

CADERNOS DO IME – Série Estatística

Universidade do Estado do Rio de Janeiro - UERJ
Rio de Janeiro - RJ - Brasil
ISSN 1413-9022 / v. 23 p. 30 - 51, 2007

REDES NEURAIIS PARA MODELAGEM DE SISTEMAS ESTRUTURAIS OFFSHORE DINÂMICOS NÃO LINEARES COM HISTERESE

Djalene Maria Rocha
CENPES - Petrobrás
djalene@petrobras.com.br

Dary Lottmar Kayser Junior
CENPES - Petrobrás
darylk@petrobras.com.br

Nelson Francisco Favilla Ebecken
COPPE - UFRJ
nelson@ntt.ufrj.br

Luiz Pereira Calôba
COPPE - UFRJ
caloba@lps.ufrj.br

Resumo

Este trabalho propõe um modelo empírico para o sistema com histerese formado por um tipo de conexão elastomérica riser-plataforma, em águas profundas. A conexão tem o objetivo de minimizar os momentos fletores atuantes, possui grande complexidade e alta criticidade devido às conseqüências econômicas e ambientais decorrentes de sua falha. O elemento principal da junta é composto de material elastomérico com comportamento histerético não-linear. Além disso, o sistema composto por essa conexão também apresenta não-linearidades devido à ação das cargas dinâmicas e devido aos grandes deslocamentos. Redes Neurais TDNN e Recorrentes são investigadas por possuírem a habilidade de modelar comportamentos histeréticos não-lineares, bem como de sistemas dinâmicos. Verificou-se que o modelo de Redes Neurais Recorrentes apresenta os melhores resultados para o sistema estudado. Devem ser ressaltadas ainda as dificuldades adicionais ao processo de modelagem deste sistema relacionadas ao emprego dos dados reais.

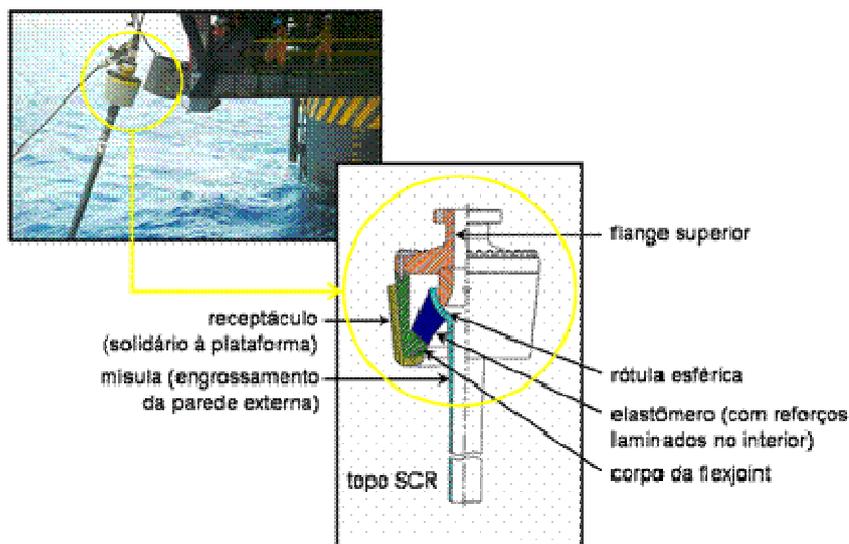
Palavras-chave: Flexjoint, SCR, Redes Neurais Recorrentes, NARX, Histerese.

1. Introdução

O sistema específico em estudo é aquele que compõe a conexão entre o riser e a plataforma, que é realizada por um equipamento denominado Flexjoint. A Flexjoint (Figura 1) é um equipamento instalado no topo do SCR e que, através de uma junta elastomérica, permite que este flexione quando sujeito a carregamentos dinâmicos ambientais de onda, vento e correnteza. O papel do elastômero é de grande importância e complexidade. Uma eventual degeneração do elastômero pode comprometer o desempenho do equipamento, embora ainda não seja possível concluir se essa degeneração se dá no sentido do aumento ou da redução da rigidez. Contudo, pode-se prever que, na hipótese de enrijecimento da conexão do riser com a plataforma, os danos de fadiga seriam agravados na região próxima ao topo, reduzindo sua vida útil.

A finalidade do estudo é de ampliar o entendimento do comportamento histerético da referida junta.

Figura 1: Flexjoint – Plataforma PXVIII



A formulação de um modelo matemático baseado em leis e princípios físicos para representação do sistema proposto é bastante complexa, devido à característica não-linear das leis constitutivas mas, principalmente, pelo fato do elastômero exibir histerese.

A disponibilidade de dados e o desenvolvimento de técnicas de identificação de sistemas conduziram este trabalho para uma modelagem empírica do comportamento

dinâmico do elastômero. Neste trabalho a técnica de identificação empregada foi a de Redes Neurais Artificiais.

2. Teoria de Redes Neurais Dinâmicas

Tradicionalmente, as redes neurais têm ampla aplicação em problemas estáticos, tais como classificação e reconhecimento de padrões. Estas redes são denominadas redes neurais estáticas e simulam propriedades da memória de longo prazo do sistema de memória dos seres humanos. São exemplos as redes MLP (Multilayer Perceptron) e RBF (Radial Basin Function). Entretanto, estas redes não são capazes de representar situações dinâmicas, temporais ou que apresentem alguma ordem no conjunto de dados.

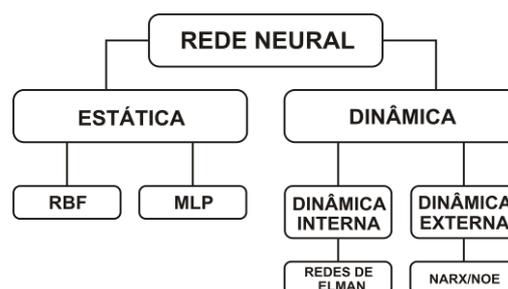
A histerese é um fenômeno dinâmico e, portanto, tem como principal característica a sua dependência com o passado. Fundamentalmente o que uma rede neural precisa para modelar esse tipo de fenômeno é alguma forma de memória. Tal memória é conhecida como memória de curto prazo e, é introduzida na rede neural através de atrasos de tempo e/ou através de realimentação (HAYKIN, 2004). Estas redes podem ser divididas em dois grupos: as redes com dinâmica externa e com dinâmica interna.

As primeiras são aquelas que usam atrasos de tempo da entrada e/ou realimentação da camada de saída para a camada de entrada. São exemplos as redes TDNN (Time Delay Neural Network): as redes NOE (Nonlinear output error) e as redes NARX (Nonlinear Autoregressive with exogenous input), também conhecidas como modelo paralelo e série-paralelo, respectivamente (NARENDRA & PARTHASARATHY, 1990).

Nas redes com dinâmica interna, os valores passados da entrada e da saída não são re-introduzidos na entrada da rede, o que significa que nenhum conhecimento a priori é utilizado. A dinâmica é inserida pelas chamadas memórias de contexto e se dá através da realimentação das camadas escondidas. Um exemplo clássico desse tipo de arquitetura é a rede Elman (ELMAN, 1990).

Um diagrama com os dois grupos e as redes estáticas é mostrado na Figura 2.

Figura 2: Diagrama redes estáticas e dinâmicas



Vários trabalhos propõem diferentes arquiteturas para modelagem empírica da histerese utilizando redes neurais, em diversas áreas. Em (BASHEER *et al.*, 2002), é proposta uma solução híbrida, denominada pelo autor de TDNN parcialmente recorrente, para modelagem do comportamento tensão-deformação de geomateriais submetidos a carregamentos cíclicos. Em função de tais carregamentos, os geomateriais exibem histerese. A investigação realizada em (G. W. ELLIS *et al.*, 1996) confirma que as RN seqüenciais com realimentação são mais efetivas que as RN convencionais sem realimentação para simular a relação tensão-deformação do solo. Na solução de problemas relacionados com água (stage-discharge) a efetividade de uma RBF e MLP são exploradas em (SUDHEER, 2003) e (TAWFIK *et al.*, 1997) respectivamente.

Neste trabalho serão avaliadas as redes MLP, TDNN, NOE e NARX.

3. Dados

Os dados utilizados para gerar o modelo do comportamento da Flexjoint são oriundos de duas fontes: do processo de monitoração da própria flexjoint e de ensaios de laboratório no elastômero. Os dados monitorados de interesse são forças e deslocamentos e as variáveis disponíveis do ensaio são tensão e deformação. As seções seguintes descrevem esses dois conjuntos de dados.

3.1 Dados Monitorados

Os dados monitorados são sinais aleatórios no tempo, discretos e oriundos de um processo de monitoração de uma plataforma de petróleo/gás semi-submersível, PXVIII, localizada na Bacia de Campos no Rio de Janeiro – Brasil (MACHADO *et al.*, 1999). As variáveis relevantes para esse estudo são:

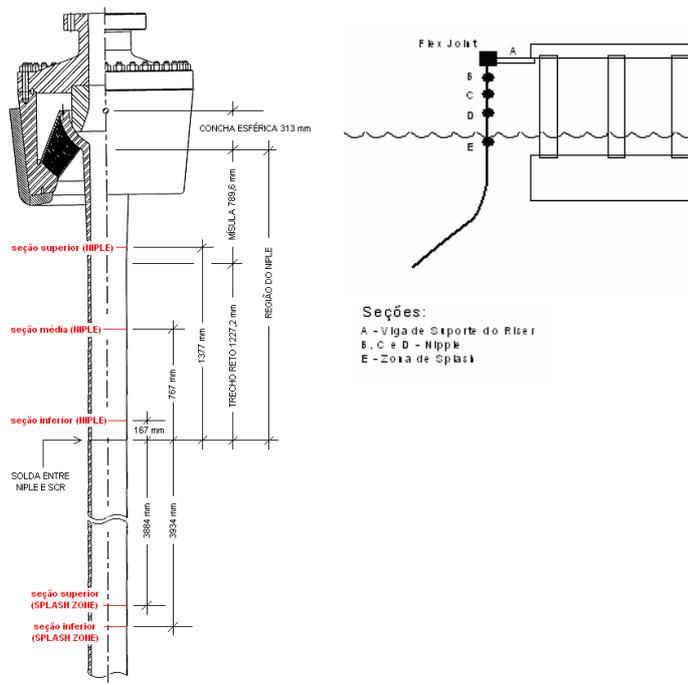
- Esforço de flexão (momento fletor), na direção da catenária do riser e perpendicular (0°, 90°);

- Esforço axial (tração);
- Ângulo relativo entre riser e plataforma definido no plano da catenária do riser;
- Ângulo relativo entre riser e plataforma definido no plano perpendicular à catenária.

As variáveis NUM0 e NUM90 (NUM – Niple Upper Momento) referem-se aos momentos fletores na direção da catenária e na direção perpendicular à catenária do SCR medidos na posição do niple superior (Niple Upper) (ver Figura 3) . O esforço axial (tração) é representado pela variável NUT, medida no plano paralelo à seção transversal do SCR. O strain gage foi o sensor adotado para medição desses esforços.

Os ângulos relativos formados entre as direções 0° e 90°, entre a plataforma e o riser (APR0 e APR90), não são medidos diretamente, mas calculados a partir das inclinações de cada um. As inclinações foram obtidas através de um inclinômetro instalado na viga suporte, ou melhor, no receptáculo (que é solidário à plataforma) e outro inclinômetro instalado no niple, ou seja, no trecho tubular da flexjoint que, estando soldado ao topo do SCR, acompanha os movimentos do riser.

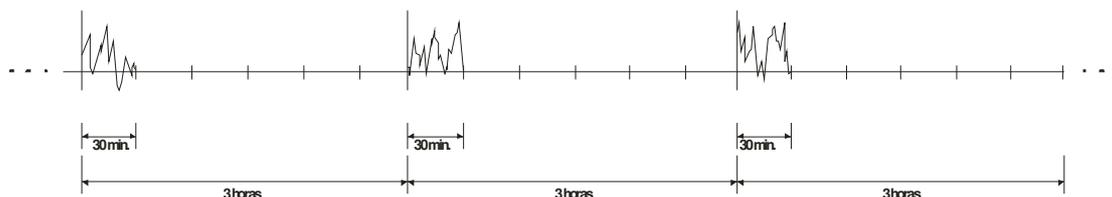
Figura 3 : Indicação dos pontos de instalação dos sensores na flexjoint



O período considerado foi de 18/07/2001 a 20/11/2001, por se constituir um período de aquisição com menor incidência de erros de aquisição, ruídos e falta de dados. Foram obtidos do banco de dados as séries temporais de cada variável. O arquivo é composto de 948 séries discretas, cada série representando um estado de mar. Resumidamente, pelo menos três informações básicas são necessárias para especificar as condições de um certo estado de mar: altura, período e direção de onda. Durante o período que define a série e, conseqüentemente, o estado de mar, o mar é descrito como um processo aleatório, ergódico e estacionário.

O período definido para satisfazer as condições acima (ergodicidade e estacionariedade) foi de 30 minutos. Então, para cada série, os registros foram feitos por cerca de 30 minutos a cada 3 horas, 24 horas por dia. A frequência de amostragem foi de 1 Hz (1s), perfazendo-se um total de cerca de 1800 pontos por série (MACHADO *et al.*, 1999). Este período foi determinado pela capacidade do sistema de aquisição de dados. A Figura 4 abaixo ilustra a composição das séries ao longo do período.

Figura 4: Composição das séries temporais ao longo do período

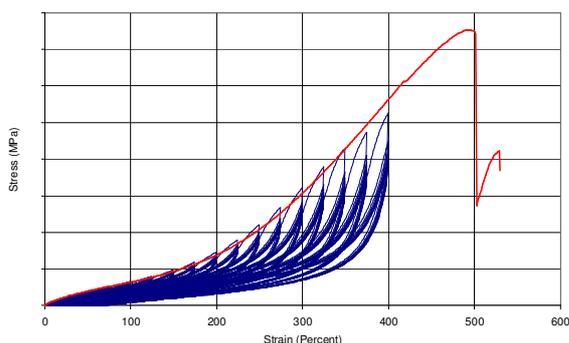


Esses dados não foram utilizados diretamente do processo de aquisição. Transformações, limpeza e outras operações com os dados foram realizadas. Detalhes e procedimentos para utilização desse conjunto de dados são apresentados em Rocha (2007).

3.2 Dados do Ensaio de Laboratório

Os ensaios foram realizados em elementos de elastômero empregados na flexjoint, para avaliação do módulo de elasticidade através da relação tensão de formação. Foram conduzidos ensaios quasi-estático com aplicação sequencial de carregamento e descarga, para crescentes níveis de deformação. A Figura 5 ilustra os ciclos. É interessante observar que os ciclos de histerese aparecem mesmo sob cargas estáticas cíclicas (quasi-estáticas).

Figura 5 - Laços de histerese do elastômero em ensaio quasi-estático em laboratório



4. Seleção dos Parâmetros das Redes Seleccionadas

Nessa parte do trabalho, a preocupação é encontrar as redes que sejam mais eficientes para lidar com a dinâmica do sistema e a histerese do elastômero na flexjoint. Três tipos de arquiteturas de redes neurais foram empregados para avaliar a habilidade da rede de modelar o comportamento histerético. Além das redes TDNN e recorrentes do tipo NARX (paralelo e série-paralelo), também foi empregado uma rede backpropagation (MLP) convencional para o problema. A retropropagação convencional é um processo estático e não produz bons resultados em processos cuja dependência do tempo é fator primordial. Entretanto, foi utilizada nesta pesquisa apenas para comparar os resultados e avaliar o ganho quando se negligencia o tempo em sistemas e materiais que exibem histerese.

Os algoritmos de treinamento tradicionais baseados no gradiente (HAYKIN, 2004), bastante empregados nas redes convencionais backpropagation, podem também ser utilizados para treinar redes dinâmicas. Porém, devido ao potencial das redes dinâmicas de processar informações ordenadas no tempo, o treinamento com esses algoritmos podem ficar significativamente lentos (MATLAB HELP, 2006). Também segundo (MATLAB HELP, 2006), a utilização do algoritmo baseado no método de otimização de Levenberg-Marquard propicia um treinamento mais adequado ao problema: "Este método minimiza a combinação dos erros quadráticos e os pesos, e então determina a combinação correta de tal forma a produzir uma rede que generalize bem".

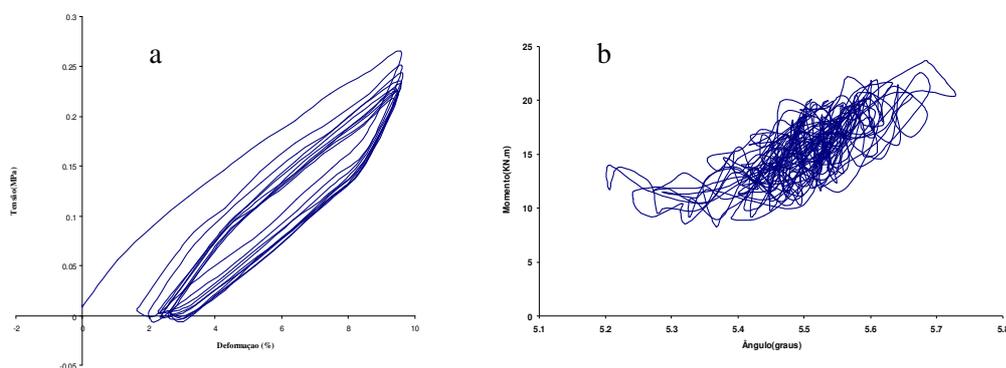
O treinamento é supervisionado e pára pelo critério Early-Stopping ou se o número máximo de 600 épocas (iterações) for atingido. Basicamente, o que se pretende com o critério early stopping é evitar o treinamento excessivo (overtraining) da rede, o

que pode fazer com que ela perca sua capacidade de generalização quando apresentada a novos padrões. A interrupção do processo de treinamento se dá, seguindo esse critério, quando o SSE (Sum squared Error) ou o MSE (Mean Squared Error) do conjunto de validação começa a crescer.

Um grande número de medidas de desempenho pode ser encontrado na literatura e cada uma possui suas vantagens e limitações (MAKRIDAKIS *et al.*, 1982). Neste estudo, a eficácia dos modelos desenvolvidos para as curvas σ - ϵ foi medida através da raiz quadrada dos erros médios quadráticos (RMSE-Root Mean Squared Error). Quanto maior o RMSE, maior o erro de previsão do modelo.

Para o entendimento do comportamento das redes selecionadas e para a definição de alguns parâmetros, na seção a seguir tem-se uma série de testes realizados utilizando os dados experimentais, que apresentam um volume de dados bem mais “comportado” que os dados reais advindos do processo de monitoração, como pode ser visto na Figura 6 a e b.

Figura 6 - a) Ciclos de histerese para dados de laboratório e b) Ciclos de histerese para dados reais.



O conjunto de dados de laboratório é formado por 180 ciclos de histerese, o que corresponde a 52194 registros e está armazenado em seqüência, ou seja, para um dado ponto arbitrário do estado tensão-deformação, os pontos que o precedem são estados que aconteceram em um tempo anterior.

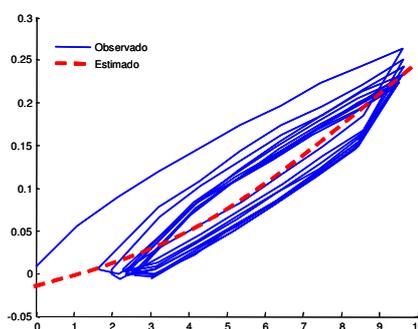
4.1.1 Backpropagation convencional sem realimentação

O interesse na aplicação da rede MLP na modelagem da histerese surgiu apenas da curiosidade de avaliar o desempenho de uma rede estática, sem a consideração temporal, requerida para este tipo de fenômeno. O desempenho da rede MLP foi observado através de uma amostra do conjunto de dados disponível. O treinamento

parou após 48 épocas pelo critério de early stopping com um RMSE = 0,036. Foram também realizados testes sem o conjunto de validação e não houve overtraining para o número de épocas estabelecido, entretanto, o treinamento foi mais longo.

Como era de se esperar, o modelo com o backpropagation convencional, sem a introdução das variáveis defasadas no tempo, se comporta como um modelo de regressão não linear, aproximando os pontos que compõem os caminhos de carga e descarga, por uma curva que passa entre os pontos minimizando os erros, conforme pode ser visto na Figura 7:

Figura 7 - Curvas tensão-deformação – observados x estimados pelo modelo backpropagation



4.1.2 Rede neural de atrasos de tempo (TDNN)

A camada de entrada da rede TDNN é composta da variável de entrada (deformação no tempo t) e por seus atrasos, espaçadas temporalmente em 1, isto é, em $t-1$, $t-2$, ..., $t-N$.

A TDNN aproxima uma função f dada pela equação :

$$\sigma(t) = f(\epsilon(t), \epsilon(t-1), \dots, \epsilon(t-N))$$

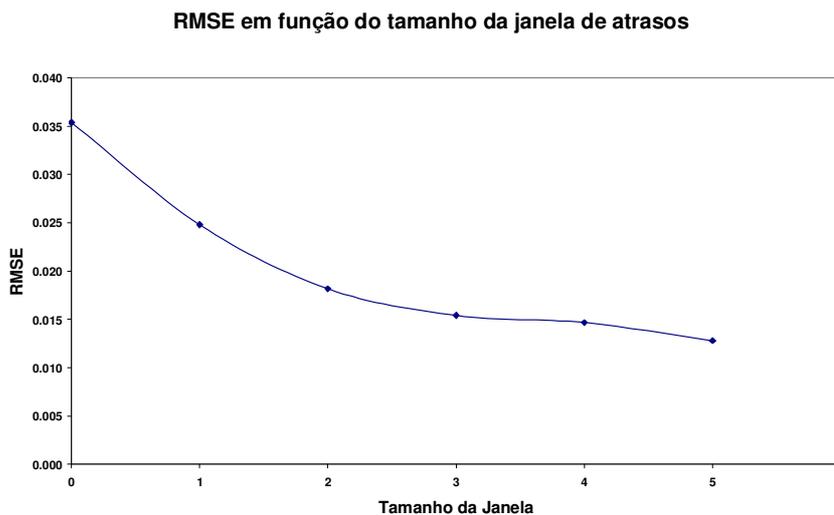
onde, $\epsilon(i)$: deformação no tempo $t = i$; $\sigma(t)$: tração no tempo t e N : tamanho da janela de tempo (sliding window).

O treinamento de uma TDNN, que atua em dados em seqüência (VOJTKO, 2004), é obtido através da alimentação da rede com uma janela de tamanho fixo das entradas para a rede, obtendo uma saída e fazendo o ajuste adequado dos pesos da rede. Este processo é repetido para mais uma janela, posicionada um passo adiante, até que todos os dados disponíveis tenham sido usados.

Em geral, a escolha do tamanho da janela influencia o desempenho das redes (HAYKIN, 2004). A metodologia adotada para descobrir o número de atrasos (lags) ótimo foi empírica, através de simulações, comparando o desempenho de cada modelo e escolhendo aquele com menor RMSE.

Diferentes janelas de tempo foram usadas para melhorar o desempenho do modelo, dado que não há uma forma sistemática de determinar quão longe um sistema deve olhar para trás a fim de prever o valor atual (T. Z. TAN *et al.*, 2005). A Figura 8 mostra que o desempenho da rede, em termos de RMSE, melhora significativamente com o aumento do tamanho da janela, até um ponto de estabilização.

Figura 8 - RMSE em função do tamanho da janela de atraso



O treinamento parou pelo critério early stopping com 68 épocas e RMSE do treinamento = 0.1163 e o RMSE do teste = 0.2355 . Sistemas cíclicos, como os que apresentam histerese, não são bem representados apenas pelo passado de suas entradas, mas sim pelo passado do par ordenado entrada-saída.

4.1.3 Redes Recorrentes NARX

Como foi visto na seção anterior, somente as entradas são defasadas nas redes TDNN. Entretanto, para modelagem da histerese é necessário usar o par (tensão-deformação) que compõe o estado do carregamento passado como parâmetro de entrada do modelo. Sendo assim, a rede não linear recorrente auto-regressiva com entradas exógenas, satisfazem esse requisito e será aqui investigada a sua aplicabilidade.

As redes NARX (Nonlinear Autoregressive with Exogenous Inputs) são redes não lineares autoregressivas, i.e., a variável de saída depende de seu passado e, por isso, também deve ser usada como entrada do sistema. Além disso, variáveis externas (exógenas) também fazem parte dos dados de entrada do modelo. Há dois tipos de arquitetura: paralelo e série-paralelo. Alguns autores denominam NARX como série-paralelo e NOE (Non-linear Output Error model) para o modelo paralelo.

As redes NARX tipo paralelo são aquelas cujas saídas do modelo são realimentadas como variáveis de entrada defasadas no tempo, juntamente com as variáveis de entrada externas. De outra forma, as redes série-paralelo usam a história das saídas, ou seja, os valores observados reais, para prever os valores futuros, ao invés dos valores estimados pelo próprio modelo, além claro das variáveis de entrada externas.

A rede NARX paralelo e série-paralelo são descritas pelas equações respectivamente:

$$\hat{\sigma}(t) = f(\varepsilon(t), [\varepsilon(t-1), \hat{\sigma}(t-1), \dots, [\varepsilon(t-N), \hat{\sigma}(t-N)])])$$

$$\hat{\sigma}(t) = f(\varepsilon(t), [\varepsilon(t-1), \sigma(t-1), \dots, [\varepsilon(t-N), \sigma(t-N)])])$$

onde $\sigma(t)$ é a aproximação de $\sigma(t)$.

Para determinar o número de atrasos de tempo e o número de neurônios da camada escondida foram adotados os mesmos procedimentos empregados para as redes TDNN. As análises concluíram o mesmo tamanho de memória, 5 atrasos, e o mesmo número de neurônios: 10.

As redes recorrentes série-paralelo, apresentam melhor desempenho e estabilidade uma vez que elas usam os dados de saída observados como entrada, não introduzindo o erro dos dados de saída estimados pela rede neural. Diferentemente, as redes recorrentes paralelo, ao introduzir esses erros, possuem um desempenho inferior e são propensas à instabilidade. A Tabela 5.1 ilustra a diferença de desempenho. Uma discussão mais detalhada sobre a convergência do modelo paralelo pode ser encontrada em (NARENDA & PARTHASARATHY, 1990) e um exemplo em (CALOBA, 2002). Por outro lado, o modelo paralelo traz a vantagem de ser capaz de captar a dinâmica do sistema em vez de simplesmente descobrir as regularidades ou periodicidades dominantes na série (VONZUBEN, 1996).

O outro aspecto diz respeito aos custos de aquisição dos dados de saída ao empregar o modelo série-paralelo em produção. Para as redes em produção é fundamental a escolha entre as redes paralelo e série-paralelo porque o uso de rede série-paralelo exige que os dados de saída sejam monitorados para servir de entrada. Custo esse que não existe quando é empregada a rede recorrente paralelo. Para efeito de treinamento, em ambos os casos será necessário a disponibilidade dos dados de saída, uma vez que ambos os modelos precisam desse dado para calcular o erro.

Uma outra forma de comparação é através do tempo de treinamento. As redes paralelo demandam muito mais tempo do que as redes série-paralelo. Por exemplo, para treinar o modelo série-paralelo com todos os ciclos levou-se em média 10 minutos, enquanto que para o modelo paralelo foram gastos 3600 minutos (ambos os casos rodados sob as mesmas configurações de hardware e software).

5. Análise e Resultados com Dados Reais Monitorados

Embora os dados de laboratório não tenham efeito dinâmico expressivo pelo fato de terem sido obtidos através de ensaios com carregamento cíclico quasi-estático, as estratégias empregadas para representar a histerese exibida pelo material podem ser as mesmas para representar a dinâmica do sistema devido à natureza do carregamento. Em ambos os casos as redes neurais mais adequadas são aqueles que representam memória (ou o tempo) através da inclusão de atrasos de tempo em sua estrutura. Logo, a metodologia empregada no item 4.1.3 serve para aplicação aos dados obtidos do sistema real em operação, em que a dinâmica e histerese estão presentes.

5.1 Definição das entradas e saídas e seleção dos dados para treinamento, validação e teste

Neste estudo, foram adotados como entrada os esforços momento em kN.m e tração em kN e como saída o deslocamento rotação em graus atuante na flexjoint, simplesmente por uma questão de lógica física mais comum, as forças como excitações e os deslocamentos como respostas. Ensaios comprovaram que a relação é reversível, ou seja, os deslocamentos tanto podem ser entrada quanto saída.

Como foi descrito na seção 3, os dados são compostos de seqüências no tempo, cada seqüência representando um estado de mar, correnteza e vento, separadas umas das outras por um intervalo constante de tempo, correspondente a 2,5 horas. Devido à limitação de memória, somente 11% dos dados foram selecionados do período aleatoriamente, tendo-se o cuidado de manter a representatividade do comportamento da flexjoint, com séries para treinamento e validação e séries para teste.

É importante observar que cada série é entendida como um comportamento único porque representa um estado de mar, que está associado ao período seguinte (pelo fato de ser o mar no mesmo local num momento posterior) mas que é independente estatisticamente deste. Por este motivo, não é problema para a solução do sistema a

apresentação ao modelo de séries em ordem aleatória, i.e. que não estejam na ordem em que foram observadas.

Outro aspecto é referente à representação da memória no modelo. Cada seqüência representa 30 minutos de cada 3 horas. E, como as redes dinâmicas trabalham com atrasos de tempo, o início de uma nova seqüência não tem como passado o final da seqüência anterior, já que as condições de carga (onda, vento e correnteza) são teoricamente outras após 2,5 horas. A princípio este problema acarretaria alguma queda de desempenho da rede devido ao ruído presente no início de cada seqüência. Porém, além dessa perturbação se dar somente no início, as seqüências são longas o suficiente para dissipar esse efeito. Fato este comprovado em análises efetuadas. Mesmo sabendo que o efeito se dissipa, optou-se por eliminar os primeiros registros (o número de registros eliminados é função do lag adotado no modelo) de cada série sendo estes apresentados ao modelo apenas como o passado para os primeiros registros efetivamente apresentados para a rede neural.

5.2 - Comparação dos modelos série-paralelo e paralelo

Nesta seção, são apresentados resultados de identificação do sistema dinâmico não linear flexjoint, através dos modelos escolhidos na seção 4, modelos NARX série-paralelo e paralelo. Os resultados dos testes com relação à estrutura das arquiteturas descritas acima são apresentados a seguir.

Os parâmetros de treinamento das redes foram: 24 unidades na camada de entrada; 10 unidades na camada escondida; 2 unidades na camada de saída; 104 padrões (séries) de treinamento; 600 épocas; função de ativação: sigmóide; número de atrasos de tempo (janela temporal) igual a 5; algoritmo de treinamento: Levenberg-Marquard; critério de overtraining: Early stopping; Software: MATLAB versão 2006Ra (funções `newnarxsp` e `newnarx`)

A Tabela 5.1, mostra os erros quadráticos médios (RMSE) de treinamento e teste de cada um dos modelos de redes neurais considerados.

Tabela 5.1 – Desempenho dos modelos serie paralelo e paralelo

	Variável Saída	RMSE Treinamento	RMSE Teste
Serie-Paralelo	Rotacao 0°	0.0238	0.0568
	Rotacao 90°	0.0289	0.0516
Paralelo	Rotacao 0°	0.1621	0.3803
	Rotacao 90°	0.2652	0.3663

Os resultados obtidos são ilustrados nas Figuras 9 e 10. Estes resultados representam os melhores resultados obtidos para cada estrutura após várias execuções, alterando os parâmetros associados a cada estrutura como taxas de aprendizado, valor inicial dos pesos, atrasos de tempo, o conjunto de treinamento e considerando o melhor desempenho para cada modelo.

Figura 9 – Observado x Estimado das series temporais da variável de saída e do momento x rotação (0° e 90°) – Modelo série-paralelo

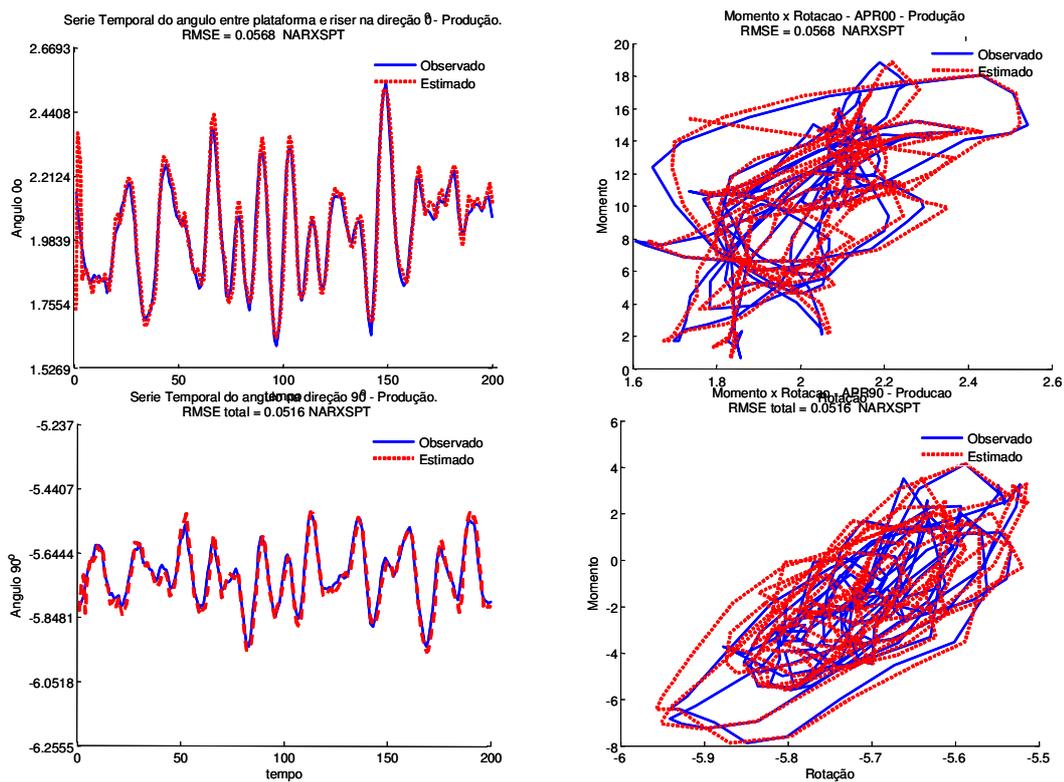
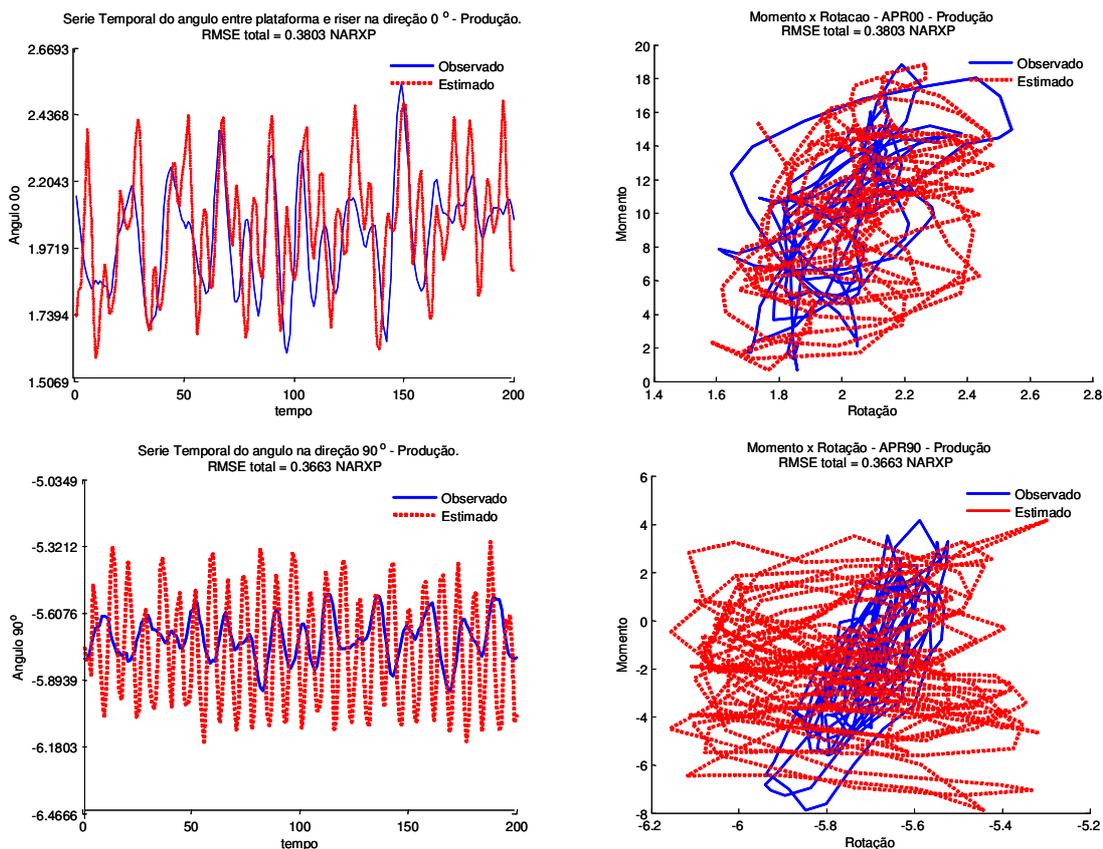


Figura 10 – Observado x Estimado das series temporais da variável de saída e do momento x rotação (0° e 90°) – Modelo paralelo



5.3 - Influência das variáveis externas nos modelos

Alguns testes foram realizados para avaliar a influência das variáveis externas (momento e tração) no comportamento do modelo através de re-análises utilizando a própria rede neural, retirando-se as variáveis externas do modelo e obtendo-se seu desempenho em termos de RMSE.

Tabela 5.2 – Resultado de análises com e sem variáveis externas

	Variáveis de Entrada	Variável Saída	RMSE Treinamento	RMSE Teste
Modelo I	Momento Traçao Rotação	Rotação 0°	0.0238	0.0568
		Rotação 90°	0.0289	0.0516
Modelo II	Rotação	Rotação 0°	0.0254	0.0453
		Rotação 90°	0.0266	0.0413

Como pode ser observado na Tabela 5.2, há pouca influência das variáveis externas. Assim como todas as análises realizadas neste estudo, estes resultados representam os melhores resultados obtidos após várias execuções. Esse resultado é

surpreendente devido ao conhecimento do fenômeno físico e da boa correlação entre as variáveis externas e as variáveis de saída.

Um das hipóteses levantadas para explicar a fraca contribuição das variáveis externas nos modelos série-paralelo foi a de que as seqüências poderiam ter sido amostradas com alta taxa de aquisição.

Para reduzir o número de pontos das seqüências sem deteriorar a qualidade do sinal, foi adotado o teorema desenvolvido por Shannon, que garante que se o critério de Niquist (MATLAB Help, 2006) for satisfeito, o sinal pode ser reconstruído sem qualquer perda de informação. Antes da decimação porém, foi passado um filtro passa-baixas, com a finalidade de eliminar as altas freqüências. A principal razão para essa filtragem é o fato de que o equipamento utilizado para medição das inclinações de topo não é capaz de capturar adequadamente as altas freqüências. Em função dessa observação, entendeu-se que o mapeamento dos esforços e rotação seria melhor representado na faixa de freqüência da onda, ou seja, em baixas freqüências (ROCHA,2007).

Foram realizadas novas análises e os modelos série-paralelo com variáveis externas e os com filtro (SP_CFD) apresentam melhores resultados que aqueles sem o filtro (SP_SF). Os RMSEs de teste são 0.0243 e 0.0568 respectivamente, para a variável de saída ângulo a 90°. Já os modelos com filtro (SF_CFD) e decimação (RMSE=0.0560) não apresentam diferenças significativas com relação aos modelos sem filtro (SF_SF) (RMSE=0.0568). Uma hipótese levantada é a da perda de qualidade do sinal com a decimação, apesar do ganho comprovado com a filtragem.

Todos os modelos sem as variáveis externas têm um desempenho levemente melhor que aqueles com as variáveis externas.

O desempenho dos modelos paralelo, treinado e testado paralelo, é significativamente inferior aos modelos série-paralelo. Aqui também a decimação parece ter piorado o desempenho do modelo. Para a variável externa ângulo a 0°, os RMSEs para os modelos P_CFD e P_SF são 0.6688 e 0.3803, respectivamente.

Tendo em vista que os erros do treinamento foram pequenos na arquitetura série-paralelo, esta pode ser convertida em paralelo e utilizada para predições a mais longo prazo. As arquiteturas série-paralelo empregadas neste estudo são para predições a “um-passo-a-frente”. Foram então gerados os modelos SP_P_CFD e SP_P_SF.

Os resultados são bastante estimuladores. Como mostra a Figura 11, apesar das discrepâncias, o modelo consegue acompanhar razoavelmente o comportamento do sistema até 2000 segundos (30 min) para a variável de saída ângulo a 0°. Entretanto, para a variável de saída ângulo a 90°, o desempenho não é tão bom, conforme pode ser visto através da Figura 12.

Uma possível explicação para essa diferença de desempenho pode ser o poder de explicação das variáveis. A variável de saída APR0 (ângulo na direção 0°) tem uma correlação com as variáveis externas (NUM0 e NUT) muito mais alta que a variável APR90 (ângulo na direção 90°) com suas correlatas (NUM90 e NUT).

Figura 11 - Observado versus Estimado das séries da variável saída APR0 para o modelo SP_P_CFD

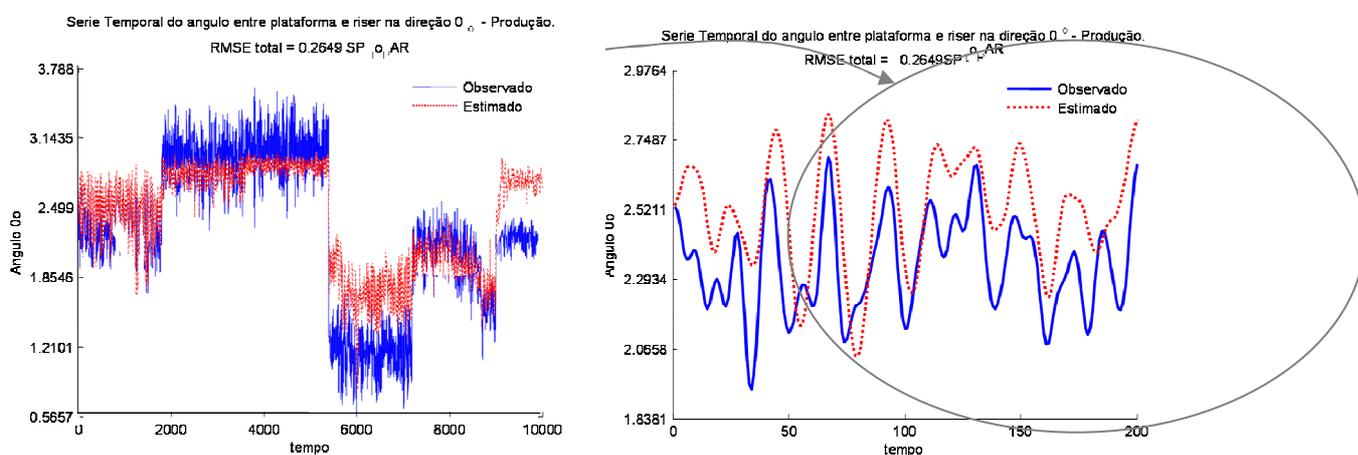
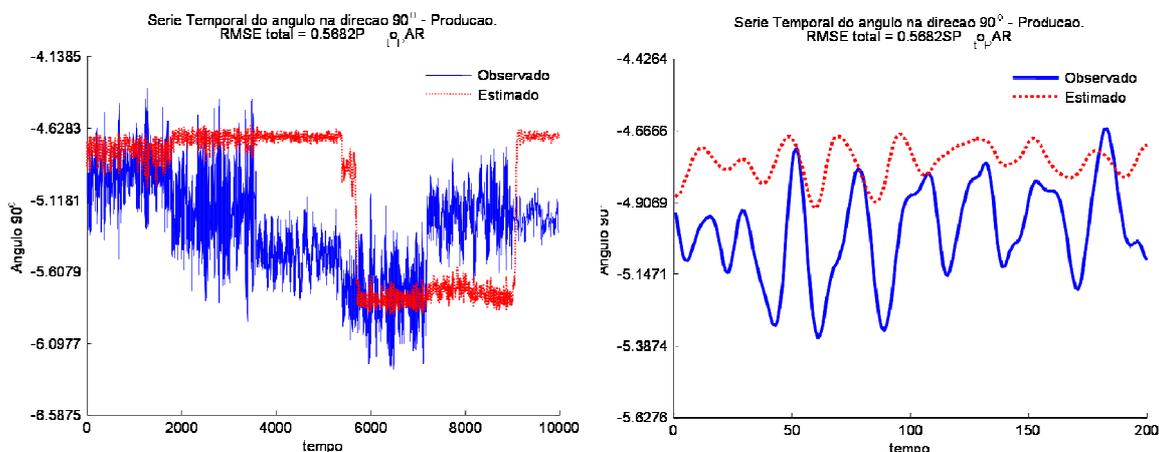


Figura 12 - Observado versus Estimado das séries da variável saída APR90 para o modelo SP_P_CFD



Os resultados para os modelos treinados em série-paralelo e testado com o paralelo sem o filtro, são inferiores aos modelos com filtro e decimação. A variável de saída APR0 tem um desempenho melhor que a APR90, comportamento semelhante aos do modelo com filtro.

5.4 Resumo

Dos resultados apresentados, pode-se dizer que as redes série-paralelo propostas mostraram-se mais eficientes no processo de identificação do sistema que as redes modelo paralelo. Contudo, conforme abordado na sessão anterior, a rede neural recorrente paralelo aproxima a dinâmica do sistema, ou seja, ela é capaz de descobrir as leis fundamentais que regem o comportamento do sistema, enquanto que, os modelos série-paralelo “descobrem” as regularidades ou periodicidades dominantes nas séries.

As redes treinadas através da arquitetura série-paralelo e convertidas em paralelo para a produção apresentaram resultados bastante promissores. O aumento da qualidade das variáveis pode melhorar sensivelmente este tipo de abordagem.

Outro aspecto importante como resultado das análises foi a investigação sobre a influência das variáveis externas. Tanto os dados de laboratório quanto os dados reais obtidos no processo de monitoração apresentaram o mesmo comportamento. Pode ser que esse problema tenha essa particularidade, ou seja, a resposta independe das variáveis externas. A resposta tem informação (memória) significativa para predizer seu próprio comportamento futuro.

6. Conclusões

Foi desenvolvido um modelo baseado em dados, empregando-se a técnica de redes neurais, objetivando a reprodução do comportamento histerético da junta de topo elastomérica, instalada no riser rígido de importação de gás da plataforma PXVIII da Petrobras.

A motivação do trabalho foi buscar um melhor conhecimento do comportamento da referida junta para verificar se a mesma estaria sofrendo alterações de suas características originais, com reflexos nos esforços do riser na região do topo.

O trabalho baseou-se em medições realizadas no riser, entre os anos de 1998 e 2002, com o objetivo de obter validações de metodologia e premissas de projeto do riser. Ou seja, na época do planejamento do sistema de monitoração, não existia a

intenção de que os dados fossem utilizadas futuramente para geração de um sistema de modelagem empírica das propriedades físicas do equipamento.

Uma situação ideal utilizaria ensaios em laboratório, sob condições controladas, que propiciariam uma calibração inicial do modelo. E permitiriam filtrar possíveis respostas espúrias ou mesmo erros dos equipamentos de campo, quando do ajuste do modelo frente aos dados reais. Este procedimento serviria inclusive como uma forma de auxiliar no processo de crítica aos dados de campo obtidos.

Apesar das dificuldades, da elevada quantidade de dados e da complexidade envolvida no problema, foi empreendida uma iniciativa pioneira na área de projeto e desenvolvimento de risers, procurando caracterizar o comportamento da junta de topo, investigando-se as várias possíveis correlações com parâmetros que não são considerados no projeto tradicional do equipamento.

A caracterização da independência do fenômeno em relação à frequência de excitação foi sugerida pelos resultados das análises realizadas, o que permitiu inferir que o elastômero instalado trabalha em níveis de deformação relativamente contidos. Esta informação é relevante na medida em que altos níveis de deformação poderiam precipitar um processo de degradação do elastômero (BURTSCHER *et al.*, 1998)

Um outro resultado relevante sobre o comportamento da junta mostra que não se pode avaliar a dependência do comportamento da mesma em relação às flutuações de tração. No projeto do riser, é assumida a hipótese de independência. A investigação realizada abordou a questão das altas frequências, ou seja, a faixa de resposta dinâmica associada a vibrações induzidas por vórtices. A resposta do modelo, eliminando-se as altas frequências, acima de 0,25 Hz, apresentou um ajuste sensivelmente melhor.

Ao se tentar investigar as causas junto aos responsáveis pela monitoração, concluiu-se que o equipamento utilizado para medição das inclinações de topo, não era capaz de capturar adequadamente altas frequências. A partir desta conclusão, uma nova especificação para os futuros equipamentos de medição de inclinações já se encontra em elaboração.

Em função dos referidos problemas, permanece a dúvida se o padrão de resposta da junta é alterado pelas vibrações de alta frequência do riser.

O modelo proposto, além de trazer informações relevantes para o projeto de risers e de sistemas de monitoração deverá ser utilizado em futuros trabalhos de monitoração do topo de risers rígidos.

7. Recomendações para Trabalhos Futuros

Uma primeira sugestão é que sejam registrados os valores de temperatura interna do fluido e pressão de operação. No caso do riser analisado dispunha-se destas informações em termos de valores médios, porém não havia registros temporais disponíveis que permitissem um tratamento rigoroso para investigação da influência destas variáveis.

As possibilidades de utilização do modelo podem ser associadas à monitoração da região de topo de risers ou às simulações realizadas dentro do projeto.

Na monitoração, uma das possibilidades é que o modelo seja instalado e passe por um período de aprendizado, no início da operação de uma junta nova de topo. Após a fase de aprendizado, ele passaria a funcionar como um preditor cujos resultados seriam comparados com os medidos. Os desvios entre resultados simulados e medidos, seriam considerados para avaliar se haveria alteração das características do equipamento. A fase de aprendizado mencionada poderia até mesmo incluir a etapa de testes de aceitação na fábrica.

Uma outra possibilidade é o emprego de 2 modelos: um para o aprendizado na fase inicial de operação do equipamento, conforme mencionado acima, e um outro adaptativo mantido em constante aprendizado. A avaliação da alteração no equipamento seria então feita através da comparação entre os modelos. O modelo adaptativo poderia também ser substituído por um modelo que seria treinado num período diferente do original, supondo-se as mesmas condições operacionais.

A rede neural, uma vez treinada para um determinado modelo de junta de topo, poderia ser acoplada ao simulador do comportamento global do riser, possibilitando assim uma representação mais realística do comportamento da junta no modelo utilizado em projeto.

Referências

BASHEER A., P.E., M.ASCE, Stress-Strain Behavior of Geomaterials in Loading Reversal Simulated by Time-Delay Neural Networks, ASCE - **Journal of Materials in Civil Engineering**, Vol.14 No.3 MAY-

JUNE 2002

BURTSCHER, S., DORFMAN, A., BERGMEISTER, K., 1998. Mechanical aspects of high damping rubber. 2nd. Int. **PhD Symposium in Civil Engineering**, Budapest.

CALÔBA, L. P. **Livro de Minicursos do XIV Congresso Brasileiro de Automática**, Natal, 2002. Introdução ao Uso de Redes Neurais na Modelagem de Sistemas Dinâmicos e Séries Temporais. COPPE & EP – UFRJ (caloba@ufrj.br).

ELMAN, J. L. Finding structure in time. **Cognitive Science**, 14(2):179-211, 1990.

G. W. ELLIS, C. YAO, R. ZHAO, AND D. PENUMADU, Stress-strain modeling of sands using artificial neural networks. **International Journal of Rock Mechanics and Mining Sciences and Geomechanics Abstracts**, Volume 33, Number 3, pp. 115A-115A(1), 1996.

HAYKIN, S. **Redes Neurais - Princípios e prática**; 2º edição; editora Bookman, 2004

MACHADO, R.Z.; MOURELLE, M.M.; FRANCISS, R.; SILVA, R.M.; LIMA, C.S.; EISEMBERG, R.; OLIVEIRA, D. ,Monitoring Program for the First Steel Catenary Riser Installed in a Moored Floating Platform in Deep Water , **OCEANS apos**;99 MTS/IEEE. Riding the Crest into the 21st Century Volume 2, Issue , Page(s):801 - 810 vol.2, 1999.

MATLAB HELP **Software**, version R2006A, 2006.

NARENDRA, K. & PARTHASARATHY, K. Identification and Control of Dynamical Systems using Neural Networks, **IEEE Transactions on Neural Networks** 1(1): 4-27, 1990.

ROCHA, Djalene Maria, **Redes Neurais para Modelagem de Sistemas Estruturais Offshore Dinâmicos não Lineares com Histerese**, (COPPE/UFRJ, D.Sc., Engenharia Civil, 2007.

SUDHEER, K. P., JAIN, S. K., Radial Basis Function Neural Network for Modeling Rating Curves, **J. Hydrologic Engrg.**, Volume 8, Issue 3, pp. 161-164, 2003.

T. Z. TAN , C. QUEK, G. S. NG, “Brain-inspired genetic complementary learning for stock market prediction”, **IEEE Congress of Evolutionary Computation**, Vol. 3, Edinburgh, Scotland, pp. 2653-2660, 2005

TAWFIK M, IBRAHIM A, FAHMY H. Hysteresis sensitive neural network for modeling rating curve. **ASCE J Comput Civil Engng**;11(3): 206-11.157, 1997.

VOJTKO, J. ,Neural Network, Component of Measuring Set for Error Reduction, **Measurement Science Review**, Volume 4, Section 1, 2004

VON ZUBEN, F.J, **Modelos Paramétricos e Não-Paramétricos de Redes Neurais Artificiais e Aplicações**, Faculdade de Engenharia Elétrica e de Computação (FEEC) - Unicamp), SP, Brasil, 1996.

NEURAL NETWORK MODELING OF NONLINEAR DYNAMIC STRUCTURAL OFFSHORE SYSTEM WITH HYSTERESIS

Abstract

This paper proposes an empirical modeling of the system formed by the riser-platform connection, in deep water. This connection has the objective of minimizing the acting bending moment, possesses high complexity and high-criticality due to economic and environmental consequences from its fault. The main element in the joint is made of elastomeric material, which reveals nonlinear hysteresis. In addition, this whole connection system presents nonlinearities due to the action of dynamic loading and large motions. TDNN and Recurrent Neural Networks (RNN) are being investigated since they possess the ability to model nonlinear hysteretic behaviors and also dynamic systems. Simulation results have confirmed that RNN is the one that presents the best representation of the system studied. Emphasis shall be given to the additional difficulties, which arise from the utilization of real data in the modeling process for this system.

Key-words: *Flexjoint, SCR , Recurrent Neural Networks, NARX, Hysteresi.*