USA, fax no. (301) 6625666.

Capítulo VI

AVALIAÇÃO DE FADIGA EM TEMPO REAL

VI.1 INTRODUÇÃO

A garantia da segurança de estruturas, como a plataforma fixa de produção de petróleo mostrada na figura VI.1, implica na correta avaliação dos seus defeitos e na realização dos reparos necessários para a manutenção da sua integridade. A capacidade de modelar corretamente as incertezas, a atualização de previsões a partir de novos dados e a utilização do conhecimento de especialistas, associado às técnicas de inteligência artificial, são os requisitos básicos para permitir o acesso à condição de segurança ótima da estrutura.

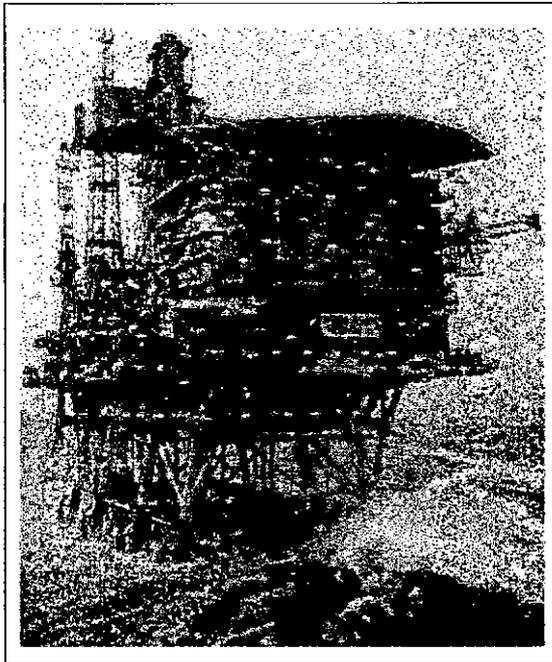


Figura VI.1 - Plataforma em condições reais de operação [OMAE,1992]

O acesso às informações referentes à condição de segurança da estrutura, começa com a distribuição inicial dos defeitos existentes, que corresponde à condição da estrutura após a sua fabricação, e é realimentado pelos resultados das inspeções realizadas ao longo da vida útil da estrutura. A probabilidade de não detecção da inspeção ultrasônica

é uma função com expoente negativo, o que significa o seu decréscimo com a dimensão do defeito. A distribuição é, então, atualizada, e todos os defeitos maiores do que um determinado padrão são removidos com excessão daqueles que, por diversas razões, não foram detectados [Pouliezos,1994].

A otimização dos procedimentos de inspeção e reparo de estruturas tem sido objeto de crescente interesse, principalmente no caso de estruturas offshore, devido aos elevados custos associados a eventuais falhas, à inspeção e ao reparo. Nos últimos dez anos, novas metodologias têm sido formuladas na tentativa de se alcançar este objetivo, utilizando as técnicas de confiabilidade estrutural [Faber,1992]. O tipo de inspeção, os locais a serem inspecionados e a frequência das inspeções têm sido normalmente baseados em critérios de engenharia, mas o aperfeiçoamento destes critérios tem se tornado cada vez mais um objetivo importante pela consequente redução dos custos que irá propiciar.

As premissas básicas para o desenvolvimento de novas estratégias são a modelação precisa do processo de crescimento de trincas, a disponibilidade de um banco de dados para todos os parâmetros utilizados, um método de confiabilidade que inclua a inferência Bayesiana (para melhor interpretar as informações de campo) e informações sobre a confiabilidade das técnicas de ensaios não destrutivos utilizadas. Um dos problemas inerentes a esta abordagem é a impossibilidade de se considerar todas estas características em aplicações práticas. Entretanto, a utilização de sistemas especialistas e redes neurais tem possibilitado o desenvolvimento de novas metodologias mais eficientes para o tratamento desta questão.

Os objetivos principais das novas metodologias devem ser [Peers,1992]:

- maior segurança para as estruturas;
- inspeção de componentes com maior probabilidade de ocorrência de trincas;
- otimização da inspeção pela definição mais precisa das suas tarefas.

A avaliação em tempo real do dano de fadiga pode contribuir para estes objetivos, pois permitirá uma avaliação mais precisa dos locais da plataforma que deverão ter prioridade para inspeção, a partir da utilização da condição real de carregamento da estrutura. Além desta contribuição, esta avaliação também irá possibilitar um melhor planejamento do reparo, propiciando um gerenciamento mais racional desta atividade.

O custo total esperado de uma estrutura offshore, durante a sua vida útil, é composto do custo inicial, do custo de inspeção, do custo de reparo e do custo causado por

eventuais falhas. A decisão para a execução do reparo, no modelo mais simples, assume que todas as trincas detectadas devem ser reparadas. Alternativamente, esta decisão pode considerar, conforme [Sorensen,1991], que o reparo seja executado nos locais onde o dano ultrapassou determinado valor, com a conseqüente redução dos custos de inspeção e reparo, caso haja disponibilidade de informações para corroborar este procedimento.

VI.2 MODELO DA PLATAFORMA

O modelo simples de pórtico espacial elaborado para a avaliação do dano de fadiga de uma plataforma fixa está mostrado na figura VI.2. A sua altura total é de 75m, a largura na face A é de 16m e a largura na face B é de 20m. As mesas, no total de 4, estão igualmente espaçadas, sendo que a superior corresponde aos conveses de uma plataforma típica de produção de petróleo e as outras 3 mesas pertencem à jaqueta da plataforma. A lâmina d'água considerada é de 55m.

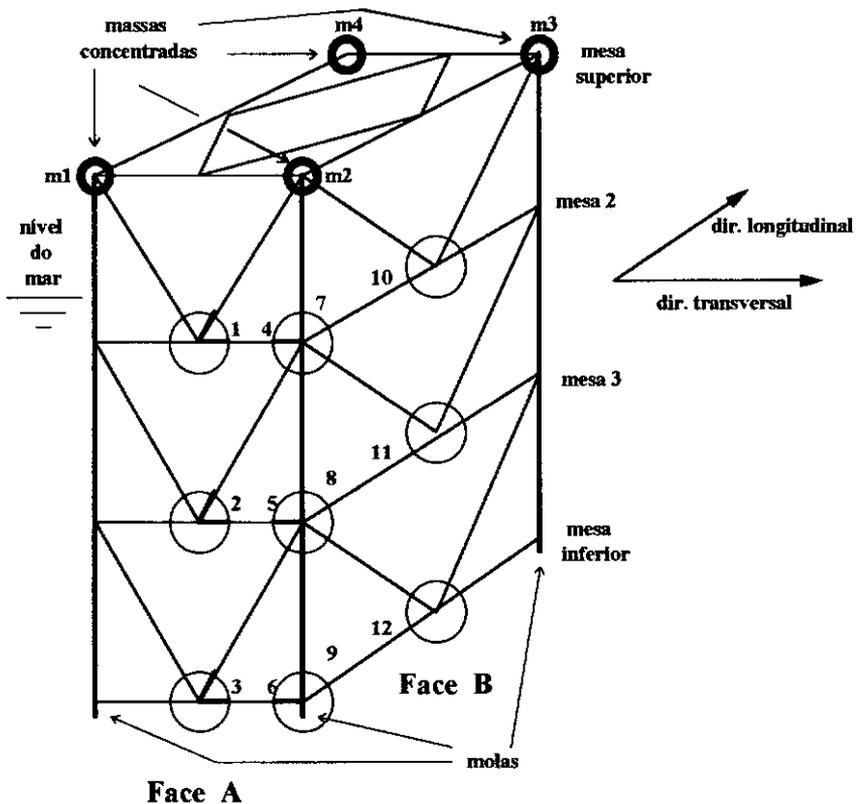


Figura VI.2 - Modelo simplificado de uma plataforma fixa

A estrutura da plataforma é composta por tubos de aço, com as dimensões que estão indicadas na tabela VI.1, onde os contraventamentos são os reforços horizontais das

mesas e os reforços inclinados das faces. As massas não estruturais dos conveses estão sendo simuladas como massas concentradas m_1 , m_2 , m_3 e m_4 , localizadas nos cantos da mesa superior, cujos valores estão discriminados na tabela VI.2. As condições de contorno estão sendo simuladas como molas verticais e horizontais, correspondentes aos valores de projeto da plataforma PGP-1, apresentados no item II.4. Para módulos longitudinal e transversal de elasticidade, coeficiente de Poisson e densidade foram considerados valores típicos referentes ao aço usado em construção naval.

TIPO	Diâmetro (mm)	Espessura (mm)
Perna	1200	60
Mesa	800	45
Contraventamento	600	35

Tabela VI.1 - Dimensões dos elementos estruturais

massas	m_1	m_2	m_3	m_4
valor (ton)	1000	1000	1500	1500

Tabela VI.2 - Valores das massas concentradas

Foi selecionado o elemento *PIPE16* do *ANSYSv5.0*, que é um elemento elástico 3D de tubo, para modelar o pórtico espacial. As molas foram modeladas pelo elemento de mola/amortecedor *COMBIN14* e as massas concentradas foram representadas pelo elemento de massa *MASS21*.

As juntas selecionadas para a avaliação da fadiga estão também indicadas na figura VI.2, correspondendo a um total de 12 conexões *brace/chord*. Os elementos da junta que estão sendo considerados para o cálculo das tensões também estão indicados na face A, sendo a posição semelhante na face B. O cálculo das tensões foi realizado na seção do elemento considerado *brace* em cada junta. O fator de concentração de tensões, em virtude da limitação do programa *ANSYSv5.0*, que só permite a sua aplicação para o caso do momento fletor, foi determinado de forma aproximada.

O efeito de massa adicionada foi considerado através de modificação da densidade dos elementos de tubo componentes da estrutura, por um fator que considera de forma adequada este efeito para seções circulares.

VI.3 FREQUÊNCIAS E MODOS NATURAIS DE VIBRAÇÃO

Inicialmente, foi feita a preparação dos dados de entrada do programa *ANSYSv5.0*, para a determinação das frequências e modos naturais de vibração da plataforma. Esta atividade correspondeu à geração do arquivo **modal.ent**, com todos os dados da geometria da plataforma, características do material e os comandos do programa *ANSYSv5.0* para este tipo de cálculo. As 3 primeiras frequências naturais da plataforma, que correspondem ao 1º modo de vibração na direção transversal, ao 1º modo na direção longitudinal e ao 1º modo de torção, respectivamente, estão apresentadas na tabela VI.3:

Frequências	modo T1	modo L1	modo Tor1
valor (Hz)	0.304	0.358	0.611

Tabela VI.3 - Frequências naturais da plataforma

Em virtude das características da força de excitação, proveniente da ação das ondas nos elementos que compõem a jaqueta, a contribuição de outros modos no cálculo das tensões é pequena e será desprezada.

Todos os dados referentes à análise modal feita pelo *ANSYSv5.0* são armazenados no arquivo binário com terminação **.db**, que é utilizado nos diversos módulos de cálculo do programa.

VI.4 EXCITAÇÃO DO MAR

A excitação do mar foi determinada por meio de densidades espectrais de mar geradas pela expressão de Pierson-Moskowitz indicada no capítulo II item 3. O critério para a determinação das alturas significativas A_s e do período T_0 se baseou em [Gupta,1987], sendo considerados os valores mostrados na tabela VI.4.

A densidade espectral da força de excitação foi calculada através das seguintes hipóteses:

- a forma da densidade espectral de força de excitação foi assumida semelhante à forma de densidade espectral do mar;
- os valores da densidade espectral da força de excitação foram determinados considerando-se os níveis de resposta obtidos nas Campanhas de Medição da plataforma PGP-1. O

critério consistiu em calibrar a densidade espectral 3 com dados experimentais, visto ser um estado de mar muito comum na Bacia de Campos. Nas demais densidades espectrais de força de excitação foi utilizado o mesmo fator.

Densidade Espectral	A_s (m)	T_0 (s)
1	0.61	2.54
2	1.52	4.24
3	2.74	5.89
4	3.96	7.23
5	5.20	8.40
6	6.40	9.46

Tabela VI.4 - Valores de A_s e T_0

As densidades espectrais de força de excitação foram aplicadas nos nós das mesas 2 e 3, considerando-se 7 direções distintas, com intervalos de 15 graus, sendo a referência zero a direção longitudinal, conforme indicado na tabela VI.5.

Direção	Referência (graus)	Observação
1	zero	dir. longitudinal
2	15	-
3	30	-
4	45	-
5	60	-
6	75	-
7	90	dir. transversal

Tabela VI.5 - Direções de incidência das ondas

Conforme mencionado no item 7 do capítulo II, no módulo de análise dinâmica aleatória do programa *ANSYSv5.0* existe um comando - PSDWAV - que foi implementado para considerar, de forma aproximada, uma atenuação de intensidade e um atraso de fase

para uma força que atua em uma estrutura como se fosse uma onda progressiva. Esta consideração é importante no caso de plataformas de petróleo, visto que a incidência das ondas na estrutura da jaqueta ocorre desta forma. Se as densidades espectrais de força de excitação forem consideradas atuando em todos os respectivos nós simultaneamente, o valor obtido para resposta ficará superdimensionado. No caso da incidência das direções transversal e longitudinal, a redução da resposta por se considerar o atraso de fase é de, aproximadamente, 30% e 40%, respectivamente. Na versão disponível do *ANSYSv5.0*, este comando não gera resultados corretos para as outras direções selecionadas, fato este que impediu a sua utilização na simulação desenvolvida neste trabalho.

O programa *ANSYSv5.0* dispõe de outra alternativa para a aplicação de densidades espectrais parcialmente correlacionadas, que é baseada em se montar uma matriz de densidades espectrais, conforme mostrado na equação (VI.1) para o caso de dois espectros. Os termos fora da diagonal principal estabelecem a correlação entre as densidades espectrais para até 10 espectros distintos.

$$\begin{bmatrix} S_{11}(\omega) & C_{21}(\omega) - iQ_{21}(\omega) \\ C_{12}(\omega) - iQ_{12}(\omega) & S_{22}(\omega) \end{bmatrix} \quad (\text{VI.1})$$

onde $i = \sqrt{-1}$.

Embora esta alternativa implique em um trabalho maior na preparação dos dados, ela foi utilizada na determinação da resposta do modelo simplificado de plataforma fixa, de forma a considerar a diferença de fase entre as densidades espectrais.

No total, foram considerados 42 carregamentos atuando na plataforma, tanto para o cálculo das densidades espectrais de resposta em deslocamento quanto para o cálculo das densidades espectrais de tensão nas seções das juntas selecionadas.

VI.5 RESPOSTA EM DESLOCAMENTO

O program *ANSYSv5.0*, no seu módulo de análise dinâmica aleatória, para o caso da entrada de dados sob a forma de densidade espectral, fornece como resposta os momentos espectrais dos deslocamentos para $i = \text{zero}, 2 \text{ e } 4$, cuja expressão é:

$$M_i^{\text{desl}} = \int_0^{\infty} \omega^i S_{\text{desl}}(\omega) d\omega \quad (\text{VI.2})$$

onde $S_{desl}(\omega)$ é a densidade espectral de deslocamento.

No caso específico deste trabalho, tendo em vista que a informação de deslocamento será a entrada da rede neural, se torna conveniente dividir o espectro em quatro regiões, conforme indicado na figura VI.3. A região A engloba a parte do espectro correspondente à resposta não amplificada da estrutura e, as regiões B, C e D, correspondem às respostas no entorno de cada uma das frequências naturais. Na realidade, não foi necessário a geração de todas as informações possíveis, pois as regiões B, C e D podem ser bem caracterizadas pelos momentos espectrais de ordem zero e 2.

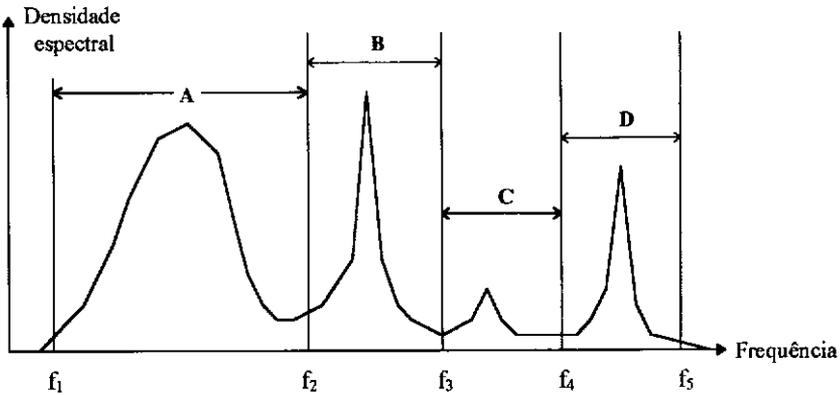


Figura VI.3 - Regiões da densidade espectral de resposta

Desta forma, as informações de deslocamento geradas pelo programa *ANSYSv5.0* para o treinamento da rede neural são:

$$\begin{aligned}
 desl(1) &= \int_{f_1}^{f_2} S_{desl}(\omega) d\omega, \quad desl(2) = \int_{f_1}^{f_2} \omega^2 S_{desl}(\omega) d\omega \quad \text{e} \quad desl(3) = \int_{f_1}^{f_2} \omega^4 S_{desl}(\omega) d\omega \\
 desl(4) &= \int_{f_2}^{f_3} S_{desl}(\omega) d\omega \quad \text{e} \quad desl(5) = \int_{f_2}^{f_3} \omega^2 S_{desl}(\omega) d\omega \\
 desl(6) &= \int_{f_3}^{f_4} S_{desl}(\omega) d\omega \quad \text{e} \quad desl(7) = \int_{f_3}^{f_4} \omega^2 S_{desl}(\omega) d\omega \\
 desl(8) &= \int_{f_4}^{f_5} S_{desl}(\omega) d\omega \quad \text{e} \quad desl(9) = \int_{f_4}^{f_5} \omega^2 S_{desl}(\omega) d\omega
 \end{aligned} \tag{VI.3}$$

onde as frequências f_j para $j=1, \dots, 5$ estão indicadas na figura VI.3.

A seleção dos pontos para o cálculo dos deslocamentos foi baseado na experiência do autor em desenvolvimento de trabalhos experimentais em plataformas de petróleo [Lopes,1991]. Visto que a aplicação prática da metodologia desenvolvida nesta tese deve levar em consideração a minimização do custo do sistema de aquisição de dados, foram selecionados quatro pontos que, teoricamente, representam o número mínimo de pontos a serem medidos. A localização destes pontos está mostrada na figura VI.5.

Para o caso da simulação realizada neste trabalho, cujo modelo de elementos finitos é excitado por uma densidade espectral de mar correspondente a ondas incidindo segundo uma única direção, ou seja, a ocorrência combinada de *swell* e *sea* com direções distintas não está sendo considerada, é possível uma simplificação na informação de deslocamento, através da utilização do valor médio em cada direção. Esta simplificação equivale a usar as densidades espectrais correspondentes ao ponto médio da mesa e foi adotada neste trabalho.

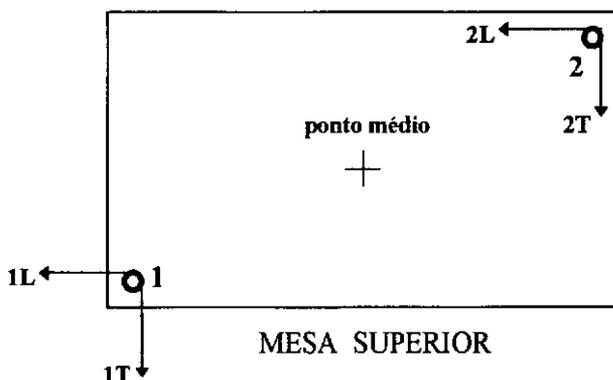


Figura VI.5 - Locais considerados para deslocamentos da plataforma

VI.6 RESPOSTA EM TENSÃO

O elemento PIPE16 permite diversos tipos de cálculo de tensão. Para o cálculo do dano de fadiga nas juntas utilizamos uma formulação de tensão combinada, que é traduzida por uma expressão do tipo:

$$S_x = \frac{F_x}{\frac{\pi}{4}(d_{\text{ext}} - d_{\text{int}})^2} + f_{ct} \frac{\sqrt{M_x^2 + M_z^2}(0.5d_{\text{ext}} - t_{\text{esp}})}{\frac{\pi}{64}(d_{\text{ext}}^4 - d_{\text{int}}^4)} \text{sen}\alpha_{\text{sec}} \quad (\text{VI.4})$$

onde F_x é a força axial, M_x e M_z são momentos fletores e o ângulo α_{sec} identifica o local na circunferência da junta onde está sendo calculada a tensão. Na figura VI.6 estão identificados os oito locais selecionados, em uma junta tipo T, para o cálculo das tensões. O procedimento é idêntico para outros tipos de junta com ângulo entre o *brace* e o *chord* diferente de 90° . Deve ser observada a limitação da expressão disponível no ANSYSv5.0 para o cálculo do f_{ct} (fator de concentração de tensões), pois este fator, naquele programa, não é considerado para esforços axiais e é o mesmo para os momentos fletores no plano e

fora do plano. No caso deste trabalho, foi aplicado um valor aproximado de f_{ct} , baseado na geometria das juntas.

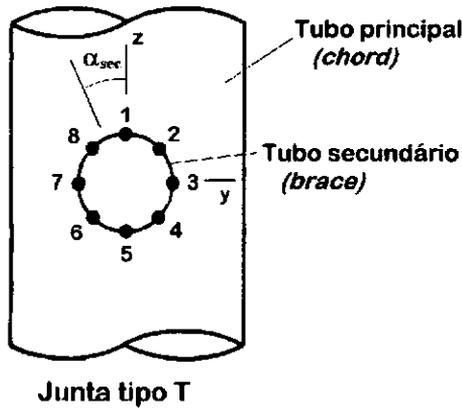


Figura VI.6 - Identificação dos locais para cálculo de tensões

Da mesma forma como no caso dos deslocamentos, o programa *ANSYSv5.0* fornece como resposta os momentos espectrais da tensão, para $i =$ zero, 2 e 4, nos locais selecionados, através da expressão:

$$M_i^{\text{tens}} = \int_{f_1}^{f_3} \omega^i S_{\text{tens}}(\omega) d\omega \quad (\text{VI.5})$$

onde $S_{\text{tens}}(\omega)$ é a densidade espectral de tensões.

VI.7 DANO DE FADIGA

Conhecendo-se os valores dos momentos espectrais, o cálculo do dano de fadiga pode ser realizado por meio da expressão (V.13), que corresponde à regra de Miner, ou pela expressão (V.18), que se baseia na regra de Paris-Erdogan. Para efeito de exemplo, estão sendo apresentados os valores do dano de fadiga para um intervalo de 20 minutos, para as 12 juntas e 8 locais, pela expressão (V.13) na tabela VI.6 e pela expressão (V.18) na tabela VI.7. Ambos os cálculos são referentes à densidade espectral 1 e à direção de onda 1.

Como esperado, os valores do dano de fadiga são diferentes com relação ao cálculo por Miner e Paris-Erdogan, pois o expoente tem o valor de 5 para a primeira regra e de 3 para a segunda regra, além de outras diferenças entre os dois métodos. Entretanto, a distribuição do dano de fadiga por junta é semelhante em ambos os casos, o que demonstra que para uma avaliação do dano relativo não deverá haver diferença, no resultado final - a

ordenação das juntas de acordo com o critério do dano relativo - sendo o cálculo feito por um ou outro método.

LOCAL JUNTA	1	2	3	4	5	6	7	8
1	0.31296E-09	0.65767E-08	0.19638E-07	0.12012E-07	0.12176E-08	0.49247E-11	0.46631E-14	0.75345E-11
2	0.42676E-09	0.10873E-07	0.32431E-07	0.17956E-07	0.13699E-08	0.14994E-11	0.24439E-12	0.81136E-10
3	0.40626E-09	0.18374E-07	0.61245E-07	0.31129E-07	0.15042E-08	0.12719E-13	0.18357E-10	0.23487E-10
4	0.50734E-10	0.31007E-09	0.61936E-09	0.41456E-09	0.91446E-10	0.69665E-11	0.66415E-12	0.65589E-11
5	0.21683E-11	0.63987E-08	0.36499E-07	0.13578E-07	0.57727E-10	0.16777E-09	0.38388E-08	0.13499E-09
6	0.27728E-11	0.18597E-08	0.52853E-08	0.77438E-09	0.22551E-12	0.35124E-09	0.13243E-08	0.91036E-08
7	0.62896E-10	0.29796E-09	0.50315E-09	0.30958E-09	0.71736E-10	0.76346E-11	0.13718E-11	0.66891E-10
8	0.28098E-11	0.12376E-07	0.72474E-07	0.25718E-07	0.71470E-10	0.51495E-09	0.10112E-07	0.55581E-09
9	0.25775E-11	0.18338E-07	0.67242E-07	0.10153E-07	0.31260E-12	0.74015E-08	0.33024E-07	0.73188E-09
10	0.48677E-10	0.21713E-09	0.35627E-09	0.22408E-09	0.56778E-10	0.67981E-11	0.11550E-11	0.19283E-11
11	0.80246E-11	0.27739E-07	0.18796E-06	0.69566E-07	0.17756E-09	0.21480E-08	0.39971E-07	0.88233E-08
12	0.34847E-12	0.63367E-07	0.30230E-06	0.55784E-07	0.20228E-11	0.33195E-07	0.18505E-06	0.77731E-08

Tabela VI.6 - Dano de fadiga pela regra de Miner

LOCAL JUNTA	1	2	3	4	5	6	7	8
1	0.17362E-08	0.10201E-07	0.19007E-07	0.13816E-07	0.34371E-08	0.12498E-09	0.23424E-11	0.75691E-09
2	0.20614E-08	0.13617E-07	0.25568E-07	0.17664E-07	0.37416E-08	0.64874E-10	0.22976E-10	0.22377E-09
3	0.20285E-08	0.18621E-07	0.37320E-07	0.24521E-07	0.39597E-08	0.41606E-11	0.27860E-09	0.49300E-09
4	0.66605E-09	0.20461E-08	0.32018E-08	0.25867E-08	0.10692E-08	0.23087E-09	0.53839E-10	0.22261E-09
5	0.11695E-09	0.12133E-07	0.33376E-07	0.18032E-07	0.66243E-09	0.13680E-08	0.84989E-08	0.22295E-08
6	0.10906E-09	0.54457E-08	0.10301E-07	0.33541E-08	0.30995E-10	0.19574E-08	0.43627E-08	0.81286E-08
7	0.76773E-09	0.20027E-08	0.28258E-08	0.21731E-08	0.92752E-09	0.24526E-09	0.84531E-10	0.55591E-09
8	0.13706E-09	0.17732E-07	0.49695E-07	0.26238E-07	0.75300E-09	0.25882E-08	0.14947E-07	0.34755E-08
9	0.10383E-09	0.21116E-07	0.46149E-07	0.14989E-07	0.37701E-10	0.12201E-07	0.29901E-07	0.84199E-08
10	0.65132E-09	0.16480E-08	0.23025E-08	0.18051E-08	0.81587E-09	0.23170E-09	0.77017E-10	0.99134E-10
11	0.26436E-09	0.28739E-07	0.87152E-07	0.47142E-07	0.13102E-08	0.60853E-08	0.33850E-07	0.53277E-08
12	0.31772E-10	0.44226E-07	0.11314E-06	0.41318E-07	0.11402E-09	0.30114E-07	0.84082E-07	0.71275E-08

Tabela VI.7 - Dano de fadiga pela regra de Paris-Erdogan

Observamos nas tabelas VI.6 e VI.7 que o maior dano ocorre na junta 12, para os dois métodos utilizados. Para efeito de comparação e visualização do efeito de valor do coeficiente m , os valores do dano para esta seção estão sendo apresentados sob forma gráfica, na figura VI.7, podendo ser constatado que:

- para os valores maiores do dano, o resultado por Miner é maior;
- para valores menores do dano, os resultados se equivalem;
- para valores muito pequenos de dano, embora não constem no gráfico devido à escala, o resultado por Paris é maior.

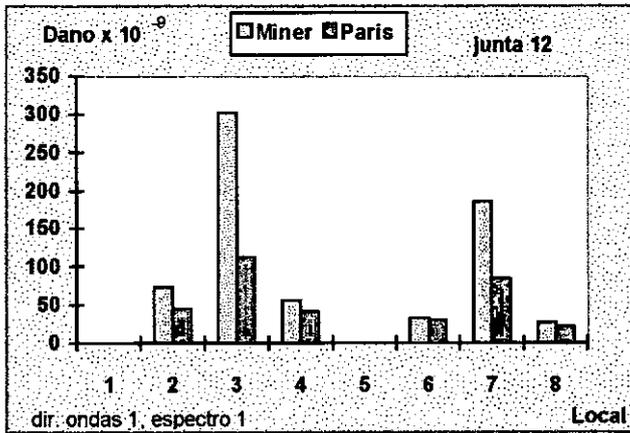


Figura VI.7 - Comparação do dano de fadiga

Visto que a combinação das tensões ao longo da seção de uma junta e a operação destas tensões com o expoente m , geralmente fornece resultados com diferenças de uma ou mais ordens de grandeza para os diversos valores de dano calculados, a conversão destes valores para outra escala, por exemplo: logarítmica, tornaria a manipulação destes valores mais fácil de ser realizada. Desta forma, os valores indicados no gráfico da figura VI.7 estão sendo rerepresentados na figura VI.8, através de uma conversão feita pelo logaritmo neperiano, considerando o seu valor absoluto, uma vez que o dano por fadiga é um valor menor do que 1.

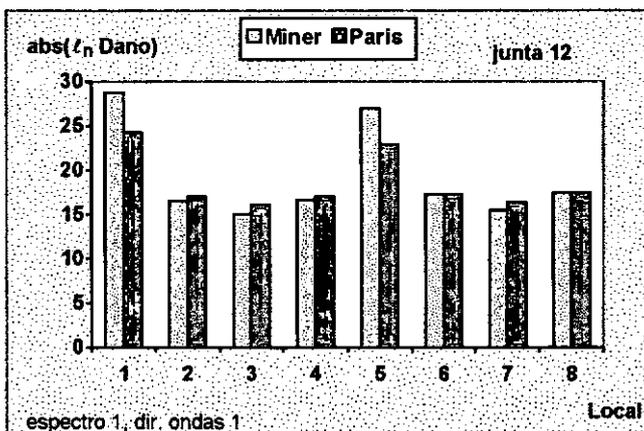


Figura VI.8 - Danos de fadiga em escala logarítmica

No caso de se utilizar o módulo do logaritmo dos valores calculados para o dano de fadiga, conforme apresentado na figura VI.8, quanto maior for o dano menor será o seu valor nesta nova escala. A diferença entre dois valores na nova escala representa $e^{\text{diferença de valores}}$ em unidades originais do dano. Este tipo de transformação é conveniente para a utilização dos valores do dano de fadiga em redes neurais.

O dano de fadiga calculado, para esta mesma junta e densidade espectral tipo 1, para as diversas direções consideradas, apresenta a distribuição mostrada na figura VI.9. Pode ser observado que o dano diminui com a mudança da direção das ondas, atingindo o seu menor valor para a onda incidindo segundo a direção transversal.

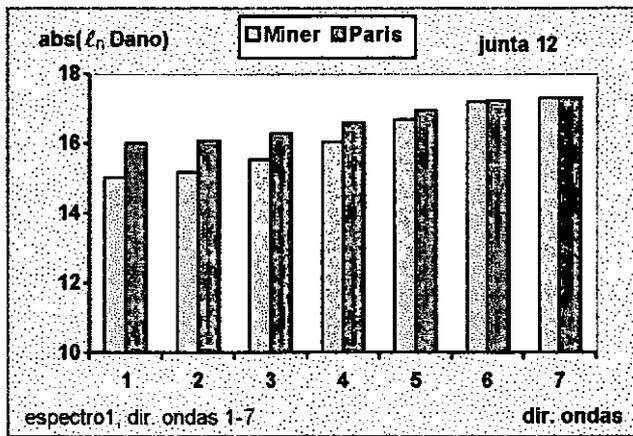


Figura VI.9 - Variação do dano com a direção das ondas

O dano de fadiga em função da variação do estado de mar e ondas incidindo segundo a direção longitudinal, para esta mesma junta 12, está indicado na figura VI.10. Pode ser observada a tendência do valor do dano aumentar com a evolução do estado de mar (tipo de densidade espectral).

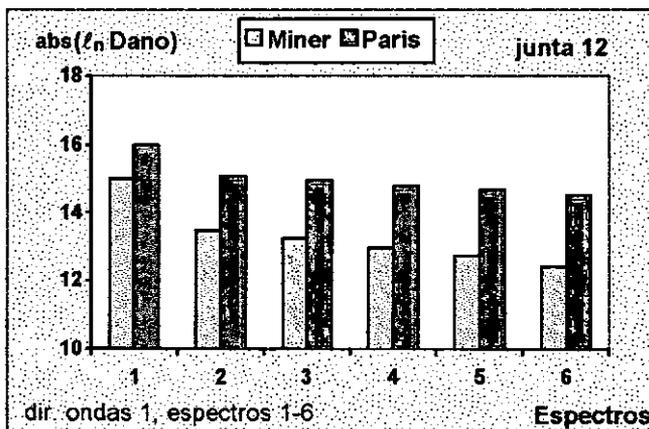


Figura VI.10 - Variação do dano com o estado de mar

VI.8 REDES NEURAIS NA SIMULAÇÃO DO DANO DE FADIGA

VI.8.1 Introdução

O objetivo a ser alcançado, que pode ser alterado caso necessário, é:

Desenvolver uma rede neural tipo *feedforward*, com treinamento pela técnica *backpropagation*, que deverá ser composta por:

- uma camada de entrada formada por 18 neurônios, representando as informações do deslocamento no ponto médio do convés de uma plataforma fixa de produção de petróleo, nas direções transversal e longitudinal;
- uma camada de saída formada por 8 neurônios, representando os valores do dano de fadiga para os 8 locais selecionados na seção do elemento da junta.
- camadas intermediárias a serem dimensionadas e funções de ativação dos neurônios a serem determinadas.

Definido o objetivo, o primeiro passo é a definição da topologia da rede. No programa *Neuroshell 2* há diversas topologias de rede que podem ser uma solução para o problema, conforme indicado a seguir. A rede tipo 1, apresentada na figura VI.11, é a mais simples, podendo ter 1, 2 ou 3 camadas intermediárias.

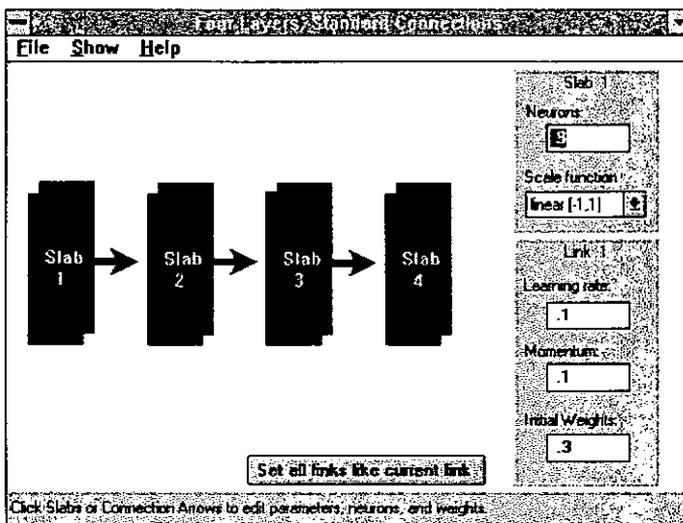


Figura VI.11 - Rede *feedforward* com conexões entre camadas adjacentes

A rede tipo 2, mostrada na figura VI.12, é semelhante à rede tipo 1, mas possui conexões entre todas as camadas, mesmo não sendo adjacentes, o que implica em um número de pesos maior do que no tipo 1.

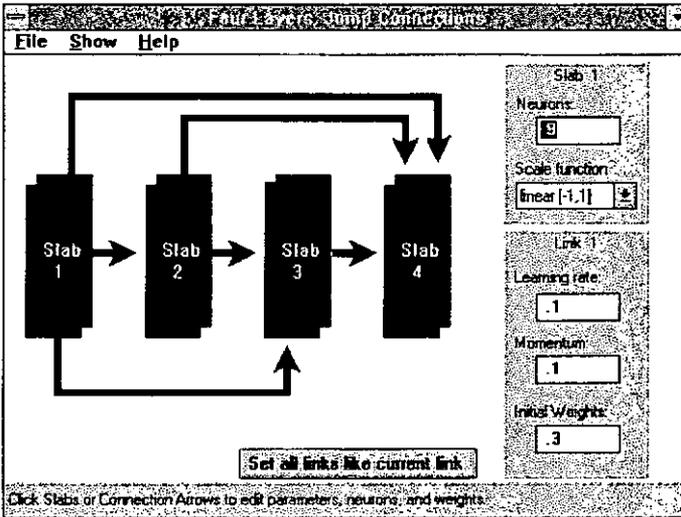


Figura VI.12 - Rede *feedforward* com conexão entre todas as camadas

A rede indicada na figura VI.13 é o tipo 3, que corresponde a uma topologia de rede recorrente com realimentação na camada intermediária, que também é treinada com a técnica de *backpropagation*.

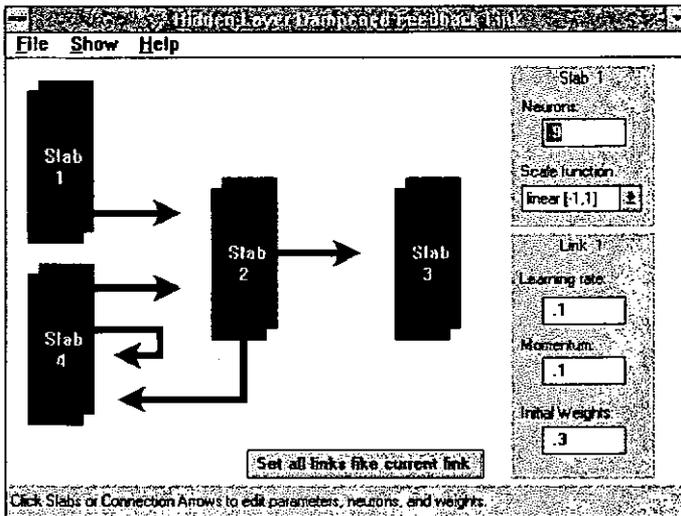


Figura VI.13 - Rede recorrente na camada intermediária

No programa *Neuroshell 2*, as redes tipos 1 e 2, embora mostradas com 2 camadas intermediárias, podem ser dimensionadas também com 1 ou 3 camadas intermediárias. O número de neurônios nas camadas intermediárias, cujo dimensionamento é uma característica do projeto de redes neurais, será determinado de acordo com sugestão baseada na experiência prática do fornecedor do programa, que é traduzida na seguinte expressão, que pode ser arredondada para mais ou para menos:

$$N_{int} = \frac{1}{2} \frac{1}{c_{int}} \left[(N_{ent} + N_{sai}) + \sqrt{N_{amostras}} \right] \quad (VI.6)$$

onde:

- N_{int} : número de neurônios nas camadas intermediárias;
- N_{ent} : número de neurônios na camada de entrada;
- N_{sai} : número de neurônios na camada de saída;
- $N_{amostras}$: número de amostras para treinar a rede;
- C_{int} : número de camadas intermediárias.

A rede neural para avaliação do dano de fadiga, em uma seção de um elemento de uma junta da plataforma, terá, de acordo com o exposto nos itens anteriores, 18 neurônios na camada de entrada, 8 neurônios na camada de saída e 42 amostras (cada amostra composta por um vetor com 18 dados de entrada e 8 dados de saída) para o seu treinamento. Desta forma, de acordo com a expressão (VI.6), o número de neurônios para 1 camada intermediária será 19 ou 20, para 2 camadas intermediárias será 9 ou 10 e para 3 camadas intermediárias será 6 ou 7.

VI.8.2 Avaliação Preliminar do Desempenho das Redes Neurais de Fadiga

Inicialmente, foi feita uma avaliação do desempenho de diversos tipos de rede com os dados do dano de fadiga referentes à junta 1. Foram considerados os casos indicados na tabela VI.8, apresentada a seguir.

Caso	Tipo de rede	Número de camadas intermediárias	neurônios nas camadas intermediárias
1a	1	1	20
1b		2	10/10
1c		3	7/7/7
2a	2	1	20
2b		2	10/10
2c		3	7/7/7
3a	3	1	20

Tabela VI.8 - Casos estudados na avaliação preliminar

Os critérios utilizados para a avaliação preliminar das redes neurais, para simulação do dano de fadiga, são os seguintes:

- o conjunto inicial de dados é dividido no conjunto de treinamento, com 38 amostras, e no conjunto de teste, com 4 amostras, sendo as amostras de teste selecionadas aleatoriamente do conjunto original;
- a função de ativação da camada de entrada é linear, da camada intermediária é logística e da camada de saída também é logística;
- o treinamento é realizado com a alternativa *TurboProp*, disponível no programa *Neuroshell 2*;
- o treinamento termina quando o erro do conjunto de treinamento < 0.00025 ou quando o número de eventos do conjunto de teste desde o erro mínimo deste conjunto > 20000 . Esta segunda condição é mais crítica, pois está relacionada à capacidade da rede generalizar.

Os resultados desta avaliação estão apresentados na figura VI.14, onde o número de vezes que os dados são apresentados à rede (eventos), o erro do conjunto de treino (erro treino) e o erro do conjunto de teste (erro teste) foram normalizados com relação aos valores mínimos de cada um destes itens. Término igual a 1 significa que o treinamento terminou antes que o número de eventos, após o erro mínimo do conjunto de teste, fosse maior do que 4000 e igual a 5 quando o seu valor atingiu 20000. Pode ser constatado que a rede com o melhor desempenho corresponde ao caso 2b.

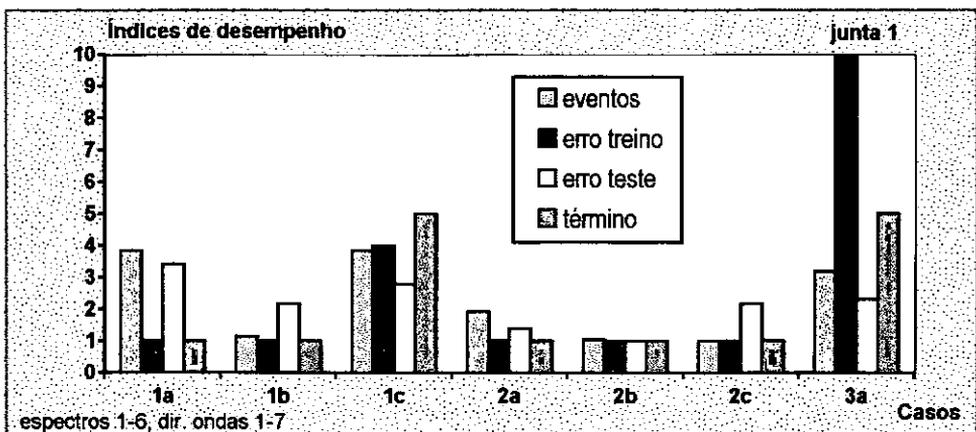


Figura VI.14 - Resultados da avaliação preliminar

A rede neural correspondente ao caso 2b pode ser analisada com maior nível de detalhamento, utilizando-se as diversas alternativas de análise gráfica, disponíveis no

programa *Neuroshell 2*. As curvas de evolução dos erros durante o treinamento e os gráficos de distribuição do erro mínimo estão apresentados nas figuras VI.15a, VI.15b, VI.15c e VI.15d apresentadas a seguir.

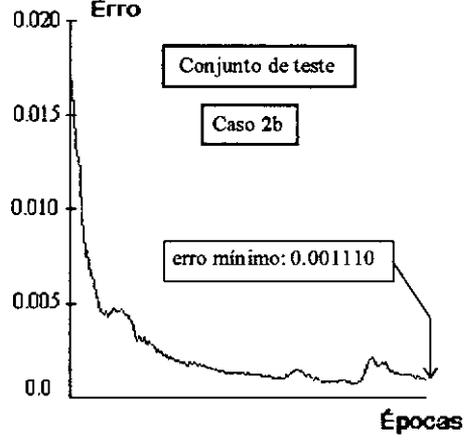
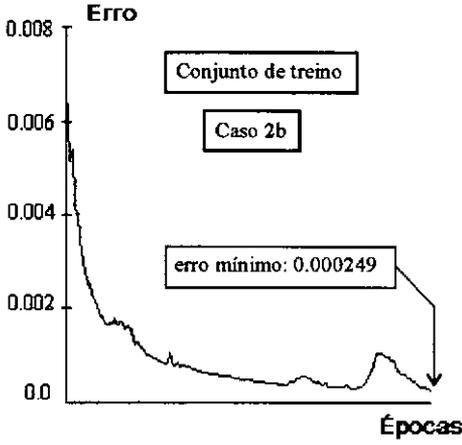


Figura VI.15a - Erro do conjunto de treino

Figura VI.15b - Erro do conjunto de teste

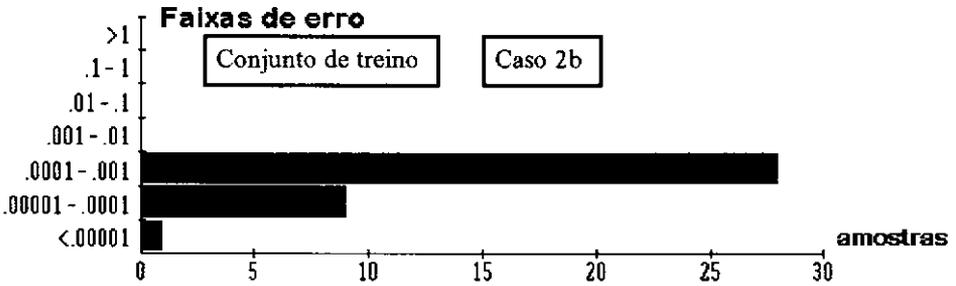


Figura VI.15c - Faixas de erro do conjunto de treino

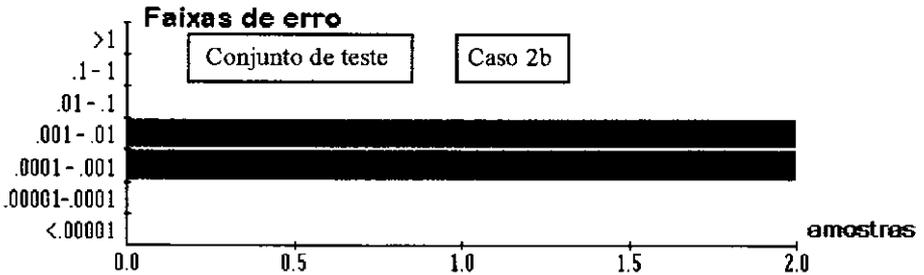


Figura VI.15d - Faixas de erro do conjunto de teste

Embora o conjunto de treino tenha atingido o erro mínimo de 0.00025, conforme indicado na figura VI.15a, o erro mínimo do conjunto de teste ainda é elevado, fato este que pode ser constatado pela grande diferença existente nos gráficos correspondentes à distribuição das faixas de erro. Como o objetivo desta avaliação é selecionar a rede com melhor desempenho global, o treinamento não foi continuado após o conjunto de treino alcançar o erro mínimo estipulado. Como o objetivo do treinamento é obter uma rede neural com boa capacidade de generalizar e também com a melhor precisão possível, o procedimento adequado, conforme sugerido no próprio programa utilizado, é prosseguir com o treinamento até ele ser interrompido quando o número de eventos após o erro mínimo do conjunto de teste se situar numa faixa de 20000 a 40000 eventos.

Após a rede ter sido treinada, é possível acessar a informação referente à participação ou fator de contribuição de cada parâmetro do conjunto de entrada na operação da rede. Este fator corresponde à importância de cada um dos dados de entrada, permitindo, inclusive, a eliminação de parâmetros que tenham pouca participação na resposta da rede. Na figura VI.16 está apresentado o fator de contribuição para a rede 2b, correspondente ao treinamento realizado, onde pode ser observado que todos os parâmetros considerados como dados de entrada participam da resposta da rede.

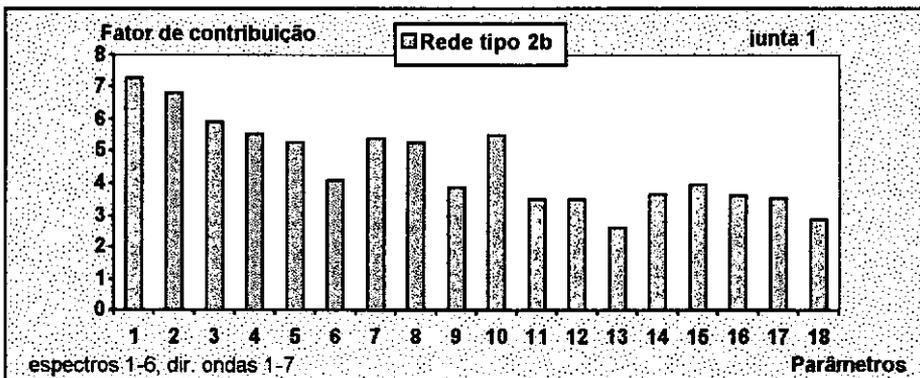


Figura VI.16 - Fator de contribuição referente à rede 2b

O programa *Neuroshell 2* permite também o acesso aos valores dos diversos pesos entre as camadas de neurônios, em qualquer fase do treinamento, possibilitando a eliminação manual de pesos que não contribuam para a resposta da rede.

A rede tipo 2b está selecionada para representar o processo de dano de fadiga e, no próximo item será feita uma avaliação da sua sensibilidade para a variação do número de neurônios na camada intermediária e da variação da função de ativação. O objetivo desta nova avaliação é selecionar a rede mais eficiente quanto ao aspecto da generalização.

VI.8.3 Avaliação Definitiva do Desempenho das Redes Neurais de Fadiga

A rede neural a ser utilizada para a simulação do dano de fadiga, além de representar bem os dados utilizados para o treinamento, deve possuir uma boa capacidade para generalizar. Em uma situação real, uma grande parte dos dados de entrada não irá coincidir com os dados usados no treinamento e, desta forma, a rede neural deverá “interpolar” ou “extrapolar” para fornecer a resposta para cada novo conjunto de parâmetros de entrada.

Os critérios utilizados para a avaliação definitiva das redes neurais para simulação do dano de fadiga são os seguintes:

- o conjunto inicial de dados é dividido em um conjunto de treinamento, com 33 amostras, em um conjunto de teste, com 4 amostras, e em um conjunto de avaliação, com 5 amostras, sendo as amostras destes dois últimos conjuntos selecionadas aleatoriamente do conjunto original;
- função de ativação da camada de entrada é linear, da camada intermediária é logística ou tangente hiperbólica e da camada de saída é logística;
- o número de neurônios das camadas intermediárias é considerado variando na faixa de 8 a 12.
- o treinamento é realizado com a alternativa *TurboProp*, disponível no programa *Neuroshell 2*;
- o treinamento termina quando o número de eventos do conjunto de teste a partir do seu erro mínimo > 20000 (essencial para a capacidade da rede generalizar).

Serão avaliados os dez casos, que estão identificados na tabela VI.9. O conjunto de avaliação não será utilizado durante o treinamento, mas numa fase posterior em que a rede já estará definida. Este conjunto será aplicado à rede na seção *Apply Neural Network* do programa *Neuroshell 2*, simulando uma condição real de operação. Nesta seção, o módulo *Apply to File* permite a utilização da rede gerada com qualquer dado de entrada, pertencente ou não aos conjuntos de treinamento. A saída deste módulo é uma planilha, contendo os resultados desejados e os resultados calculados pela rede, assim como coeficientes de correlação para avaliar o desempenho da rede. Estes dados podem ser colocados sob a forma gráfica, de forma que seja mais fácil a visualização dos erros relativos, fornecendo subsídios para se aceitar ou não determinada rede como a melhor representante para simular o problema que estiver sendo analisado.

Caso	Tipo de rede	Número de camadas intermediárias	Neurônios nas camadas intermediárias	Função de ativação
1	2b	2	8	logística
2	2b	2	9	logística
3	2b	2	10	logística
4	2b	2	11	logística
5	2b	2	12	logística
6	2b	2	8	tang. hiperb.
7	2b	2	9	tang. hiperb.
8	2b	2	10	tang. hiperb.
9	2b	2	11	tang. hiperb.
10	2b	2	12	tang. hiperb.

Tabela VI.9 - Casos estudados na avaliação definitiva

Os erros mínimos do conjunto de teste, correspondentes a cada um dos casos estudados estão indicados na figura VI.17. Pela avaliação do erro relativo do conjunto de teste, podemos concluir que a rede correspondente ao caso 4 é aquela que tem o melhor desempenho. Mas, a distribuição dos valores do erro relativo para os casos 1, 2, 3 e 4 indica, aparentemente, a possibilidade da existência de outra solução caso seja aumentado o número de eventos considerado no treinamento. O valor do número de eventos correspondente ao treinamento, que está indicado na parte superior de cada barra para os casos 1, 2, 3 e 4, permitiria concluir que o caso 1, devido ao menor número de neurônios e ao maior número de eventos, não deverá possuir uma capacidade de generalização melhor do que os casos 2, 3 e 4, em virtude da grande diferença do número de eventos para treinamento e do menor número de neurônios intermediários.

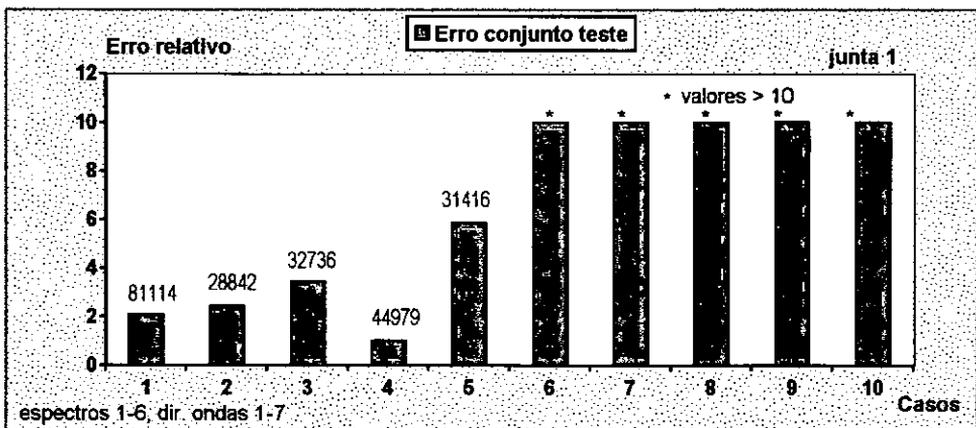


Figura VI.17 - Erros no conjunto de teste nos casos 1-10

Aumentado-se o número de eventos no treinamento para 40000, é realmente possível se conseguir a redução do erro relativo, conforme indicado na figura VI.18, mas a capacidade de generalização é bastante reduzida.

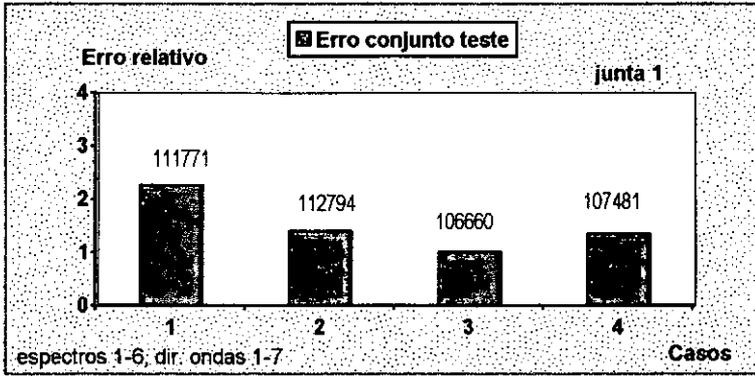


Figura VI.18 - Influência do número de eventos no erro mínimo

Fazendo-se uma avaliação do caso 4 treinado com 24979 eventos (que corresponde a 44979 eventos menos os 20000 eventos do critério) e do caso 3 treinado com 86660 eventos (que corresponde a 106660 eventos menos os 40000 eventos do segundo critério), com o conjunto de avaliação já definido (conjunto que não foi ainda apresentado às redes), são obtidos os coeficientes de correlação indicados na tabela VI.10. A análise da tabela permite concluir que a rede neural referente ao caso 4 é a melhor rede para representar o dano de fadiga, pois possui boa capacidade de generalização.

Locais de dano Rede	1	2	3	4	5	6	7	8
3	0.989	0.999	0.707	0.841	0.511	0.864	0.958	0.996
4	1.000	0.999	1.000	1.000	0.999	0.998	0.999	0.999

Tabela VI.10 - Desempenho das redes com o conjunto de avaliação

A metodologia aqui utilizada para procurar a rede mais eficiente é considerada válida apenas para este tipo de problema, não devendo ser interpretada como uma técnica para a busca de uma rede ótima para qualquer tipo de problema.

Nas figuras VI.19a e VI.19b estão apresentadas as curvas de erro dos conjuntos de treino e de teste correspondentes ao treinamento. A distribuição destes erros por faixas está apresentada nas figuras VI.19c e VI.19d.

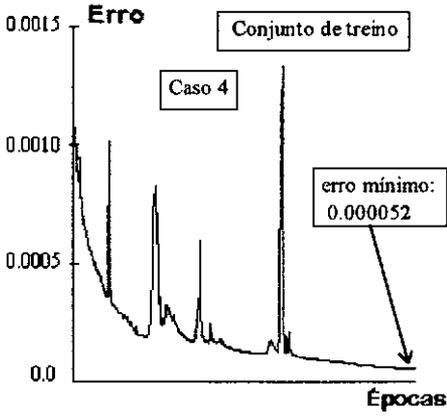


Figura VI.19a - Erro no conjunto de treino

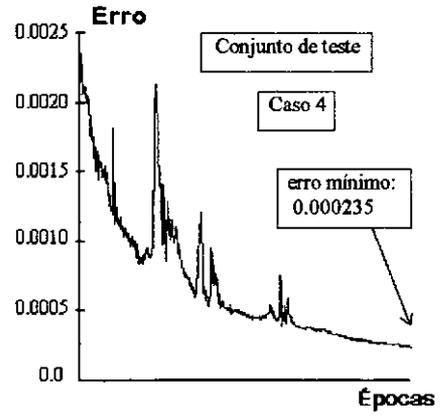


Figura VI.19b - Erro no conjunto de teste

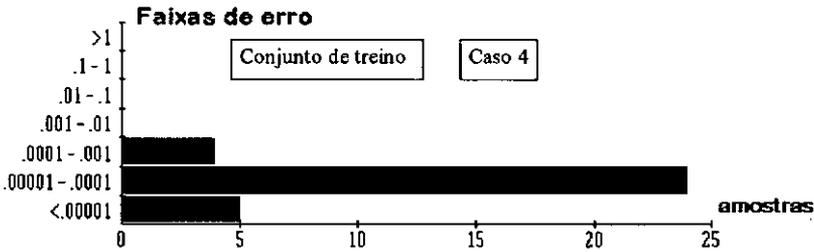


Figura VI.19c - Faixas de erro do conjunto de treino

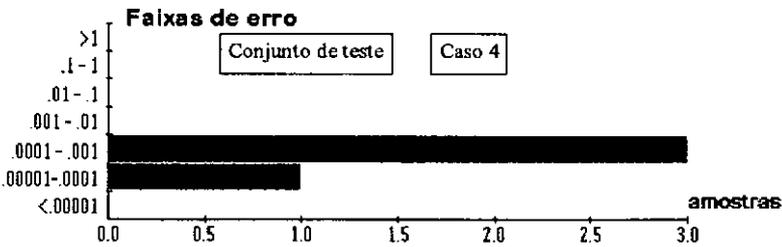


Figura VI.19d - Faixas de erro do conjunto de teste

Pode ser observado na figura VI.19d que houve uma mudança na distribuição do erro pelas faixas quando compara-se a rede correspondente aos casos 4 e 2b, que são redes neurais com a mesma topologia, havendo diferença somente no critério de treinamento.

O fator de contribuição da nova rede está mostrado na figura VI.20. Comparando-se com a situação anterior, nota-se a maior participação do parâmetro 1, que

corresponde ao momento de ordem zero do espectro de deslocamento, direção transversal, na faixa referente à região não amplificada da resposta.

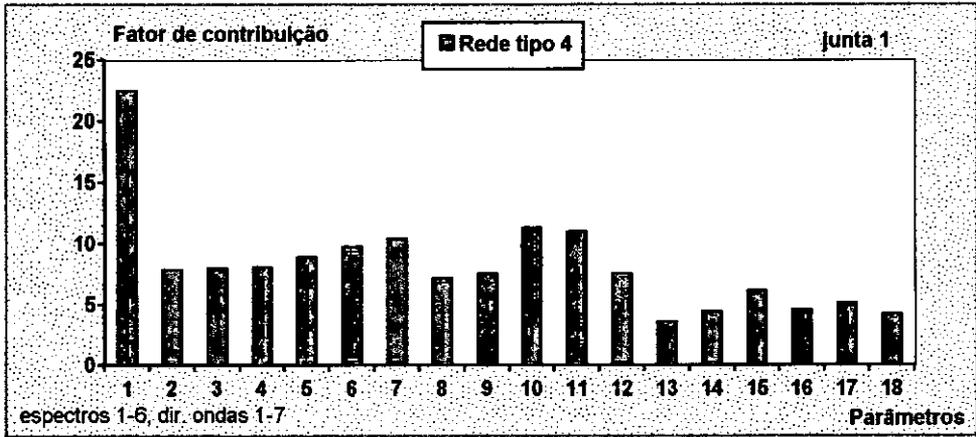


Figura VI.20 - Fator de contribuição referente à rede 4

Os dados originais fornecidos à rede, referentes ao conjunto de avaliação, estão apresentados na tabela VI.11 e os valores calculados pela rede, para este mesmo conjunto, estão indicados na tabela VI.12.

Locais Amostras	1	2	3	4	5	6	7	8
1	19.72	16.96	16.04	16.67	19.12	24.80	32.98	25.68
2	18.65	15.78	14.81	15.41	17.81	23.41	32.49	24.08
3	20.99	18.85	18.30	19.22	21.91	27.68	34.52	25.82
4	18.03	15.23	14.31	14.94	17.39	23.02	32.61	24.90
5	26.03	28.16	40.16	27.68	26.33	28.63	36.76	27.94

Tabela VI.11 - Valores originais fornecidos à rede

Locais Amostras	1	2	3	4	5	6	7	8
1	19.69	16.90	16.04	16.57	18.94	24.71	32.98	25.76
2	18.92	16.06	14.87	15.59	17.87	23.42	32.61	24.73
3	21.06	18.85	18.24	19.29	21.95	27.62	34.48	25.22
4	18.26	15.70	14.77	15.20	17.57	23.18	32.80	24.02
5	25.84	28.01	39.96	27.79	26.72	28.89	36.50	27.45

Tabela VI.12 - Valores calculados pela rede

O erros relativos referentes aos dados calculados encontram-se na tabela VI.13. Os valores correspondentes ao erro relativo são pequenos, indicando que a rede neural possui uma boa capacidade de generalização. A informação do dano sob a forma logaritmica permite se obter uma informação instantânea referente ao dano de fadiga, mas para o cálculo do dano acumulado, seria necessário um erro muito menor do que o obtido pelo fato de estar sendo utilizado o valor absoluto do logaritmo neperiano do dano de fadiga.

Locais Amostras	1	2	3	4	5	6	7	8
1	0.15	0.35	0.0	0.59	0.94	0.36	0.0	(0.31)
2	(1.44)	(1.77)	(0.40)	(1.20)	(0.32)	(0.03)	(0.35)	(0.26)
3	(0.35)	0.0	0.33	(0.37)	(0.19)	0.19	0.13	(0.15)
4	(1.25)	(3.04)	(3.24)	(1.68)	(1.07)	(0.68)	(0.60)	(0.05)
5	0.74	0.52	0.49	(0.41)	(1.48)	(0.93)	0.71	0.54

Tabela VI.13 - Erros relativos (%)

Considerando-se os dados de dano de fadiga pela regra de Miner na sua forma original, sem nenhum tipo de transformação, para a junta 1, densidade espectral 1 e direções 1-7, os valores obtidos estão apresentados na tabela VI.14.

LOCAL DIREÇÃO	1	2	3	4	5	6	7	8
1	3.12943E-10	6.57494E-09	1.96340E-08	1.20163E-08	1.21806E-09	4.92350E-12	4.66354E-15	8.93172E-12
2	2.78946E-10	5.61963E-09	1.64984E-08	1.00068E-08	1.00930E-09	4.08376E-12	4.04215E-15	9.20369E-13
3	1.78042E-10	3.32764E-09	9.54738E-09	5.75037E-09	5.84070E-10	2.47693E-12	2.52383E-15	7.95344E-13
4	7.71708E-11	1.25265E-09	3.45653E-09	2.07770E-09	2.18332E-10	1.05867E-12	1.07549E-15	5.74659E-13
5	2.03487E-11	2.39852E-10	6.08515E-10	3.71675E-10	4.39046E-11	3.07592E-13	2.86440E-16	3.57371E-13
6	2.88932E-12	1.22806E-11	2.25338E-11	1.62163E-11	3.38726E-12	7.07942E-14	4.48592E-17	2.06598E-13
7	4.87736E-13	5.80193E-14	3.56126E-19	9.45167E-14	3.62410E-13	3.65169E-14	1.07137E-17	1.39042E-13

Tabela VI.14 - Dano de fadiga pela regra de Miner na junta 1

Observa-se na tabela VI.14, correspondente à densidade espectral de menor energia, que a diferença entre o maior e o menor valores é de aproximadamente 10^{11} , fato este que tornaria impossível o treinamento de uma rede sem a realização de transformações no conjunto de dados. As tentativas de treinar a rede completa, utilizando-se o logaritmo neperiano dos danos de fadiga, com a metodologia disponível no programa *Neuroshell 2*,

também não conduziram a resultados com precisão suficiente para a sua utilização prática. No caso da transformação logarítmica, o erro transmitido para o domínio original pode ser calculado através da expressão (VI.7):

$$E_{\text{exp}} = e^{\pm \varepsilon_1} \Rightarrow \approx 1 \pm \varepsilon_1 \text{ se } |\varepsilon_1| \leq 0.15 \quad (\text{VI.7})$$

onde $\pm \varepsilon_1$ corresponde ao erro entre o valor fornecido à rede (v_{fom}) e o valor calculado pela rede (v_{calc}). Por exemplo, no caso de um erro relativo de 0.5% para $v_{\text{fom}} = 20$, o erro transmitido ao dano será de $e^{0.1}$, que irá corresponder a um erro de aproximadamente 10% no domínio original.

Uma alternativa para a redução do erro é a geração de uma rede para cada local da junta. Neste caso, a dispersão dos dados será menor e a rede poderá ser treinada com mais facilidade. O objetivo definido será então modificado, passando a camada de saída da rede a ser formada por apenas um neurônio.

Outra alternativa que pode ser utilizada para a atenuação do erro, caso ele ainda seja elevado, é a utilização de uma segunda transformação. Se o valor do dano, sob a forma de logaritmo neperiano, for elevado a um expoente k , e o treinamento da rede for executado neste novo domínio, o erro transmitido é fornecido por:

$$E_{\text{raiz}} = \left(\frac{v_f \pm \varepsilon_2}{v_f} \right)^{\frac{1}{k}} \Rightarrow \approx 1 \pm \frac{\varepsilon_2/k}{v_f^{1/k}} \text{ se } (|\varepsilon_2|/v_f) \ll 1 \quad (\text{VI.8})$$

onde ε_2 é erro produzido pela rede no domínio correspondente a esta segunda transformação e v_f é o valor correspondente a um determinado dado fornecido à rede. Por exemplo, se o valor de v_f for $16 \cdot 10^4$ e o valor de ε_2 for $0.32 \cdot 10^4$, correspondendo a um erro de 2%, no caso de $k=4$ o erro transmitido será de aproximadamente 0.5%. Isto significa que um erro de 2% no treinamento da rede irá conduzir a um erro no entorno de 10% no dano de fadiga expresso na sua forma original, para este valor de v_f .

Considerando todas as avaliações já realizadas, decidiu-se adotar os seguintes procedimentos para o treinamento da rede neural, com a finalidade de reduzir o seu erro :

1) Os conjuntos de dados, com relação à direção das ondas, foram divididos em dois subconjuntos, de forma a separar os valores do dano em dois grupos distintos, identificados por uma faixa de menor variação e outra de maior variação do dano. Na tabela VI.15 estão apresentados os danos referentes às densidades espectrais 1 e 6 em dois locais da junta 1. As variáveis $\text{desl}(1)_L$ e $\text{desl}(1)_R$ são os momentos de primeira ordem correspondentes à

resposta estrutural na região não amplificada, definidos nas equações (VI.3). A direção correspondente a razão $desl(1)_L / desl(1)_T = .85$ pode ser utilizada para identificar os subconjuntos, no caso da junta 1. As direções estão numeradas de 1 a 19, sendo o primeiro grupo correspondente à densidade espectral 1. O dano calculado por Miner nos locais 1 e 3 estão identificados por Loc1M e Loc3M e, por Paris, como Loc 1P e Loc 3P.

Direções	$desl(1)_L$	$desl(1)_T$	Loc1M	Loc3M	Loc1P	Loc3P
1	0.29282	0.00610	21.885	17.746	20.172	17.778
2	0.29080	0.01531	21.903	17.774	20.189	17.804
3	0.28711	0.03378	21.944	17.837	20.218	17.848
4	0.28287	0.05182	22.000	17.920	20.242	17.883
5	0.27676	0.06866	22.082	18.024	20.314	17.972
6	0.26579	0.08747	22.249	18.230	20.428	18.110
7	0.25359	0.09971	22.449	18.467	20.514	18.211
8	0.24351	0.11569	22.628	18.702	20.661	18.395
9	0.22590	0.13148	22.952	19.099	20.874	18.650
10	0.20703	0.14089	23.285	19.483	21.021	18.821
11	0.19317	0.15371	23.635	20.015	21.283	19.186
12	0.16993	0.16567	24.159	20.689	21.619	19.611
13	0.14641	0.17252	24.618	21.220	21.831	19.863
14	0.12836	0.18081	25.263	22.809	22.275	20.778
15	0.10063	0.18826	26.010	23.859	22.758	21.490
16	0.07584	0.19242	26.570	24.516	23.034	21.842
17	0.01591	0.19529	27.123	26.582	23.426	22.784
18	0.00089	0.19780	27.812	30.786	23.872	24.189
19	0.00003	0.19917	28.349	42.479	24.133	32.611
1	1.42550	0.02187	18.038	14.311	18.014	15.844
2	1.41567	0.06344	18.035	14.340	18.013	15.870
3	1.39765	0.15864	18.029	14.404	18.011	15.915
4	1.37700	0.26035	18.019	14.489	18.009	15.950
5	1.34724	0.34509	18.076	14.594	18.062	16.040
6	1.29387	0.43978	18.196	14.803	18.147	16.179
7	1.23450	0.50136	18.347	15.042	18.213	16.281
8	1.18541	0.58175	18.494	15.279	18.338	16.466
9	1.09968	0.66117	18.772	15.678	18.524	16.722
10	1.00780	0.70852	19.069	16.064	18.655	16.894
11	0.94034	0.77302	19.384	16.600	18.897	17.262
12	0.82723	0.83319	19.874	17.278	19.212	17.689
13	0.71275	0.86765	20.314	17.810	19.415	17.942
14	0.62489	0.90934	21.036	19.424	19.897	18.867
15	0.48990	0.94681	21.825	20.478	20.405	19.583
16	0.36921	0.96770	22.401	21.136	20.690	19.936
17	0.07798	0.98218	23.680	23.272	21.344	20.715
18	0.00439	0.99481	24.371	27.476	22.299	23.920
19	0.00016	1.00170	26.038	40.169	22.863	31.342

Tabela VI. 15 - Dano de fadiga em função das direções de onda

2) conforme exposto no ítem anterior, foram consideradas direções adicionais de incidência de ondas, visto que a quantidade inicial de dados é reduzida para o treinamento das redes. Os novos dados foram obtidos, como no conjunto inicial, a partir do programa *ANSYSv5.0*.

3) o número de dados de entrada da rede foi reduzido de 18 para 14, eliminando-se as informações referentes ao terceiro modo de vibração do modelo de plataforma.

4) os dados referentes ao dano de fadiga, previamente transformados em logaritmo neperiano, foram divididos em dois subconjuntos, com 13 e 7 direções de incidência de onda. No caso da junta 1, o primeiro sub-conjunto, correspondendo a 13 direções, contém os menores valores do logaritmo do dano (\Rightarrow maiores valores de dano). Os dados deste grupo foram elevados a quarta potência. Os dados do segundo grupo, com 7 direções de incidência, foram elevados ao cubo. Os valores maiores do logaritmo do dano, que aparecem no final de cada grupo, nas colunas de Loc3M e Loc3P, representam, na realidade, valores extremamente reduzidos de dano e, como podem causar imprecisões no treinamento da rede, assumiu-se um intervalo máximo de 5 entre dois valores consecutivos.

Com a finalidade de se fazer uma avaliação qualitativa, foram calculados os erros, em valor absoluto, produzidos por um conjunto de avaliação não utilizado no seu treinamento, para os locais 1 e 3 da junta 1. Para o grupo a, referente aos menores valores do logaritmo do dano, foram considerados 63 vetores de treinamento, 8 vetores de teste e 7 vetores de avaliação. Para o grupo b, referente aos maiores valores do logaritmo do dano, foram utilizados 34 vetores de treinamento, 4 vetores de teste e 4 vetores de avaliação. A preparação destes vetores foi feita a partir da geração de números aleatórios.

Na figura VI.21 está apresentada a distribuição de erro (caso 1), para o local 1 da junta 1 do grupo a, pelas regras de Miner ($E11ma(8)$ - camada intermediária com 8 neurônios) e pelo critério de Paris ($E11pa(8)$ - camada intermediária com 8 neurônios).

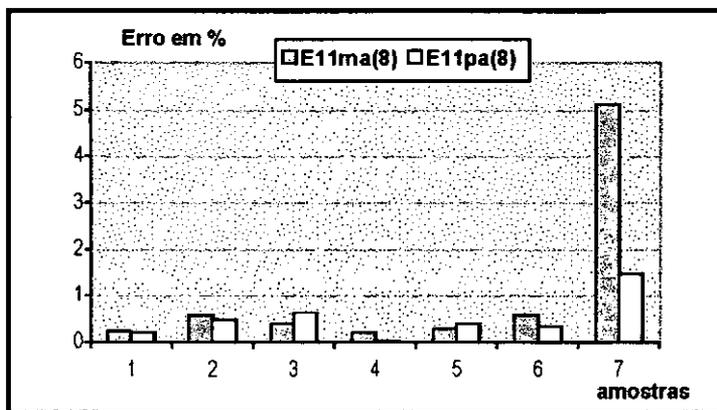


Figura VI.21 - Distribuição do erro para o local 1 da junta 1 do grupo a (caso 1)

Na figura VI.22, os erros correspondem ao mesmo local do caso anterior, porém a rede treinada pelos dados da regra de Miner tem 9 neurônios na camada intermediária. Pode ser verificado que o acréscimo do número de neurônios corresponde a uma redução nos valores dos erros.

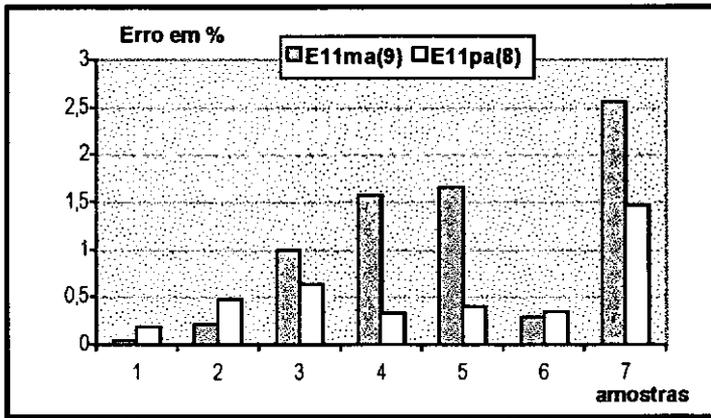


Figura VI.22 - Distribuição do erro para o local 1 da junta 1 do grupo a (caso 2)

Na figura VI.23 está apresentada a distribuição de erro, para o local 3 da junta 1 do grupo a, pelas regras de Miner (E13ma(8) - camada intermediária com 8 neurônios) e pelo critério de Paris (E13pa(8) - camada intermediária com 8 neurônios).

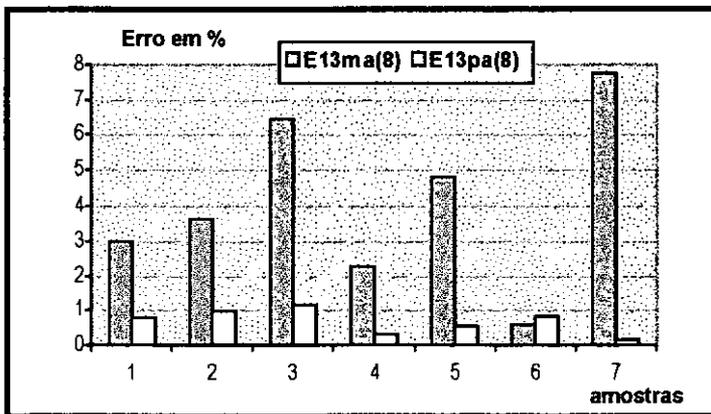


Figura VI.23 - Distribuição do erro para o local 3 da junta 1 do grupo a (caso 1)

Na figura VI.24, os erros correspondem ao mesmo local do caso anterior, porém a rede treinada pelos dados da regra de Miner tem 9 neurônios na camada intermediária. Também, neste caso, é obtida uma grande redução dos erros, havendo uma clara indicação de que 9 é o número ótimo de neurônios para a rede treinada com os dados de fadiga provenientes da regra de Miner. No procedimento de cálculo do dano, as tensões são elevadas ao expoente 5, no caso da regra de Miner, e ao expoente 3, no caso da regra de Paris, ocasionando relações funcionais distintas com os deslocamentos da plataforma.

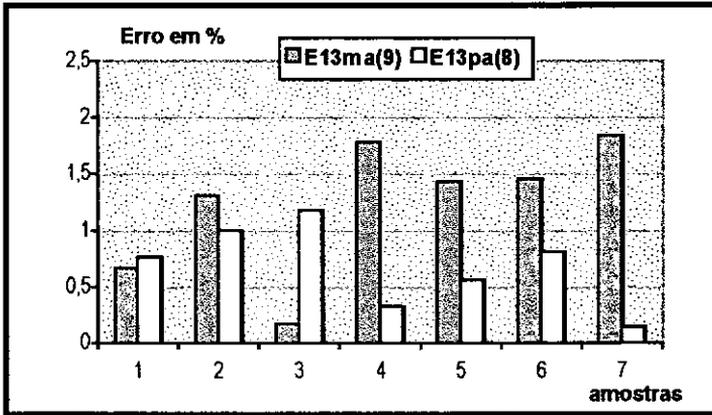


Figura VI.24 - Distribuição do erro para o local 3 da junta 1 do grupo a (caso 2)

Nas figuras VI.25 e VI.26 estão apresentadas as distribuições de erro, para o local 1 e 3 da junta 1 do grupo b, para redes com camada intermediária de 6 neurônios, não havendo, praticamente, diferenças para regras de Miner e Paris.

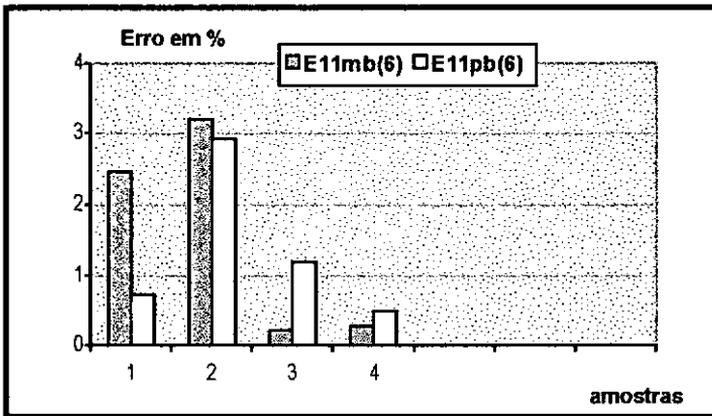


Figura VI.25 - Distribuição do erro para o local 1 da junta 1 do grupo b

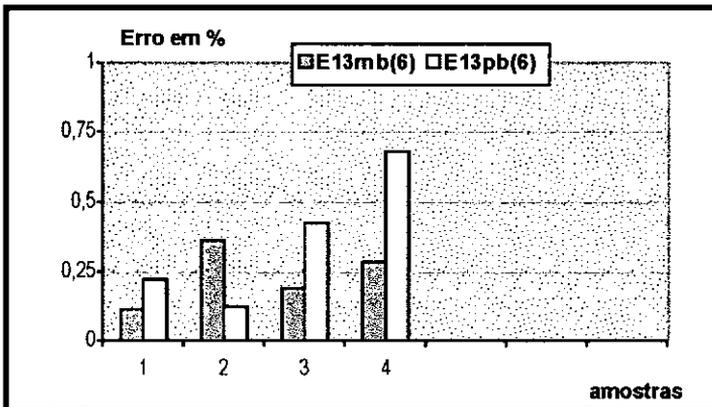


Figura VI.26 - Distribuição do erro para o local 3 da junta 1 do grupo b

Com a finalidade de se comparar os erros nos locais 1 e 3 da junta 1, considerando-se os resultados das redes já treinadas (E11pa(8) e E13pa(6)), com os erros nos mesmos locais produzidos por uma rede com 8 neurônios de saída, isto é, uma rede treinada com todos os locais da junta simultaneamente, foi desenvolvida e treinada uma nova rede neural. Ela é semelhante às redes neurais com um elemento de saída, com a diferença de que as 2 camadas intermediárias possuem 11 neurônios cada, constituindo-se na melhor rede para este caso. Os resultados obtidos estão apresentados nas figuras VI.27 e VI.28, denominados de ECO11pa(11) para o local 1 e ECO13pa(11) para o local 3. Estas redes foram treinadas com os dados provenientes da regra de Paris. A observação destes resultados permite concluir, como esperado, que as redes com apenas um neurônio na camada de saída produzem os menores erros, visto que estas redes são treinadas com conjunto de dados que correspondem aos danos de fadiga de cada local da junta.

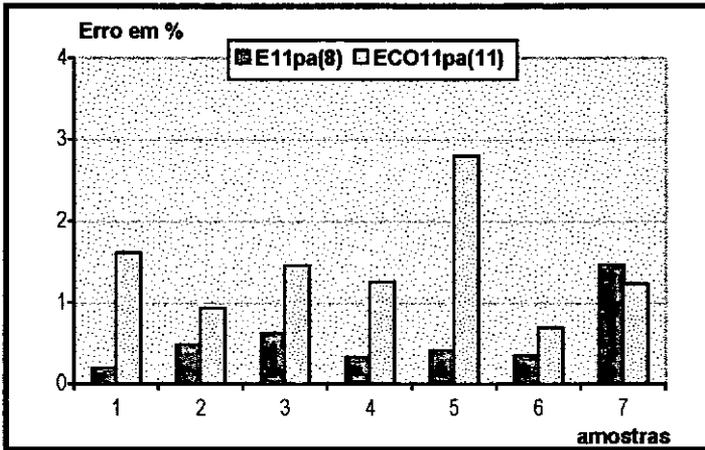


Figura VI.27 - Comparação dos erros das redes neurais E11pa(8) e ECO11pa(11)

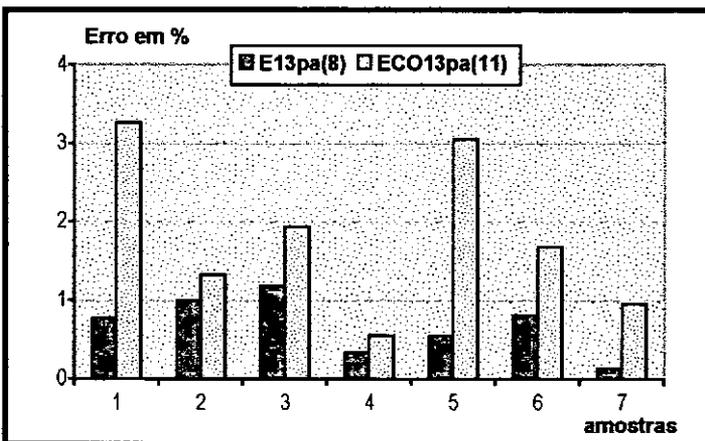


Figura VI. 28 - Comparação dos erros das redes neurais E13pa(8) e ECO13pa(11)

Caso a rede neural fosse treinada com os dados correspondentes às 19 direções, considerando-se o valor absoluto do logaritmo do dano sem nenhum tipo de transformação, a distribuição dos erros seria diferente. Para se fazer a avaliação desta condição, foram treinadas as redes denominadas 11pa(8) e 11pb(6). Os erros referentes às redes E11pa(8) e E11pb(6) foram divididos por 4 e 3, respectivamente, de forma que uma comparação entre as distribuições de erros pudesse ser realizada. Os resultados destas comparações estão apresentados nas figuras VI.29 e VI.30.

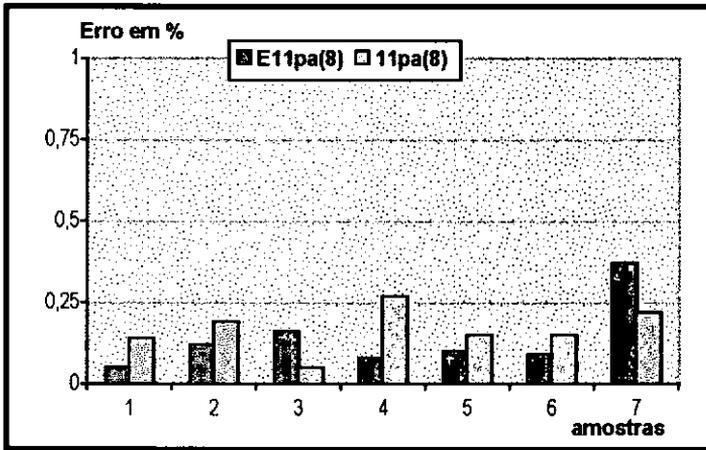


Figura VI.29 - Comparação dos erros das redes neurais E11pa(8) e 11pa(8)

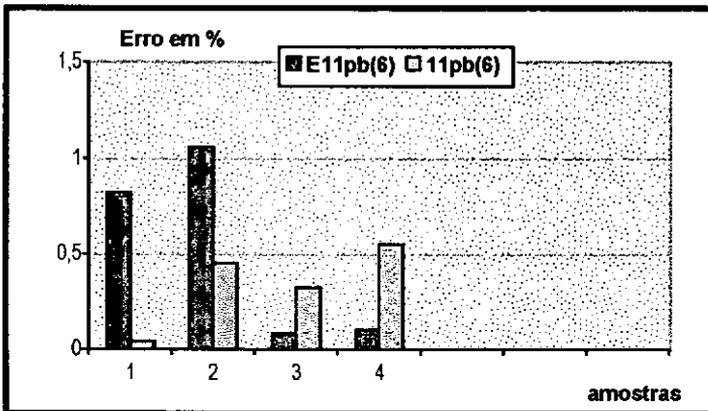


Figura VI.30 - Comparação dos erros das redes neurais E11pb(6) e 11pb(6)

Os resultados obtidos são um indicativo de que, a princípio, não se conseguiria uma redução significativa da distribuição dos erros com a transformação exponencial.

Assim sendo, o treinamento das redes neurais será realizado com o valor absoluto do logaritmo neperiano, sem nenhum tipo de transformação adicional.

Os resultados obtidos permitem concluir que a rede neural com um elemento de saída, treinada pelos dados referentes à regra de Paris, é a que melhor representa o processo do dano de fadiga da junta 1 do modelo de plataforma fixa. Esta conclusão considera que os locais 1 e 3 são representativos da junta pelo fato de não haver outro local com faixa de variação de dano superior às faixas de variação destes locais.

Os fatores de contribuição correspondentes às redes 11pa(8) e 11pb(6) estão apresentados a seguir, nas figuras VI.31 e VI.32.

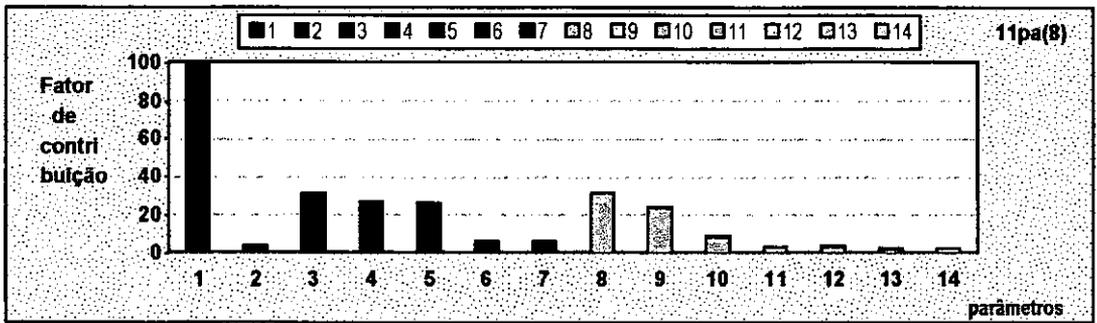


Figura VI.31 - Fator de contribuição referente à rede 11pa(8)

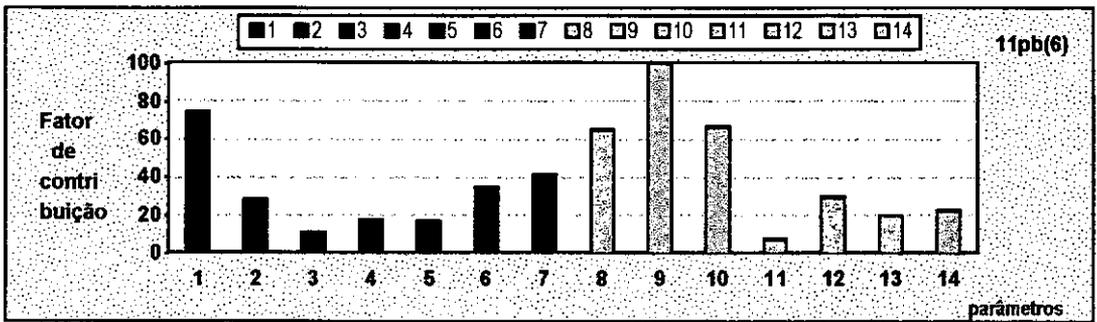


figura VI.32 - Fator de contribuição referente à rede 11pb(6)

No caso da rede 11pa(8), que corresponde às direções de incidência de onda de zero a 60 graus, a influência do deslocamento não amplificado na direção zero graus é predominante com relação aos outros dados de entrada e alguns dos parâmetros (2, 6, 7, 11, 12, 13 e 14) praticamente não participam da resposta da rede. No caso da rede 11pb(6), que corresponde às direções de incidência de onda de 60 a 90 graus, a influência dos deslocamentos e momentos na direção 90 graus são tão importantes quanto os da direção zero graus. Estas características são coerentes com o comportamento físico do problema, com relação à influência da direção das ondas no valor do dano de fadiga.

Para efeito de uma avaliação final da precisão das redes neurais, o mesmo procedimento foi aplicado para as outras 11 juntas do modelo, locais 1 e 3, considerando-se o dano calculado pela regra de Paris e redes neurais com a mesma configuração das redes desenvolvidas para a junta 1. A topologia das redes está indicada na figura VI.33, sendo que a diferença é o número de neurônios na camada intermediária, que pode ser 8 ou 6, dependendo da rede representar o grupo a (valores menores do logaritmo do dano) ou o grupo b (valores maiores do logaritmo do dano).

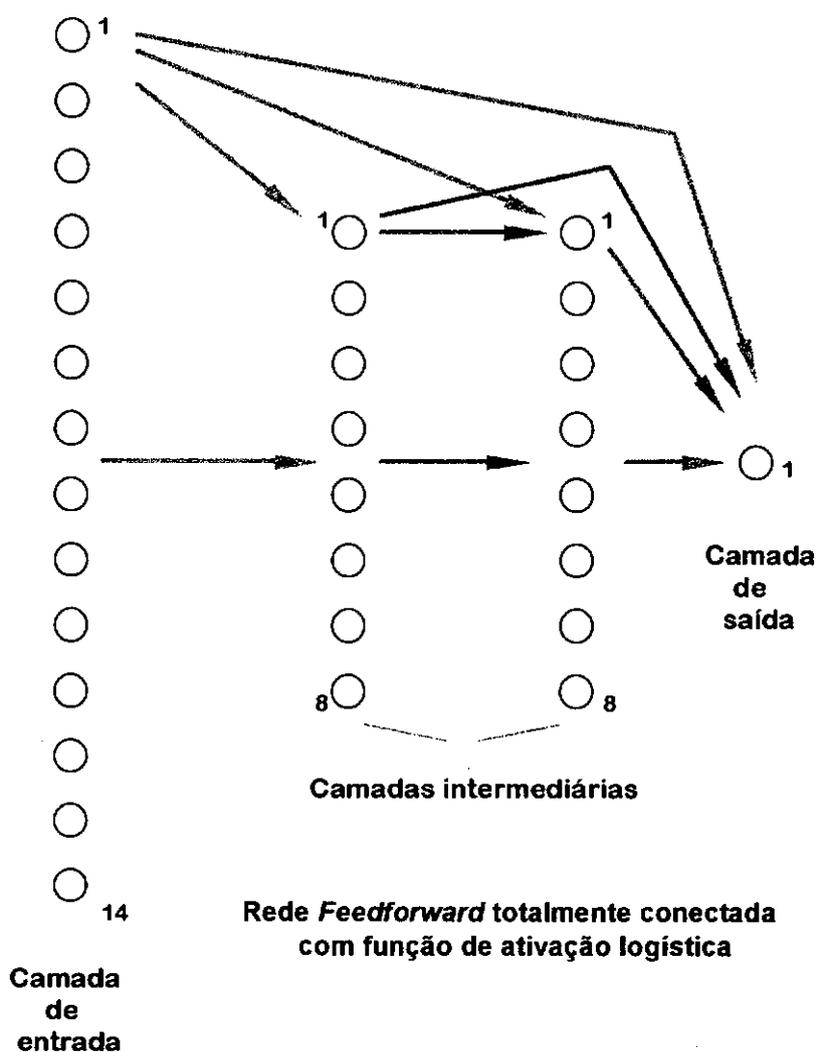


Figura VI.33 - Topologia da rede neural para dano de fadiga

Nas figuras VI.34 a VI.77, apresentadas a seguir, são indicados os erros, em valor absoluto, para o conjunto de avaliação para todas as demais juntas seleccionadas. Os cálculos foram realizados apenas para os locais 1 e 3, que são considerados significativos para a finalidade deste trabalho.

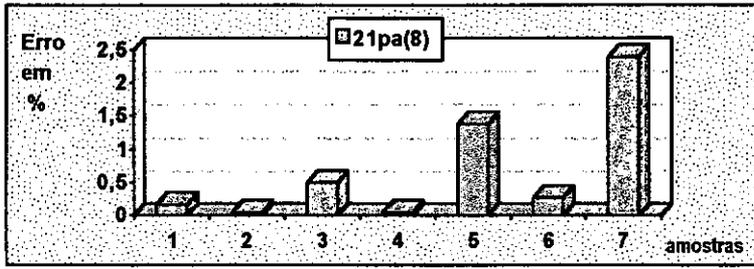


Figura VI.34 - Distribuição do erro para o local 1 da junta 2 do grupo a

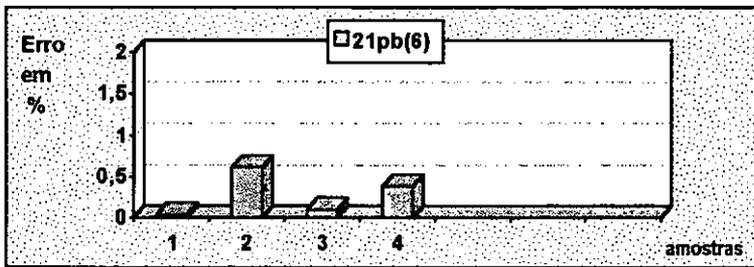


Figura VI.35 - Distribuição do erro para o local 1 da junta 2 do grupo b

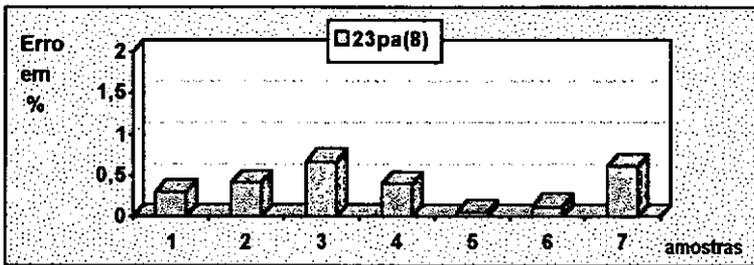


Figura VI.36 - Distribuição do erro para o local 3 da junta 2 do grupo a

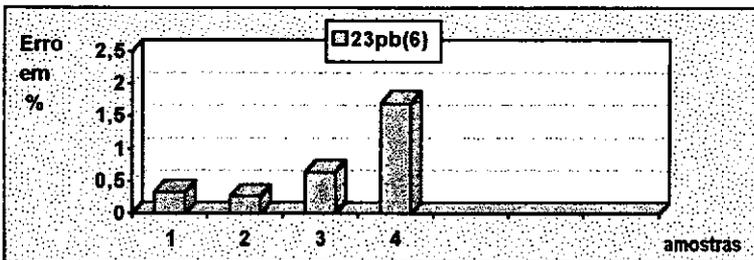


Figura VI.37 - Distribuição do erro para o local 3 da junta 2 do grupo b

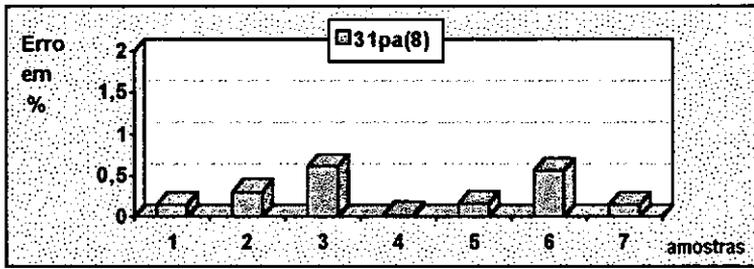


Figura VI.38 - Distribuição do erro para o local 1 da junta 3 do grupo a

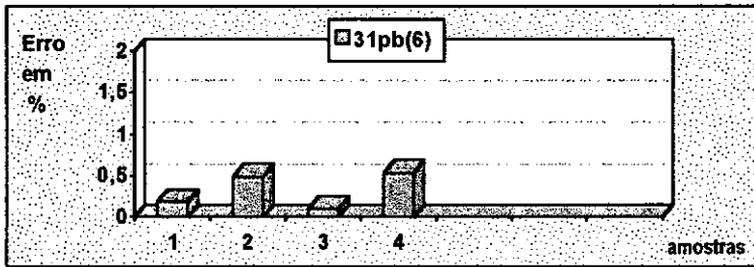


Figura VI.39 - Distribuição do erro para o local 1 da junta 3 do grupo b

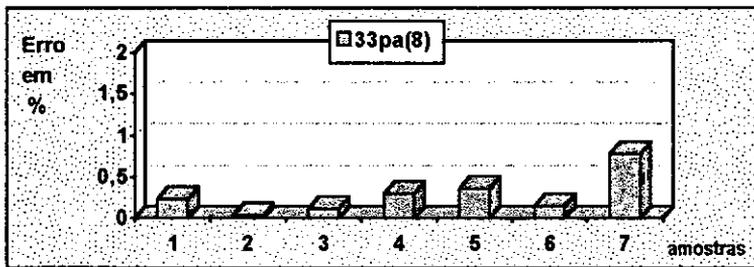


Figura VI.40 - Distribuição do erro para o local 3 da junta 3 do grupo a

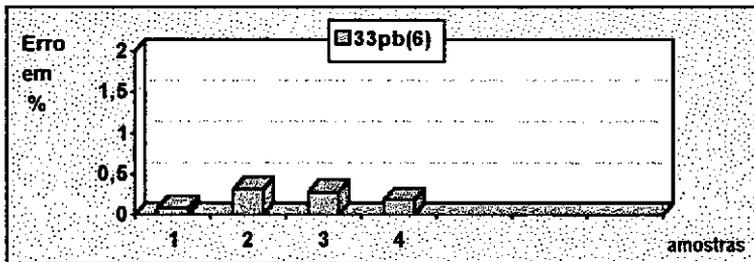


Figura VI.41 - Distribuição do erro para o local 3 da junta 3 do grupo b

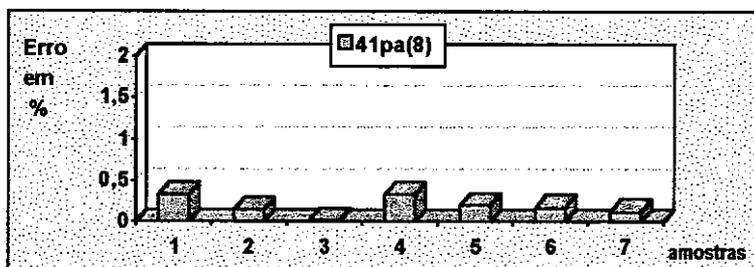


Figura VI.42 - Distribuição do erro para o local 1 da junta 4 do grupo a

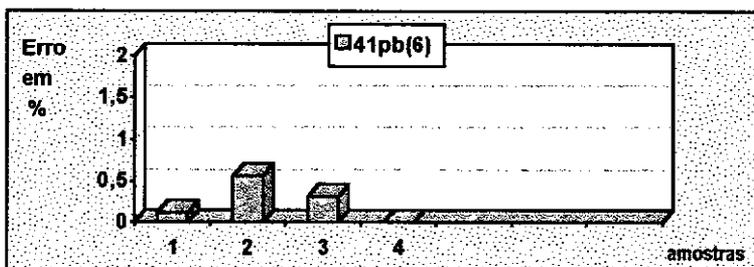


Figura VI.43 - Distribuição do erro para o local 1 da junta 4 do grupo b

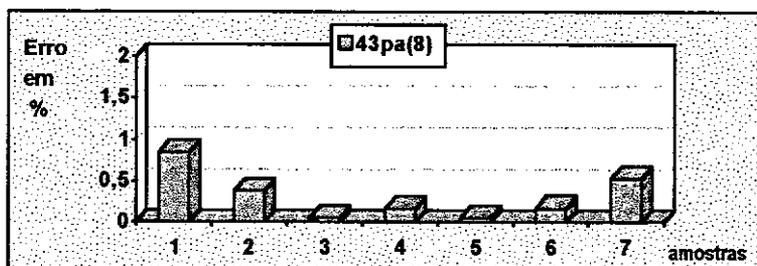


Figura VI.44 - Distribuição do erro para o local 3 da junta 4 do grupo a

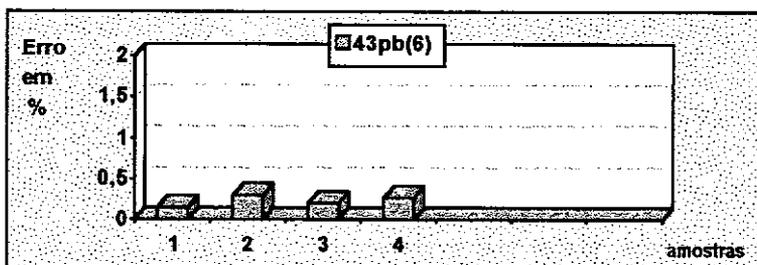


Figura VI.45 - Distribuição do erro para o local 3 da junta 4 do grupo b

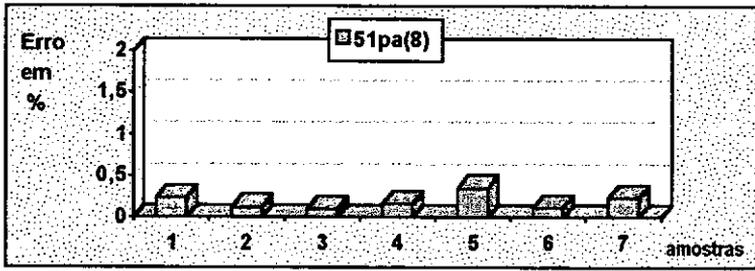


Figura VI.46 - Distribuição do erro para o local 1 da junta 5 do grupo a

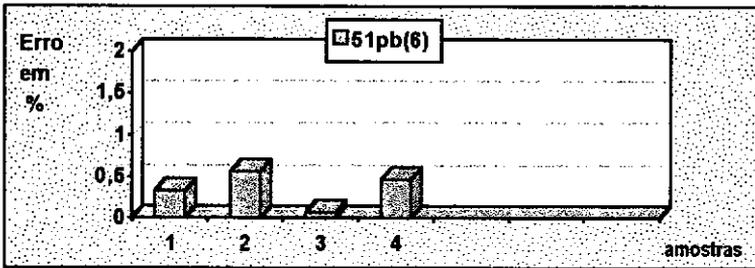


Figura VI.47 - Distribuição do erro para o local 1 da junta 5 do grupo b

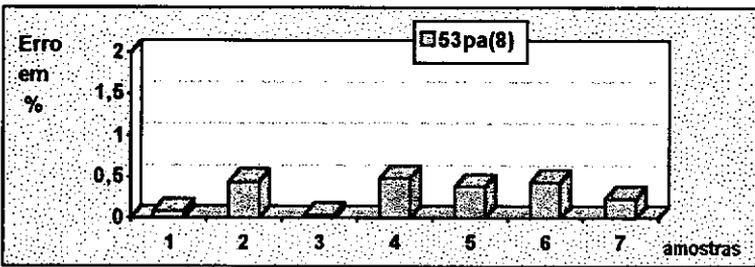


Figura VI.48 - Distribuição do erro para o local 3 da junta 5 do grupo a

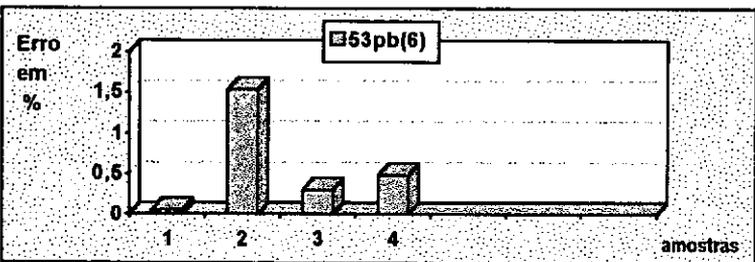


Figura VI.49 - Distribuição do erro para o local 3 da junta 5 do grupo b

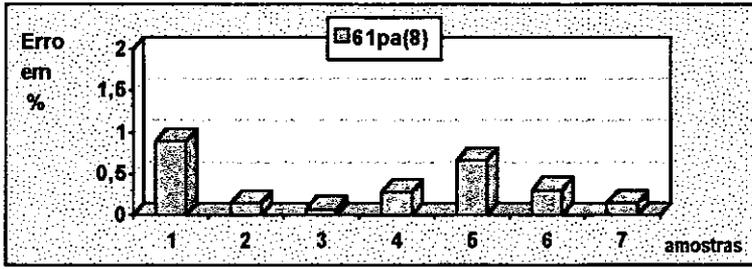


Figura VI.50 - Distribuição do erro para o local 1 da junta 6 do grupo a

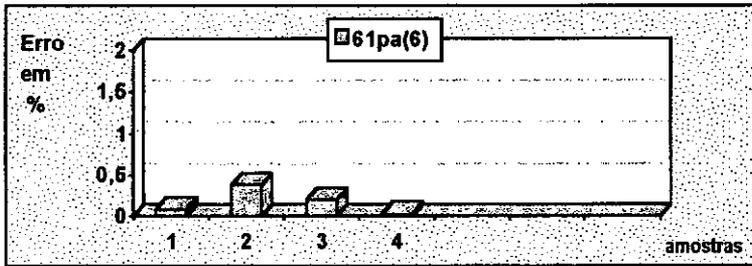


Figura VI.51 - Distribuição do erro para o local 1 da junta 6 do grupo b

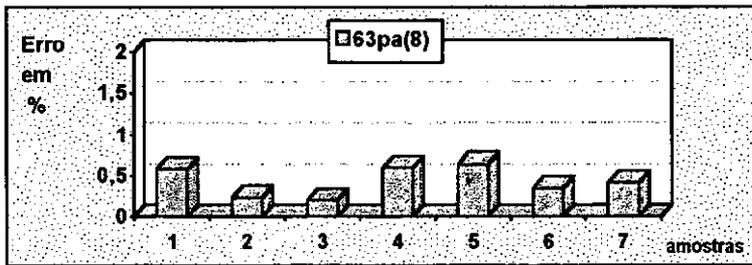


Figura VI.52 - Distribuição do erro para o local 3 da junta 6 do grupo a

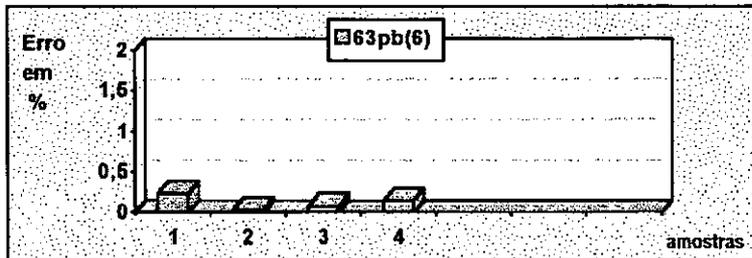


Figura VI.53 - Distribuição do erro para o local 3 da junta 6 do grupo b

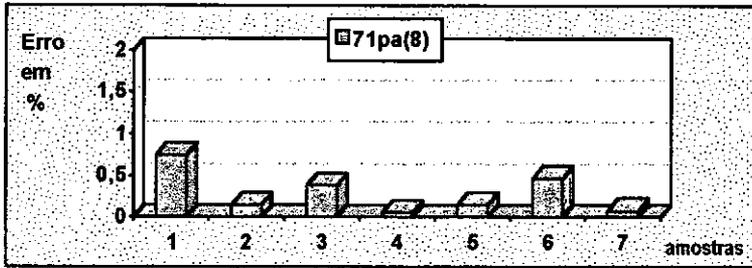


Figura VI.54 - Distribuição do erro para o local 1 da junta 7 do grupo a

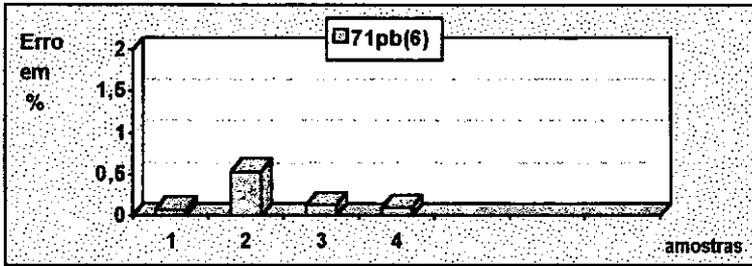


Figura VI.55 - Distribuição do erro para o local 1 da junta 7 do grupo b

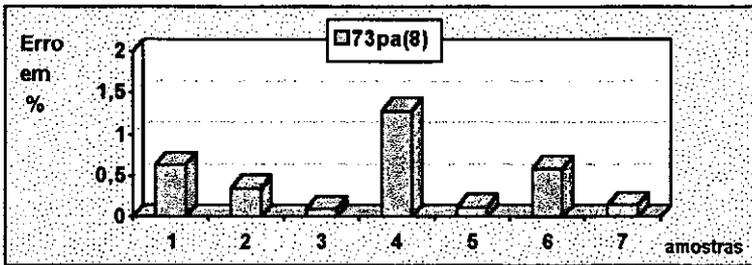


Figura VI.56 - Distribuição do erro para o local 3 da junta 7 do grupo a

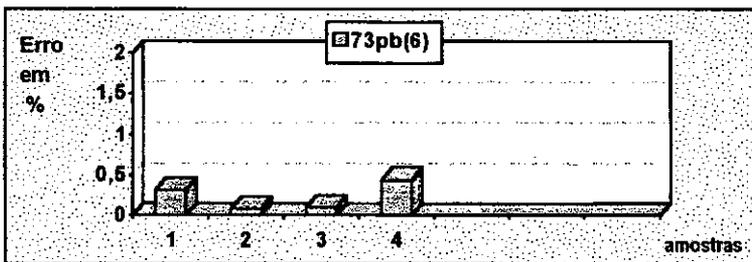


Figura VI.57 - Distribuição do erro para o local 3 da junta 7 do grupo b

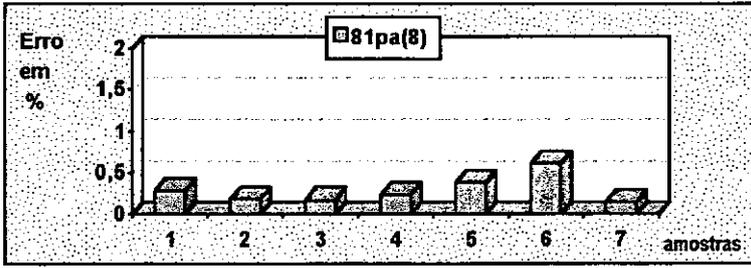


Figura VI.58 - Distribuição do erro para o local 1 da junta 8 do grupo a

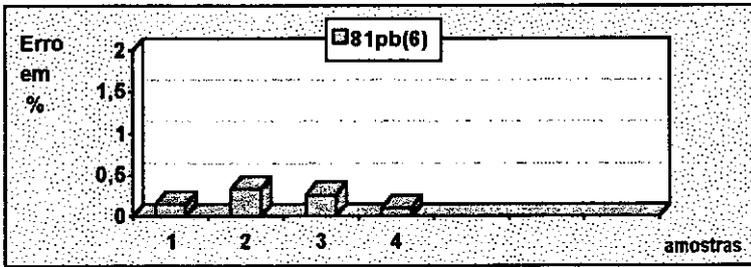


Figura VI.59 - Distribuição do erro para o local 1 da junta 8 do grupo b

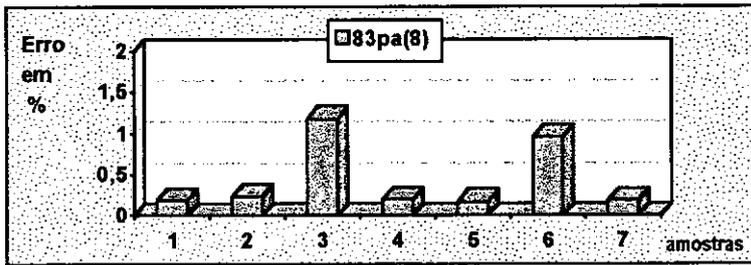


Figura VI.60 - Distribuição do erro para o local 3 da junta 8 do grupo a

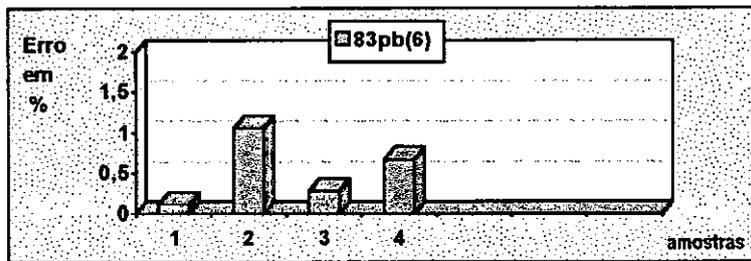


Figura VI.61 - Distribuição do erro para o local 3 da junta 8 do grupo b

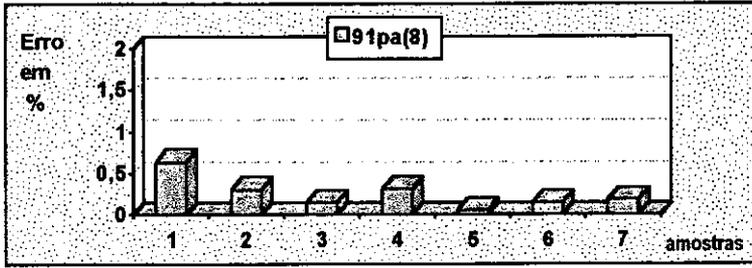


Figura VI.62 - Distribuição do erro para o local 1 da junta 9 do grupo a

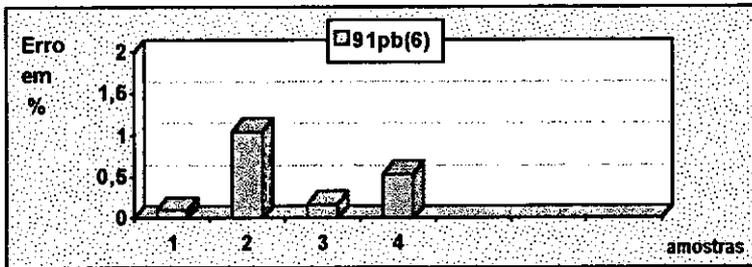


Figura VI.63 - Distribuição do erro para o local 1 da junta 9 do grupo b

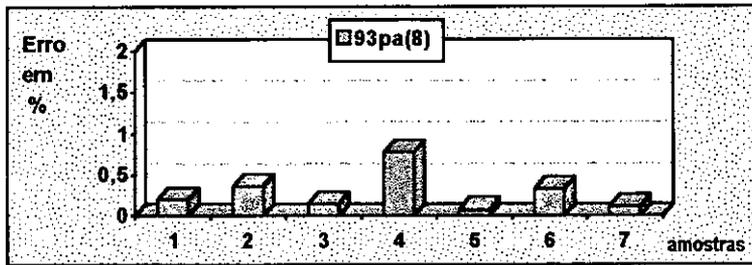


Figura VI.64 - Distribuição do erro para o local 3 da junta 9 do grupo a

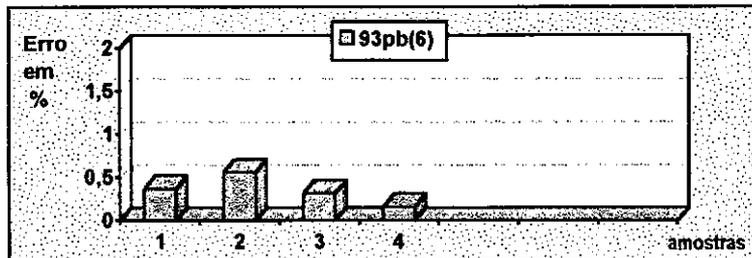


Figura VI.65 - Distribuição do erro para o local 3 da junta 9 do grupo b

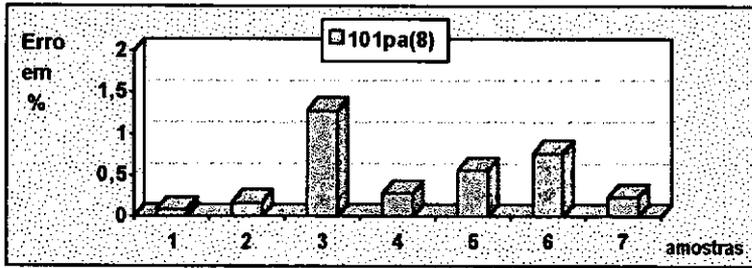


Figura VI.66 - Distribuição do erro para o local 1 da junta 10 do grupo a

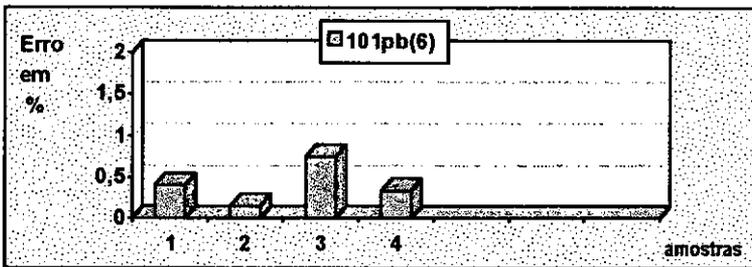


Figura VI.67 - Distribuição do erro para o local 1 da junta 10 do grupo b

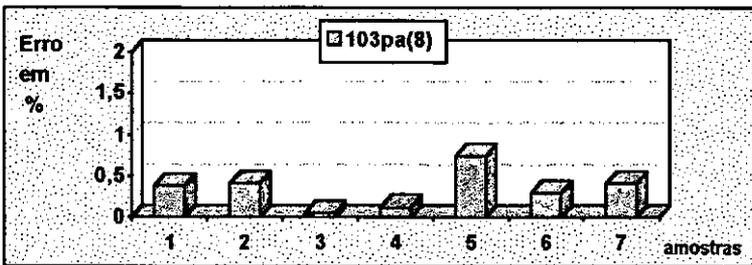


Figura VI.68 - Distribuição do erro para o local 3 da junta 10 do grupo a

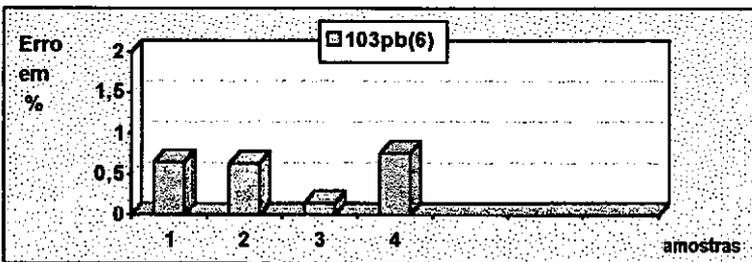


Figura VI.69 - Distribuição do erro para o local 3 da junta 10 do grupo b

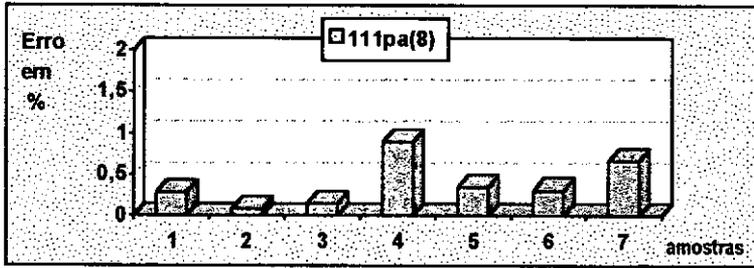


Figura VI.70 - Distribuição do erro para o local 1 da junta 11 do grupo a

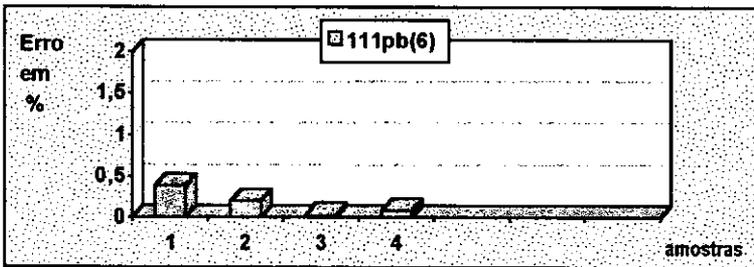


Figura VI.71 - Distribuição do erro para o local 1 da junta 11 do grupo b

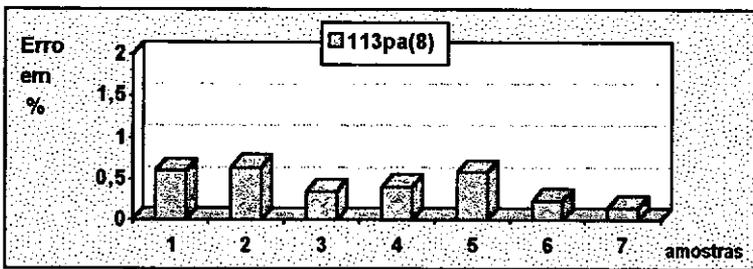


Figura VI.72 - Distribuição do erro para o local 3 da junta 11 do grupo a

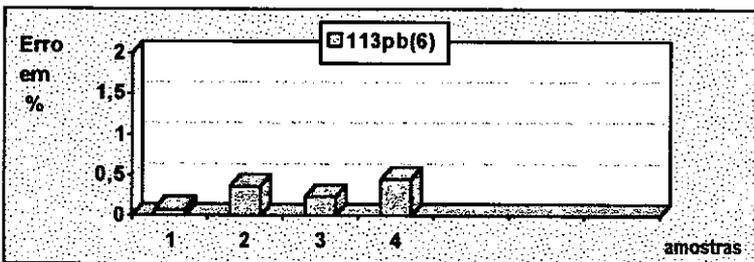


Figura VI.73 - Distribuição do erro para o local 3 da junta 11 do grupo b

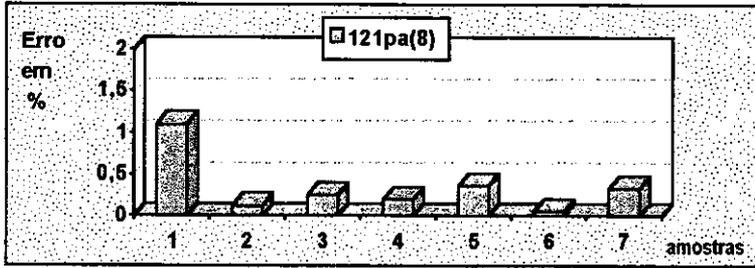


Figura VI.74 - Distribuição do erro para o local 1 da junta 12 do grupo a

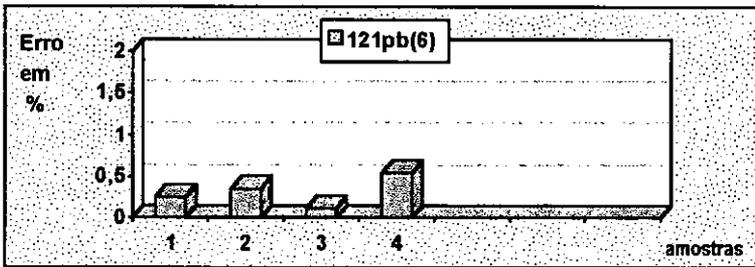


Figura VI.75 - Distribuição do erro para o local 1 da junta 12 do grupo b

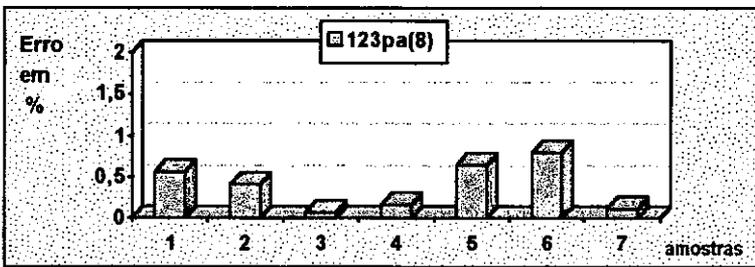


Figura VI.76 - Distribuição do erro para o local 3 da junta 12 do grupo a

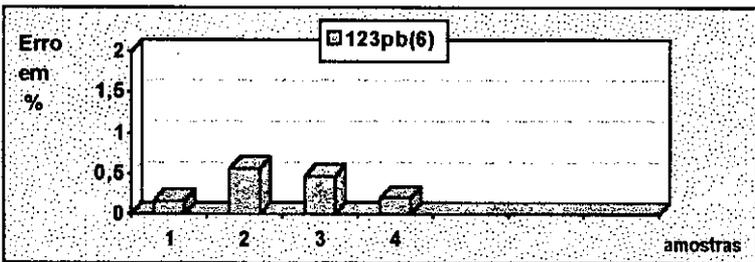


Figura VI.77 - Distribuição do erro para o local 3 da junta 12 do grupo b

Os maiores erros ocorreram para o grupo a do local 1 da junta 2, correspondendo ao valor 2,39% para a sétima amostra e 1,41% para a quinta amostra. A rede neural que gerou este erro é formada com 2 camadas intermediárias com 8 neurônios cada. Considerando-se uma nova rede, com 9 neurônios em cada camada intermediária, os erros são reduzidos, conforme a nova distribuição referente a pa21(9), apresentada na figura VI.78. O aumento do número de neurônios de 8 para 9 produz uma redução dos erros mais elevados, indicando ser a nova rede a solução ótima para este caso.

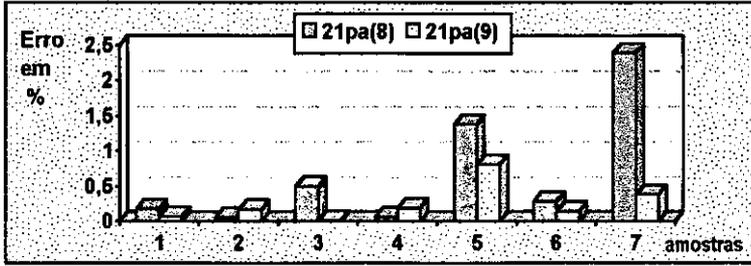


Figura VI.78 - Nova distribuição do erro para o local 1 da junta 2 do grupo a

O erro máximo do local 3 da junta 2, grupo b, também ultrapassou 1%. A primeira tentativa de reduzir este erro foi realizada com a rede 23pb(7/7), onde os números entre parênteses correspondem aos neurônios intermediários. Os resultados referentes à esta nova rede, em conjunto com a rede 23pb(6/6), estão indicados no gráfico da figura VI.79.

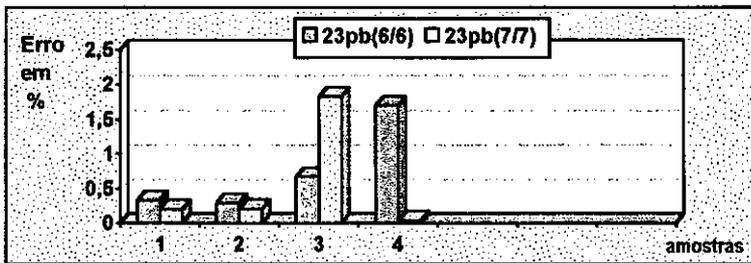


Figura VI.79 - Distribuição do erro para a rede 23pb(7/7)

Visto que o aumento do número de neurônios nas duas camadas intermediárias não conduziu ao objetivo desejado, foram criadas duas novas redes, a 23pb(6/5) e a 23pb(7/6), indicadas nas figuras VI.80 e VI.81, respectivamente, com quantidade distinta de neurônios nas camadas intermediárias. Verifica-se que todos os erros da rede 23pb(7/6) são inferiores a 1%, sendo então a rede ótima para este caso. Este resultado e o resultado do caso anterior demonstram, de forma clara, a grande sensibilidade da distribuição dos erros com a variação do número de neurônios nas camadas intermediárias.

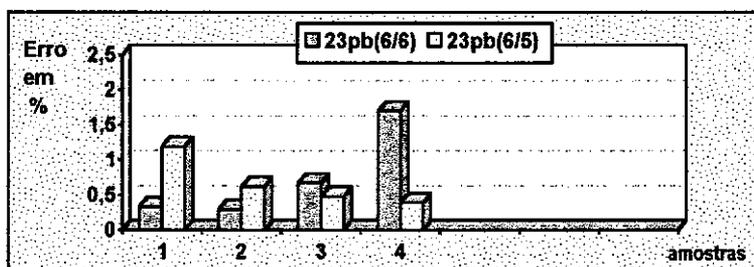


Figura VI.80 - Distribuição do erro para a rede 23pb(6/5)

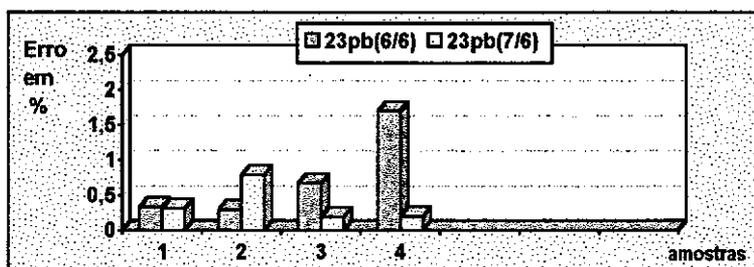


Figura VI.81 - Distribuição do erro para a rede 23pb(7/6)

A questão final a ser abordada é a influência do processo de seleção dos vetores de treino, de teste e de avaliação na distribuição dos erros. Para a nova rede neural correspondente ao caso anterior, denominada 21pa(9), foi feita uma variação na composição destes vetores e gerados os casos indicados na tabela VI.16. A composição da rede 21pa(9) também está indicada para efeito de comparação.

Casos vetores	21pa(9) (amostras)	21pa(9)A (amostras)	21pa(9)B (amostras)	21pa(9)C (amostras)
vetor de treino	63	65	62	64
vetor de teste	8	7	5	9
vetor de avaliação	7	6	11	5

Tabela VI.16 - Verificação da influência da composição dos vetores

Os erros produzidos por estas novas redes estão apresentados na figuras VI.82, VI.83 e VI.84. Embora as amostras não sejam correspondentes, a apresentação em conjunto com a rede 21pa(9) permite uma rápida avaliação da influência de vetores distintos.

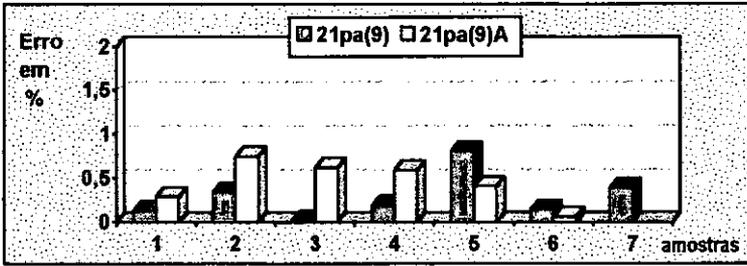


Figura VI.82 - Distribuição do erro das redes 21pa(9) e 21pa(9)A

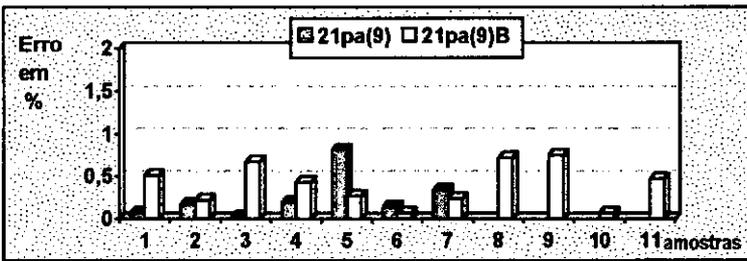


Figura VI.83 - Distribuição do erro das redes 21pa(9) e 21pa(9)B

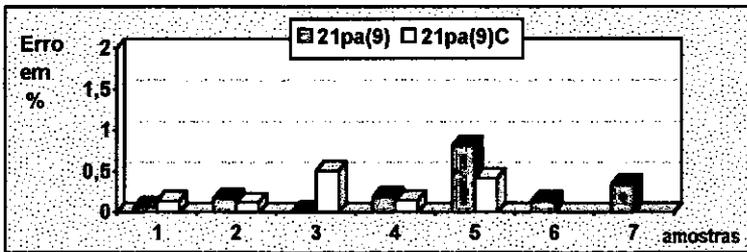


Figura VI.84 - Distribuição do erro das redes 21pa(9) e 21pa(9)C

A observação destes resultados mostra que a influência da composição dos vetores de treino, de teste e de avaliação não altera, na prática, a distribuição dos erros. Entretanto, deve ser também observado que o número de amostras do vetor de treino foi mantido em, aproximadamente, 80% do número total de amostras disponíveis, conforme recomendação prática para treinamento de redes neurais. Considerando-se a redução deste valor para 70%, 60% e 50%, foram criadas as redes 21pa(9)D, 21pa(9)E e 21pa(9)F, respectivamente. As novas distribuições de erro estão indicadas a seguir nas figuras VI.85, VI.86 e VI.87. Os resultados não estão sendo apresentados em conjunto com a distribuição dos erros da rede 21pa(9), como nos casos anteriores, em virtude da grande diferença na dimensão do vetor de avaliação.

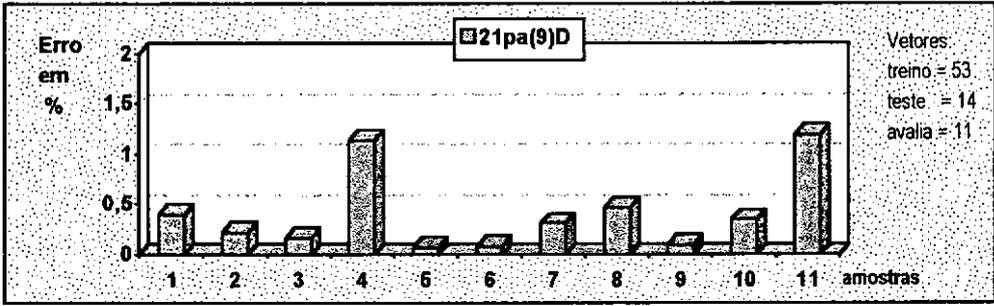


Figura VI.85 - Vetor de treinamento com 70% do total de dados

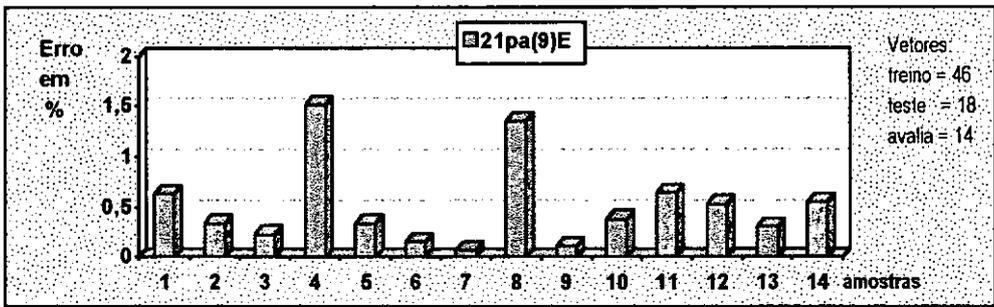


Figura VI.86 - Vetor de treinamento com 60% do total de dados

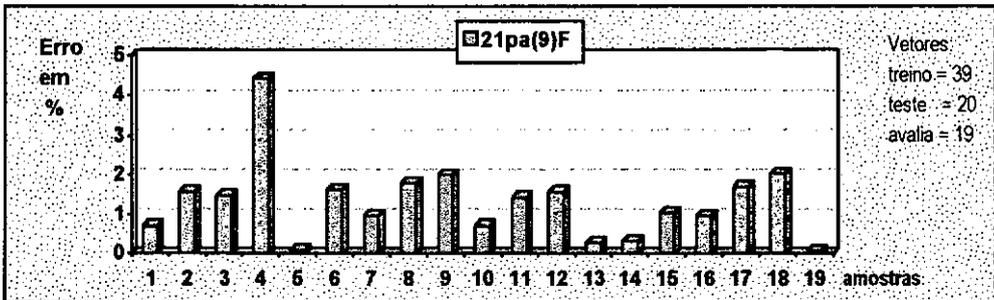


Figura VI.87 - Vetor de treinamento com 50% do total de dados

Pode ser verificado, nas figuras VI.85 a VI.87, que a redução da dimensão do vetor de treino e o aumento das dimensões dos vetores de teste e de avaliação acarreta um acréscimo dos erros referentes ao vetor de avaliação.

Foi também verificado que os erros máximos produzidos pelos vetores de treino e de teste são da mesma ordem de grandeza dos erros dos vetores de produção para todas as juntas consideradas e para todas as situações estudadas.

VL9 REDES NEURAIS NA ATUALIZAÇÃO DO MODELO DINÂMICO

De acordo com a formulação desenvolvida no capítulo III, o conceito de rede neural pode ser utilizado no problema de atualização dinâmica descrito por:

$$\delta \mathbf{p} = \mathbf{V}_p \mathbf{S}_a^t (\mathbf{S}_a^t \mathbf{V}_p \mathbf{S}_a + \mathbf{V}_z)^{-1} \delta \mathbf{z} = (\text{Rede Neural}) \delta \mathbf{z} \quad (\text{VI.9})$$

onde $\delta \mathbf{p}$ é o vetor que representa a variação dos parâmetros e $\delta \mathbf{z}$ é o vetor que representa a variação nas variáveis medidas. A matriz \mathbf{S}_a representa a sensibilidade do sistema e as matrizes \mathbf{V}_p e \mathbf{V}_z correspondem às matrizes de variância dos parâmetros e das variáveis medidas, respectivamente. As matrizes de variância permitem uma abordagem mais precisa do problema, considerando as incertezas existentes.

O problema a ser resolvido neste trabalho não irá considerar as incertezas e tem como objetivo determinar a variação das massas concentradas do modelo em função de variações de frequências e modos naturais de vibração da estrutura da plataforma. As massas concentradas, denominadas 1, 2, 3 e 4, estão localizadas nos vértices da mesa superior, numerados de forma idêntica, conforme indicado na figura VI.88.

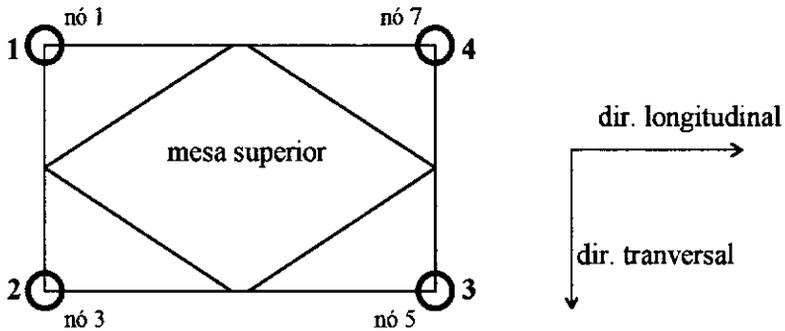


Figura VI.88 - Localização das massas concentradas

Serão consideradas as variações de massas concentradas e as correspondentes variações de frequências e modos naturais de vibração descritas nas tabelas VI.17 a VI.19.

Variável	modo 1(transv)	modo 2(long)	modo 3(torc)
Frequência	δf_1	δf_2	δf_3

Tabela VI.17 - Frequências naturais consideradas

O primeiro modo corresponde à vibração na direção transversal, o segundo modo é na direção longitudinal e o terceiro modo produz uma torção na plataforma. As informações referentes aos modos de vibração foram consideradas nos vértices 1 e 3, nas direções longitudinal e transversal. Denominando-se os deslocamentos modais de t_{ij} e ℓ_{ij} , onde o índice i refere-se ao modo, o índice j indica o local medido e as letras t e ℓ também indicam as direções transversal e longitudinal, os dados fornecidos à rede estão indicados na tabela VI.18.

	modo 1	modo 2	modo 3
quociente 1	$t_{1,1} / \ell_{1,1}$	$t_{2,1} / \ell_{2,1}$	$t_{3,1} / \ell_{3,1}$
quociente 2	$t_{1,3} / \ell_{1,3}$	$t_{2,3} / \ell_{2,3}$	$t_{3,3} / \ell_{3,3}$

Tabela VI.18 - Dados referentes aos modos de vibração

As variações de massa foram fornecidas de acordo com a tabela VI.19, onde a indicação de m_1 entre parênteses significa que os dados estão normalizados em relação ao valor desta massa.

variação de massa	δm_1	δm_2	δm_3	δm_4
1	10%(m_1)	10%(m_1)	15%(m_1)	15%(m_1)
2	20%(m_1)	20%(m_1)	30%(m_1)	30%(m_1)
3	30%(m_1)	30%(m_1)	45%(m_1)	45%(m_1)

Tabela VI.19 - Dados referentes às massas concentradas

Foram preparados 48 vetores treinamento, contendo cada um 9 informações para entrada na rede (3 variações de frequência natural e 6 variações de deslocamento modal) e 4 informações para a saída da rede (4 variações de massa) e 14 vetores de teste (utilizados para testar a rede e avaliar a sua capacidade de generalizar) com as mesmas características dos vetores de treino, a partir do módulo de análise modal do *ANSYSv5.0*.

Foi utilizada a mesma topologia de rede do estudo do dano de fadiga, com duas camadas intermediárias. O treinamento da rede foi feito com os 48 vetores já definidos e o critério de menor erro do conjunto de teste para um número de eventos de treinamento até 20000 após o melhor conjunto de teste. Os resultados obtidos estão apresentados na tabela VI.20, onde os valores negativos significam retirada de massa ou a sua mudança para outro local da mesa superior. Os valores positivos representam acréscimo de massa.

Rede	Dados de teste da rede				Dados produzidos pela rede				
	amostras	δm_1	δm_2	δm_3	δm_4	δm_1	δm_2	δm_3	δm_4
1		7.00	0.00	0.00	0.00	7.72	0.14	1.02	-0.66
2		15.00	0.00	0.00	0.00	15.51	0.22	-0.15	-0.61
3		-18.00	0.00	18.00	0.00	-18.04	0.33	17.88	0.17
4		27.00	0.00	0.00	-27.00	27.13	-0.36	-0.15	-27.63
5		0.00	22.00	0.00	0.00	-0.68	21.60	0.60	-0.15
6		0.00	-25.00	0.00	0.00	-0.34	-25.71	-1.25	0.84
7		0.00	0.00	-21.00	0.00	-0.80	0.43	-42.76	-0.61
8		0.00	0.00	0.00	-35.00	0.20	-0.31	-0.81	-34.25
9		0.00	0.00	25.00	-25.00	-1.24	1.41	24.67	-26.30
10		50.00	0.00	0.00	0.00	49.63	-0.21	0.88	1.37
11		-50.00	0.00	50.00	0.00	-48.45	-0.34	49.50	-0.29
12		0.00	-40.00	0.00	0.00	0.75	-38.47	1.10	-1.92
13		0.00	0.00	-59.00	0.00	0.44	0.18	-56.32	-0.71
14		0.00	0.00	0.00	65.00	0.10	0.26	0.51	63.84

Tabela VI.20 - Resultados da rede neural

Não houve intenção, neste caso, de procurar a melhor rede neural para a solução do problema e sim demonstrar a possibilidade de se utilizar este tipo de enfoque para a atualização da matriz de massa do modelo de plataforma. Os resultados da tabela acima indicam que as redes neurais podem ser utilizadas como um método de atualização dinâmica. Os métodos geralmente utilizados neste tipo de problema de atualização podem conduzir a um número praticamente infinito de soluções, sendo que somente algumas delas têm significado físico. Para a obtenção de soluções com significado físico, diversas restrições precisam ser aplicadas ao problema, tornando mais complicado o processo da busca do ótimo. No caso das redes neurais, a solução sempre tem o perfeito significado físico, havendo as questões da forma de entrada de dados, da precisão e, dependendo do tipo de rede, da estabilidade da rede para serem avaliadas.

VI.10 DANO DE FADIGA EM TEMPO REAL

Um procedimento sistemático para a obtenção de informações referentes à deterioração nas juntas soldadas de plataformas fixas de produção de petróleo, devido ao processo de fadiga, deve ser composto de:

- gerenciamento dos dados de inspeção e de simulação disponíveis e localização das regiões críticas da estrutura;
- acesso ao dano acumulado de fadiga nas regiões críticas da estrutura;
- determinação da prioridade de reparo.

Um sistema de aquisição e processamento de sinais digitais, contendo oito transdutores de aceleração instalados no *cellar deck* de uma plataforma fixa, pode gerar as informações necessárias para o acesso ao dano de fadiga em tempo real, a partir da disponibilidade de redes neurais que transformem os dados de deslocamentos no convés da plataforma no dano correspondente nas diversas juntas. Neste caso, os sinais de aceleração são adquiridos, calculadas as suas densidades espectrais de potência e estimado o dano de fadiga em oito locais de cada seção, por meio rotinas geradas pelo programa de treinamento de redes neurais.

O diagrama de blocos básico de um sistema de aquisição/processamento de sinais a ser instalado a bordo da plataforma está apresentado na figura VI.89.

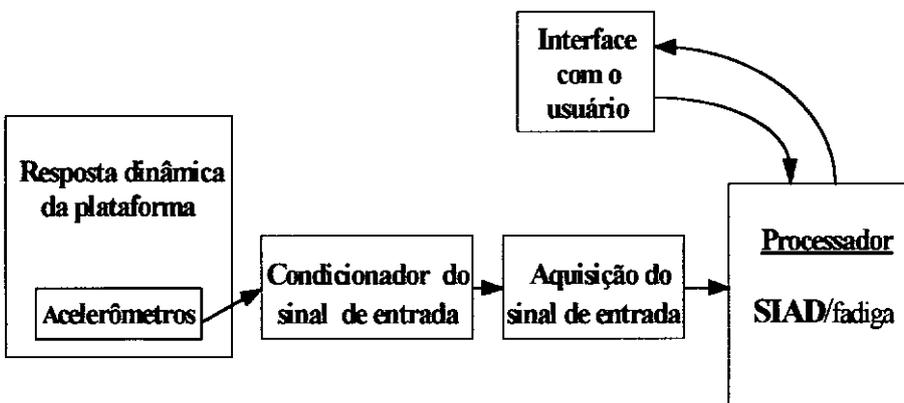


Figura VI.89 - Diagrama de blocos básico

O acesso ao dano de fadiga, para posterior cálculo do dano acumulado, deve ser feito em tempo real, visto que a fadiga é um processo contínuo de deterioração da condição

de integridade estrutural das juntas soldadas. O termo tempo real, que está sendo utilizado neste trabalho, deve ser entendido de forma mais flexível e sem o rigor normalmente existente nas teorias de aquisição e processamento de sinais de alta frequência. De acordo com [Lawrence,1987], o seguinte conceito pode ser considerado para um sistema que opera em tempo real:

“Whenever a computer system is required to acquire data, emit data, or interact with its environment at precise times, the system is said to be a real time computer system. All computer systems are in some sense real time systems. For control of process or mechanisms, a real time system is a system whose temporal performance (response time, data acquisition, period, etc.) is of critical importance to the industrial system to which it is connected.

In real time systems, the response time of the system is often of critical importance. All critical response times must be listed in the specification. In addition, any actions that must be performed in a precisely sequence must be listed. However, it is also important to avoid overspecification of time-critical responses since this adds to the complexity and cost of the design.”

De acordo com [Collacoat,1979], uma definição mais específica pode ser aplicada para o caso de processamento de sinais:

“The real time bandwidth of a Fourier analyser is the highest nominal bandwidth (i.e. half of the highest sampling rate) at which some task such as power spectrum averaging can be performed without loss of input data. This definition implies that the input data frames are buffered, that is, collection of new data frame proceeds while the previous collected data frame is being analysed. For real time, the analysis can take no more time than the collection of the new data frame.”

Para ilustrar este último conceito, o exemplo é o cálculo da FFT de um sinal, na faixa de 20 KHz. Como a taxa de amostragem mínima deve ser de 40 KHz, a aquisição de um bloco de 1024 pontos irá ocorrer em 25 ms. Para o processamento ser em tempo real, o tempo de processamento da FFT deve ser de 15~16 ms [Collacoat,1979]. O conceito de tempo real normalmente está associado a blocos de dados de 1024 pontos.

Lawrence, P. D. e Mauch, K. (1987) -“**Real-Time Microcomputer System Design: An Introduction**”- MacGraw-Hill Book Company, USA.

Collacoat, R. A. (1979) - “**Vibration Monitoring and Diagnosis**”- John Wiley & Sons, USA.

A aquisição dos sinais de aceleração é feita em intervalos de tempo de T_i , de 1200 s, sendo cálculo das densidades espectrais e sua integração (Tarefa 1) concluídos antes do início do intervalo de tempo T_{i+1} , isto é, o intervalo de tempo imediatamente posterior. Desta forma, o cálculo do dano de fadiga pelas redes neurais, a acumulação do dano de fadiga e outras atividades de processamento, correspondentes aos sinais adquiridos em T_i , estarão sendo realizadas durante o intervalo T_{i+1} , em paralelo com a nova aquisição de dados, caracterizando a Tarefa 2. O sistema operacional utilizado deverá ser multi-tarefa, de forma que a aquisição dos sinais e os diversos tipos de processamento já previstos ou que venham a ser incorporados ao SIAD/fadiga, sejam executados sem a interrupção da aquisição dos sinais. A comunicação via modem/linha telefônica ou via rede, não será detalhada nesta proposta, mas tem previsão de ser implementada como tarefa 3, visto a sua importância para o acompanhamento remoto da performance do sistema.

- Tarefa 1 (no intervalo T_i) - módulo 1

Inicialmente, este intervalo é subdividido em 16 intervalos iguais t_j , com duração de 75 s cada um. De acordo com o critério de Nyquist (teorema de Shannon), a taxa de amostragem deve ser, no mínimo, 2 vezes a maior frequência do sinal. No caso das plataformas fixas, a maior frequência considerada (1^o modo de torção) é sempre inferior a 0.75 Hz, sendo este valor garantido por filtros de passa-baixo. Desta forma, a frequência mínima de amostragem é 1.5 Hz/canal. Assumindo-se uma taxa de 13.65334 Hz para os quatro canais efetivos e quatro de reserva, um bloco de 1024 pontos irá corresponder ao intervalo de aquisição de 75 s.

Considerando-se placas de aquisição de sinais de última geração, contendo *chip* tipo DSP e memória própria, os seguintes tempos de processamento podem ser obtidos:

→ atividade 1.1 (ao final de cada bloco de 1024 pontos)

- cálculo da FFT: $\Delta t < 65$ ms

→ atividade 1.2 (ao final de cada bloco de 1024 pontos)

- média dos espectros e integração dos espectros médios $\Delta t < 10$ ms

- Tarefa 2 (no intervalo T_{i+1}) - módulo 2

→ atividade 2.1 (antes do final da aquisição do 1^o bloco deste intervalo)

- avaliação da qualidade do sinal: $\Delta t < 1$ s

→ atividade 2.2 (antes do final da aquisição do 1^o bloco deste intervalo)

- cálculo do dano de fadiga pelas redes neurais (100 locais): $\Delta t < 5$ s

→ atividade 2.3 (antes do final da aquisição do 1^o bloco deste intervalo)

- cálculo do dano de fadiga acumulado (100 locais): $\Delta t < 20$ ms

Todas as informações obtidas serão armazenadas em arquivos binários, no microcomputador responsável pelo gerenciamento do processo, com identificação do tipo e a data de cada arquivo.

O passo mais importante para a implantação deste sistema é o treinamento das redes neurais. Este passo irá depender de informações precisas sobre o comportamento estrutural da plataforma, sendo imprescindível a atualização dinâmica das suas matrizes de massa, rigidez e amortecimento. A instalação de um sistema inteligente de aquisição/processamento de sinais a bordo da plataforma complementa o processo, permitindo a criação de um banco de dados que pode ser consultado pelos engenheiros responsáveis pela manutenção da estrutura da plataforma. As informações deste banco de dados, em conjunto com outras informações de inspeção e reparo, permitirão uma abordagem mais racional das técnicas de inspeção e de reparo.

Na figura VI.90 está apresentado um diagrama de blocos com todos os procedimentos necessários para a implantação de um sistema de avaliação de fadiga em tempo real. Após a identificação da plataforma (estudo de seus dados de projeto e manutenção), deve ser realizada uma aquisição de dados preliminar, que irá fornecer dados sobre o comportamento dinâmico real da estrutura. A partir do modelo numérico, obtido pelo método dos elementos finitos, e dos dados experimentais, é realizada a atualização dinâmica da plataforma com o objetivo de se otimizar a correlação com a estrutura real, utilizando-se as frequências e modos naturais de vibração, os coeficientes de amortecimento, os deslocamentos no convés e as tensões nominais em locais selecionados.

O modelo de elementos finitos ajustado é então utilizado na geração de dados para as redes neurais, em conjunto com as informações de resposta e condições de mar obtidas na aquisição de dados preliminar. As redes neurais são treinadas e geradas as rotinas para cálculo do dano de fadiga nas juntas selecionadas, a partir das condições reais de sollicitação da estrutura.

O sistema inteligente de aquisição/processamento de sinais para avaliação do dano de fadiga (SIAD/fadiga), que tem a capacidade de interagir com o meio externo e selecionar a sua melhor condição de operação, é instalado a bordo da plataforma com as rotinas de cálculo do dano de fadiga. Relatórios periódicos são gerados e armazenados em arquivos para posterior acesso via modem. Caso necessário, rotinas adicionais para previsão de crescimento de trinca e de níveis de tensão em locais críticos podem ser implementadas,

tornando o processo de avaliação mais abrangente. Ocorrências anormais, tais como choque de embarcações e acidentes que provoquem impactos na plataforma, também poderão ser identificadas e registradas, sendo necessário o desenvolvimento de redes neurais específicas para a classificação e o reconhecimento de padrões.

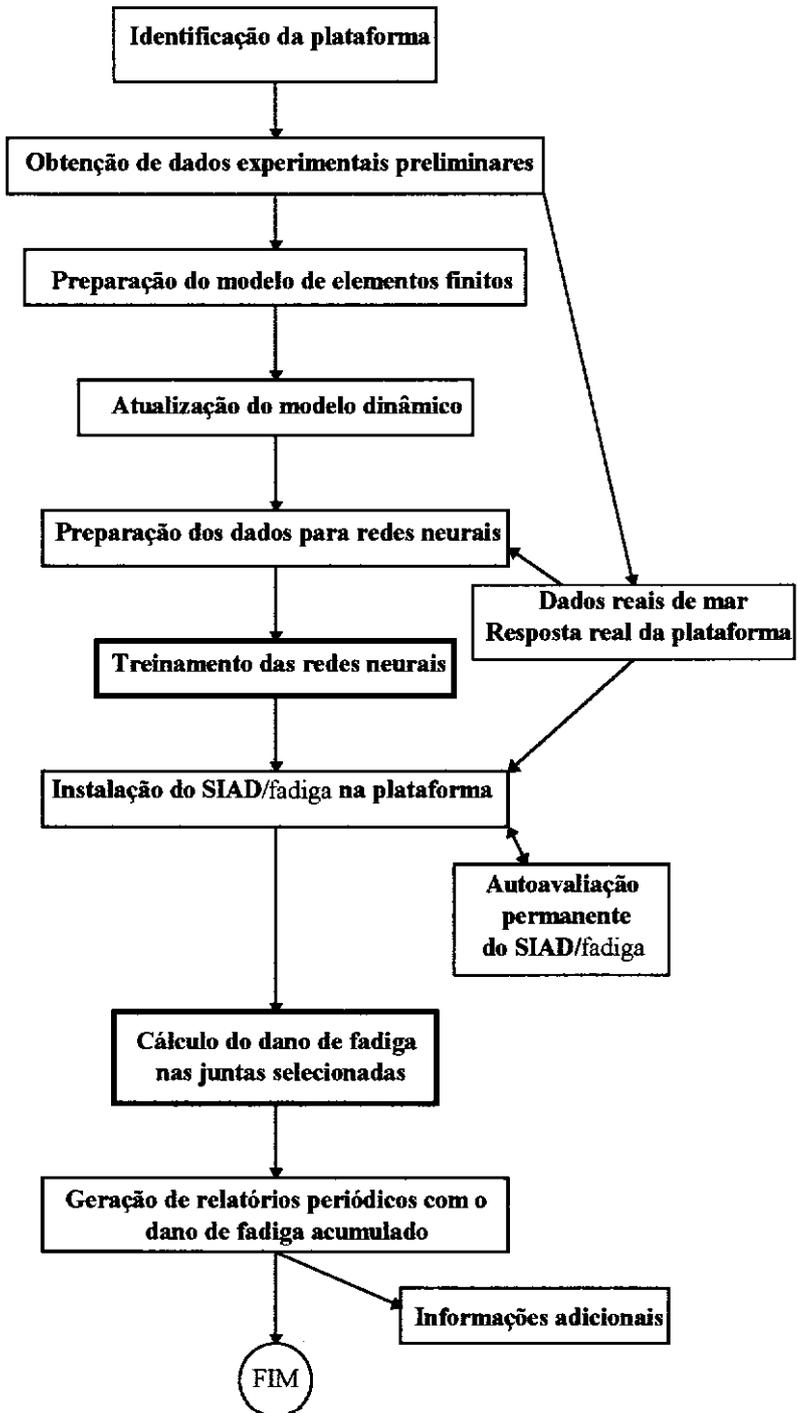


Figura VI.90 - Procedimentos para a implantação do sistema

Após a sua instalação a bordo da plataforma, o SIAD/fadiga irá executar as tarefas 1, 2 e 3 já descritas. O diagrama de blocos referente a estas tarefas está indicado na figura VI.91.

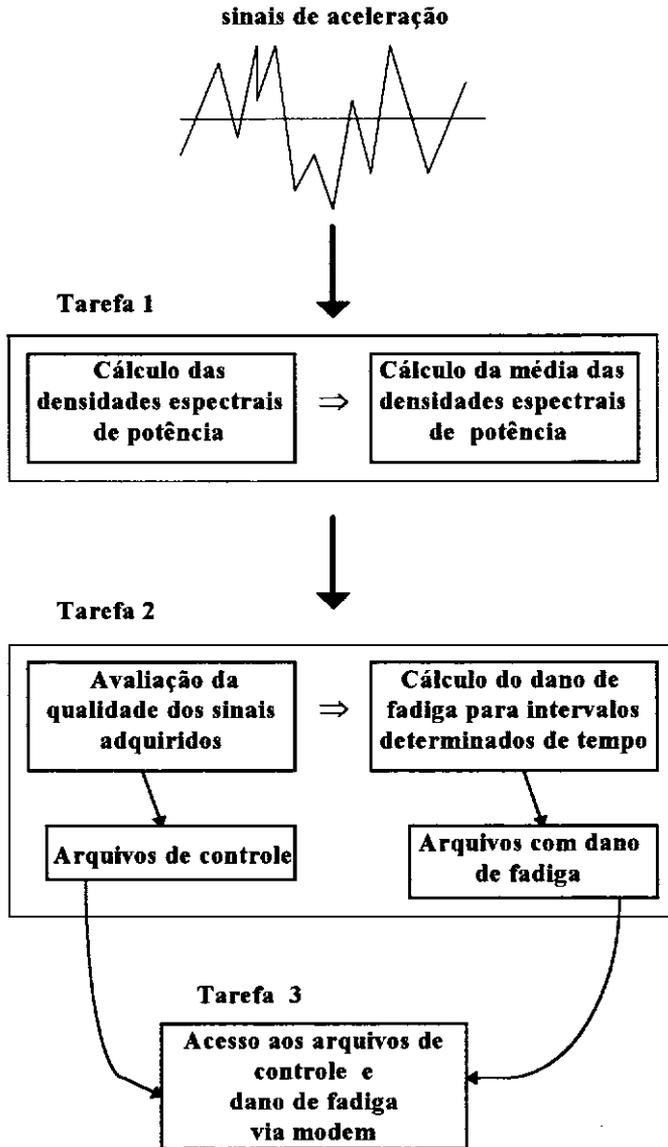


Figura VI.91 - Tarefas executadas pelo SIAD/fadiga

O sistema SIAD/fadiga, proposto pelo autor, é inédito, tanto em termos nacionais quanto internacionais. Conforme pode ser constatado, a utilização de redes neurais para avaliar o dano de fadiga e a aplicação de redes neurais para o ajuste do modelo dinâmico caracterizam o pioneirismo deste trabalho.

Capítulo VII

CONCLUSÕES E SUGESTÕES

As redes neurais, utilizadas para a simulação do dano de fadiga, que apresentaram os menores erros são do tipo *feedforward* totalmente conectadas, com função de ativação sigmóide logística, com duas camadas de neurônios intermediários e com critério de treinamento baseado em um conjunto de vetores de treino e um conjunto de vetores de teste. O histograma correspondente aos valores dos erros de todas as juntas, sem considerar a otimização das redes quando ocorre $|\text{erro máximo}| > 1\%$, está apresentado na figura VII.1. Na tabela estão indicadas as classes, o valor central de cada classe (corresponde ao erro em %) e o número de ocorrências de cada classe.

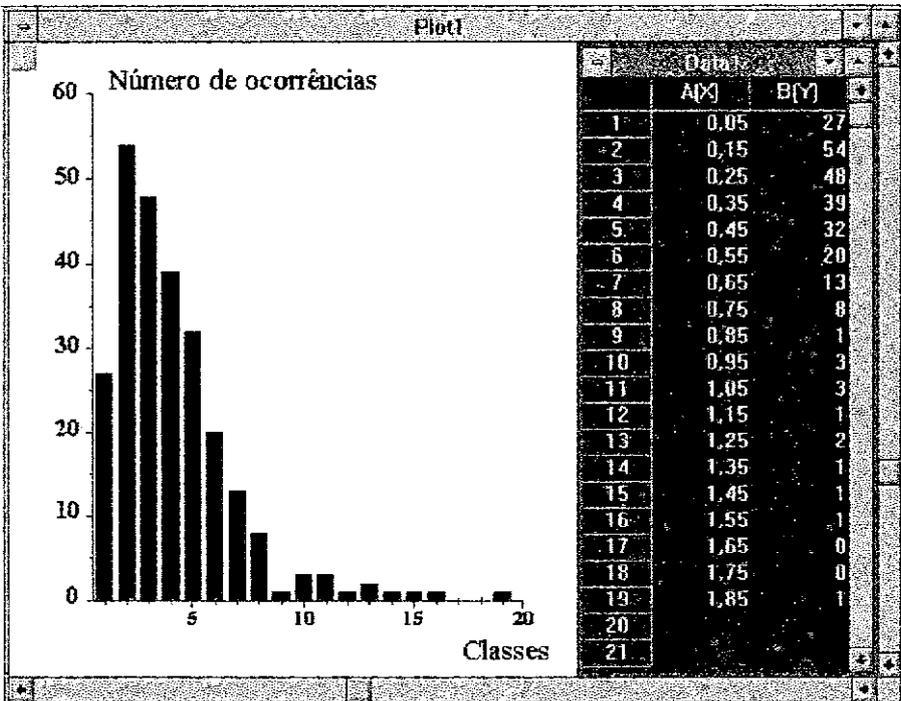


Figura VII.1 - Histograma dos erros das 12 juntas

A distribuição da figura VII.1 é referente aos valores absolutos do erros. No caso de se considerar os valores positivos e negativos dos erros, o valor médio da

distribuição seria próximo de zero e a sua dispersão poderia ser avaliada através do desvio padrão. Conhecendo-se estes valores, a propagação dos erros poderia ser avaliada.

Pode ser verificado, utilizando-se a expressão VI.7, que o mesmo valor de erro relativo (em %) do |logaritmo do dano| irá produzir erros propagados distintos, conforme exemplificado na tabela VII.1.

V_{fom}	Dano($e^{-V_{fom}}$)	$\frac{V_{fom} - V_{calc}}{V_{fom}} * 100$	ϵ_1	E_{exp}
10	$4.539 * 10^{-5}$	0.5%	0.05	1.05
20	$2.061 * 10^{-9}$	0.5%	0.10	1.10
30	$9.356 * 10^{-14}$	0.5%	0.15	1.16

Tabela VII.1 - Erros propagados

Visto que os maiores valores do |logaritmo do dano| - V_{fom} - estão relacionados a valores muito pequenos de dano, o fato de possuírem os maiores erros afetará pouco, na prática, o cálculo do dano acumulado nas juntas da plataforma.

A incerteza inerente ao carregamento na estrutura reduz-se bastante pela utilização de registros correspondentes ao comportamento dinâmico real da estrutura. É um fato indiscutível que existem outras incertezas nos diversos parâmetros que são utilizados no processo de avaliação do dano de fadiga mas, partindo-se do princípio de que estas incertezas são semelhantes para todas as juntas, as incertezas referentes ao cálculo do dano relativo também serão semelhantes para todas as juntas. Por exemplo, se para um local da junta i, o valor médio do erro for $\bar{e}_{d,i}$ e o seu desvio padrão for $\sigma_{d,i}$, tendo a junta j os valores $\bar{e}_{d,j}$ e $\sigma_{d,j}$, a propagação do erro referente ao dano relativo estaria associada ao cálculo do desvio padrão relativo (distribuição normal) dado por [Dally,1984]:

$$\sigma_{rel} = \frac{\bar{e}_{d,i}}{\bar{e}_{d,j}} \sqrt{\frac{\sigma_{d,i}^2}{\bar{e}_{d,i}^2} + \frac{\sigma_{d,j}^2}{\bar{e}_{d,j}^2}} \quad (VII.1)$$

Através destes resultados, pode-se concluir que, sob o ponto de vista prático, o dano de fadiga em tempo real permitiria classificar as juntas, com razoável precisão, de acordo com o dano de fadiga acumulado.

A transformação efetuada nos valores originais tem grande influência no erro produzido pelas redes neurais. Parece evidente que esta transformação poderia ser otimizada, de forma a reduzir ainda mais o erro propagado.

Existem 318+31 pesos em uma rede neural totalmente conectada, com os neurônios distribuídos na forma 14x8x8x1. Esta rede está sendo treinada com 63 amostras, o que resulta em uma relação 5.54 : 1 entre os parâmetros a serem determinados e os conjuntos de dados fornecidos à rede. A princípio, a capacidade de uma rede generalizar poderia aumentar com a redução da relação parâmetros / dados, implicando no aumento do número de dados ou na diminuição seletiva do número de pesos.

Conforme foi definido em V.5.1, a superfície de erro de uma rede neural tipo *feedforward*, treinada pela técnica de *backpropagation*, é definida pela equação $F=F_0(\mathbf{w})$ no espaço de dimensão $n+1$ dos vetores (F, \mathbf{w}) , onde n é a dimensão de \mathbf{w} . Existem três aspectos básicos com referência a este tipo de superfície de erro:

- devido às combinações de pesos que não causam modificações na relação entrada-saída da rede, a superfície de erro possui vários mínimos globais e é uma superfície extremamente irregular com diversos “vales” profundos;
- a superfície de erro possui um grande número de partes praticamente “planas”, pelo fato de combinações específicas de pesos causarem valores elevados nos somatórios dos sinais de entrada de neurônios das camadas intermediárias. Desta forma, a ativação dos neurônios afetados é insensível a pequenas variações de peso.
- os mínimos locais da superfície de erro existem.

Devido a estes aspectos, a dificuldade de se obter uma rede neural para representar um determinado tipo de problema é geralmente associada ao aprendizado inadequado, número insuficiente de neurônios nas camadas intermediárias e a não existência de relação determinística entre a entrada e a saída da rede. Um fator extremamente importante, que muitas vezes não é considerado, é a utilização do computador para implementar as redes neurais. Em [Wray,1995] é demonstrado que os resultados da teoria da aproximação não podem ser utilizados indiscriminadamente, sem considerações sobre os limites de precisão dos algoritmos computacionais, e como estas limitações reduzem sensivelmente a capacidade de aproximação das redes neurais.

Os neurônios das camadas intermediárias de uma rede neural tipo *Radial Basis Function* (RBF) utilizam uma função de ativação que não pertence ao grupo das sigmóides.

Esta função pode ser, por exemplo, uma gaussiana normalizada e a expressão da função de ativação é [Hertz,1990]:

$$G_n(\mathbf{v}) = \frac{\exp\left[\frac{(\mathbf{v} - \mu_j)^2}{2\sigma_j^2}\right]}{\sum_k \exp\left[\frac{(\mathbf{v} - \mu_k)^2}{2\sigma_k^2}\right]} \quad (\text{VII.2})$$

onde \mathbf{v} é o vetor de entrada. Por normalizada deve ser entendido que $\sum_n G_n(\mathbf{v}) = 1$ para qualquer \mathbf{v} . Desta forma, o neurônio n fornece a resposta máxima para um vetor de entrada próximo de μ_j e cada neurônio intermediário possui a sua própria área de atuação no espaço dos vetores de entrada, uma região centrada em μ_j e com tamanho proporcional a σ_j .

Em [Wray,1995] é demonstrado que a rede tipo RBF produz uma aproximação global dos dados de treinamento por um somatório de aproximações locais e, desta forma, possui uma precisão numérica superior a rede utilizada neste trabalho.

Embora os resultados obtidos na simulação realizada neste trabalho sejam considerados bons, mostrando que um programa de computador não sofisticado como o *Neuroshell 2* é confiável, os dados reais possuem ruído, fato inerente a sistemas de aquisição de sinais dinâmicos, e as ondas que atuam na estrutura da plataforma não são tão bem comportadas como as ondas utilizadas para gerar os dados para o treinamento das redes neurais aqui desenvolvidas. Como sugestões para a continuação do assunto, de forma que seja possível garantir a mesma precisão alcançada neste trabalho ou, até mesmo, obter uma melhor precisão na aplicação prática da metodologia proposta nesta tese, são recomendados:

- o desenvolvimento de novas avaliações, considerando o estudo paramétrico da rede neural *feedforward* treinada por *backpropagation*, com dados reais;
- a avaliação da rede tipo RBF.

A metodologia desenvolvida nesta tese pode ser aplicada, na realidade, a todos os tipos de estruturas metálicas submetidas a carregamentos aleatórios. Certamente, a sua aplicação deverá ter como consequências uma avaliação mais precisa da condição de integridade estrutural e uma redução nos custos de inspeção e reparo. O autor, que também é o responsável pelo Laboratório de Estruturas Navais da COPPE/UFRJ, considera este trabalho como um passo inicial para se utilizar a resposta dinâmica real da estrutura, associada às técnicas de Inteligência Artificial, na otimização dos procedimentos referentes à inspeção e ao reparo de juntas metálicas soldadas.

Apêndice A

Um das aplicações das redes neurais é a aproximação de uma função contínua de mapeamento f_{con} . Como há mapeamentos muito simples que uma rede neural, com apenas uma camada, não consegue realizar, a seguinte questão pode ser formulada: “uma rede neural com várias camadas é capaz de representar qualquer função contínua de mapeamento?”. A resposta para esta questão é dada pelos teoremas de Kolmogorov [Kolmogorov,1963], que estabelece que uma rede neural com três camadas (entrada, intermediária e saída) pode representar exatamente qualquer função contínua, de Sprecher [Sprecher,1965] e de Hecht-Nielsen [Hecht-Nielsen,1987], que estão apresentados a seguir.

Teorema de Kolmogorov

Qualquer função contínua $f_{con}(x_1, \dots, x_n)$ de diversas variáveis definidas em I^n ($n \geq 2$), onde $I = [0,1]$, pode ser representada na forma:

$$f_{con}(x) = \sum_{j=1}^{2n+1} \chi_j \left(\sum_{i=1}^n \psi_{ij}(x_i) \right) \quad (A.1)$$

onde χ_j e ψ_{ij} são funções contínuas de uma variável e ψ_{ij} é uma função monotônica que não depende da função de mapeamento f_{con} .

Teorema de Sprecher

Para cada inteiro $n \geq 2$ existe uma função real e de crescimento monotônico $\psi(x)$, sendo $\psi: [0,1] \rightarrow [0,1]$, que depende de n e possui a seguinte propriedade: para cada número pré-estabelecido $\delta > 0$ existe um número racional ϵ , onde $0 < \epsilon < \delta$, de tal forma que qualquer função contínua de n variáveis $f_{con}(x)$, definida em I^n , pode ser representada por:

$$f(x) = \sum_{j=1}^{2n+1} \chi \left(\sum_{i=1}^n \zeta^i \psi(x_i + \epsilon(j-1)) + j-1 \right) \quad (A.2)$$

onde χ é real e contínua e ζ é uma constante que independe de f_{con} .

Teorema de Hecht-Nielsen

Para qualquer função contínua $f_{\text{con}} : I^n \rightarrow \mathbb{R}^n$, onde I é o intervalo fechado $[0,1]$, f_{con} pode ser representada exatamente por uma rede neural tipo *feedforward*, com n neurônios de entrada, $2n+1$ neurônios intermediários e m neurônios na saída.

Os neurônios de entrada endereçam os sinais que chegam à rede para os neurônios intermediários. A função de ativação de um neurônio intermediário j é dada pela expressão:

$$G_{\text{int}}^{(j)} = \left(\sum_{i=1}^n \zeta^i \psi(x_i + \varepsilon_j) + j \right) \quad (\text{A.3})$$

onde a constante ζ e a função real e monotonicamente crescente ψ são independentes de f_{con} (mas dependem de n) e a constante ε satisfaz às condições do teorema de Sprecher. A função de ativação de um neurônio de saída k é dada por:

$$G_{\text{sai}}^{(k)} = \sum_{j=1}^{2n+1} g_k \left(\sum_{i=1}^n \zeta^i \psi(x_i + \varepsilon_j) + j \right) \quad (\text{A.4})$$

onde as funções g_k são reais e contínuas e dependem de f_{con} e ε .

Bibliografia

- 1- Ables, J. G. (1978) - **“Maximum Entropy Spectral Analysis”** - Modern Spectrum Analysis, IEEE Selected Reprint Series, IEEE Press, USA, pp. 23-31.
- 2- ADEP, Sistema Computacional (1988) - **“Subsistema ADEP-DINAL: Manual da Teoria”** - PETROBRAS/CENPES.
- 3- Akyurek, T. e Bilir, O. G. (1992) - **“A Survey of Fatigue Crack Growth Life Estimation Methodologies”** - Engineering Fracture Mechanics, vol. 43, no. 5, pp. 797-222.
- 4- Allemandy, R. J. e Brown, D. L. (1983) - **“A Correlation Coefficient for Modal Testing”** - 1st. International Modal Analysis Conference, , USA, pp. 257-262.
- 5- Almar-Naess, A. (1985) - **“Fatigue Handbook”** - Tapir Publishers, Trondheim, Norway.
- 6- Alvarado, F. A. U. (1988) - **“Ajuste de Parâmetros para o Cálculo de Frequências Naturais em Estruturas Oceânicas”** - Tese de Mestrado, COPPE/UFRJ.
- 7- ANSYS (1992) - **“User’s Manual”** - vol. I, II, III e IV, Swanson Analysis Systems, inc., Houston, Texas, USA.
- 8- ARSEM (1985) - **“Design Guide for Offshore Structures”** - Association de Recherche sur les Structures Métalliques Marines, Editions Technip, France.
- 9- ASME (1992) - 11th. International Conference on Offshore Mechanics and Arctic Engineering (OMAE), vol II: Safety and Reliability.
- 10- ASTM (1992) - **“Standard Definition of Terms Relating to Fatigue Testing and Statistical Analysis of Data”** - ASTM Designation E206-72.
- 11- Baker, M. J. e Vrouwenvelder, A. C. W. M. (1992) - **“Reliability Methods for the Design and Operation of Offshore Structures”** - 11th. International Conference on Offshore Mechanics and Arctic Engineering (OMAE), vol II: Safety and Reliability, pp. 123-132.
- 12- Batiti, R. (1992) - **“First and Second-Order Methods for Learning: Between Steepest and Newton’s Methods”** - Neural Computation, vol. 4, no. 2, pp. 141-166.
- 13- Baum, E. B. e Haussler, D. (1989) - **“What Size Net Gives Valid Generalization?”** - Neural Computation, vol. 1, no. 1, pp. 151-160.
- 14- Bendat, J. S. e Piersol, A. G. (1986) - **“Random Data: Analysis and Measurement Procedures”** - John Wiley & Sons, USA.
- 15- Benjamin, A. C. e Ebecken, N. F. F. (1991) - **“CALCAE1: A Computer Program for Geometric and Material Nonlinear Analysis of General Shell Structures”** - 8th. International Symposium on Offshore Engineering, held at COPPE/UFRJ, pp. 268-289.

- 16- Berge, S. (1993) - **"Fatigue Design of Tubular Joints - Developments and Problems"** - Conference on Fatigue Under Spectrum Loading and in Corrosive Environments, Denmark, pp. 227-248.
- 17- Beyko, E. e Bernitsas, M. M. (1992) - **"Reliability of Large Scale Structures by Large Admissible Perturbations"** - 11th. International Conference on Offshore Mechanics and Arctic Engineering (OMAE), vol II: Safety and Reliability, pp. 245-253.
- 18- Bishop, R. E. D. e Price, W. G. (1979) - **"Hydroelasticity of Ships"** - Cambridge University Press, USA.
- 19- Blakely, K. D. e Walton, W. B. (1984) - **"Selection of Measurement and Uncertainties for Finite Element Model Revision"** - 2nd. International Modal Analysis Conference, pp. 82-88.
- 20- Borgman, L. E. (1972) - **"Statistical Models for Ocean Waves and Wave Forces"** - Advances in Hydroscience, Academic Press, USA.
- 21- Burg, J. P. (1978) - **"Maximum Entropy Spectral Analysis"** - Modern Spectrum Analysis, IEEE Selected Reprint Series, IEEE Press, USA, pp. 34-41.
- 22- Burg, J. P. (1978) - **"A New Technique for Time Series Data"** - Modern Spectrum Analysis, IEEE Selected Reprint Series, IEEE Press, USA, pp. 42-48.
- 23- Caloba, L. P. (1993) - **"Introdução à Computação Neural"** - COPPE/UFRJ, Notas de aula.
- 24- Campbell, R.B. e Vandiver, J.K. (1982) - **"The Determination of Modal Damping Ratios from Maximum Entropy Spectral Estimates"** - Journal of Dynamic Systems, Measurements and Control, vol. 104, pp. 78-85.
- 25- Charniak, E. e McDermott, D. (1987) - **"Introduction to Artificial Intelligence"** - Addison-Wesley Publishing Company, USA.
- 26- Chaudhury, G. K. e Dover, W. D. (1985) - **"Fatigue Analysis of Offshore Platforms Subject to Sea Wave Loading"** - International Journal of Fatigue, vol. 7, no. 1, pp. 13-19.
- 27- Chow, M. Y., Mangum, P. M. e Yee, S. O. (1991) - **"A Neural Network Approach to Real Time Condition Monitoring of Induction Motors"**- IEEE Transactions on Industrial Electronics, vol. 38, no. 6, pp. 448-453.
- 28- Clough, R. W. e Penzien, J. (1975) - **"Dynamics of Structures"** - McGraw-Hill Kogakusha Ltd, USA.
- 29- Cohen, M. A. e Grossberg, S. (1983) - **"Absolute Stability of Global Pattern Formation and Parallel Memory Storage by Competitive Neural Networks"** - IEEE Transactions on Systems, Man, and Cybernetics, vol. 13, pp. 815-826.
- 30- Cooley, J. W. e Tukey, J. W. (1965) - **"An Algorithm for the Machine Calculation of Complex Fourier Series"** - Mathematics of Computation, vol. 19, pp. 297-301.
- 31- Dally, J. W., Riley, W. F. e McConnell, K. G. (1984) - **"Instrumentation for Engineering Measurements"** - John Wiley & Sons, USA.

- 32- Dascotte, E. e Vanhonacker, P. (1989) - **“Development of an Automatic Model Updating Program”** - 7th. International Modal Analysis Conference, pp. 596-602.
- 33- Dascotte, E. (1990) - **“Practical Applications of Finite Element Tuning Using Experimental Modal Data”** - 8th. International Modal Analysis Conference, pp. 1032-1037.
- 34- Department of Energy (1982) - **“Background to New Fatigue Design Guidance for Steel Welded Joints in Offshore Structures”** - Report of Department of Energy, Revision Draft Panel, London, UK.
- 35- DNV (1977) - **“Rules for the Design, Construction and Inspection of Fixed Offshore Structures”** - Det Norske Veritas, Norway.
- 36- DNV (1991) - **“Structural Reliability Methods”** - Det Norske Veritas, Classification Notes, no. 30.6, Norway.
- 37- Dover, W. D. (1979) - **“Variable Amplitude Fatigue of Welded Structures”** - SEE Conference on Fracture Mechanics: Current Status and Future Prospects (ed. R. A. Smith), UK, pp. 125-147.
- 38- Eberhart, R. C. e Dobbins, R. W. (1990) - **“Neural Network PC Tools: A Practical Guide”** - Academic Press Inc., USA.
- 39- Estrella, R. A. (1995) - **“Estimativa de Amortecimento em Plataformas Offshore pelo Método da Máxima Entropia”** - Tese de M. Sc., COPPE/UFRJ.
- 40- Ewins, D. J. e Lieven, N. A. J. (1988) - **“Spatial Correlation of Mode Shapes, the Coordinate Modal Assurance Criterion (COMAC) ”** - 6th. International Modal Analysis Conference, Florida, USA, pp. 322-326.
- 41- Faber, M. H., Sorensen, J. D. e Kroon, I. (1992) - **“Optimal Inspection Strategies for Offshore Structural System”** - 11th. International Conference on Offshore Mechanics and Artic Engineering (OMAE), vol II: Safety and Reliability, pp. 145-151.
- 42- Fahlman, S. E. (1988) - **“Faster-Learning Variations on Back-Propagation: An Empirical Study”** - Proceedings of the 1988 Connectionist Models Summer School, San Mateo, CA, USA, pp. 38-51.
- 43- Fahlman, S. E. e Lebiere, C. (1990) - **“The Cascade-Correlation Learning Architecture”** - Advances in Neural Information Processing Systems 2, San Mateo, CA, pp. 524-532.
- 44- Fausset, L. (1994) - **“Fundamentals of Neural Networks”** - Prentice Hall International Editions, USA.
- 45- Fox, R. L. e Kapoor, M. P. (1968) - **“Rates of Change of Eigenvalues and Eigenvectors”** - American Institute of Aeronautics and Astronautics Journal, vol. 6. no. 12, pp. 2426-2429.
- 46- Friswell, M. I. (1989) - **“The Adjustment of Structural Parameters Using a Minimum Variance Estimator”** - Mechanical Systems and Signal Processing, vol.3, no. 2, pp. 143-155.
- 47- Fuchs, H. O. e Stephens, R. I. (1980) - **“Metal Fatigue in Engineering”** - John Wiley & Sons, USA.

- 48- Fujimoto, Y. e Swilem, S. A. M. (1992) - **“Inspection Strategy for Deteriorating Structures Based on Sequential Cost Minimization Method”** - 11th. International Conference on Offshore Mechanics and Arctic Engineering (OMAE), vol II: Safety and Reliability, pp. 219-226.
- 49- Geman, S., Bienenstock, E. e Doursat, R. (1992) - **“Neural Networks and the Bias/Variance Dilemma”** - Neural Computation, vol. 4, no. 1, pp. 1-58.
- 50- Ghaboussi, J., Garret, J. H. e Wu, X. (1991) - **“Knowledge-based Modeling of Material Behavior with Neural Networks”** - Journal of Engineering Mechanics, no. 117, pp. 112-122.
- 51- Griffith, A. A. (1920) - **“The Phenomena of Rupture and Flow in Solids”** - Transactions of Royal Society (London), vol. A221, pp. 163.
- 52- Gupta, A. e Singh, R. P. (1986) - **“Fatigue Behaviour of Offshore Structures”** - Lecture Notes in Engineering, Springer-Verlag, Germany.
- 53- Gurney, T. R. (1978) - **“A Comparison of Three Stress Counting Methods Using Simulated Stress Spectra”** - The Welding Institute Press, Research Report, Abington, UK.
- 54- Gurney, T. R. (1979) - **“Fatigue of Welded Structures”** - Cambridge University Press, UK.
- 55- Haver, S. e Moan, T. (1983) - **“On Some Uncertainties Related to the Short Term Stochastic Modelling of Ocean Waves”** - Applied Ocean Research, vol. 5, no. 2, pp. 93-108.
- 56- Haykin, S. S. e Kesler, S. (1983) - **“Prediction-Error Filtering and Maximum-Entropy Spectral Evaluation”** - Chapter 2 in Nonlinear Methods of Spectral Analysis, Springer-Verlag, New York, USA.
- 57- He, J. e Ewins, D. J. (1991) - **“Compatibility of Measured and Predicted Vibration Modes in Model Improvement Studies”** - American Institute of Aeronautics and Astronautics Journal, vol. 29, no. 5, pp. 798-803.
- 58- Hetch-Nielsen, R. (1987) - **“Kolmogorov’s Mapping Neural Network Existence Theorem”** - IEEE First International Conference on Neural Networks, San Diego, CA, vol. 3, pp. 11-14.
- 59- Hecht-Nielsen, R. (1990) - **“Neurocomputing”** - Addison-Wesley Publishing Company, USA.
- 60- Hertz, J., Krogh, A. e Palmer, R. G. (1990) - **“Introduction to the Theory of Neural Computation”** - Addison-Wesley Publishing Company, USA.
- 61- Hopfield, J. J. (1984) - **“Neurons with Graded Response Have Collective Computational Properties like Those Two-state Neurons”** - Proceedings of the National Academy of Sciences, USA, pp. 579-584.
- 62- Ibsø, J. B. e Agerskov, H. (1993) - **“Fatigue Life Prediction of Offshore Tubular Structures Under Stochastic Loading”** - Conference on Fatigue Under Spectrum Loading and in Corrosive Environment, Denmark, pp. 205-226.

- 63- Irwin, G. R. (1957) - **“Analysis of Stresses and Strains Near the End of a Crack Transversing a Plate”** - Journal of Applied Mechanics, Transaction ASME, vol. 24, pp. 361-378.
- 64- Jacobs, R. A. (1988) - **“Increased Rates of Convergence Through Learning Rate Adaptation”** - Neural Networks, vol. 1, no. 4, pp. 295-308.
- 65- Janter, T., Heylen, W. e Sas, P. (1989) - **“QA Model Updating”** - Proceedings of 14th International Seminar on Modal Analysis, Leuven, paper no. 9.
- 66- Jensen, J. L. (1990) - **“System Identification of Offshore Platforms”** - Ph. D. Thesis, University of Aalborg, Denmark.
- 67- Jiao, G. (1992) - **“Reliability Analysis of Crack Growth with Inspection Planning”** - 11th. International Conference on Offshore Mechanics and Arctic Engineering (OMAEE), vol II: Safety and Reliability, pp. 227-235.
- 68- Kam, J. C. P. e Dover, W. D. (1987) - **“Structural Integrity of Welded Tubular Joints in Random Load Fatigue Combined with Size Effect”** - Third International Symposium on Integrity of Offshore Structures (Elsevier Applied Science Publishers Ltd.), Scotland, pp. 265-283.
- 69- Kidder, R. L. (1973) - **“Reduction of Structural Frequency Equation”** - American Institute of Aeronautics and Astronautics Journal, vol. 11, no. 3, pp. 892-899.
- 70- Kim, K., Aljundi, T. L. e Bartlet, E. (1992) - **“Confirmation of Artificial Neural Networks: Nuclear Power Plant Fault Diagnosis”** - Transactions of the American Nuclear Society, no. 66, pp. 15-20.
- 71- Kirkegaard, P. H., Sorensen, J. D. e Brinker, R. (1988) - **“Fatigue Reliability Analysis of a Monotower Platform”** - Fracture & Dynamics, paper no. 9, Aalborg University, Denmark.
- 72- Kirkegaard, P. H., Sorensen, J. D. e Brinker, R. (1990) - **“Optimization of Measurements on Dynamically Sensitive Structures Using a Reliability Approach”** - Fracture & Dynamics, paper no. 21, Aalborg University, Denmark.
- 73- Kolmogorov, A. N. (1963) - **“On the Representation of Continuous Functions of Many Variables by Superposition of Continuous Functions of One Variable and Addition”** - Doklady Akademii Nauk SSSR, vol. 144, pp. 679-681 (American Mathematical Society (translation) vol. 28, pp. 55-59).
- 74- Kosko, B. (1990) - **“Neural Networks and Fuzzy Systems: A Dynamical Systems Approach to Machine Intelligence”** - Prentice-Hall International Editions, USA.
- 75- Kramer, A. H. e Vincentelli, A. S. (1989) - **“Efficient Parallel Learning Algorithms for Neural Networks”** - Advances in Neural Information Processing Systems 1, San Mateo, CA, USA, pp. 40-48.
- 76- Lieven, N. A. J. e Ewins, D. J. (1991) - **“Expansion of Modal Data for Correlation”** - Proceedings of 8th IMAC, pp. 605-609.

- 77- Lim, K. B., Junkins, J. L. e Wang, B. P. (1987) - **“Re-examination of Eigenvectors Derivatives”** - American Institute of Aeronautics and Astronautics Journal, vol. 25, no. 6, pp. 581-587.
- 78- Lin, Y. K. (1967) - **“Probabilistic Theory of Structural Dynamics”** - MacGraw-Hill, New York.
- 79- LMS International (1991) - **“Large Scale Modal Testing of a Space Frame Structure-from Pretest analysis to FEA Model Validation”** - Journal of Sound and Vibration, vol. 167, no. 2, pp. 6-16.
- 80- Lopes, T. A. P. (1987) - **“Instrumentação de Plataformas Fixas de Produção na Bacia de Campos”** - COPPE/UFRJ, Relatórios Técnicos.
- 81- Lopes, T. A. P. e Novaes, F. (1989) - **“An Automatic System for Data Acquisition on Board Offshore Structures”** - 7th. International Symposium on Offshore Engineering, held at COPPE/UFRJ, pp. 398-406.
- 82- Lopes, T. A. P. (1991) - **“Evaluation of Fatigue Damage on Fixed Jacket Platforms”** - Computer Methods in Marine and Offshore Engineering, Computational Mechanics Publication, UK, pp. 345-356.
- 83- Madsen, H. O., Skjong, R. e Kirkemo, F. (1987) - **“Probabilistic Fatigue Analysis of Offshore Structures - Reliability Updating Through Inspection Results”** - Third International Symposium on Integrity of Offshore Structures (Elsevier Applied Science Publishers Ltd.), Scotland, pp. 361-374.
- 84- Marple, S. L. Jr. (1987) - **“Digital Spectral Analysis with Applications”** - Prentice-Hall Inc., USA.
- 85- McCulloch, W. S. and Pitts, W. (1943) - **“A Logical Calculus of the Idea Immanent in Nervous Activity”** - Bulletin of Mathematical Biophysics, vol. 5, pp. 115-133.
- 86- Meniconi, L. C. M. (1989) - **“Estudo Numérico-Experimental do Dano Produzido por Fadiga em Jaquetas de Plataformas Marítimas”** - Tese de M.Sc., COPPE/UFRJ.
- 87- Miner, M. A. (1945) - **“Cumulative Damage in Fatigue”** - Journal of Applied Mechanics, Transaction ASME, vol. 67, no. 12, pp. 159-164.
- 88- Minsky, M. L. e Papert, S. (1969) - **“Perceptrons: An Introduction to Computational Geometry”** - MIT Press, Cambridge, MA, USA.
- 89- Moody, J. e Darken, C. J. (1989) - **“Fast Learning in Networks of Locally-Tuned Processing”** - Neural Computation, vol. 1, no. 2, pp. 281-294.
- 90- Moore, H. F. e Kommers, J. B. (1927) - **“The Fatigue of Metals”** - MacGraw-Hill Book Company, New York.
- 91- Mottershead, J. E. e Friswell, M. I. (1993) - **“Model Updating in Structural Dynamics: a Survey”** - Journal of Sound and Vibration, vol. 167, no. 2, pp. 347-375.
- 92- Natke, H. G. (1988) - **“Updating Computational Models in the Frequency Domain Based on Measured Data: a Survey”** - Probabilistic Engineering Mechanics, vol. 3, no. 1, pp. 28-35.

- 93- Nelson, R. B. (1976) - **"Simplified Calculation of Eigenvectors Derivatives"** - American Institute of Aeronautics and Astronautics Journal, vol.14, no. 9, pp. 1201-1205.
- 94- Newland, D. E. (1975) - **"An Introduction to Random Vibrations and Spectral Analysis"** - Longman Group Limited, London.
- 95- Novaes, F. (1990) - **"Sistema de Aquisição de Dados Baseado em Técnicas de Inteligência Artificial"** - Tese de M. Sc., COPPE/UFRJ.
- 96- Nguyen, D. e Widrow, B. (1990) - **"Improving the Learning Speed of Two-Layer Neural Networks by Choosing Initial Values of the Adaptive Weights"** - International Joint Conference On Neural Networks, San Diego, CA, vol. III, pp.21-26.
- 97- Ojalvo, I. U. (1987) - **"Efficient Computation of Mode Shape Derivatives for Large Dynamic Problems"** - American Institute of Aeronautics and Astronautics Journal, vol. 25, no. 10, pp. 1386-1390.
- 98- Olagnon, M. e Prevosto, M. (1984) - **"The Variation of Damping Ratios with Sea Conditions for Offshore Structures Under Natural Excitation"** - Offshore Technology Conference, paper OTC no. 3412, USA, pp. 4654-4661.
- 99- Palmgreen, A. (1924) - **"Die Lebensdauer von Kugellagern"** - ZDVI, vol. 68, no. 14, pp. 339 (in German).
- 100- Paris, P. C. e Erdogan, F. (1963) - **"A Critical Analysis of Crack Propagation Law"** - Journal of Basic Engineering, Transaction ASME, vol. 85, no. 4, pp. 528-540.
- 101- Pedersen, C., Madsen, H. O., Nielsen, J. A., Riber, P. e Krenk, S. (1992) - **"Reliability Based Inspection Planning for the TYRA Field"** - 11th. International Conference on Offshore Mechanics and Arctic Engineering (OMAE), vol II: Safety and Reliability, pp. 255-263.
- 102- Peers, S. M. C., Dharmavasan, S., Kam, J. P. e Dover, D. (1992) - **"A Rational Inspection Schedule Philosophy for Fixed Offshore Platforms"** - 11th. International Conference on Offshore Mechanics and Arctic Engineering (OMAE), vol II: Safety and Reliability, pp. 133-139.
- 103- Potvin, A. B., Kuang, J. G., Leik, R. D. e Kahlich, J. L. (1977) - **"Stress Concentration in Tubular Joints"** - Society of Petroleum Engineers Journal, vol. 25, no. 4, pp. 287-299.
- 104- Pouliezios, A. D. e Atavrakakis, G. S. (1994) - **"Real Time Fault Monitoring of Industrial Processes"** - Kluwer Academic Publishers, Netherlands
- 105- Ray, A. K. (1991) - **"Equipment Fault Diagnosis - A Neural Network Approach"** - Computers in Industry, vol. 16, pp. 169-177.
- 106- Rodriguez, M. V. R., Garcia, C. H. P., Borges, J. L. P. e Ferrante, A. J. (1991) - **"A Data System for Structural Models of Offshore Platforms"** - 8th. International Symposium on Offshore Engineering, held at COPPE/UFRJ, pp. 290-299.
- 107- Rumelhart, D. E., Hinton, G. E. and Williams, R. J. (1986a) - **"Learning Representations by Back-Propagating Errors"** - Nature, no. 323, pp. 533-536.

- 108- Rumelhart, D. E., Hinton, G. E. and Williams, R. J. (1986b) - **“Learning Internal Representations by Error Propagation”** - *Parallel Distributed Processing* - volume 1: Foundations, MIT Press, pp. 318-362.
- 109- Sarpkaya, T. e Isaacson, M. (1981) - **“Mechanics of Wave Forces on Offshore Structures”** - Van Nostrand Reinhold Company, New York.
- 110- Smith, M. (1993) - **“Neural Network for Statistical Modeling** - Van Nostrand Reinhold, New York.
- 111- Spidsoe, N. e Langen, I. (1985) - **“Damping of Fixed Offshore Platforms”** - *Behaviour of Offshore Structures*, Elsevier Science Publishers, Amsterdam, pp. 915-925.
- 112- Sprecher, D. A. (1965) - **“On the Structure of Continuous Functions of Several Variables”** - *Transactions of the American Mathematical Society*, no. 115, pp. 340-355.
- 113- Sigbjornsson, R. (1979) - **“Stochastic Theory of Wave Loading Processes”** - *Applied Mathematical Modelling*, vol. 4, no. 6, pp. 155-165.
- 114- Sigurdson, G. (1989) - **“Some Aspects of Reliability of Offshore Structures”** - Ph. D. thesis, University of Aalborg, Denmark.
- 115- Skjong, R. e Madsen, H. (1987) - **“Practical Stochastic Fatigue Analysis of Offshore Platforms”** - *Ocean Engineering*, vol. 14, no. 6, pp. 313-324.
- 116- Sorensen, J. D., Faber, M. H., Thoft-Christensen, P. e Rackwitz, R. (1991) - **“Modeling in Optimal Inspection and Repair”** - 11th. International Conference on Offshore Mechanics and Arctic Engineering (OMAE), vol II: Safety and Reliability, pp. 281-288.
- 117- Subia, J. E. P., Lima, E. C. P. e Jacobs, T. L. (1991) - **“Structural Reliability Using Monte-Carlo Method with Domain Discretization in Offshore Structures”** - 8th. International Symposium on Offshore Engineering, held at COPPE/UFRJ, pp. 240-254.
- 118- Szu, H. H. e Maren, J. (1990) - **“Multilayer Feedforward Neural Networks II: Optimizing Learning Methods”** - *Handbook of Neural Computing Applications*, San Diego Academic Press, USA.
- 119- Tan, R. C. E. e Andrew, A. L. (1989) - **“Computing Derivatives of Eigenvalues and Eigenvectors by Simultaneous Iteration”** - *Journal of Numerical Analysis*, vol 9, no. 1, pp. 111-122.
- 120- Tarantola, A. (1987) - **“Inverse Problem Theory: Methods for Data Fitting and Model Parameter Estimation”** - Elsevier Science Publishers, Netherlands.
- 121- Thoft-Christensen, P. e Murotsu, Y. (1986) - **“Application of Structural Systems Reliability Theory”** - Springer-Verlag, New York.
- 122- Torres, A. L. F. L. (1984) - **“Determinação da Fadiga em Estruturas Metálicas Soldadas Submetidas a Solicitações Dinâmicas”** - Tese de M. Sc., COPPE/UFRJ.

- 123- Tuna, J. M. (1986) - **“Fatigue Life Prediction for Gaussian Random Loads at the Design Stage”** - Fatigue Fracture of Engineering Materials and Technology, vol. 9, no. 3, pp.169-184.
- 124- UEG/CIRIA (1985) - **“Design of Tubular Joints for Offshore Structures”** - vol. 1 e 2, UEG Offshore Research: part of the Construction Industry Research and Information Association, UK.
- 125- Ulrych, J. T. e Bishop, T. N. (1978) - **“Maximum Entropy Spectral Analysis and Autoregressive Decomposition”** - Modern Spectrum Analysis, IEEE Selected Reprint Series, IEEE Press, USA, pp. 54-71.
- 126- Virkler, D. A., Hillberry, B. M. e Goel, K. (1979) - **“The Statistical Nature of Fatigue Crack Propagation”** - ASME Journal Engineering Materials Technology, vol. 101, pp. 148-162.
- 127- Vughts, J. H. e Kuna, R. K. (1976) - **“Probabilistic Fatigue Analysis of Fixed Offshore Structures”** - Offshore Technology Conference, paper 2608, pp. 889-906.
- 128- Watt, B. J. (1978) - **“Basic Structural Systems - A Review of Their Design and Analysis Requirements”** - Numerical Methods in Offshore Engineering, John Wiley & Sons, Ltd, USA.
- 129- Werbos, P. (1974) - **“Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences”** - PhD Thesis, Department of Applied Mathematics, Harvard University, USA.
- 130- Widrow, B. e Hoff, M. E. (1960) - **“Adaptative Switching Circuits”** - IRE WESCON Convention Record, USA, pp. p6-104.
- 131- Wirshing, P. H. e Shehata, A. M. (1977) - **“Fatigue Under Wide Band Random Stresses Using The Rainflow Method”** - Journal of Engineering Materials and Technology, Transaction ASME, pp. 205-211.
- 132- White, H. (1989) - **“Learning in Artificial Neural Networks: A Statistical Perspective”** - Neural Computation, vol. 1, no. 4, pp. 425-469.
- 133- Wray, J. e Green, G. G. R. (1995) - **“Neural Networks, Approximation Theory and Finite Precision Computation”** - Neural Networks, vol. 8, no. 1, pp. 31-37.
- 134- Wu, X., Ghaboussi, J. e Garret, J. H. (1992) - **“Use of Neural Network in Detection of Structural Damage”** - Computers and Structures, vol. 42, no. 4, pp.649-659.
- 135- Yamashima, H., Kumamoto, H., Okumura, S. e Ikesaki, T. (1990) - **“Failure Diagnosis of a Servovalve by Neural Networks with New Learning Algorithm and Structure Analysis”** - International Journal of Production Research, vol. 28, no. 6, pp. 1009-1021.
- 136- Yao, J. T. P., Kozin, F., Wen, Y. K., Yang, J. N., Schuëller, G. I. e Ditlevsen, O. (1986) - **“Stochastic Fatigue, Fracture and Damage Analysis”** - Structural Safety, vol. 3, pp. 231-267.

Lista de Símbolos

Capítulo II:

$x(t)$ - função contínua no domínio do tempo

$R_x(\tau)$ - função autocorrelação

ω - frequência em rad/s

$S_x(\omega)$ - função densidade espectral de potência

$E[]$ - valor esperado de variável ou função

$R_{xy}(\tau)$ - função autocorrelação cruzada

$S_{xy}(\omega)$ - função densidade espectral cruzada de potência

$S_{\text{mar}}(\omega)$ - função densidade espectral de potência do mar

A_s - altura significativa de mar

T_z - período de cruzamento ascendente do nível médio

C_m - coeficiente de inércia

C_d - coeficiente de arraste

$H_1(\omega)$ - resposta complexa em frequência

$H_1^*(\omega)$ - conjugado complexo de $H_1(\omega)$

$S_y(\omega)$ - função densidade espectral de potência da resposta

\mathbf{M} - matriz massa

\mathbf{C} - matriz amortecimento

\mathbf{K} - matriz de rigidez

\mathbf{f} - vetor de forças de excitação

\mathbf{f}^t - vetor transposto de forças de excitação

\mathbf{u} , $\dot{\mathbf{u}}$ e $\ddot{\mathbf{u}}$ - vetores de deslocamento, velocidade e aceleração, respectivamente

Capítulo III: ℓ_n - logaritmo natural f - frequência em Hertz f_n - frequência natural em Hertz $S_{\text{mem}}(f)$ - função densidade espectral de máxima entropia $R_x(k)$ - função autocorrelação de ordem k ξ - coeficiente de amortecimento viscoso equivalente ϕ_i^C - modo calculado de vibração i ϕ_j^E - modo experimental de vibração j $()^t$ - notação para vetor (ou matriz) transposto Φ - matriz modal δz - vetor das perturbações nos parâmetros δp - vetor das perturbações nas variáveis medidas S_a - matriz de sensibilidade dos parâmetros λ_i - autovalor i ϕ_i - autovetor i (modo natural de vibração i) V_p - matriz de variância dos parâmetros V_z - matriz de variância das variáveis medidas $()^{-1}$ - notação para matriz inversa**Capítulo IV:** a - profundidade da trinca N - número de ciclos C - constante do material ΔK - fator de intensidade de tensões m - constante do material

α - fator de irregularidade

ΔS - intervalo de variação das tensões

M_n - momento espectral de ordem n

$S_{ten}(\omega)$ - função densidade espectral de tensões

σ_{ten}^2 - variância do processo aleatório correspondente às tensões

n_i - número de ciclos correspondente ao intervalo de tensões ΔS_i

f_c - fator de correção para espessura

ε - parâmetro de largura de banda

Capítulo V:

w_{ij} - peso (eficiência das sinapses) entre os neurônios i e j

w_{0j} - valor mínimo de atividade do neurônio j

y_j - sinal de saída ou ativação do neurônio j

$G()$ - função de ativação

Esta simbologia, referente ao capítulo V, é básica; os demais termos estão explicados no texto.