

UTILIZAÇÃO DE REDES NEURAIIS NA AVALIAÇÃO DE FADIGA DE RISERS RÍGIDOS

João Paulo Ramos Cortina

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Civil, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Civil.

Orientador: Luis Volnei Sudati Sagrilo

Rio de Janeiro
Agosto de 2016

UTILIZAÇÃO DE REDES NEURAIS NA AVALIAÇÃO DE
FADIGA DE RISERS RÍGIDOS

João Paulo Ramos Cortina

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA
(COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE
EM CIÊNCIAS EM ENGENHARIA CIVIL.


Examinada por:




Prof. Luis Volnei Sudati Sagrilo, D.Sc.



Prof. Breno Pinheiro Jacob, D.Sc.



Dr. Marcelo Caire, D.Sc.



Dr. Fernando Jorge Mendes de Sousa, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

AGOSTO DE 2016

Cortina, João Paulo Ramos

Utilização de Redes Neurais na Avaliação de Fadiga de Risers Rígidos / João Paulo Ramos Cortina. – Rio de Janeiro: UFRJ/COPPE, 2016.

XII, 143 p.: il.; 29,7 cm.

Orientador: Luis Volnei Sudati Sagrilo

Dissertação (mestrado) – UFRJ/ COPPE/ Programa de Engenharia Civil, 2016.

Referências Bibliográficas: p. 97-100.

1. Redes neurais artificiais. 2. Risers rígidos. 3. Análise dinâmica estocástica. 4. Metodologias híbridas. 5. Estruturas offshore. I. Sagrilo, Luis Volnei Sudati. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Civil. III. Título.

Agradecimentos

Gostaria de agradecer ao meu orientador, Professor Luis Volnei Sudati Sagrilo, por sua orientação, paciência e recomendações ao longo deste trabalho.

A Marcelo Caire, por me apresentar ao instigante mundo *offshore* e pelo incentivo a cursar o mestrado no Programa de Engenharia Civil.

A toda equipe do Laboratório de Análise e Confiabilidade de Estruturas Offshore (LACEO), especialmente ao meu supervisor Fernando Jorge Mendes de Sousa por sempre estar solícito.

A Victor Viana Chaves pelas ideias trocadas quanto à aplicação das redes neurais.

Agradeço a toda a minha família, em especial meus pais João Luiz Cortina e Virginia Maria Ramos Cortina, minha irmã Natália Ramos Cortina e avó Carolina Abreu Ramos por todo amor, suporte, incentivo e motivação em todos os momentos. A todos os amigos que me acompanham desde muito tempo, pelos bons momentos e amizade.

A minha companheira, Paula do Sacramento Rocha, por todo amor e carinho, paciência e motivação, por trazer alegria a minha vida. Agradeço também a toda sua família.

Finalmente, a Deus pela vida e por tudo.

João Paulo Ramos Cortina

Agosto, 2016

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

UTILIZAÇÃO DE REDES NEURAIS NA AVALIAÇÃO DE FADIGA DE RISERS RÍGIDOS

João Paulo Ramos Cortina

Agosto/2016

Orientador: Luis Volnei Sudati Sagrilo

Programa: Engenharia Civil

Com cenários ambientais e operacionais cada vez mais hostis, o projeto de estruturas *offshore* requer progressivamente o uso de métodos numéricos sofisticados, capazes de representar as não-linearidades envolvidas na análise dinâmica. A combinação de modelos refinados, longas simulações estocásticas no domínio do tempo e análises de muitos cenários de carregamento ambiental resulta em elevado custo computacional, e muito tempo dispendido na etapa da verificação de fadiga, por exemplo. Recentemente metodologias híbridas que combinam a análise de elementos finitos (AEF) com redes neurais artificiais (RN) têm apresentado resultados promissores na redução do tempo computacional demandado, e mantendo acurácia adequada em relação à AEF.

Este trabalho apresenta a aplicação de um método híbrido AEF-RN em análises dinâmicas de *risers* metálicos para avaliação de fadiga. Dois *risers* são analisados: um numa configuração catenária (SCR) e outro em *lazy wave* (SLWR), sendo o primeiro conectado a uma plataforma semi-submersível e o outro a um FPSO. A partir de uma série temporal curta da resposta estrutural (trações e momentos) fornecida pela AEF, redes neurais são treinadas para prever o restante da resposta em função dos movimentos impostos pelo flutuante no topo da estrutura. Com os esforços globais preditos, a série temporal de tensão em vários pontos da seção transversal do duto é obtida, os ciclos de tensão são contados e os danos anuais finais são determinados. As regiões avaliadas são o topo e a *touch-down zone* (TDZ) do SCR e topo do SLWR.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

NEURAL NETWORKS APPLIED TO FATIGUE
ANALYSIS OF STEEL RISERS

João Paulo Ramos Cortina

August/2016

Advisor: Luis Volnei Sudati Sagrilo

Department: Civil Engineering

With increasingly harsh environmental and operational conditions, the design of offshore structures requires progressively use of sophisticated numerical methods, able to represent the nonlinearities involved in dynamic analysis. The combination of refined models, long stochastic simulations in time domain and analysis of many environmental loading cases results in high computational cost, and much time spent on the step of fatigue verification, for example. Recently, hybrid methodologies that combines the finite element analysis (FEA) with artificial neural networks (ANN) have presented promising results in reduction of computational time demanded, and maintaining adequate accuracy in relation to the FEA.

This work presents the application of a hybrid method FEA-ANN in dynamic analysis of steel risers for fatigue analysis. Two risers are evaluated: one in a catenary configuration (SCR) and another in a lazy wave (SLWR), the first is connected on a semi-submersible platform and the other on a FPSO. From a short time series structural response (tension and moments) obtained by FEA, neural networks are trained to predict the remaining response as a function of the prescribed movements imposed by the floater on the top of the structure. With the predicted global loads, the stress time series in several points of the pipe cross section are obtained, the stress cycles are counted and the final annual damages are determined. The regions analyzed are the top and the touch-down zone (TDZ) of the SCR and the top of the SLWR.

Índice

Introdução.....	1
1.1 Motivação.....	1
1.2 Objetivos	2
1.3 Revisão Bibliográfica.....	3
1.4 Organização do Estudo.....	4
 Redes Neurais Artificiais	6
2.1 Introdução	6
2.2 Breve Histórico	7
2.3 Componentes e Arquiteturas	8
2.3.1 Camadas	10
2.3.2 Funções de Ativação	12
2.3.3 Bias.....	13
2.4 Treino e Validação	14
2.4.1 Função Erro	15
2.4.2 Treinamento	16
2.4.3 Iniciação dos Pesos.....	17
2.4.4 Generalização e Validação.....	18
2.5 Redes Neurais e Sistemas Dinâmicos	21
2.5.1 Modelos NARX	21
2.5.2 Comentários sobre Redes Neurais NARX	23
2.6 Exemplo de Aplicação	24
 Análise de Fadiga de Risers Metálicos	30
3.1 Análise Global.....	30
3.1.1 Carregamentos Ambientais	31
3.1.2 Ondas Irregulares e Movimentos da Unidade Flutuante	33
3.1.3 Resposta Estrutural.....	37
3.2 Fadiga.....	39
3.3 Risers rígidos.....	43
3.3.1 Fadiga em Risers Rígidos.....	45
 Metodologia Híbrida.....	48

Estudos de Caso.....	53
5.1 Carregamentos Ambientais	55
5.2 Riser rígido em catenária – SCR.....	58
5.2.1 Modelo	58
5.2.2 Topo do SCR.....	59
5.2.3 TDZ do SCR	69
5.3 Riser rígido em configuração lazy wave – SLWR.....	82
5.3.1 Modelo	82
5.3.2 Topo do SLWR	84
5.4 Resumo dos Resultados.....	93
Conclusões e Trabalhos Futuros.....	95
Referências Bibliográficas	97
Anexo A - Estudos de Sensibilidade	101
Anexo B - Parâmetros Estatísticos Respostas Globais.....	119
Anexo C - Coeficientes de Correlação, Tensões.....	133

Lista de Figuras

Figura 1 – Modelo matemático de um nó.....	7
Figura 2 – Rede neural de três camadas feedforward.....	9
Figura 3 – Diagrama detalhado da rede neural.....	10
Figura 4 – Funções sigmoidais.....	13
Figura 5 – Exemplos de formas da tangente hiperbólica.....	14
Figura 6 – Superfície de erro.....	15
Figura 7 – Exemplo de super-ajuste, e extrapolação e generalização ruim.....	19
Figura 8 – Evolução dos erros médios de treino e validação.....	21
Figura 9 – Exemplo de arquitetura rede neural-NARX.....	22
Figura 10 – Representação do modelo físico do exemplo.....	24
Figura 11 – Espectro retangular equivalente.....	25
Figura 12 – Configuração da rede neural NARX.....	26
Figura 13 – Estudo de sensibilidade, nós na camada oculta.....	27
Figura 14 – Estudo de sensibilidade, atrasos das séries temporais.....	28
Figura 15 – Janela das séries temporais de resposta.....	29
Figura 16 – Espectros energéticos das respostas.....	29
Figura 17 – Caracterização de curto e longo prazo dos parâmetros ambientais.....	32
Figura 18 – (a) Representação do espectro de mar; (b) Geração de onda irregular.....	35
Figura 19 – Movimentos da unidade flutuante.....	36
Figura 20 – RAOs empregados nos estudos de caso.....	37
Figura 21 – Representação da análise global.....	38
Figura 22 – Curvas S-N: (a) linear; (b) bi-linear.....	40
Figura 23 – Tipos de lançamento: (a) J-Lay; (b) S-Lay; (c) Reel-Lay.....	43
Figura 24 – Configurações usuais para risers rígidos: (a) SCR; (b) SLWR.....	44
Figura 25 – Sistema referencial e seção transversal.....	46
Figura 26 – Relação custo computacional e complexidade de modelo (CHAVES, 2015).....	48
Figura 27 – Arquitetura da rede neural - NARX.....	49
Figura 28 – Representação da metodologia híbrida AEF-RN.....	51
Figura 29 – Representação da avaliação do Estudo de Caso.....	54
Figura 30 – Visão esquemático do modelo do SCR.....	58
Figura 31 – Estudo de sensibilidade de nós, caso de carregamento NN04.....	60
Figura 32 – Estudo de sensibilidade de atrasos, caso de carregamento NN04.....	61
Figura 33 – Exemplo de series temporais do treino, caso de carregamento SW07, topo do SCR.....	62
Figura 34 – Séries temporais da tração T, caso de carregamento NN10.....	63
Figura 35 – Séries temporais do momento My, caso de carregamento NN10.....	63
Figura 36 – Séries temporais do momento Mz, caso de carregamento NN10.....	64
Figura 37 – Valores estatísticos da tração T, casos com ondas da direção NW.....	64
Figura 38 – Valores estatísticos do momento My, casos com ondas da direção NW.....	65
Figura 39 – Valores estatísticos do momento Mz, casos com ondas da direção NW.....	65
Figura 40 – Tensão na superfície externa a 225°, caso de carregamento SE06.....	66
Figura 41 – Valores estatísticos de tensão, superfície externa a 270°, casos com ondas da direção SE.....	67
Figura 42 – Danos relativos, topo do SCR.....	68
Figura 43 – Estudo de sensibilidade de nós, caso de carregamento NE11.....	71
Figura 44 – Estudo de sensibilidade de atrasos, caso de carregamento NE11.....	72
Figura 45 – Séries temporais da tração T, caso de carregamento NN05.....	73
Figura 46 – Séries temporais do momento My, caso de carregamento NN05.....	73
Figura 47 – Valores estatísticos da tração T, casos com ondas da direção SW.....	74
Figura 48 – Valores estatísticos do momento My, casos com ondas da direção SW.....	74
Figura 49 – Tensão na superfície externa a 270°, caso de carregamento NE06.....	76
Figura 50 – Valores estatísticos de tensão, superfície externa à 270°, casos com ondas da direção SS.....	76
Figura 51 – Danos relativos, TDZ do SCR.....	77
Figura 52 – Danos anuais normalizados, superfície externa, TDZ do SCR.....	78
Figura 53 – Séries temporais de treino - redes modificadas, caso de carregamento NW04, TDZ do SCR.....	79
Figura 54 – Danos relativos - redes modificadas (Z^2), TDZ do SCR.....	81
Figura 55 – Visão esquemática do SLWR.....	83
Figura 56 – Estudo de sensibilidade de nós, caso de carregamento SW08.....	85
Figura 57 – Estudo de sensibilidade de atrasos, caso de carregamento SW08.....	86

Figura 58 – Séries temporais de tração T, caso de carregamento EE08	87
Figura 59 – Séries temporais do momento My, caso de carregamento EE08.....	87
Figura 60 – Séries temporais do momento Mz, caso de carregamento EE08.....	88
Figura 61 – Valores estatísticos da tração T, casos com ondas da direção SW	88
Figura 62 – Valores estatísticos do momento My, casos com ondas da direção SW	89
Figura 63 – Valores estatísticos do momento Mz, casos com ondas da direção SW	89
Figura 64 – Tensão na superfície externa a 315°, caso de carregamento WW06	91
Figura 65 – Valores estatísticos de tensão, superfície externa a 270°, casos com ondas da direção NE	91
Figura 66 – Danos relativos, topo do SLWR.....	92
Figura 67 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento NE02.....	101
Figura 68 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento NE02	101
Figura 69 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento NN04	102
Figura 70 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento NN04.....	102
Figura 71 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento SE06	103
Figura 72 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento SE06.....	103
Figura 73 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento SW03	104
Figura 74 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento SW03	104
Figura 75 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento WW07	105
Figura 76 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento WW07	105
Figura 77 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento EE11	106
Figura 78 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento EE11.....	106
Figura 79 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento EE10	107
Figura 80 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento EE10	107
Figura 81 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento NE11	108
Figura 82 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento NE11	108
Figura 83 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento NN05.....	109
Figura 84 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento NN05	109
Figura 85 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento NW04.....	110
Figura 86 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento NW04	110
Figura 87 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento SE03.....	111
Figura 88 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento SE03	111
Figura 89 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento WW08.....	112
Figura 90 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento WW08	112
Figura 91 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento EE11.....	113
Figura 92 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento EE11	113
Figura 93 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento NN04.....	114
Figura 94 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento NN04	114
Figura 95 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento NW06.....	115
Figura 96 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento NW06	115
Figura 97 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento SE05.....	116
Figura 98 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento SE05	116
Figura 99 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento SW08	117
Figura 100 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento SW08.....	117
Figura 101 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento WW11	118
Figura 102 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento WW11	118

Lista de Tabelas

Tabela 1 – Propriedades físicas do exemplo.....	25
Tabela 2 – Parâmetros da rede neural mantidos constantes.....	26
Tabela 3 – Parâmetros estatísticos comparados.....	28
Tabela 4 – Frequências relativas por direção de incidência	56
Tabela 5 – Frequências relativas dos estados de mar por direção de incidência	56
Tabela 6 – Diagrama de dispersão adotado	57
Tabela 7 – Perfil da corrente empregada	57
Tabela 8 – Propriedades do SCR	58
Tabela 9 – Malha de elementos finitos do SCR	59
Tabela 10 – Estudo de sensibilidade de nós, topo do SCR.....	59
Tabela 11 – Estudo de sensibilidade de atrasos, topo do SCR	61
Tabela 12 – Correlação entre respostas, casos com ondas da direção SW	66
Tabela 13 – Correlação tensão, casos com ondas da direção NN.....	67
Tabela 14 – Diferenças relativas AEF-RN, topo do SCR.....	68
Tabela 15 – Estudo de sensibilidade de nós, TDZ do SCR	70
Tabela 16 – Estudo de sensibilidade de atrasos, TDZ do SCR.....	71
Tabela 17 – Correlação entre respostas, casos com ondas da direção NW	75
Tabela 18 – Correlação tensão, casos com ondas da direção WW	77
Tabela 19 – Diferenças relativas AEF-RN, TDZ do SCR	77
Tabela 20 – Contribuição dos casos de carregamento ao dano total final, TDZ do SCR	78
Tabela 21 – Comparação das diferenças relativas entre redes, TDZ do SCR.....	80
Tabela 22 – Diferenças relativas AEF-RN - redes modificadas, TDZ do SCR.....	81
Tabela 23 – Contribuição dos casos de carregamento - redes modificadas, TDZ do SCR.....	82
Tabela 24 – Propriedades do SLWR	82
Tabela 25 – Malha de elementos finitos do SLWR	83
Tabela 26 – Perfil da corrente empregada, SLWR	84
Tabela 27 – Estudo de sensibilidade de nós, topo do SLWR	84
Tabela 28 – Estudo de sensibilidade de atrasos, topo do SLWR.....	85
Tabela 29 – Correlação entre respostas, casos com ondas da direção SE	90
Tabela 30 – Correlação tensão, casos com ondas da direção NN.....	92
Tabela 31 – Diferenças relativas AEF-RN, topo do SLWR	93
Tabela 32 – Resumo comparativo dos resultados.....	93
Tabela 33 – Parâmetros estatísticos, tração T, topo do SCR	119
Tabela 34 – Parâmetros estatísticos, momento My, topo do SCR.....	121
Tabela 35 – Parâmetros estatísticos, momento Mz, topo do SCR	123
Tabela 36 – Parâmetros estatísticos, tração T, TDZ do SCR.....	124
Tabela 37 – Parâmetros estatísticos, momento My, TDZ do SCR	126
Tabela 38 – Parâmetros estatísticos, tração T, topo do SLWR.....	128
Tabela 39 – Parâmetros estatísticos, momento My, topo do SLWR	129
Tabela 40 – Parâmetros estatísticos, momento Mz, topo do SLWR.....	131
Tabela 41 – Coeficientes de correlação, tensão superfície externa topo do SCR	133
Tabela 42 – Coeficientes de correlação, tensão superfície interna topo do SCR.....	135
Tabela 43 – Coeficientes de correlação, tensão superfície externa TDZ do SCR	136
Tabela 44 – Coeficientes de correlação, tensão superfície interna TDZ do SCR	138
Tabela 45 – Coeficientes de correlação, tensão superfície externa topo do SLWR.....	140
Tabela 46 – Coeficientes de correlação, tensão superfície interna topo do SLWR	141

NOMENCLATURA

AEF	Análise de Elementos Finitos
MEF	Método dos Elementos Finitos
RN	Redes Neurais Artificiais
AEF-RN	Metodologia Híbrida Análise de Elementos Finitos e Redes Neurais
NARX	<i>Nonlinear AutoRegressive model with eXogenous inputs</i>
MSE	<i>Mean Squared Error</i> (Erro Quadrático Médio)
T	Tração axial
My	Momento em torno do eixo local Y
Mz	Momento em torno do eixo local Z
SCR	<i>Steel Catenary Riser</i> (riser rígido em configuração de catenária livre)
SLWR	<i>Steel Lazy Wave Riser</i> (riser rígido em configuração <i>lazy wave</i>)
TDZ	<i>Touch-down zone</i> (região do <i>riser</i> que interage com o fundo marinho)
RAO	<i>Response Amplitude Operator</i>
Hs	Altura significativa de onda
Tz	Período de cruzamento zero de onda
Tp	Período de pico de onda
FPSO	<i>Floating Production, Storage and Offloading</i> (Unidade Flutuante de Produção, Armazenamento e Transferência)
LDA	Lâmina de água

Capítulo 1

Introdução

1.1 Motivação

Atualmente a indústria *offshore* é uma das maiores fontes de inovação tecnológica, solicitando soluções criativas, viáveis e de baixo custo. Na prática deste cenário, as estruturas marítimas (*risers*, linhas de ancoragem, umbilicais, etc.) estão sujeitas a ambientes cada vez mais hostis, sofrendo carregamentos devido a ondas, correntes e ventos. Novos projetos situam-se em profundidades cada vez maiores, superando lâminas de água de mais de 2 km, e alcançando reservatórios com elevados teores de contaminantes químicos e altas pressões.

O projeto de tais estruturas deve atender a critérios diversos: de instalação, operação, integridade física durante o tempo de operação, por exemplo. Muito esforço é empregado para otimizar e aprimorar os projetos, através da utilização de modelos numéricos mais realistas e sofisticados na análise dinâmica estocástica de tais estruturas. Em sua grande maioria, tais modelos são baseados no Método dos Elementos Finitos (MEF) e requerem a integração numérica de longas séries temporais de resposta estrutural a fim de se obter estimativas estatísticas fidedignas.

No caso de projeto de *risers* metálicos, a fadiga é um dos mais importantes e decisivos estados limite a ser verificado. Para análises de fadiga a descrição dos parâmetros ambientais de longo prazo resulta em uma grande quantidade de cenários ambientais, avaliados por análises de elementos finitos (AEF) dinâmicas individuais.

Combinando esta grande quantidade de análises dinâmicas com a necessidade de longas séries temporais de resposta, análises de fadiga resultam em alto custo computacional. Dentro da etapa de avaliação de fadiga do projeto a utilização de computadores se torna intensiva, e o tempo de realização das análises se eleva consideravelmente. Isto fica ainda mais crítico se forem consideradas etapas iniciais de projeto, onde muitas configurações estruturais são avaliadas até a seleção das mais adequadas ou eficientes.

Dependendo da lâmina de água, configuração geométrica estrutural, presença de propriedades físicas não-lineares, discretização da malha de elementos finitos e uso de

elementos não-lineares de pórtico espacial, uma única análise dinâmica estocástica de 3 horas pode facilmente demandar mais de 3 horas de processamento computacional.

Como a aquisição e manutenção de grandes servidores de processadores é uma solução onerosa para tal inconveniente, nos últimos anos surgiram diferentes métodos híbridos combinando a análise de elementos finitos (AEF) com técnicas de aprendizado de máquinas, especialmente as redes neurais artificiais (RN).

A ideia básica dos métodos híbridos que empregam redes neurais é utilizar sua marcante capacidade de aprendizado de padrões, generalização e predição na substituição da onerosa integração numérica da análise dinâmica por elementos finitos (AEF). Na maioria das aplicações deste gênero, as redes neurais são utilizadas para apreender a relação entre os movimentos impostos no topo da estrutura esbelta (*risers*, linhas de ancoragem) pela unidade flutuante com as respostas estruturais de interesse, e prever o restante da série temporal dos esforços.

1.2 Objetivos

Neste trabalho, visando aplicação na análise de fadiga, redes neurais são empregadas para apreender a relação entre os deslocamentos do topo com a resposta estrutural de *risers* rígidos em duas configurações distintas.

Na primeira configuração, o *riser* metálico está numa configuração de catenária livre, *Steel Catenary Riser – SCR*, e ligado à uma plataforma semi-submersível. Redes neurais são treinadas para prever as respostas estruturais da tração axial (T) e momentos em torno das direções locais (M_y e M_z) de duas seções transversais do *riser*: uma na região do topo e outra na região do TDZ (*touch-down zone*).

O outro exemplo é constituído de um *riser* metálico na configuração *lazy wave*, *Steel Lazy Wave Riser – SLWR*, conectado à uma unidade flutuante tipo FPSO, onde o mesmo procedimento é aplicado à uma seção na região do topo do duto.

Com os esforços das análises dinâmicas globais preditos pelas redes (metodologia híbrida AEF-RN), a tensão variável no tempo é avaliada para os pontos da seção transversal e o dano devido à fadiga é obtido pela contagem dos ciclos de tensão. Os danos são ponderados pela frequência relativa dos casos que compõe a distribuição de longo prazo ambiental e somados para a composição do dano anual total final. Por fim, os danos totais obtidos através do método híbrido AEF-RN são comparados com o

dano resultante das análises dinâmicas completas AEF e o custo computacional economizado é avaliado.

O método é denominado híbrido uma vez que as redes neurais precisam de amostras dos deslocamentos ou movimentos do topo e a respectiva resposta estrutural induzida. Essas amostras possuem a finalidade de servir como um exemplo para o treino da rede neural, para que a relação movimento-esforço seja aprendida pela rede. No presente trabalho os esforços globais utilizados para compor a amostra de treino são obtidos pela análise de elementos finitos AEF, por isso a metodologia é nomeada AEF-RN. Porém, em outras situações os dados para treino de redes neurais podem ser provenientes de experimentos, outros modelos numéricos ou medições em estruturas reais.

1.3 Revisão Bibliográfica

A primeira aplicação de redes neurais à análise dinâmica de estruturas marítimas foi realizada por GUARIZE (2004). A metodologia híbrida AEF-RN foi aplicada na predição da tração de topo de uma linha de ancoragem de um FPSO, obtendo resultados estimulantes, com redução de tempo computacional da ordem de 20 vezes. Posteriormente GUARIZE *et al.* (2007) utilizaram o mesmo método, predizendo a tração no topo de um SLWR e também o fator de utilização DNV-LRFD (DNV-OS-F201, 2010) na corcova inferior (*sag-bend*) do duto ligado a um FPSO. Em ambos trabalhos o modelo de rede neural utilizado considerava o efeito de memória dos movimentos, mas valores prévios da própria resposta não eram utilizados como entrada no modelo (modelo puramente exógeno).

Já nos trabalhos de MATOS (2005) e de PINA *et al.* (2013) métodos híbridos são apresentados empregando redes neurais com modelos dinâmicos auto-regressivos, ou seja, valores passados da resposta também alimentam o modelo. O primeiro trabalho apresenta modelos tipo *NARX* (*Nonlinear AutoRegressive model with eXogenous inputs*) nas formas polinomiais, racionais e implementados com redes neurais. Os esforços de tração e momento são avaliados pelo método para um SLWR no topo e corcova. Uma análise de extremos via amostra de máximos observados em realizações independentes também é avaliada com a metodologia para a tração no topo de uma linha de ancoragem. O segundo trabalho utiliza o modelo *NARX* com redes neurais para predizer a tração de topo em linhas de ancoragem e em um *riser* flexível. Em geral, rede neurais

aplicadas utilizando modelos *NARX* apresentam convergência mais rápida durante o treino e melhores previsões.

CHRISTIANSEN *et al.* (2013) apresentam a metodologia AEF-RN na previsão da tração de topo de uma linha de ancoragem e realizam análise de fadiga, apresentando uma nova alternativa para o treino das redes. Diferentemente dos trabalhos anteriores em que as redes neurais são treinadas para estados de mar individualmente, CHRISTIANSEN *et al.* (2013) treinam a rede para alguns estados de mar, e a resposta é predita para um diagrama de dispersão de ondas completo. O dano final apresenta boa concordância quando comparado com o dano obtido pelas análises de elementos finitos completas e a redução do tempo de análise é da ordem de 600 vezes.

Em CHRISTIANSEN *et al.* (2014) um estudo é conduzido com objetivo de identificar a contribuição e influência dos sinais de entrada da rede neural (movimentos impostos e atrasos, atrasos da própria resposta) na previsão da tração de topo de uma linha de ancoragem. Concluiu-se que alguns movimentos não são relevantes para a resposta, e podem até mesmo introduzir ruído e perturbação na rede.

CHAVES (2015) e CHAVES *et al.* (2015) aplicam uma metodologia similar à CHRISTIANSEN *et al.* (2013) na análise de fadiga no topo de um *riser* flexível ligado a um FPSO. São escolhidos três estados de mar para compor a amostra de treino das respostas estruturais (tração e curvaturas locais). O restante das séries temporais são preditas para os 11 estados de mar do diagrama de dispersão de cada direção, a partir das redes neurais treinadas com os 3 estados de mar. A redução do esforço computacional é da ordem de 40 vezes.

1.4 Organização do Estudo

Neste trabalho uma análise de fadiga simplificada é realizada para *risers* rígidos em duas configurações (SCR e SLWR) utilizando a metodologia híbrida AEF-RN. O treino é feito para cada estado de mar, conforme apresentado por GUARIZE *et al.* (2007) e PINA *et al.* (2013). Análises de sensibilidade a respeito da arquitetura das redes são realizadas para prover uma visão geral das configurações mais adequadas.

As redes são treinadas separadamente para as respostas estruturais: tração axial T , e momentos locais M_y e M_z . Para o SCR, são avaliados uma seção de um elemento na região do topo e outra no TDZ. Para o SLWR é analisada a região do topo. O objetivo é avaliar a relação acurácia e economia de tempo da metodologia AEF-RN com

relação a análise tradicional baseada em elementos finitos, para pontos nos dutos sujeitos a diferentes regimes dinâmicos e estruturas em diferentes configurações.

O trabalho foi dividido em 6 capítulos, sendo este primeiro o introdutório.

No Capítulo 2 as redes neurais artificiais são apresentadas. Uma breve introdução ao tema é realizada e a atual forma mais empregada de rede neural para sistemas dinâmicos é apresentada. O processo de treino das redes e comentários a respeito das adversidades (e soluções) mais comuns são feitos. O modelo *NARX* empregado em conjunto com as redes neurais é introduzido, e logo em seguida um exemplo simples de aplicação a um sistema dinâmico é estudado.

O Capítulo 3 contém os principais tópicos a respeito da análise dinâmica global de *risers*, carregamentos ambientais e caracterização ambiental de curto e longo prazo, geração de ondas irregulares, fadiga, curvas S-N, *risers* rígidos e a tradução dos esforços globais em tensões em um *riser* metálico é apresentada.

A metodologia híbrida AEF-RN empregada no trabalho é descrita no Capítulo 4.

Os estudos de caso para o SCR e o SWLR são conduzidos e os resultados apresentados e comentados no Capítulo 5.

Por fim, no Capítulo 6 são realizadas as conclusões e comentários finais, além de sugestões para estudos futuros.

Capítulo 2

Redes Neurais Artificiais

2.1 Introdução

Redes Neurais Artificiais constituem uma forma de processamento matemático de informação com arquitetura e funcionamento semelhante às redes neurais biológicas. A característica fundamental é, a partir do emprego de grande quantidade de elementos básicos conectados uns aos outros por transformações de sinais simples, obter grandes capacidades de aprendizado. O aprendizado pode ser entendido em meios práticos por previsões de séries temporais, reconhecimento de padrões, classificação e mapeamento de elementos, por exemplo.

Como apresentado em GUARIZE (2004), a associação entre o funcionamento de computadores e o cérebro humano é abordada por dois campos de estudo: o simbolista e o conexionista. A abordagem simbolista se baseia na solução de problemas através de processos lógicos, apresentados numa forma algorítmica sequencial.

No conexionismo, a solução de processos complexos baseia-se no modo de organização e operação do próprio modelo empregado, como por exemplo o cérebro humano. As principais características desses sistemas são a capacidade de aprendizado, generalização e adaptação. Tais características são frutos das conexões entre os elementos básicos do sistema. Para cada conexão há um peso para ponderação do sinal transmitido. O princípio básico da aprendizagem está no ajuste dos pesos das ligações mediante comparação com valores de referência.

Os elementos básicos destes sistemas são denominados nós (seu equivalente biológico é o neurônio). A Figura 1 apresenta o modelo matemático de um nó. Neste caso, ele recebe n sinais de entrada e um limiar, ou *bias*, ($x_{1...n}$ e b) ponderados pelos pesos das ligações ($w_{1...n}$ e w_b), efetua uma transformação $H(\)$ sobre a adição deles, liberando esse valor como resposta, num sinal de saída (y).




Figura 1 – Modelo matemático de um nó

Estabelecendo conexões dos sinais de saída de nós para entradas de outros nós, pode-se montar uma rede complexa e com organização semelhante ao cérebro biológico.

A capacidade de aprendizado, generalização e adaptação do sistema são originadas da arquitetura de funcionamento, das ponderações entre as conexões e do caráter excitatório ou inibitório dos sinais transmitidos.

O ajuste dos valores de ponderação da rede é denominado aprendizado e é feito na etapa de treino, como será visto mais à frente. As arquiteturas das redes, funções de ativação dos nós, pesos e *bias* são apresentados e discutidos no item 2.3, enquanto o próximo item apresenta um rápido histórico deste campo de estudo.

2.2 Breve Histórico

Os atuais estudos de redes neurais artificiais se originaram num campo denominado connexionismo, por volta da metade do Século XX (SMITH, 1993). Na década de 40, MCCULLOCH & PITTS (1943) apresentaram o primeiro modelo de um neurônio artificial e exploraram suas capacidades computacionais. Basicamente, o modelo de neurônio de *McCulloch-Pitts* emite um sinal de resposta resultante se o somatório dos sinais excitatórios de entrada excede seu valor limite característico e se ele não recebe nenhum valor inibitório de entrada. Este simples modelo suscitou questões de máquinas de estados limites e de elementos de decisão baseados em limiares.

ROSENBLATT (1960) e WIDROW & HOFF (1960) aprimoraram este modelo posteriormente, denominando os elementos adaptativos resultantes de *perceptron* e *adaline*, respectivamente. A maior contribuição destes trabalhos reside na

implementação de uma regra de aprendizado baseada na minimização do erro quadrático médio dos pesos. Esta regra foi denominada regra delta, fundamentada no método do gradiente de problemas gerais de otimização.

No final da década de 60 o tópico sofreu uma redução de interesse devido ao trabalho de MINSKY & PAPERT (1969), em que indicavam que, como o neurônio artificial isoladamente não conseguia resolver problemas de separação de variáveis não lineares e processar condições de “exclusivo-ou” (*XOR*), então *perceptrons* com várias camadas também não conseguiriam. Outro possível problema apontado seria que o algoritmo de otimização dos pesos não garantiria a convergência para sistemas com mais de uma camada de nós.

As redes neurais voltaram a ganhar atenção principalmente devido aos trabalhos de HOPFIELD (1982) e de WERBOS (1974), a partir do final dos anos 70 e início dos anos 80. O primeiro apresentou estudos sobre a relação de redes neurais recorrentes auto-associativas e sistemas físicos, enquanto o último desenvolveu o algoritmo de retropropagação (*backpropagation*), para o treinamento de redes com mais de uma camada. O algoritmo de retropropagação ainda foi aperfeiçoado mais apropriadamente no campo das redes neurais nos trabalhos de RUMELHART & MCCLELLAND (1986) e de LE CUN (1987). Estes desenvolvimentos e estudos superaram os possíveis problemas apontados por MINSKY & PAPERT (1969).

Na década seguinte, o entusiasmo com as possibilidades e capacidades das redes neurais artificiais era crescente, girando principalmente em torno do *perceptron* multicamadas (MLP). A obtenção de demonstrações da capacidade de aproximação universal do MLP alimentava a renovação neste campo de estudo.

Neste cenário, HORNIK (1993) e CYBENKO (1989), dentre outros, provaram ser possível qualquer mapeamento contínuo definido numa região compacta do espaço de aproximação. As condições para isto são uma quantidade adequada de nós na camada intermediária e emprego de funções de ativação respeitando certas propriedades de suavidade e continuidade.

2.3 Componentes e Arquiteturas

Os principais elementos de uma rede neural artificial são os nós, as ligações entre eles (e os pesos associados), os *bias* e as funções de ativação empregadas nos nós.

As formas como se dão as conexões entre os nós (arquitetura da rede) podem ser as mais diversas possíveis.

Apesar disso, neste trabalho opta-se por introduzir o estudo com uma rede neural de três camadas, alimentadas sempre para frente, *feedforward* (SMITH, 1993). Na Figura 2 tal rede é representada.




Figura 2 – Rede neural de três camadas *feedforward*

Ela é constituída por uma camada de entrada, uma camada intermediária, denominada camada oculta e uma camada de saída. Os nós da camada intermediária recebem sempre os sinais das saídas dos nós da camada de entrada e um sinal adicional provindo de um *bias* da camada de entrada, computam a soma dos sinais e aplicam uma função de ativação, liberando o sinal de saída para os nós da próxima camada, a de saída. Os nós da camada de saída repetem o mesmo procedimento e liberam os sinais finais da rede considerada.

No diagrama, cada linha representa um peso de ponderação e a conexão entre os nós, ou seja, para onde os valores ponderados são encaminhados. O elemento *bias* é fixo e geralmente possui valor unitário, sua importância será abordada no item 2.3.3.

2.3.1 Camadas

Geralmente, redes neurais empregadas para predições temporais de sistemas dinâmicos apresentam funções de transferências lineares nas camadas de entrada e de saída. A rede de três camadas apresentada anteriormente pode ser melhor compreendida através do seguinte diagrama, apresentado na Figura 3:




Figura 3 – Diagrama detalhado da rede neural

A rede representada na Figura 3 possui I dados de entrada, J nós na camada oculta e K nós (e saídas) na camada de saída.

Na camada de entrada, a rede neural recebe os valores de entrada x_i . Na camada oculta, cada nó recebe todos os valores da entrada ponderados com os respectivos pesos e o valor estático do *bias*, também ponderado pelo respectivo peso. Assim, um nó j na camada oculta recebe o valor u_j :

$$u_j = w_{0,j}^{IH} \cdot 1 + \sum_{i=1}^I (w_{i,j}^{IH} \cdot x_i) \quad (2.1)$$

onde $w_{i,j}^{IH}$ é o peso da conexão entre o sinal de entrada i e o nó da camada oculta j e $w_{0,j}^{IH}$ é o peso do bias da camada de entrada. Com o valor da soma ponderada (u_j), cada nó da camada oculta aplica uma função de ativação $g(\)$:

$$y_j = g(u_j) \quad (2.2)$$

onde y_j constitui a resposta do nó j da camada oculta.

De maneira análoga, cada nó na camada de resposta recebe a soma ponderada v_k :

$$v_k = w_{0,k}^{HO} \cdot 1 + \sum_{j=1}^J (w_{j,k}^{HO} \cdot y_j) \quad (2.3)$$

onde $w_{j,k}^{HO}$ é o peso relativo à conexão proveniente do nó da camada oculta j para o nó da camada de saída k e $w_{0,k}^{HO}$ é o peso relativo ao *bias* da camada oculta. Por fim, os nós da camada de saída aplicam, também, uma função de ativação sobre a soma e liberam o valor final como saída da rede neural (z_k):

$$z_k = h(v_k) \quad (2.4)$$

Em geral, esta função de ativação da camada de saída é linear, ou seja: $h(v_k) = 1 \cdot v_k$. O mesmo ocorre para a camada de entrada, onde as funções de ativação são lineares e os nós operam somente transmitindo os mesmos valores de entrada. Por isso, no diagrama da Figura 3 os nós da camada de entrada têm sua representação omitida, para melhor compreensão das transformações internas da rede.

Nota-se que a resposta de saída z_k é definida por:

$$z_k = h \left(w_{0,k}^{HO} \cdot 1 + \sum_{j=1}^J \left(w_{j,k}^{HO} \cdot g \left(w_{0,j}^{IH} \cdot 1 + \sum_{i=1}^I (w_{i,j}^{IH} \cdot x_i) \right) \right) \right) \quad (2.5)$$

Generalizando, a rede neural opera como uma função matemática $f(\cdot)$:

$$z = f(W, x) \quad (2.6)$$

ou seja, o vetor de saída/resposta da rede, z , é determinado em função da matriz que contém o valor de todos os pesos das ligações, W , e do vetor com os valores de entrada da rede, x .

2.3.2 Funções de Ativação

As funções de ativação exercem papel significativo no funcionamento das redes neurais. Elas sempre estão associadas a um nó e o resultado de sua aplicação é o valor de saída do nó. Seu principal objetivo é introduzir um mapeamento não-linear e fazer com que o sinal de saída dos nós esteja sempre dentro de um intervalo definido de valores.

Também chamadas de funções sigmoidais, devido ao seu formato de S achatado, as funções de ativação devem possuir certas características. Devem ser limitadas (valores máximos e mínimos não devem exceder limite superior nem serem menores que o limite inferior); devem ser monotonicamente crescentes; devem ser contínuas e diferenciáveis em todo seu domínio.

As funções de ativação mais empregadas são a função logística e a tangente hiperbólica. A função logística está definida por:

$$g_{Log}(u) \equiv \frac{1}{1+e^{-u}} \quad (2.7)$$

onde sua imagem está contida num intervalo de 0 a 1. A função tangente hiperbólica é expressa por:

$$\tanh(u) \equiv \frac{e^u - e^{-u}}{e^u + e^{-u}} \quad (2.8)$$

em que os valores de saída estão contidos de -1 a 1. O gráfico de ambas as funções é apresentado na Figura 4, onde pode ser observado o cumprimento das exigências anteriormente mencionadas.




Figura 4 – Funções sigmóides

Devido à natureza dos limites da função logística (0 a 1), normalmente ela é utilizada em aplicações para reconhecimento de padrões. A tangente hiperbólica é comumente empregada em previsões de séries temporais, e atinge seus limites mais rápido que a logística.

2.3.3 Bias

O *bias* está intimamente ligado à função de ativação do nó. Sua função é efetuar uma translação da função de ativação para a direita ou esquerda do zero. Desta forma ele permite que a função retorne valor nulo para valores mais elevados ou menores que o da função original.

Ele pode ser entendido como um nó que não está conectado à nenhuma camada da rede anterior. Possuindo um valor fixo (geralmente unitário), ele se liga a todos os nós de uma camada (Figura 3), possuindo pesos associados.

A influência do *bias* e de seus pesos sobre a função de ativação pode ser exemplificado considerando a seguinte função tangente hiperbólica:

$$\tanh(a_0 \cdot 1 + a_1 u) \quad (2.9)$$

onde a_0 representa o peso do *bias* unitário e a_1 um valor do peso de ponderação sobre a variável u (a_0 e a_1 constituem os coeficientes da função de mapeamento). A Figura 5

apresenta as formas que a função assume para alguns valores do peso do *bias* e do peso de ponderação sobre u .




Figura 5 – Exemplos de formas da tangente hiperbólica

De forma geral, o valor do bias translada a função para a direita ou esquerda do zero, enquanto o valor do peso altera a declividade da função (podendo inclusive espelhá-la em torno do eixo vertical, $a_1 < 0$).

Deste modo, a combinação dos pesos e bias auxilia a representação de uma variedade maior de funções, aumentando a flexibilidade de um nó. Combinando uma quantidade de nós numa rede pode-se alcançar o mapeamento de funções mais complexas. O poder de aproximação e de mapeamento não linear das redes neurais provêm do uso de tais funções, combinações entre elas e dos pesos de ponderação.

2.4 Treino e Validação

A expressão (2.6) representa matematicamente o que denota-se por mapeamento da rede neural. De posse dos valores dos pesos das conexões, a rede neural pode aproximar funções de diferentes aspectos e formas.

O treinamento de uma rede neural consiste na busca pelos valores dos pesos que propiciam o melhor ajuste entre a função de mapeamento $f(\mathbf{W}, \mathbf{x})$ e os exemplos da função que deseja ser aproximada.

A calibração dos pesos consiste de: partindo de um conjunto de valores de pesos iniciais, comparar a diferença do mapeamento da rede com os valores de referência da

função a ser modelada e alterar os valores dos pesos, num processo iterativo de otimização.

2.4.1 Função Erro

A diferença entre o mapeamento da rede neural e o valor da função mapeada pode ser mensurado por uma função erro. A mais comum utilizada em aplicações de redes neurais a sistemas dinâmicos é a função erro quadrático médio (MSE, *mean squared error*), definida por:

$$E(\mathbf{W}) = \frac{\frac{1}{2} \sum_{n=1}^N \sum_{k=1}^K (z_{k,n}(\mathbf{W}) - t_{k,n})^2}{NK} \quad (2.10)$$

onde N é a quantidade de amostras de referência da função mapeada, K é a quantidade de saídas da rede neural, $z_{k,n}$ é o valor de mapeamento obtido pela rede ($z_{k,n} = f_k(\mathbf{W}, \mathbf{x}_n)$) e $t_{k,n}$ é o respectivo valor de referência, o valor da função a ser modelada.

Uma forma de entender o comportamento da função erro é considerá-la definida para um conjunto de dois pesos. Estes dois pesos formam um domínio bidimensional e considerando uma terceira dimensão representando o erro sobre o domínio (altura), têm-se uma situação próxima à representada na Figura 6:




Figura 6 – Superfície de erro

Na representação, têm-se o que é comumente denominado superfície de erro. Os valores dos pares dos pesos mais adequados são aqueles que resultam no menor erro, graficamente o ponto onde a superfície possui menor altura. Porém frequentemente há muitos mínimos locais e um mínimo global, onde o erro quadrático médio será o absolutamente menor.

Quando a quantidade de pesos aumenta, a superfície do erro não pode ser visualizada, porém ela apresenta comportamento semelhante ao observado na figura anterior.

2.4.2 Treinamento

A busca por um conjunto de valores para os pesos que minimize o erro pode ser feita por um algoritmo de otimização. O algoritmo mais simples empregado é o do gradiente descendente. A ideia é, a partir de um conjunto de valores iniciais do peso, alterar os valores dos pesos na direção em que a superfície da função erro decresce mais rapidamente.

Em termos matemáticos:

$$\mathbf{W}_i = \mathbf{W}_{i-1} - \eta \frac{\partial E(\mathbf{W})}{\partial \mathbf{W}} \quad (2.11)$$

onde i denota a etapa do processo iterativo, ou também chamado época de treinamento ($i=0$ representa o conjunto inicial de pesos), η é o parâmetro denominado taxa de aprendizagem e, por último, têm-se a derivada da função erro em relação aos pesos.

A taxa de aprendizagem pode ser fixa por todo o treinamento, ou pode ter seu valor adaptável. Em algoritmos com a taxa de aprendizagem adaptável, normalmente seu valor é elevado quando o erro é diminuído em relação à época anterior, ou reduzido se o erro aumenta (CHRISTIANSEN *et al.*, 2013).

As expressões analíticas para as derivadas da função erro em relação aos pesos podem ser encontradas em SMITH (1993) e HAYKIN (2005).

O algoritmo de treinamento empregado neste trabalho é o método de *Levenberg-Marquardt*, disponível no *Neural Network Toolbox* do *Matlab R2014a*®. Ele baseia-se numa modificação do algoritmo de *Newton*, aperfeiçoado para minimizar funções que são somas quadráticas de outras funções não lineares e eficiente quando se utiliza a função erro médio quadrático (HAGAN *et al.*, ISBN 0-9717321-0-8). Por sua

vez, o método de *Newton* é uma modificação do método do gradiente descendente cuja principal diferença é que o de *Newton* se baseia numa expansão de *Taylor* de segunda ordem da função erro sobre os pesos, enquanto o gradiente descendente se baseia numa expansão de primeira ordem.

Uma boa apresentação destes algoritmos de otimização para redes neurais é encontrada em HAGAN *et al.* (ISBN 0-9717321-0-8).

2.4.3 Iniciação dos Pesos

Todos os algoritmos de treino de redes partem de um conjunto inicial de valores de pesos, de um ponto da superfície de erro. Com a arquitetura da rede definida, o ponto de partida ideal seria o mais próximo possível dos valores ótimos de peso, porém na maior parte das aplicações não há conhecimento prévio sobre tal conjunto de valores. Apesar disso há uma série de técnicas disponíveis para definir um ponto de partida adequado.

A maioria destas técnicas são orientadas a tornar o treino o mais rápido possível. Para isso, é desejável iniciar com valores que façam a soma ponderada de entrada de cada nó ser próxima de zero. Deste modo o valor da função de ativação fica próximo da metade do seu intervalo máximo (Figura 4). Tal procedimento é adequado, uma vez que não conhecendo o comportamento dos valores mapeados, o valor médio é um bom ponto de partida. Outro ponto favorável é que evita-se a saturação das funções de ativação no início do treino. A saturação resulta em derivadas de erro de baixa magnitude, pequenas mudanças nos valores dos pesos e consequentemente maior quantidade de épocas necessárias ao treino.

Uma proposta simples de iniciação seguindo os princípios anteriores é apresentada por SMITH (1993):

- Nós da camada oculta: Pesos são iniciados com valores aleatórios pequenos, distribuídos uniformemente em torno de zero;
- Nós da camada de saída: iniciar metade do conjunto de pesos dos nós de saída com valores de 1, e a outra metade com valores de -1.

Outros métodos mais refinados estão disponíveis. O presente trabalho utiliza o método de *Nguyen-Windrow* (NGUYEN & WIDROW, 1990). Sucintamente: este

algoritmo usa a forma da função sigmoidal e os limites dos valores de entrada para determinar os valores dos pesos e, então, usa os *bias* para centralizar as funções sigmoidais na região ativa (longe da saturação).

Até agora muito foi apresentado sobre o treinamento, mas ainda não discutiu-se o critério de parada de treino. Isto será realizado no próximo item.

2.4.4 Generalização e Validação

Até aqui o objetivo do treino de redes neurais foi sempre minimizar o erro médio para a amostra de treino. Porém, o objetivo final da rede é que ela seja capaz de prever valores para novas entradas (não utilizadas no treinamento) com fidelidade à função que se deseja aproximar. Ou seja, a etapa de treino tem como finalidade fazer com que a rede neural aprenda a relação global entre entrada e resposta do sistema modelado. Isso é chamado de generalização.

O principal problema que ocorre durante o treinamento, prejudicando a generalização da rede, é o super-ajuste (*overfitting*). Quando a rede aprende em demasia os exemplos de entrada ela pode “memorizar” a relação específica da amostra de treino. Deste modo ela apreenderá características particulares da amostra, deixando de capturar os efeitos globais da função modelada. Quando a rede é aplicada a novas entradas, sua resposta diverge da função modelada. Um exemplo prático dessa situação é quando a amostra possui ruído proveniente do processo de obtenção da mesma.

A Figura 7 ilustra tal inconveniente. A curva em azul representa a função que se deseja aproximar e as cruzes representam os pontos de treino, com ruído. A curva em vermelho representa a resposta da rede neural treinada e os círculos representam a resposta da rede para os pontos de treino. Pode ser observado que a resposta da rede neural corresponde exatamente à função aproximada nos pontos de treino. Entretanto, ela falha em aproximar a função modelada nos demais pontos. Esta falha é ocasionada pelo super-ajuste que ocorre à esquerda da linha vertical tracejada, na região onde se encontra o conjunto de pontos da amostra de treino.

À direita da linha tracejada a rede neural também falha em sua aproximação, mas não devido ao super-ajuste, e sim porque não há amostras de treino ali. A rede realiza uma extrapolação além do domínio de treino. A única forma de prevenir extrapolação incorreta é garantir que a amostra de treino cubra todas as regiões do domínio de entrada. Considerando, por exemplo um sistema dinâmico, a forma de

garantir adequada extrapolação é assegurar que a amostra de treino possua tamanho adequado e seja representativa da relação entre excitação e resposta.




Figura 7 – Exemplo de super-ajuste, e extrapolação e generalização ruim

De maneira geral, a generalização é influenciada pelos seguintes fatores:

- Tamanho e representatividade amostral do treino. A amostra de treino deve possuir tamanho adequado, de tal forma que várias características do sistema estejam presentes. Isso pode ser avaliado através da comparação dos parâmetros estatísticos amostrais com os esperados para a função modelada (se disponíveis), comparação do espectro de resposta na frequência, etc.
- Arquitetura da rede neural. O emprego de muitos nós na camada oculta, ou muitos atrasos no modelo (será visto no item 2.5), representa uma rede com muitos pesos e com elevado poder de aproximação. Se o sistema modelado apresentar uma complexidade inferior à capacidade da rede, provavelmente haverá um super-ajuste sobre a amostra de treino. Uma forma de avaliar isso é comparar a quantidade de pesos totais da rede com a quantidade de amostras de treino. Outro meio é realizar análises de sensibilidade sobre o erro de validação para algumas arquiteturas selecionadas (isto será visto mais a frente).
- Complexidade do sistema modelado: é necessário que haja uma mínima relação mapeável entre as entradas e a resposta do sistema modelado.

Isto está relacionado com a modelagem do sistema: o que é definido como excitação e o que é definido como resposta. Podem ocorrer situações em que alguns dos sinais de entrada sejam irrelevantes para a resposta (CHRISTIANSEN *et al.*, 2014) ou ainda situações em que as excitações principais do sistema não sejam conhecidas pela própria complexidade do sistema (sistemas econômicos muito sensíveis a vários fatores, por exemplo). Uma forma de mensurar isso seria observar os parâmetros estatísticos da amostra de entrada e de resposta (iniciando pelo coeficiente de correlação, por exemplo).

Uma forma de prevenir o super-ajuste é o emprego de uma metodologia prática, simples e muito comum chamada validação cruzada. Ela está baseada na limitação da quantidade de épocas de treino.

A validação é uma forma de estimar o erro de generalização da rede. Ela é empregada separando uma parte da amostra disponível exclusivamente para o treino e outra exclusivamente para a validação da rede. Os pesos da rede são ajustados utilizando os valores da amostra de treino e o erro médio do treino é avaliado sobre essa amostra. Após cada época, a rede com os pesos atualizados é aplicada sobre a amostra de validação e o erro médio é computado, sendo denominado erro médio de validação. A amostra de validação não é utilizada no ajuste dos pesos, isto é, no treino da rede. A Figura 8 apresenta tipicamente a evolução dos erros médios de treino e validação com o avanço das épocas de treino.

Ambos os erros médios começam sua trajetória descendente, mas após determinada época o erro médio de validação começa a se elevar, enquanto o erro médio de treino segue sua trajetória descendente. Este ponto representa o conjunto ótimo de pesos da rede, uma vez que a partir dele a rede perde sua capacidade de generalização e o super-ajuste se inicia. Este seria o ponto ideal para parar o processo de treino da rede.




Figura 8 – Evolução dos erros médios de treino e validação

Assim, o processo de aprendizado completo é composto pelo treino da rede sobre uma parte da amostra (atualização dos pesos) e a aplicação da rede sobre a outra parte para avaliação da generalização da rede (validação).

2.5 Redes Neurais e Sistemas Dinâmicos

Como visto anteriormente, redes neurais possuem grande poder de aproximar funções. Esta capacidade pode ser empregada para aproximar respostas de sistemas dinâmicos, em previsões de séries temporais. O presente item apresenta as formas de aplicações de redes neurais na modelagem de sistemas dinâmicos, iniciando pela apresentação de modelos *NARX*.

2.5.1 Modelos *NARX*

A principal característica de um sistema dinâmico é a importância dos efeitos de memória, oriundos das inércias e amortecimentos presentes no sistema. A resposta em um instante de tempo depende das excitações naquele momento, da história passada da excitação e da própria resposta.

Um dos modelos mais utilizados na representação de sistemas dinâmicos é o *Nonlinear AutoRegressive model with eXogenous inputs* – *NARX* (CHEN & BILLINGS, 1989). Este modelo baseia-se no uso de polinômios que incluem termos lineares e não-

lineares e na combinação dos sinais de excitação e seus atrasos (*eXogenous*) e dos atrasos da própria resposta (*AutoRegressive*).

Considerando um sistema hipotético composto por duas entradas $x_1(t)$ e $x_2(t)$, e uma resposta $z(t)$, o modelo *NARX* assume que a resposta $z(t)$ pode ser expressa como:

$$z(t) = f\{ x_1(t), x_1(t-\Delta t), \dots, x_1(t-N_{x_1}\Delta t), \\ x_2(t), x_2(t-\Delta t), \dots, x_2(t-N_{x_2}\Delta t), \\ z(t-\Delta t), \dots, z(t-N_z\Delta t) \} \quad (2.12)$$

onde Δt é o intervalo de amostragem temporal, N_{x_1} , N_{x_2} e N_z são as quantidades de atrasos associados aos dois sinais de entrada e a própria resposta, respectivamente.

Em vez de utilizar a forma *NARX* polinomial (MATOS, 2005), a arquitetura da expressão (2.12) anterior pode ser aplicada numa rede neural, onde a relação expressa pela função $f(\cdot)$ será aprendida e determinada através do treinamento. A Figura 9 apresenta a arquitetura da rede neural implementada com o modelo *NARX*.




Figura 9 – Exemplo de arquitetura rede neural-NARX

Redes neurais *NARX* são cada vez mais utilizadas em modelagem de sistemas dinâmicos, devido aos bons resultados alcançados (PINA, *et al.*, 2013; MATOS, 2005).

2.5.2 Comentários sobre Redes Neurais NARX

Ao longo dos trabalhos desenvolvidos empregando redes neurais *NARX*, alguns métodos e práticas que propiciam boas predições foram se tornando comuns. Neste item, é realizada uma rápida passagem sobre tais práticas e comentários gerais são realizados.

Como apresentado no item 2.4, durante o treino é desejável valores pequenos de pesos para que as derivadas dos erros sejam elevadas e o treino seja mais rápido. Porém, se os valores das entradas da rede possuírem grandes magnitudes, as funções de ativação apresentam saturação inicialmente, elevando o tempo de treino. A fim de diminuir os valores de entrada, uma opção geralmente empregada é fazer um ajuste para que os valores da amostra de treino permaneçam dentro de um intervalo de valores máximo e mínimo. Isto pode ser feito da seguinte forma:

$$y(t) = \frac{y_{max} - y_{min}}{x_{max} - x_{min}} (x(t) - x_{min}) + y_{min} \quad (2.13)$$

onde $x(t)$ é a série original, x_{max} e x_{min} são os seus valores máximos e mínimos amostrais; $y(t)$ é a série alterada, y_{max} e y_{min} são os valores máximos e mínimos definidos como os limites desejados. Normalmente, esses limites são definidos em 1 e -1.

Uma outra opção de tratamento das séries temporais antes do treino é a normalização:

$$y(t) = \frac{x(t) - \mu_x}{\sigma_x} \quad (2.14)$$

em que: $y(t)$ é a série normalizada, $x(t)$ é a série original, μ_x é a média da série original e σ_x o seu desvio padrão. A normalização melhora o treino e aprendizado da rede neural (MATHWORKS, 2014), e foi empregada neste trabalho. É preciso ter em mente que os valores amostrais da resposta (saída) também devem ser normalizados durante o treino. E na aplicação da rede as novas séries de entrada também devem ser normalizadas, utilizando os mesmos parâmetros estatísticos do treino. A resposta da

rede também estará normalizada e para interpretação deve sofrer o tratamento inverso, invertendo-se a expressão (2.14).

Como um último comentário, é possível a necessidade da repetição do treino em alguns casos. A superfície de erro de redes neurais para sistemas dinâmicos apresenta alta complexidade, com a presença de muitos mínimos locais (HORN *et al.*, 2009). O caráter aleatório da iniciação dos pesos faz com que cada vez o treino seja iniciado de um ponto diferente da superfície de erro. Deste modo, o algoritmo de otimização dos pesos percorre um caminho diferente que pode terminar num mínimo local que não seja adequado à utilização posterior da rede. Assim, o treino deve ser repetido até alcançar um conjunto de valores para os pesos adequado à aplicação.

2.6 Exemplo de Aplicação

Neste item é desenvolvido um exemplo simples para apresentar a utilização do modelo *NARX* com redes neurais para predição de resposta de sistemas dinâmicos.

O exemplo consiste de um sistema mecânico tipo massa, mola e amortecedor não-linear de um grau de liberdade. Na Figura 10 encontra-se uma representação do sistema.




Figura 10 – Representação do modelo físico do exemplo

A equação de equilíbrio dinâmico é expressa por:

$$M \frac{d^2 x(t)}{dt^2} + C_1 \frac{dx(t)}{dt} + C_2 \frac{dx(t)}{dt} \left| \frac{dx(t)}{dt} \right| + k_1 x(t) + k_3 x(t)^3 = P(t) \quad (2.15)$$

Os valores numéricos das propriedades físicas são exibidos na Tabela 1.

Tabela 1 – Propriedades físicas do exemplo

Propriedade	Valor numérico
Massa M	50
Coef. Amortecimento C_1	0.8
Coef. Amortecimento C_2	1.2
Constante de rigidez k_1	4
Constante de rigidez k_3	3

O carregamento imposto ao sistema $P(t)$ é obtido de uma realização temporal de um espectro energético constante, um espectro retangular sobre uma faixa de frequências. Este espectro energético possui a mesma densidade energética por todas as frequências da faixa. Para definir o valor energético para este espectro, adotou-se a mesma energia contida num espectro de *Pierson-Moskowitz* (FALTINSEN, 1999), definido para os valores de uma altura de onda significativa $H_s=1.2\text{ m}$ e um período de pico de onda $T_p=7.5\text{ s}$. A Figura 11 representa o procedimento adotado.




Figura 11 – Espectro retangular equivalente

A equação (2.15) é resolvida numericamente por um método de *Runge-Kutta* de 4º ordem e todas as séries temporais tiveram o transiente inicial retirado. A discretização temporal empregada na resolução numérica consiste de passos de tempo $\Delta t=0.1\text{ s}$, e a integração é realizada até 5000 segundos. Com as séries temporais de carregamento $P(t)$ e a resposta do sistema $x(t)$, uma rede neural empregada com modelo NARX é configurada.

O objetivo é investigar a capacidade da rede de apreender a relação entre a entrada (o carregamento P) e a resposta (deslocamento x), e prever a resposta para novos valores de carregamento. A Figura 12 representa a configuração da rede neural NARX. Nela os principais parâmetros que definem a arquitetura da rede são encontrados: a quantidade K de nós na camada oculta e a quantidade de atrasos de passos de tempo da série temporal N .




Figura 12 – Configuração da rede neural NARX

Para investigar a arquitetura de rede mais apropriada ao caso, um estudo de sensibilidade é conduzido para avaliar a quantidade de nós na camada oculta e a quantidade de atrasos das séries temporais. Os demais parâmetros que definem a rede são mantidos constantes e encontram-se listados na Tabela 2. Os treinos e implementações das redes neurais foram realizados utilizando o *Neural Network Toolbox™* do software *MATLAB® R2014a*.

Tabela 2 – Parâmetros da rede neural mantidos constantes

Algoritmo de Aprendizado	<i>Levenberg-Marquardt</i>
Funções de Ativação (camada oculta)	Tangente Hiperbólica
Funções de Ativação (camada de entrada e saída)	Linear
Algoritmo de iniciação dos pesos	<i>Nguyen-Windrow</i>
Processamento - Entradas	Normalização (expressão 2.14)
Processamento - Saída	Normalização (expressão 2.14)
Amostra temporal para Treino e Validação	500 segundos (5000 passos de tempo): 70% da amostra para Treino e 30% para Validação
Atrasos Séries temporais	Mesma quantidade de atrasos para as séries de entrada e de resposta

O estudo de sensibilidade para os nós ocultos foi realizado variando a quantidade de nós de 2 a 30. Um atraso das séries temporais fixo de 5 passos de tempo é utilizado durante este estudo. O desempenho da arquitetura de rede é avaliado por meio do menor valor do erro quadrático médio de validação, obtido para uma quantidade máxima de 500 épocas de treinamento. Como discutido no item 2.4, uma vez que a iniciação dos pesos é aleatória, cada configuração avaliada tem o treino repetido 20 vezes (PINA *et al.*, 2013) para compor uma distribuição amostral dos erros. A Figura 13 apresenta os resultados. Nela, os valores médios dos erros para a quantidade de nós são impressos em conjunto com a barra de dispersão vertical, representando o desvio padrão. Os valores possuem baixas magnitudes uma vez que são valores quadráticos de números de pequenos valores. O comprimento da barra que representa o desvio padrão pode atingir a região de valores negativos do gráfico devido a escala.




Figura 13 – Estudo de sensibilidade, nós na camada oculta

Os erros de validação possuem valores mais elevados em média e desvio para uma quantidade pequena de nós na camada oculta, caindo rapidamente com o aumento destes. Até certa quantidade de nós, que no presente caso é 15, o erro quadrático médio de validação apresenta valor mínimo (e com pequena dispersão). A partir de 15 nós na camada oculta, o erro não diminui ou, em outras palavras, não há ganho expressivo de desempenho da rede que justifique seu aumento.

Para o estudo de sensibilidade da quantidade de atrasos das séries temporais, estas foram variadas de 2 a 50 passos de tempo, em processo análogo ao estudo anterior. O número de nós na camada oculta foi mantido fixo em 15 nós, a partir do estudo de

sensibilidade para os nós anterior. A Figura 14 apresenta o resultado de do estudo da quantidade de atrasos das séries temporais.




Figura 14 – Estudo de sensibilidade, atrasos das séries temporais

O comportamento do desempenho da rede, no que diz respeito à quantidade de atrasos, é semelhante ao observado para a quantidade de nós. Conclui-se que a partir de 30 passos de tempo não há ganho expressivo de performance da rede.

Os resultados indicam que a rede neural *NARX* com melhor arquitetura é:

- Nós na camada oculta: 15;
- Atrasos da série temporal: 30.

Treinando uma rede neural *NARX* com esta arquitetura e aplicando-a ao restante da série temporal dos esforços $P(t)$, a predição dos deslocamentos pela rede é comparada com os valores da integração numérica. A Tabela 3 apresenta a comparação dos valores dos parâmetros estatísticos das séries temporais.

Tabela 3 – Parâmetros estatísticos comparados

<i>Parâmetro Estatístico</i>	<i>Integração Numérica</i>	<i>Rede Neural</i>
Média	-0.00011991	-0.00025246
Desvio Padrão	0.50473	0.50474
Curtose (<i>kurtosis</i>)	2.4424	2.4491
Coef. Assimetria (<i>skewness</i>)	-0.010077	-0.0091109
Máximo Observado	1.2793	1.2763
Mínimo Observado	-1.2772	-1.2828
Coef. Correlação	0.99962	

A Figura 15 apresenta uma janela das séries temporais de resposta previstas pela rede neural *NARX* e a resposta obtida pela integração numérica. Observa-se grande concordância entre as séries temporais, com diferenças desprezíveis. Os sinais se sobrepõem fortemente na maior parte do tempo.




Figura 15 – Janela das séries temporais de resposta

Já na Figura 16, os espectros energéticos de ambas as séries são exibidos. Os bons resultados da predição pela rede neural *NARX* treinada refletem-se na grande semelhança da distribuição do conteúdo energético da resposta predita em relação a resposta da integração numérica.




Figura 16 – Espectros energéticos das respostas

Deste simples exemplo, nota-se a relevante e poderosa capacidade de aprendizado e predição da resposta de sistemas dinâmicos por redes neurais *NARX*.

Capítulo 3

Análise de Fadiga de Risers Metálicos

Devido à natureza dinâmica do ambiente marinho resultante da ação de ondas, ventos, correntes, as estruturas marítimas sofrem carregamentos cíclicos constantemente durante sua vida útil de operação em campo. Os *risers* estão sujeitos à ação das ondas e correntes diretamente sobre sua estrutura e recebem os movimentos da unidade flutuante (devido às ondas, ventos e correntes) em suas conexões no topo.

A análise de fadiga em estruturas marítimas é realizada em duas etapas fundamentais. A primeira é denominada análise global, onde os esforços estruturais globais (trações, momentos, curvaturas) são obtidos para os casos de carregamento (cenários ambientais). O segundo passo, a análise local, compreende a transformação dos esforços globais em tensões nos pontos de interesse da seção transversal do *riser*, para posterior uso na identificação e contagem dos ciclos de tensões.

Este Capítulo está dividido em 3 itens principais. O item 3.1 apresenta uma visão geral sobre análise global, modelagem ambiental, casos de carregamento e resposta estrutural. No item 3.2 os principais conceitos a respeito do fenômeno de fadiga são comentados e, por fim, o item 3.3 introduz os *risers* rígidos, exibindo as tensões na seção transversal do duto e sua relação com os esforços globais.

3.1 Análise Global

Na análise global a série temporal de parâmetros de resposta estrutural do *riser*, tais como esforços axiais e momentos fletores ao longo do mesmo, são obtidos. Devido ao comportamento não-linear dessas estruturas esbeltas, geralmente a análise global é realizada por simulações numéricas não-lineares no domínio do tempo, baseadas no método dos elementos finitos (MEF) e empregando elementos de pórtico na discretização espacial do modelo estrutural.

A análise pode ser baseada num modelo acoplado ou desacoplado. No modelo acoplado (BAHIENSE, 2007), a unidade flutuante é representada por um elemento rígido de seis graus de liberdade dentro da matriz contendo a discretização dos nós dos

elementos finitos dos modelos das linhas de ancoragem e *risers*. Este grande modelo numérico é resolvido em conjunto: os movimentos da unidade flutuante e os esforços nas estruturas são obtidos simultaneamente, considerando as influências das estruturas sobre a unidade flutuante e vice-versa. No modelo desacoplado, os movimentos da unidade flutuante são obtidos numa primeira etapa (item 3.1.2) e depois os movimentos, transferidos para o ponto de conexão do *riser*, são aplicados no topo do modelo de elementos finitos da estrutura. O presente trabalho utilizou modelos desacoplados.

Quanto à representação ambiental dos carregamentos devido às ondas, as análises podem ser baseadas em ondas regulares (análise determinística) ou ondas irregulares (análise estocástica). Análises determinísticas não demandam séries temporais de resposta longas, uma vez que poucos ciclos harmônicos já são suficientes para a avaliação das respostas. Em oposição, análises estocásticas requerem maiores séries temporais afim da estabilização dos parâmetros estatísticos das respostas, porém são mais representativas do comportamento das ondas no mar. A análise de fadiga de *risers* rígidos é tradicionalmente baseada em análises estocásticas no domínio do tempo. Assim, todas as análises realizadas neste trabalho foram estocásticas.

3.1.1 Carregamentos Ambientais

Do ponto de vista estatístico, os fenômenos ambientais envolvidos na análise estatística de estruturas marítimas são considerados processos estocásticos. A longo prazo (períodos de um ou mais anos) estes processos não podem ser considerados estacionários. Porém para intervalos de tempo mais curtos, eles podem ser considerados aproximadamente estacionários.

Normalmente considera-se esses períodos de curto prazo como intervalos de 3 horas, onde o ambiente marinho é caracterizado pelos parâmetros estatísticos das variáveis ambientais mensuradas dentro desse intervalo. Desta maneira, a observação dos parâmetros ambientais de mar, vento e corrente em períodos de curto prazo durante períodos longos e sucessivos determina a caracterização ambiental de longo prazo. As relações entre curto e longo prazo são representadas na Figura 17.

Os parâmetros ambientais de curto prazo que caracterizam as ondas são a altura significativa de onda H_s , o período de cruzamento zero T_z e a direção de incidência θ_w (SOUSA, 2005). Para o vento, utiliza-se uma velocidade média V_{wi} e direção de incidência θ_{wi} . Já as correntes marinhas possuem perfis complexos, com velocidades e

direções variando ao longo da profundidade. Usualmente um perfil fixo é definido e identificado por uma velocidade C_v e direção de propagação θ_c na superfície.




Figura 17 – Caracterização de curto e longo prazo dos parâmetros ambientais

A partir das medições sucessivas dos estados de curto prazo, pode-se definir uma distribuição de probabilidade conjunta de longo prazo dos parâmetros ambientais (PAPALEO, 2009). Porém na prática a obtenção dessa função conjunta é dificultosa e o mais usual é a utilização de diagramas de dispersão com hipóteses simplificadoras, geralmente assumindo colinearidade de direção entre onda, vento e corrente. Neste caso assume-se frequências discretas para cada direção de incidência e para as respectivas ondas da direção, e geralmente perfis de corrente por direção ou um perfil único em

todos os casos de carregamento. Os casos de carregamento consistem em análises para um cenário ambiental de curto prazo definido. Tratamento estatísticos adequados devem ser aplicados para os dados disponíveis de longo prazo da locação para definição dos cenários característicos na verificação de estados limite de extremos e na verificação de fadiga.

Embora o vento não atue diretamente sobre os *risers*, ele provoca um arrasto sobre a unidade flutuante, alterando o aproamento e contribuindo para o deslocamento estático da unidade. Os efeitos das forças de onda de segunda ordem (CAIRE *et al.*, 2015) contribuem também para alteração no aproamento e deslocamento estático. Desta maneira, em análises desacopladas é prática comum representar a combinação média destes efeitos em conjunto com o arrasto da corrente, como um deslocamento estático, denominado *offset*.

Os movimentos da unidade flutuante (impostos no topo do *riser*) são representados somente pelos movimentos induzidos por ondas de primeira ordem, e são obtidos através do RAO (*Response Amplitude Operators*) característico da unidade flutuante. Isto será abordado no próximo item.

3.1.2 Ondas Irregulares e Movimentos da Unidade Flutuante

No curto prazo a variação temporal das elevações da superfície do mar (ondas) é geralmente considerada um processo aleatório estacionário e Gaussiano. Empregando análises de *Fourier*, é possível obter funções de densidade espectral para os registros de elevação observados, caracterizando a distribuição de energia para as frequências (e períodos) dos estados de mar.

Através de observações de campo e ajustes de curvas, várias expressões matemáticas foram propostas relacionando o espectro energético do estado de mar com os parâmetros H_s e T_z . As duas formulações mais utilizadas são o espectro de *Pierson-Moskowitz* de dois parâmetros e o espectro de *JONSWAP* (FALTINSEN, 1999). O espectro de *Pierson-Moskowitz* para os parâmetros H_s e T_z é definido pela expressão:

$$S_{\eta}(\omega) = \frac{4\pi^3 H_s^2}{\omega^5 T_z^4} \cdot \exp\left(-\frac{16\pi^3}{\omega^4 T_z^4}\right) \quad (3.1)$$

onde $S_\eta(\omega)$ é a função densidade espectral, ω é a frequência angular e H_s e T_z são os parâmetros que definem o estado de mar: altura significativa de onda e período de cruzamento zero (respectivamente). Já o espectro de *JONSWAP* é definido por:

$$S_\eta(\omega) = \alpha \frac{g^2}{2\pi^4 \omega^5} \cdot \exp \left[-1.25 \left(\frac{\omega}{\omega_p} \right)^{-4} \right] \cdot \gamma^{\exp \left[\frac{(\omega - \omega_p)^2}{2 \sigma^2 \omega_p^2} \right]} \quad (3.2)$$

onde g é a aceleração do campo gravitacional e ω_p é a frequência do pico espectral:

$$\omega_p = \frac{2\pi}{T_p} \quad (3.3)$$

e T_p é o respectivo período de pico do espectro. Neste caso o estado de mar está definido em função dos parâmetros H_s e T_p . O parâmetro de forma σ é fixo e determinado em função da frequência de pico:

$$\sigma = \begin{cases} 0.07 & , \text{ para } \omega \leq \omega_p \\ 0.09 & , \text{ para } \omega > \omega_p \end{cases} \quad (3.4)$$

Os demais parâmetros da expressão do espectro de *JONSWAP* são α e γ , e são dependentes da localização ambiental. Para uma região na Bacia de Campos eles são (BAHIENSE, 2007):

$$\gamma = \exp \left(1.0394 - 0.01966 \frac{T_p}{\sqrt{H_s}} \right) \quad (3.5)$$

$$\alpha = 5.0609 \frac{H_s^2}{T_p^4} (1 - 0.287 \cdot \ln(\gamma)) \quad (3.6)$$

A análise numérica estrutural pelo MEF requer a série temporal da elevação do mar. Assumindo-se que o processo é Gaussiano e baseado no caráter linear da Teoria de *Airy* para as ondas (DEAN & DALRYMPLE, 2010), uma onda irregular (análise

estocástica) pode ser representada pela superposição linear de ondas regulares com diferentes amplitudes, frequências e fases (FALTINSEN, 1999):

$$\eta(t) = \sum_{i=1}^{N_w} A_i \cos(\omega_i t + \phi_i) \quad (3.7)$$

em que N_w é a quantidade de componentes (ondas harmônicas) da divisão do espectro e: A_i é a amplitude da componente de onda i , ω_i é a respectiva frequência e ϕ_i é um ângulo de fase. Os ângulos de fase são escolhidos aleatoriamente por uma distribuição uniforme dentro do intervalo $[0; 2\pi]$. A mudança dos valores dos ângulos de fase gera uma série temporal diferente de elevação da superfície do mar, mas que mantém os mesmos valores estatísticos e energéticos do estado de mar em questão. A relação entre a amplitude e a discretização do espectro de mar é expressa por:

$$A_i = \sqrt{2 S_\eta(\omega_i) \Delta\omega} \quad (3.8)$$

A Figura 18 representa a forma como é feita discretização do espectro (a) e a relação entre os domínios do tempo e da frequência na geração de uma onda irregular (b).




Figura 18 – (a) Representação do espectro de mar; (b) Geração de onda irregular

Com a série temporal da elevação da superfície do mar determinada, o RAO é empregado para a obtenção dos movimentos da unidade flutuante. O RAO é um operador linear que relaciona a resposta (movimentos) da unidade flutuante para uma onda de amplitude unitária e frequência definida. Ele depende unicamente das propriedades do corpo flutuante (massa, geometria, inércias). Ele é determinado por

programas que utilizam a teoria linear do potencial implementada numericamente pelo método dos painéis para solucionar o potencial de velocidades e pressões do fluido na superfície submersa da unidade flutuante (WAMIT, 2015; NEMOH, 2014).

O RAO é utilizado para representar a resposta de movimentos da unidade flutuante. Considerando esta como um corpo rígido, seus movimentos podem ser determinados no espaço através dos 6 graus de liberdade: 3 de translação e 3 de rotação. Estes movimentos são denominados: *Surge*, *Sway* e *Heave* para os graus de liberdade de translação e *Roll*, *Pitch* e *Yaw* para as rotações. A orientação dos movimentos é representada na Figura 19.




Figura 19 – Movimentos da unidade flutuante

O RAO de resposta dos movimentos é caracterizado pela amplitude de resposta $RAO_r(\omega)$ e pelos respectivos ângulos de fase $\varphi_r(\omega)$. Os ângulos de fase determinam o atraso entre a excitação (onda) e a resposta. Utilizando o princípio da superposição linear dos efeitos, a série temporal do movimento no grau de liberdade r da unidade flutuante é designado por:

$$r(t) = \sum_{i=1}^{N_w} RAO_r(\omega_i) A_i \cos(k_i x \pm \omega_i t \pm \phi_i \pm \varphi_r(\omega_i)) \quad (3.9)$$

onde k_i é o número de onda da componente i (FALTINSEN, 1999), x é a posição do centro de movimentos do RAO em relação ao zero do referencial global e o sinal $\pm$ é definido de acordo com o programa utilizado na geração do RAO.

O RAO é também dependente da direção de incidência de onda e é avaliado para um ponto da unidade, o centro de movimentos. De posse dele, os movimentos de um ponto qualquer da unidade flutuante são facilmente determinados através de combinação linear dos movimentos de translações e rotações (BATALHA, 2009).

Como um exemplo dos comportamentos usuais dos RAOs, a Figura 20 ilustra as amplitudes de resposta para os RAOs (apresentados em função dos períodos e para ondas de incidência de 45° e 90°) da plataforma semi-submersível e do FPSO utilizados nos estudos de caso do Capítulo 5.




Figura 20 – RAOs empregados nos estudos de caso

3.1.3 Resposta Estrutural

A avaliação de cada caso de carregamento pode ser realizada em duas etapas. Na primeira é realizada uma análise estática onde os únicos carregamentos a que o modelo do *riser* está sujeito é o campo gravitacional (e empuxo), o arrasto devido ao perfil de corrente atuante e o deslocamento aplicado, o *offset*. O resultado desta análise é uma configuração estática final que é utilizada como ponto de partida do próximo passo, a análise dinâmica.

Na análise dinâmica, a estrutura está sujeita também aos campos gravitacionais e ao arrasto da corrente, acrescidos do carregamento dinâmico das ondas sobre o duto e aos movimentos da unidade flutuante no topo (obtidos pelo RAO, conforme item anterior).

Outra forma também empregada é a aplicação gradual dos carregamentos de caráter estático (*offset* e arrasto por corrente) na análise dinâmica. Desta maneira, a

duração dos transientes iniciais é um pouco maior e deve ser eliminada da série temporal nas análises posteriores.

Os resultados da análise dinâmica são as séries temporais dos deslocamentos e esforços globais estruturais. A Figura 21 representa o procedimento, para o caso em que há a aplicação de *offset* e corrente diretamente na análise dinâmica.




Figura 21 – Representação da análise global

As análises dinâmicas constituem-se da aplicação do método dos elementos finitos para a solução numérica da expressão:

$$M \cdot \ddot{X}(t) + C(\dot{X}) \cdot \dot{X}(t) + K(X) \cdot X(t) = F(t) \quad (3.10)$$

onde X , $\dot{X}$ e $\ddot{X}$ são os vetores que contêm, respectivamente, os deslocamentos, velocidades e acelerações nodais; M é a matriz de inércia (massas estruturais e adicionais), C é a matriz de amortecimento (estrutural e hidrodinâmico), K é a matriz de rigidez (incluindo hidrostática) e F é o vetor que contém os carregamentos temporais nodais, excitação do sistema. Este vetor contém todos os carregamentos sobre o *riser* anteriormente citados. Geralmente os algoritmos empregam para representação do carregamento das ondas sobre o *riser* uma forma modificada da equação de *Morison* (FALTINSEN, 1999).

O *riser* pode experimentar grandes deslocamentos e estar situado em lâminas de água elevadas. As configurações geométricas resultantes, a interação com o solo e a

combinação de carregamentos resulta em comportamento e resposta não-linear. Por isso deve-se empregar uma adequada discretização e elementos de pórtico espacial não-lineares no algoritmo de elementos finitos utilizado (MOURELLE, 1993). Desta forma, optou-se por ressaltar a dependência da matriz de amortecimento e da matriz de rigidez em relação às, respectivamente, velocidades e deslocamentos na expressão (3.10).

A análise dinâmica pelo MEF apresenta elevado custo computacional. A presença das não linearidades, o refinamento da malha de elementos que pode acarretar em matrizes de dimensões muito elevadas (expressão 3.10) e a necessidade de longas séries temporais de resposta para a adequada caracterização estatística nas análises estocásticas são os principais fatores contribuintes deste elevado esforço computacional.

No cotidiano de projeto de *risers* este cenário se torna mais problemático uma vez que análises de estados limites de extremos e de fadiga possuem muitos casos de carregamento. O tempo de obtenção dos resultados cresce rapidamente.

O objetivo deste trabalho reside justamente neste tópico. Uma avaliação da metodologia híbrida análise elementos finitos e redes neurais – AEF-RN é realizada na verificação de fadiga de dois *risers* rígidos.

É importante destacar que na análise desacoplada, a principal fonte de excitação sobre a estrutura são os movimentos impostos no topo pela unidade flutuante. Eles são determinados previamente através do RAO e o esforço computacional empregado nesta etapa é desprezível. Os movimentos transferidos para o ponto de conexão são utilizados como entrada da rede neural treinada para a predição da resposta estrutural, constituindo a base da metodologia híbrida AEF-RN, como será discutido no Capítulo 4.

3.2 Fadiga

Pode-se definir fadiga como a falha de uma estrutura quando submetida a ações de cargas cíclicas que se aplicadas estaticamente não levariam à sua ruptura imediata. O fenômeno está relacionado à ruptura progressiva (ou acumulação de danos) e perda de capacidade resistiva da estrutura ao longo de sua operação, num ambiente dinâmico.

O processo físico da fadiga consiste das fases de iniciação de trinca, propagação estável da trinca e propagação instável (ruptura) (NAESS & MOAN, 2013). Para materiais base, a fase de iniciação da trinca representa percentagem elevada da vida de fadiga. Para juntas soldadas defeitos semelhantes a trincas já existem depois da fabricação, estando a percentagem de vida mais relevante sobre a fase de propagação. A

propagação de trincas é estudada pelo campo da Mecânica da Fratura. Porém, no projeto de novas estruturas a avaliação de fadiga é realizada baseada nas muito conhecidas curvas S-N e a regra de *Miner* para o acúmulo linear dos danos.

As curvas S-N relacionam a variação de tensão com o respectivo número de ciclos até a falha estrutural. São obtidas experimentalmente para amplas situações: tipo de material (base, junta soldada), forma e local do ponto avaliado e condições ambientais de operação (DNV-RP-C203, 2011). Normalmente, as curvas S-N são lineares ou bi-lineares e apresentadas em escalas logarítmicas, conforme exemplificado na Figura 22.




Figura 22 – Curvas S-N: (a) linear; (b) bi-linear

Matematicamente, uma curva S-N pode ser expressa como:

$$\log(N(S)) = \log(K) - m \cdot \log(S) \quad (3.11)$$

e, retirando a base logarítmica:

$$N(S) = K \cdot S^{-m} \quad (3.12)$$

onde S é a variação de tensão, $N(S)$ é a quantidade de ciclos que a variação de tensão S ocasiona falha por fadiga. K e m são os parâmetros da curva obtidos experimentalmente: m é o inverso negativo da inclinação da curva e $\log(K)$ é o intercepto da curva com o eixo $\log(N)$. Para curvas com duas inclinações, as regiões são divididas, possuindo parâmetros diferentes em cada parte (Figura 22).

Para estruturas marítimas soldadas, considera-se que o principal parâmetro que influencia a fadiga é a amplitude da variação de tensão. Isto baseia-se na suposição de que tensões residuais estão sempre presentes e que todos os ciclos de tensão atuam efetivamente sobre o crescimento de trincas. Para materiais base, a tensão média deve ser considerada também como variável. Em estruturas em condições de corrosão livre e avaliadas no filete de solda, as curvas adotadas podem ser lineares (DNV-RP-C203, 2011). Esta será a condição adotada para os estudos de caso deste trabalho.

De acordo com a hipótese do acúmulo linear de dano, regra de *Miner*, cada ciclo de variação de tensão S_i induz um dano de fadiga d_i expresso como:

$$d_i = \frac{1}{N(S_i)} = \frac{(S_i)^m}{K} \quad (3.13)$$

A regra de *Miner* geralmente é empregada para variações de tensões em análises estocásticas. O dano acumulado consiste do somatório linear dos danos ocasionados pelos ciclos de variação de tensão atuantes:

$$D_T = \sum_{i=1}^{N_c} \frac{(S_i)^m}{K} \quad (3.14)$$

onde D_T é o dano acumulado durante o tempo de carregamento T e N_c é a quantidade de ciclos observadas neste intervalo de tempo.

Considera-se que a falha ocorre quando o dano acumulado atinge um certo limite, geralmente o valor unitário. Assim, a vida à fadiga VF em anos é avaliada por:

$$VF = \frac{1}{D_{anual}} = \frac{1}{\sum_{i=1}^{N_c} \left(\frac{(S_i)^m}{K} \right)} \quad (3.15)$$

onde N_c são os ciclos de variação de tensão observados durante o período completo de um ano.

Uma vez que a análise de fadiga é realizada através de análises de estados de mar de 3 horas (casos de carregamento de curto prazo), o dano anual pode ser também expresso da seguinte forma:

$$D_{anual} = 2920 \cdot \sum_{j=1}^{N_{EM}} \sum_{i=1}^{N_C^j} \left(\frac{(S_i^j)^m}{K} \cdot p_j \right) \quad (3.16)$$

onde N_{EM} é o número total de estados de mar de 3 horas, presentes nos diagramas de dispersão de ondas utilizados, N_C^j é a quantidade total de ciclos observados no estado de mar j (de duração de 3 horas) e p_j é a probabilidade de ocorrência anual do estado de mar j . 2920 é o número total de estados de mar de 3 horas que ocorrem em um ano.

Usualmente, a análise de fadiga de estruturas marítimas é realizada da maneira anteriormente apresentada. As séries temporais de tensão para cada estado de mar são obtidas pela análise local, a partir das respostas estruturais determinadas pelas análises globais de 3 horas pelo MEF, sendo esta a etapa que consome maior tempo computacional. Uma vez que a análise e respostas globais são estocásticas, a resposta de tensão avaliada também será.

A avaliação do dano requer a contagem dos ciclos de variação de tensão. Isto é realizado empregando o conhecido método numérico *Rainflow* (ALMAR-NAESS, 1985). Tal método foi desenvolvido primeiramente por MATSUISHI & ENDO (1968) e baseia-se na comparação da chuva escorrendo sobre os telhados de um Pagode (templo) com a série temporal da tensão com o eixo temporal na vertical.

O conceito fundamental da contagem *Rainflow* é identificar picos e vales da série temporal de tensão e, através de procedimento definido, identificar os ciclos de tensão e suas variações. Com os ciclos identificados, o dano computado d_j é a soma de todos os ciclos de tensão observados no estado de mar j :

$$d_j = \sum_{i=1}^{N_R} \frac{(S_i^j)^m}{K} \frac{T}{T_s} \quad (3.17)$$

onde N_R é a quantidade de ciclos identificados na série temporal de comprimento T_s (tamanho de simulação) e T é o período de referência de curto prazo (3 horas, ou 10800 segundos).

Nesta definição os valores de T e T_s podem ser diferentes. Baseando-se na hipótese de processo estacionário e ergódico, o dano avaliado para uma série temporal

de duração diferente do intervalo de curto prazo pode ser extrapolado/interpolado linearmente para o curto prazo, através desta expressão.

Nos estudos de caso acadêmicos para avaliação da metodologia híbrida AEF-RN, uma série temporal de 3100 segundos de tensão é obtida pelos esforços globais preditos. O respectivo dano é extrapolado linearmente para o período de curto prazo pela expressão (3.17): $T_s = 3100$ segundos e $T = 10800$ segundos. Desta maneira, o dano anual total é expresso por:

$$D_{anual} = 2920 \sum_{j=1}^{N_{EM}} d_j \cdot p_j = 2920 \sum_{j=1}^{N_{EM}} \sum_{i=1}^{N_R} \frac{(S_i^j)^m}{K} \frac{T}{T_s} \cdot p_j \quad (3.18)$$

3.3 Risers rígidos

Risers rígidos são estruturas formadas por segmentos de dutos convencionais (API 5L, 2000) soldados, e utilizados para transporte de petróleo ou gás dos poços no fundo do mar até a unidade flutuante de processamento, na superfície.

O processo de soldagem dos trechos pode ser feito durante o lançamento (instalação), nos casos de lançamento pelos métodos *J-Lay* e *S-Lay*, ou a linha pode ser manufaturada em terra e bobinada em carretel para instalação pelo método *Reel-Lay* (Figura 23).

Risers rígidos são economicamente atrativos: os materiais empregados e a manufatura dos tubos são menos onerosas que os *risers* flexíveis. Apresentam elevadas resistências às pressões internas e externas, com viabilidade do uso de diâmetros elevados em grandes profundidades. Em contrapartida, os *risers* flexíveis apresentam maior facilidade no armazenamento, transporte e instalação, acelerando a produção dos campos.




Figura 23 – Tipos de lançamento: (a) *J-Lay*; (b) *S-Lay*; (c) *Reel-Lay*

Quanto ao comportamento estrutural, os *risers* metálicos são mais sensíveis a excitações dinâmicas elevadas impostas pela unidade flutuante, principalmente quanto aos movimentos de *roll* e *pitch* alcançados por um FPSO. Geralmente os níveis de tensão são menores quando comparados aos observados nas armaduras de tração de *risers* flexíveis. As configurações de operação mais empregadas são a catenária livre (SCR), e a configuração *lazy wave* (SLWR), ilustradas na Figura 24. A configuração SLWR é atingida utilizando flutuadores em trechos da linha.

O primeiro SCR foi instalado pela Shell em 1994 no Golfo do México, numa lâmina de água de 872m e conectado a uma plataforma de pernas tracionadas (TLP) (DANTAS, 2004). No Brasil, a Petrobras foi a pioneira na instalação de uma linha desse tipo em 1998, em uma plataforma semi-submersível (SERTÃ *et al.*, 1996).




Figura 24 – Configurações usuais para risers rígidos: (a) SCR; (b) SLWR

Grandes amplitudes de movimentos verticais no topo da estrutura podem induzir compressões no *touch-down zone* (TDZ) de SCR, fenômeno que deve ser evitado no projeto de tais linhas. Além disso, dutos de grandes diâmetros provocam carregamentos de elevadas magnitudes no topo da linha. A configuração SLWR permite uma diminuição dos esforços no topo, os flutuadores diminuem o comprimento suspenso suportado pelo topo e amortecem a dinâmica na região do TDZ.

Muito esforço tem sido empregado nos últimos anos na viabilidade prática e projeto de *risers* metálicos em águas profundas (SAGRILO *et al.*, 2005). Um panorama prático e recente do cenário geral de projetos de sistemas de *risers* rígidos e flexíveis, configurações de arranjo submarino das linhas e unidades flutuantes é apresentada por

SAINT-MARCOUX & LEGRAS (2014). Apesar de primeiramente empregado em plataformas tipo semi-submersíveis, SCRs também estão sendo empregados conectados a FPSOs de ancoragem tipo *spread-mooring* no Leste da África (ExxonMobil Ehra, Shell Bhonga), onde as condições ambientais são amenas e unidirecionais. No Brasil, SLWRs estão instalados no FPSO Espírito Santo (Shell, lâmina de água de 1780m) e FPSO Cidade de Ilhabela (Petrobras, lâmina de água de 2140m), por exemplo. Há ainda a adoção de configurações mistas de *risers* rígidos com flexíveis, como no projeto da Bóia de Sustentação de *Risers* (BSR) da Petrobras.

Risers metálicos possuem dois tipos de componentes em seu topo com a função de atenuar os esforços nesta região: a mísula (também chamada *stressjoint*) e a *flexjoint*. A mísula consiste de um segmento cônico soldado ao *riser*, às vezes manufaturada em ligas de titânio. Seu objetivo é similar aos enrijecedores utilizados em linhas flexíveis: realizar transição suave da rigidez à flexão, dispersando a atuação dos momentos em um comprimento maior do duto. As *flexjoints* são empregadas para permitir moderadas rotações relativas entre o *riser* e a unidade flutuante, baseando-se no uso de um elemento flexível compósito laminado, com camadas alternadas de elastômero e aço. No modelo do *riser* para AEF, as *flexjoints* são representadas por molas de rigidez torcional no topo, enquanto as mísulas são representadas por elementos com diâmetros externos que aumentam de dimensão, compondo um segmento cônico.

3.3.1 Fadiga em Risers Rígidos

Devido à simplicidade estrutural, a tensão na seção transversal de *risers* metálicos pode ser avaliada através de expressões simples, diferentemente do que ocorre para dutos flexíveis, onde a tensão nas armaduras de tração deve ser avaliada por modelos numéricos locais ou expressões com aproximações ou suposições (CHAVES, 2015).

As tensões na seção de um duto cilíndrico são originadas dos esforços de tração axial, momentos locais e pressões internas e externas (hidrostáticas e devido à pressurização do fluido interno). Considerando o sistema referencial apresentado na Figura 25, desprezando-se os efeitos de esforços cisalhantes e considerando a formulação de tubos de paredes grossas, a tensão axial pode ser expressa por (SOUSA, 2005; DNV-RP-F204, 2010):

$$\sigma(t) = \frac{T(t)}{A} + \frac{My(t) \cdot r \cdot \sin(\theta)}{I} + \frac{Mz(t) \cdot r \cdot \cos(\theta)}{I} \quad (3.19)$$

onde A é a área da seção transversal do duto, My e Mz são os momentos locais atuantes na seção, r é o raio onde a tensão é avaliada, θ é a coordenada angular do ponto avaliado e I é o momento de inércia da seção tubular. A tração axial atuante T é definida por (SPARKS, 1984):

$$T(t) = -Fx(t) + p_i \pi r_i^2 - p_e \pi r_e^2 \quad (3.20)$$

em que p_i , p_e , r_i e r_e são, respectivamente, pressão interna, pressão externa e raios interno e externo. O sinal negativo no esforço axial Fx é empregado por uma questão de sistema de referência, conforme a Figura 25.




Figura 25 – Sistema referencial e seção transversal

Utilizando a expressão (3.19) é possível obter a série temporal de tensões na seção transversal do *riser* através dos esforços de tração T , e momentos My e Mz , que são as respostas das análises globais de curto prazo. O dano resultante pode ser determinado pela expressão (3.17) e o dano anual pela expressão (3.18), para todos os estados de mar que compõem a distribuição de longo prazo.

Na prática de análise de fadiga em *risers* metálicos, a tensão determinada pela expressão (3.19) é denominada tensão nominal e necessita ser multiplicada por fatores concentradores de tensão. Esses fatores são empíricos e referem-se à possíveis

problemas de excentricidade, diferenças de espessura e ovalização dos tubos durante a soldagem (sendo o mais relevante a ovalização dos segmentos), além de mudanças de seções e conicidade (DNV-RP-C203, 2011). Quanto aos pontos de análise da tensão na seção, recomenda-se que pelo menos oito pontos ao longo da circunferência sejam avaliados (DNV-RP-F204, 2010).

Os estudos de caso acadêmicos posteriores não levaram em conta fatores de concentração de tensão, uma vez que o escopo deste trabalho é comparar o desempenho e acurácia da metodologia híbrida AEF-RN. Não há influência de tais fatores sobre a comparação dos danos finais obtidos entre as metodologias, uma vez que a curva S-N empregada é linear e o efeito destes fatores é constante sobre as variações de tensões. O dano é avaliado para pontos da seção transversal espaçados a cada 45° graus (8 pontos), tanto na superfície interna quanto na superfície externa do duto.

Capítulo 4

Metodologia Híbrida

Conforme apresentado no Capítulo 2, redes neurais possuem grandes capacidades de modelagem e predição de sistemas dinâmicos não lineares. Esta capacidade pode ser empregada nas análises dinâmicas não lineares globais de *risers* metálicos (Capítulo 3), para obtenção dos esforços globais, reduzindo assim, em grande parte, o esforço computacional relacionado à análise de fadiga.

Neste trabalho a metodologia híbrida AEF-RN é utilizada para modelar a relação entre os movimentos/deslocamentos dos seis graus de liberdade do topo do *riser* com os esforços globais (T , M_y e M_z) numa dada seção transversal do *riser*, e prever o restante da série temporal. O objetivo da metodologia híbrida é ser capaz de conciliar a representação da complexidade do modelo com redução do custo computacional empregado, conforme esquematizado na Figura 26.




Figura 26 – Relação custo computacional e complexidade de modelo (CHAVES, 2015)

As redes neurais utilizadas são modelos redes neurais - *NARX*, apresentadas no item 2.5 e Figura 9, aplicadas separadamente para as respostas estruturais (T , M_y , M_z) do *riser*. A arquitetura delas é apresentada na Figura 27.




Figura 27 – Arquitetura da rede neural - NARX

Na Figura 27 a resposta F representa um dos esforços estruturais preditos: T ou M_y ou M_z . Os valores de X , Y e Z são os movimentos de translação e RX , RY e RZ são os movimentos de rotação da conexão superior do *riser* nos três graus de liberdade globais. Estes valores são obtidos facilmente e sem custo computacional através da transferência dos movimentos do RAO ao ponto de conexão. $N_X, N_Y, \dots, N_{RZ}$, são as respectivas quantidade de atrasos empregados para os movimentos e N_F é a quantidade de atrasos da resposta utilizada no modelo da rede neural-NARX. Δt é o passo de tempo, a discretização temporal das séries.

Desta maneira, as redes neurais para as respostas globais podem ser expressas matematicamente como:

$$T(t) = f_T(W_T, X(t)) \quad (4.1)$$

$$My(t) = f_{My}(\mathbf{W}_{My}, \mathbf{X}(t)) \quad (4.2)$$

$$Mz(t) = f_{Mz}(\mathbf{W}_{Mz}, \mathbf{X}(t)) \quad (4.3)$$

onde $\mathbf{W}_T$, $\mathbf{W}_{My}$ e $\mathbf{W}_{Mz}$ são as matrizes contendo os valores dos pesos obtidos durante a etapa de treino de cada resposta estrutural e $\mathbf{X}(t)$ é a matriz que contém as séries temporais de entrada da rede neural: os movimentos no topo e seus atrasos e os atrasos da própria resposta. Uma vez que no emprego das redes o treino já foi efetuado e os pesos estão constantes, as redes neurais *NARX* podem ainda ser representadas como:

$$T(t) = f_T \left[\begin{array}{l} \{X(t), X(t-\Delta t), \dots, X(t-N_X \Delta t)\}, \\ \{Y(t), Y(t-\Delta t), \dots, Y(t-N_Y \Delta t)\}, \\ \{Z(t), Z(t-\Delta t), \dots, Z(t-N_Z \Delta t)\}, \\ \{RX(t), RX(t-\Delta t), \dots, RX(t-N_{RX} \Delta t)\}, \\ \{RY(t), RY(t-\Delta t), \dots, RY(t-N_{RY} \Delta t)\}, \\ \{RZ(t), RZ(t-\Delta t), \dots, RZ(t-N_{RZ} \Delta t)\}, \\ \{T(t-\Delta t), \dots, T(t-N_T \Delta t)\} \end{array} \right] \quad (4.4)$$

$$My(t) = f_{My} \left[\begin{array}{l} \{X(t), X(t-\Delta t), \dots, X(t-N_X \Delta t)\}, \\ \{Y(t), Y(t-\Delta t), \dots, Y(t-N_Y \Delta t)\}, \\ \{Z(t), Z(t-\Delta t), \dots, Z(t-N_Z \Delta t)\}, \\ \{RX(t), RX(t-\Delta t), \dots, RX(t-N_{RX} \Delta t)\}, \\ \{RY(t), RY(t-\Delta t), \dots, RY(t-N_{RY} \Delta t)\}, \\ \{RZ(t), RZ(t-\Delta t), \dots, RZ(t-N_{RZ} \Delta t)\}, \\ \{My(t-\Delta t), \dots, My(t-N_{My} \Delta t)\} \end{array} \right] \quad (4.5)$$

$$Mz(t) = f_{Mz} \left[\begin{array}{l} \{X(t), X(t-\Delta t), \dots, X(t-N_X \Delta t)\}, \\ \{Y(t), Y(t-\Delta t), \dots, Y(t-N_Y \Delta t)\}, \\ \{Z(t), Z(t-\Delta t), \dots, Z(t-N_Z \Delta t)\}, \\ \{RX(t), RX(t-\Delta t), \dots, RX(t-N_{RX} \Delta t)\}, \\ \{RY(t), RY(t-\Delta t), \dots, RY(t-N_{RY} \Delta t)\}, \\ \{RZ(t), RZ(t-\Delta t), \dots, RZ(t-N_{RZ} \Delta t)\}, \\ \{Mz(t-\Delta t), \dots, Mz(t-N_{Mz} \Delta t)\} \end{array} \right] \quad (4.6)$$

Ressalta-se que a metodologia poderia ser aplicada para a tensão diretamente, como resposta da rede. Entretanto, como recomenda-se que sejam avaliados pelo menos

8 pontos nas superfícies interna e externa, a aplicação da metodologia diretamente para as tensões resultaria no treino de 16 redes diferentes. A obtenção de redes para os três esforços permite a determinação das tensões em qualquer ponto da seção transversal através da expressão (3.19) e, por isso, foi empregada no presente trabalho.

O fundamento principal da metodologia híbrida AEF-RN é simplesmente encurtar a obtenção das séries temporais de resposta através da rede neural treinada. Ela é denominada híbrida pois necessita da AEF para fornecimento de uma curta amostra da resposta estrutural para o treino da rede. Este procedimento constitui a primeira etapa da metodologia AEF-RN. Com a arquitetura da rede definida e treino realizado, a resposta estrutural restante é predita utilizando como entrada os valores dos movimentos e valores passados da própria resposta estrutural. O procedimento é representado na Figura 28.




Figura 28 – Representação da metodologia híbrida AEF-RN

A economia de tempo η_{tempo} , desprezando o tempo de treino e aplicação da rede, é aproximadamente:

$$\eta_{tempo} = \frac{T_s}{T_T} \quad (4.7)$$

onde T_s é o comprimento desejado da série temporal de resposta predita pela rede neural e T_T é o comprimento da série temporal utilizada na etapa de treino da rede, obtido por AEF.

Empregando redes neurais com somente uma camada oculta, os parâmetros em aberto das redes são: nós na camada oculta e atrasos das séries temporais (arquitetura de rede, Figura 27) e o comprimento da amostra de treino (T_T). Estes parâmetros influenciam na acurácia da rede e na facilidade da convergência durante a etapa de treino. Normalmente os parâmetros são avaliados por estudos de sensibilidade para a resposta e o modelo estrutural avaliado.

No presente trabalho, os estudos de sensibilidade são realizados para a quantidade de nós na camada oculta e quantidade de atrasos da série temporal. O comprimento da amostra de treino é mantido fixo em 500 segundos, baseado em trabalhos anteriores (GUARIZE *et al.*, 2007; PINA *et al.*, 2013; CHAVES *et al.*, 2015). Isto será explicitado no Capítulo 5, a seguir.

Capítulo 5

Estudos de Caso

Neste capítulo são apresentados estudos de caso, onde investiga-se o desempenho da metodologia híbrida AEF-RN na análise de fadiga de *risers* rígidos.

Os estudos de caso são constituídos por uma análise simplificada de fadiga de dois *risers* rígidos. As duas configurações de *risers* avaliadas são: um em catenária livre – SCR e outro na configuração *lazy wave* – SLWR, modelados por elementos finitos.

Para o SCR, a análise é realizada para uma seção transversal de um elemento próximo ao topo e outro na região do TDZ. Para o SLWR um ponto no topo do duto é estudado. Os carregamentos ambientais selecionados são os mesmos para o SCR e para o SLWR, porém as unidades flutuantes e lâminas de água são diferentes. A definição dos carregamentos ambientais é realizada no item 5.1, enquanto os modelos, análises e resultados são apresentados nos itens 5.2 (SCR) e 5.3 (SLWR). O item 5.4 apresenta um sumário dos resultados finais.

Como mencionado anteriormente no Capítulo 4, são utilizados 500 segundos de simulação (AEF) de cada carregamento ambiental de curto prazo para o treino das redes neurais para cada resposta estrutural global (T, My, Mz). O restante da série temporal dos esforços é predito pelas redes a partir dos movimentos prescritos no topo da linha. A tensão em cada ponto da seção transversal é obtida dos esforços globais pela expressão (3.19) a partir dos 500 até 3600 segundos. Em seguida emprega-se um algoritmo de contagem de ciclos sobre a série temporal de tensão e o dano é computado, extrapolando linearmente para 3 horas (expressão 3.17). Os danos então são ponderados pela frequência de ocorrência dos casos de carregamento e somados para a avaliação do dano total final (expressão 3.18). São avaliados oito pontos (espaçados de 45° em 45° graus) nas superfícies externa e interna da seção transversal. A Figura 29 ilustra o procedimento dos estudos de caso conduzidos.




Figura 29 – Representação da avaliação do Estudo de Caso

A acurácia da metodologia híbrida AEF-RN é avaliada através da comparação com a análise de elementos finitos (AEF) completa, sobre o mesmo intervalo de tempo. Os esforços estruturais globais (T , M_y , M_z), as tensões e os danos totais finais são comparados. Ao final são realizados comentários a respeito da acurácia alcançada pela metodologia AEF-RN e a redução de tempo computacional.

Em todos os casos apresentados são conduzidos estudos de sensibilidade a respeito da quantidade de nós na camada oculta e da quantidade de passos de tempo de atrasos das séries temporais. Tais estudos são apresentados para cada caso, e o seu objetivo é avaliar em geral o desempenho de diferentes arquiteturas de rede para alguns casos de carregamento. Deste modo, um treino programado sequencialmente é efetuado com as arquiteturas que mostraram melhor desempenho.

Os treinos e implementações das redes neurais foram realizados utilizando o *Neural Network Toolbox™* do software *MATLAB® R2014a*. Para todos os treinamentos realizados por todo este trabalho, os seguintes parâmetros mantidos fixos:

- Todas as análises são desacopladas, onde os movimentos da unidade flutuante são de primeira ordem e obtidos pelos seus RAOs;
- Todas as séries temporais de movimentos e de esforços são amostras com passo de tempo de 0.1 segundo;
- Todas as redes são modelos *NARX* com uma única camada oculta de nós;

- Todos os atrasos de passo de tempo são iguais para movimentos e para esforços;
- O algoritmo de otimização dos pesos utilizado é o de *Levenberg-Marquadt*;
- A iniciação aleatória dos pesos é feita pelo algoritmo de *Nguyen-Widrow*;
- As séries temporais de movimentos e resposta estrutural foram normalizadas durante o treino e aplicação da rede (expressão 2.14);
- A função de avaliação de erro é a Erro Quadrático Médio (MSE);
- O tamanho total das séries temporais de treino e validação é de 500 segundos (5000 passos de tempo);
- A série de validação representa 15% da amostra total de 500 segundos;
- A resposta global (Fx, My ou Mz) é predita até 3600 segundos.

A curva S-N empregada na avaliação do dano foi a curva denominada Curva E, condição de corrosão livre, definida em DNV-RP-C203 (2011). Seus parâmetros são: $K=3.412 \times 10^{11}$ e $m=3.0$.

5.1 Carregamentos Ambientais

Os carregamentos ambientais adotados contemplam a atuação de ondas, corrente e aplicação de *offsets*.

A magnitude do *offset* foi calculada de forma simplificada como função da altura de onda significativa (H_s) do estado de mar em questão e proporcional a 3% da lâmina de água (LDA) para a maior altura de onda significativa ($H_{s_{max}}$) do diagrama de dispersão:

$$Offset(H_s) = \left(\frac{0.03 \cdot LDA}{H_{s_{max}}} \right) \cdot H_s \quad 5.1$$

Seu sentido de aplicação é o mesmo do de propagação da onda do respectivo caso de carregamento.

As ondas adotadas nas análises provêm de um modelo de diagrama de dispersão simplificado (FILHO, 2008), e foram divididas em oito direções de incidência. Para cada direção de incidência têm-se onze estados de mar (pares de H_s e T_z/T_p).

As direções de incidência e as frequências relativas de ocorrências das ondas por direção são apresentadas na Tabela 4, abaixo.

Tabela 4 – Frequências relativas por direção de incidência

<i>Direção de Incidência</i>		<i>Frequência (%)</i>
NN	Norte	26.0
NE	Nordeste	9.0
EE	Leste	1.5
SE	Sudeste	1.5
SS	Sul	10.0
SW	Sudoeste	23.0
WW	Oeste	13.0
NW	Noroeste	16.0
<i>Total:</i>		100.0

Os onze estados de mar utilizados e suas respectivas probabilidades de ocorrência relativas para uma dada direção são encontrados na Tabela 5.

Tabela 5 – Frequências relativas dos estados de mar por direção de incidência

#	<i>Estado de Mar</i>			<i>Frequência de Ocorrência (%)</i>
	<i>H_s (m)</i>	<i>T_z (s)</i>	<i>T_p (s)</i>	
01	0.25	3.75	4.95	1.74E-03
02	0.75	4.75	6.33	3.40E+00
03	1.25	5.25	7.02	2.41E+01
04	1.75	6.25	8.41	3.33E+01
05	2.25	6.75	9.11	2.21E+01
06	2.75	7.25	9.81	1.05E+01
07	3.25	7.75	10.51	4.20E+00
08	3.75	8.25	11.21	1.60E+00
09	4.25	8.75	11.91	5.63E-01
10	4.75	9.25	12.62	2.01E-01
11	5.25	9.75	13.32	3.40E-02
<i>Total:</i>				100.00

Desta forma, a análise de fadiga contempla 88 estados de mar. A Tabela 6 apresenta o diagrama de dispersão destes, e suas frequências absolutas.

Tabela 6 – Diagrama de dispersão adotado

<i>Estados de Mar</i>		<i>Direção de Incidência</i>								<i>Soma</i>
<i>Hs</i>	<i>Tp</i>	<i>NN</i>	<i>NE</i>	<i>EE</i>	<i>SE</i>	<i>SS</i>	<i>SW</i>	<i>WW</i>	<i>NW</i>	
0.25	4.95	4.51E-06	1.56E-06	2.60E-07	2.60E-07	1.74E-06	3.99E-06	2.26E-06	2.78E-06	0.00
0.75	6.33	8.84E-03	3.06E-03	5.10E-04	5.10E-04	3.40E-03	7.82E-03	4.42E-03	5.44E-03	0.03
1.25	7.02	6.27E-02	2.17E-02	3.62E-03	3.62E-03	2.41E-02	5.54E-02	3.13E-02	3.86E-02	0.24
1.75	8.41	8.66E-02	3.00E-02	5.00E-03	5.00E-03	3.33E-02	7.66E-02	4.33E-02	5.33E-02	0.33
2.25	9.11	5.75E-02	1.99E-02	3.32E-03	3.32E-03	2.21E-02	5.08E-02	2.87E-02	3.54E-02	0.22
2.75	9.81	2.73E-02	9.45E-03	1.58E-03	1.58E-03	1.05E-02	2.42E-02	1.37E-02	1.68E-02	0.11
3.25	10.51	1.09E-02	3.78E-03	6.30E-04	6.30E-04	4.20E-03	9.66E-03	5.46E-03	6.72E-03	0.04
3.75	11.21	4.16E-03	1.44E-03	2.40E-04	2.40E-04	1.60E-03	3.68E-03	2.08E-03	2.56E-03	0.02
4.25	11.91	1.46E-03	5.07E-04	8.45E-05	8.45E-05	5.63E-04	1.30E-03	7.32E-04	9.01E-04	0.01
4.75	12.62	5.23E-04	1.81E-04	3.02E-05	3.02E-05	2.01E-04	4.62E-04	2.61E-04	3.22E-04	0.00
5.25	13.32	8.83E-05	3.06E-05	5.09E-06	5.09E-06	3.40E-05	7.81E-05	4.41E-05	5.43E-05	0.00
<i>Soma</i>		0.26	0.09	0.01	0.01	0.10	0.23	0.13	0.16	1.00

A fim de facilitar a identificação dos casos durante a apresentação dos estudos, adota-se a seguinte nomenclatura: os casos são identificados por 4 caracteres. Os dois primeiros são letras que denotam a direção de incidência da onda, e os dois últimos são os números do par de H_s e T_p . Por exemplo, o código SS06 representa o caso com uma onda vinda do Sul com valores de $H_s = 2.75\text{m}$ e $T_p = 9.81\text{s}$ (conforme a Tabela 5).

Um perfil de corrente único foi empregado em todos os casos de carregamento. Na Tabela 7 o perfil utilizado é apresentado.

Tabela 7 – Perfil da corrente empregada

<i>LDA</i> (m)	<i>Velocidade</i> (m/s)	<i>Azimute de</i> <i>Propagação</i> (°)
0	0.35	160
50	0.40	165
100	0.50	163
150	0.40	150
250	0.30	161
350	0.20	159
450	0.20	194
550	0.15	171
650	0.10	207
750	0.20	204
900	0.15	159
1050	0.20	180
1220	0.10	180
1298	0.10	180
1299.5	0.10	180
1300	0.00	-

5.2 Riser rígido em catenária – SCR

5.2.1 Modelo

O riser rígido se encontra numa posição de catenária livre, conectado a uma plataforma do tipo semi-submersível. A lâmina de água é de 1300m. Um sumário com as propriedades da estrutura é apresentado na Tabela 8.

Tabela 8 – Propriedades do SCR

<i>Parâmetro</i>	<i>Valor</i>
Diâmetro Externo (m)	0.219 (8.6")
Diâmetro Interno (m)	0.187 (7.37")
Diâmetro Hidrodinâmico (m)	0.279 (11.00")
Módulo Elasticidade (kN/m ²)	2.07E+08
Peso Específico (kN/m ³)	77.00
Fluido Interno (kN/m ³)	7.00 (Óleo)
Pressão no topo (MPa)	10.00
Rigidez do Solo (kN/m)	1000.00
Ângulo de topo	10°
Azimute do riser	135°

A Figura 30 apresenta uma visão esquemática do SCR, assim como a plataforma, e as respectivas orientações e a Tabela 9 apresenta os segmentos e discretização da malha de elementos finitos. O modelo contempla uma mísula no topo, mas não foi empregado modelagem de *flexjoint* neste riser. O RAO da resposta de *Heave*, para algumas direções de incidência, foi apresentado no Capítulo 3 (Figura 20).




Figura 30 – Visão esquemática do modelo do SCR

Tabela 9 – Malha de elementos finitos do SCR

<i>Seg.</i>	<i>Comprimento (m)</i>	<i>Quantidade de elementos</i>	<i>Comp. inicial do elemento (m)</i>	<i>Comp. final do elemento (m)</i>
1	18	180	0.10	0.10
2	50	167	0.10	0.50
3	60	82	0.50	1.00
4	755	755	1.00	1.00
5	130	174	1.00	0.50
6	864	1728	0.50	0.50
7	200	267	0.50	1.00

5.2.2 Topo do SCR

A seção transversal avaliada neste item é relativa à um elemento do modelo que se localiza na região do topo do SCR, à 10m abaixo da conexão e após a mísula.

O treinamento das redes neurais foi realizado usando como entrada os movimentos prescritos no topo da linha, nos 6 graus de liberdade e os atrasos da própria resposta estrutural (Figura 28).

5.2.2-A Redes Neurais

A fim de avaliar a influência da arquitetura de rede sobre o desempenho, um estudo de sensibilidade é conduzido para a quantidade de nós na camada oculta e a quantidade de atrasos das séries temporais.

Optou-se por realizar primeiro o estudo de sensibilidade para os nós. Foram selecionados alguns casos de carregamento e os nós na camada oculta são variados de 2 a 30. Os três esforços estruturais são avaliados. O desempenho é avaliado pelo erro quadrático médio sobre a amostra de validação. Na Tabela 10 é encontrado um sumário do estudo de sensibilidade.

Tabela 10 – Estudo de sensibilidade de nós, topo do SCR

Topo do SCR										
Parâmetro:		Nós na Camada Oculta								
Quantidade de Nós:										
2	5	7	10	12	15	18	20	25	30	
Casos avaliados:										
NE02		NN04		SE06		SW03		WW07		EE11
Detalhes:		20 iterações para cada valor de nó; máximo de 500 épocas por treino; 5 atrasos na série temporal em todos os casos.								

Como discutido no Capítulo 2, uma vez que os pesos das redes neurais são iniciados aleatoriamente, cada treino resultará num valor mínimo de erro diferente. Deste modo é necessário, para cada valor de quantidade de nós, repetir o treino a fim de avaliar a configuração pela distribuição estatística de seus erros (média e desvio padrão).

Neste estudo adotou-se 20 iterações (PINA *et al.*, 2013) para cada quantidade de nós das redes. O limite máximo de épocas de treinamento foi 500. A quantidade de atrasos das séries temporais foi mantida fixa em 5 passos de tempo. A Figura 31 apresenta o resultado do estudo para o caso de carregamento NN04, como um exemplo. Ressalta-se, como feito para o exemplo simples apresentado no item 2.6, que o comprimento da barra de dispersão representando o desvio padrão pode atingir a região negativa do gráfico devido a escala.




Figura 31 – Estudo de sensibilidade de nós, caso de carregamento NN04

Os demais resultados podem ser encontrados no Anexo A, ao final do trabalho. De modo geral, com uma quantidade pequena de nós, o erro médio quadrático tende a ser alto e apresentar grande variação a cada vez que o treino é repetido. Por outro lado, quando o número de nós é muito elevado, não ocorre ganho expressivo em desempenho. Observa-se, ainda, que para alguns dos casos e respostas estruturais, não há uma tendência clara do comportamento do desempenho quanto à variação do número de nós.

Após foi realizado estudo semelhante para a quantidade de atrasos das séries temporais. Fixando o valor da quantidade de nós de 10 para a resposta de tração e de 12

para os momentos, os atrasos foram variados de 2 a 40. A Tabela 11 exibe o sumário deste novo estudo de sensibilidade.

Tabela 11 – Estudo de sensibilidade de atrasos, topo do SCR

Topo do SCR						
Parâmetro:		Atrasos da Série Temporal				
Valores dos Atrasos:						
2	5	10	15	20	30	40
Casos avaliados:						
NE02	NN04	SE06	SW03	WW07	EE11	
Detalhes:		20 iterações para cada valor de nó; máximo de 200 épocas por treino; Nós na camada oculta: 10 para tração T e 12 para My/Mz				

A Figura 32 apresenta o resultado deste estudo para o caso NN04, como um exemplo novamente. Os demais resultados são, também, encontrados no Anexo A.




Figura 32 – Estudo de sensibilidade de atrasos, caso de carregamento NN04

O desempenho da rede apresenta comportamento similar ao anteriormente observado para a variação dos nós. Não ocorre melhora substancial do desempenho após certa quantidade de atrasos da série temporal.

Os resultados das análises de sensibilidade e a aplicação de redes para verificação em casos isolados indicam que para a maior parte dos casos:

- Para a tração (T): 10 nós na camada oculta e 10 atrasos das séries temporais são adequados;

- Para os momentos (M_y e M_z): 12 nós na camada oculta e 10 atrasos das séries temporais são suficientes.

Alguns casos apresentaram resultados não satisfatórios para essas arquiteturas de rede. Notadamente os casos com excitações dinâmicas reduzidas, ondas de $H_s = 0.25\text{m}$ e $T_p = 5.95\text{s}$. Através de testes para estes casos de carregamento, observou-se que reduzir os atrasos temporais melhora o desempenho da rede (2 passos de tempo para a tração e 5 para os momentos). Isto faz sentido uma vez que o efeito dinâmico de resposta deve perder importância nesses casos ou, ainda, uma rede de tamanho elevado oferece muito maior poder que a complexidade da resposta desses casos.

Como uma rede neural foi treinada para cada uma das 3 respostas estruturais (T , M_y e M_z) e para cada um dos 88 estados de mar, ao final a metodologia AEF-RN empregou 264 redes neurais treinadas para o topo do SCR. A Figura 33 apresenta um exemplo das séries temporais normalizadas utilizadas durante os treinos.




Figura 33 – Exemplo de series temporais do treino, caso de carregamento SW07, topo do SCR

5.2.2-B Esforços Globais

As redes treinadas anteriormente com amostras de 500 segundos foram utilizadas para prever o restante dos 3600 segundos das respostas estruturais. As Figuras 34 a 36 apresentam janelas das séries temporais da tração T e dos momentos locais M_y e M_z , obtidos pelas redes neurais (metodologia híbrida AEF-RN), comparados com os resultados da análise de elementos finitos completa (AEF). O caso

de carregamento é o NN10. A concordância é muito boa: as respostas se sobrepõem na maior parte do tempo.




Figura 34 – Séries temporais da tração T , caso de carregamento NN10




Figura 35 – Séries temporais do momento My , caso de carregamento NN10




Figura 36 – Séries temporais do momento M_z , caso de carregamento NN10

Outro modo eficaz de avaliar o desempenho é por meio da comparação dos valores estatísticos das respostas. As Figuras 37 a 39 apresentam os valores médios e desvios padrões dos esforços, para os casos de carregamento com estados de mar de ondas vindas da direção Noroeste (NW01, NW02, ..., NW11). A Tabela 12 apresenta os valores de correlação entre as séries temporais dos esforços globais, para os casos com ondas da direção Sudoeste (SW).




Figura 37 – Valores estatísticos da tração T , casos com ondas da direção NW




Figura 38 – Valores estatísticos do momento M_y , casos com ondas da direção NW




Figura 39 – Valores estatísticos do momento M_z , casos com ondas da direção NW

Tabela 12 – Correlação entre respostas, casos com ondas da direção SW

<i>Correlação respostas globais, topo do SCR</i>			
Caso de carregamento	T	MY	MZ
SW01	1.000	0.999	1.000
SW02	0.998	0.999	0.998
SW03	1.000	1.000	1.000
SW04	1.000	1.000	1.000
SW05	1.000	0.999	1.000
SW06	1.000	0.999	1.000
SW07	1.000	0.996	1.000
SW08	1.000	0.998	1.000
SW09	1.000	0.999	1.000
SW10	1.000	0.995	1.000
SW11	1.000	0.996	1.000

Os parâmetros estatísticos observados indicam boa acurácia das predições dos esforços globais pela metodologia AEF-RN, no topo do SCR. No Anexo B, ao final deste trabalho, são encontrados os demais parâmetros estatísticos: curtose, coeficiente de assimetria e valor de correlação das respostas da AEF bem como as respectivas diferenças relativas percentuais das respostas obtidas pela AEF-RN, para todos os casos.

5.2.2-C Tensões e Danos

Com os esforços estruturais globais preditos via AEF-RN, a tensão é avaliada para os oito pontos da seção transversal, nas superfícies interna e externa através da expressão (3.19). A Figura 40 apresenta uma janela da série temporal da tensão, para o ponto na superfície externa a 225°, caso de carregamento SE06. Há grande concordância quando comparada com a análise de elementos finitos completa.




Figura 40 – Tensão na superfície externa a 225°, caso de carregamento SE06

Na Figura 41 são encontrados os valores estatísticos da média e desvio padrão para os casos de carregamento com ondas vindas de Sudeste, considerando a tensão num ponto na superfície externa, a 270°. Enquanto na Tabela 13 podem ser observadas os valores de correlação da tensão estimadas, entre as metodologias AEF-RN e AEF, para os pontos na superfície externa da seção transversal e casos da direção Norte.




Figura 41 – Valores estatísticos de tensão, superfície externa a 270°, casos com ondas da direção SE

Tabela 13 – Correlação tensão, casos com ondas da direção NN

<i>Correlação valores de tensão na superfície externa, topo do SCR</i>								
	0°	45°	90°	135°	180°	225°	270°	315°
NN01	1.000	1.000	1.000	0.993	1.000	1.000	1.000	0.993
NN02	1.000	1.000	1.000	0.996	0.999	1.000	1.000	0.997
NN03	1.000	1.000	1.000	0.997	1.000	1.000	1.000	0.999
NN04	0.998	0.999	0.999	0.986	0.999	1.000	1.000	0.994
NN05	0.999	1.000	0.999	0.980	1.000	1.000	0.999	0.993
NN06	0.999	1.000	1.000	0.989	1.000	1.000	1.000	0.997
NN07	0.999	0.999	0.999	0.972	0.999	1.000	1.000	0.992
NN08	0.996	0.999	0.999	0.916	0.998	0.999	0.999	0.971
NN09	0.999	1.000	1.000	0.974	1.000	1.000	1.000	0.992
NN10	0.999	0.999	0.999	0.972	0.999	1.000	1.000	0.992
NN11	0.998	0.999	0.999	0.938	0.999	0.999	1.000	0.979

Como visto, as tensões obtidas pela metodologia AEF-RN também apresentam boa concordância com a análise de elementos finitos completa. No Anexo C, os valores de correlação das séries de tensão para os demais casos de carregamento são apresentados.

Realizando a soma ponderada dos danos para todos os casos de carregamento (expressão 3.18), os danos anuais totais avaliados pelas duas metodologias podem ser comparados. Na Figura 42 é apresentado o dano relativo total, D_{AEF-RN} / D_{AEF} .




Figura 42 – Danos relativos, topo do SCR

Outra forma de comparação é definindo uma diferença relativa para a resposta do dano pela metodologia híbrida AEF-RN, em relação à AEF:

$$\varepsilon_{AEF-RN} = \frac{|D_{AEF-RN} - D_{AEF}|}{D_{AEF}} \cdot 100\% \quad (5.2)$$

onde ε_{AEF-RN} é a diferença relativa da metodologia híbrida, D_{AEF-RN} o dano anual total obtido através desta metodologia e D_{AEF} é o dano anual total computado através da análise de elementos finitos completa. Desta forma, a Tabela 14 apresenta as diferenças relativas para os danos obtidos pela AEF-RN para todos os pontos da seção transversal.

Tabela 14 – Diferenças relativas AEF-RN, topo do SCR

<i>Diferenças relativas dos danos anuais AEF-RN (%)</i>								
	0°	45°	90°	135°	180°	225°	270°	315°
Superfície Externa	0.53	0.23	0.02	0.51	0.48	0.79	0.00	0.11
Superfície Interna	0.52	1.58	0.02	0.43	0.48	0.18	0.06	0.22

A maior diferença relativa observada possui valor de 1.58% e ocorre para o ponto a 45°, na superfície interna. A complexa interação temporal entre os momentos e

tração preditos nos pontos da seção transversal faz com que seja difícil estimar em que ponto da seção a metodologia AEF-RN apresenta pior desempenho, antes da avaliação do dano total final.

À primeira vista, poderia ser considerado improvável o maior erro ocorrer para a superfície interna do duto, uma vez que os momentos têm maior influência na superfície externa. Porém, há que se ter em mente que as tensões são avaliadas por séries temporais preditas combinando a tração e os momentos. Como o dano é avaliado pela contagem de ciclos, podem ocorrer situações em que a diferença de um esforço diminua a influência da diferença de outro esforço, aproximando os valores de tensão ao fim.

Entretanto a diferença relativa máxima de 1.58% pode ser considerada pequena diante da economia computacional que será discutida juntamente com os resultados para os outros pontos e *risers* no item 5.4.

5.2.3 TDZ do SCR

A fim de verificar a capacidade da metodologia AEF-RN em outra zona de regime dinâmico diferente da do topo, uma seção transversal de um elemento no TDZ do SCR é avaliada.

A seção selecionada é a do elemento da discretização do MEF que toca primeiro o leito marinho, após a aplicação da corrente numa análise estática da estrutura. Desta forma, dependendo da magnitude e da direção de aplicação do *offset* do caso de carregamento, a seção avaliada no duto está mais em repouso no fundo, ou mais suspenso, experimentando diversas interações dinâmicas na região do TDZ.

O comportamento da resposta estrutural na região do TDZ apresenta elevado grau de não linearidade devido à interação com o fundo marinho (LI & LOW, 2012).

O momento local M_z é o momento responsável por mover o *riser* para fora do plano da sua configuração inicial. No topo ele possui dinâmica elevada, devido ao movimento imposto pela unidade flutuante, e vai se dissipando ao longo do comprimento do duto. No TDZ volta a apresentar alguma resposta, porém possui baixa significância em muitos casos de carregamento, principalmente quando comparado com o outro momento local M_y .

Não raro os parâmetros estatísticos da série temporal do momento M_z não atingem estabilidade em períodos curtos de tempo ou apresentam ruído numérico na

AEF. Isso é resultado da complexa combinação de interação dos movimentos da estrutura com o solo marinho e do arrasto devido ao perfil de corrente.

Diante desse cenário, optou-se por não levar em conta o efeito deste momento na avaliação da tensão da seção transversal. A tensão no TDZ do SCR é avaliada através dos esforços globais de tração T e o momento My, neste exemplo acadêmico.

5.2.3-A Redes Neurais

A fim de avaliar a influência da arquitetura de rede sobre o desempenho das redes neurais, um estudo de sensibilidade é conduzido, similar ao realizado para o topo do *riser*.

Iniciou-se o estudo pela influência da quantidade de nós na camada oculta, em processo similar ao realizado anteriormente para o topo do *riser*. A Tabela 15 apresenta um sumário do estudo. A quantidade de nós foi variada de 2 a 35.

Tabela 15 – Estudo de sensibilidade de nós, TDZ do SCR

TDZ do SCR											
Parâmetro:				Nós na Camada Oculta							
Quantidade de Nós:											
2	5	7	10	12	15	18	20	23	25	30	35
Casos avaliados:											
EE10			NE11		NN05		NW04		SE03		WW08
Detalhes:				15 iterações para cada valor de nó; máximo de 500 épocas por treino; 1 atrasos nas séries temporais em todos os casos.							

A Figura 43 apresenta o resultado das análises de sensibilidade para o caso de carregamento NE11. Os demais resultados podem ser encontrados no Anexo A, ao fim do documento.




Figura 43 – Estudo de sensibilidade de nós, caso de carregamento NE11

Para o caso particular apresentado, há tendência de redução do erro quadrático médio de validação com o aumento dos nós na camada oculta.

A seguir, realizou-se um estudo para os atrasos das séries temporais. Os atrasos são variados de 2 a 30 passos de tempo. A Tabela 16 apresenta o sumário do estudo. Uma quantidade de 10 nós na camada oculta foi utilizada para o estudo de sensibilidade dos atrasos.

Tabela 16 – Estudo de sensibilidade de atrasos, TDZ do SCR

TDZ do SCR						
Parâmetro:		Atrasos da série temporal				
Valores dos Atrasos:						
2	3	5	10	15	20	30
Casos avaliados:						
EE10	NE11	NN05	NW04	SE03	WW08	
Detalhes:		15 iterações para cada valor de nó; máximo de 200 épocas por treino; Nós na camada oculta: 10 para tração T e momento My				

Como um exemplo de resposta, tem-se o resultado para o caso NE11 exibido na Figura 44.




Figura 44 – Estudo de sensibilidade de atrasos, caso de carregamento NE11

Para o caso em particular apresentado, o erro quadrático médio de validação decresce rapidamente com um pequeno aumento da quantidade de atrasos no modelo da rede neural *NARX*. De modo geral, alguns casos apresentaram tendências similares e, para outros, não há indicação clara da relação. Novamente, o gráfico atinge a região negativa por uma questão de escala, devido ao comprimento da barra de dispersão que representa o desvio padrão.

A principal conclusão destes estudos de sensibilidade é que o desempenho das redes é mais sensível à arquitetura da rede caso a caso, em comparação às utilizadas no topo do *riser*. Tal comportamento ocorre principalmente para o momento *My* e pode ser constatado pela grande dispersão dos valores de erros obtidas para algumas arquiteturas de rede particulares (ver Anexo A). Isso era esperado uma vez que há grande variação de comportamento das respostas dinâmicas na região do TDZ: o ponto avaliado ora está mais suspenso, ora mais em repouso no leito marinho devido à magnitude e direção dos *offsets*.

Dos resultados do estudo de sensibilidade e aplicação das redes em casos isolados, as seguintes conclusões gerais são obtidas:

- Para a tração *T*: uma quantidade de nós igual a 10 e uma quantidade de atrasos de 10 é adequada na maioria dos casos;
- Para o momento *My*: a arquitetura da rede é mais sensível caso a caso. Um procedimento iterativo baseado em tentativa e erro foi

utilizado. A partir de testes expeditos, os treinos foram programados variando a arquitetura em configurações pré-determinadas. Algumas delas foram (Nós/Atrasos): 10/10, 8/10, 8/20 e 4/20.

5.2.3-B Esforços Preditos

As redes treinadas são aplicadas para prever o restante da resposta global no TDZ. As Figuras 45 e 46 apresentam uma janela das séries temporais dos esforços preditos.




Figura 45 – Séries temporais da tração T , caso de carregamento NN05




Figura 46 – Séries temporais do momento M_y , caso de carregamento NN05

Como esperado, as respostas da metodologia AEF-RN apresentam maiores dificuldades em prever o comportamento mais complexo no TDZ, quando comparada com as previsões de resposta na região do topo.

As respostas globais também são avaliadas estatisticamente. A Figura 47 apresenta os valores estatísticos da tração T , enquanto na Figura 48 podem ser observados os do momento M_y , ambos representantes dos casos de carregamento com ondas vindas da direção Sudoeste (SW).




Figura 47 – Valores estatísticos da tração T , casos com ondas da direção SW




Figura 48 – Valores estatísticos do momento M_y , casos com ondas da direção SW

Os valores médios das séries temporais de tração para os casos da direção Sudoeste são muito próximos pois os *offsets* aplicados estão numa direção perpendicular ao plano do *riser* (Figura 30), não influenciando significativamente o valor médio. A mesma explicação pode ser utilizada para o valor médio do momento local My.

Os valores de correlação entre as respostas da metodologia AEF-RN com as da AEF são encontrados na Tabela 17, para os casos de carregamento com ondas vindas da direção Noroeste (NW).

Tabela 17 – Correlação entre respostas, casos com ondas da direção NW

<i>Correlação respostas globais</i>		
Caso de carregamento	T	MY
NW01	1.000	0.974
NW02	0.999	0.950
NW03	0.999	0.997
NW04	0.998	0.953
NW05	0.994	0.996
NW06	0.991	0.872
NW07	0.995	0.967
NW08	0.995	0.972
NW09	0.998	0.969
NW10	0.993	0.971
NW11	0.986	0.951

As correlações e demais parâmetros estatísticos das respostas para os demais casos de carregamento estão disponíveis no Anexo B.

5.2.3-C Tensões e Danos

A tensão é obtida a partir dos esforços globais preditos anteriormente pela metodologia híbrida AEF-RN. A Figura 49 apresenta uma janela temporal da resposta de tensão obtida, como um exemplo.




Figura 49 – Tensão na superfície externa a 270°, caso de carregamento NE06

Observa-se mais uma vez que as previsões apresentam relativamente maiores discrepâncias, quando comparadas com os resultados da metodologia híbrida no topo do *riser*. Os valores estatísticos para a tensão num ponto na superfície externa a 270° para os casos de carregamento com ondas vindas da direção Sul são encontrados na Figura 50. A Tabela 18 apresenta os valores de correlação entre as tensões obtidas pela análise completa AEF e a metodologia híbrida AEF-RN (carregamentos com ondas da direção Oeste).




Figura 50 – Valores estatísticos de tensão, superfície externa à 270°, casos com ondas da direção SS

Tabela 18 – Correlação tensão, casos com ondas da direção WW

	<i>TDZ do SCR, superfície externa</i>							
	0°	45°	90°	135°	180°	225°	270°	315°
WW01	0.993	0.971	0.970	0.971	0.993	0.970	0.970	0.970
WW02	0.979	0.981	0.979	0.981	0.979	0.974	0.974	0.974
WW03	0.917	0.916	0.913	0.916	0.917	0.907	0.900	0.907
WW04	0.981	0.982	0.982	0.982	0.981	0.979	0.979	0.979
WW05	0.984	0.984	0.984	0.984	0.984	0.984	0.984	0.984
WW06	0.960	0.960	0.960	0.960	0.960	0.960	0.960	0.960
WW07	0.985	0.984	0.984	0.984	0.985	0.985	0.985	0.985
WW08	0.965	0.965	0.965	0.965	0.965	0.966	0.966	0.966
WW09	0.959	0.958	0.958	0.958	0.959	0.959	0.959	0.959
WW10	0.973	0.972	0.972	0.972	0.973	0.973	0.973	0.973
WW11	0.958	0.958	0.958	0.958	0.958	0.958	0.958	0.958

Ponderando os danos de curto prazo pela probabilidade de ocorrência dos casos de carregamento e somando; o dano total relativo entre as metodologias é apresentado na Figura 51. A Tabela 19 apresenta as diferenças relativas dos danos totais da metodologia híbrida AEF-RN nos diversos pontos da seção transversal.




Figura 51 – Danos relativos, TDZ do SCR

Tabela 19 – Diferenças relativas AEF-RN, TDZ do SCR

	<i>Diferenças relativas dos danos anuais AEF-RN (%)</i>							
	0°	45°	90°	135°	180°	225°	270°	315°
Superfície Externa	4.27	2.13	2.03	2.13	4.27	1.43	1.47	1.43
Superfície Interna	4.27	2.25	2.11	2.25	4.27	1.40	1.39	1.40

Os pontos a 0° e 180° apresentaram as maiores diferenças relativas (4.27%). Nesses pontos a tensão é regida somente pela tração (Figura 25), uma vez que o

momento M_z foi desconsiderado. Nesses pontos os danos anuais totais são muito baixos, principalmente quando comparados com os pontos que possuem influência do momento M_y , como pode ser observado na Figura 52. Nela são apresentados os danos normalizados na superfície externa, ou seja, os danos divididos pelo dano máximo observado pela AEF. O maior dano é registrado no ponto a 270° .

Para os pontos localizados a 0° e 180° , o dano total anual se encontra distribuído numa quantidade de casos de carregamento maior (Tabela 20), quando comparado com os pontos sob influência do momento, e os danos são de pequena magnitude. Assim as maiores diferenças relativas para estes pontos podem ser explicadas pela dificuldade de predição para danos de valores de baixa magnitude em uma quantidade maior de casos de carregamento que contribuem para o dano anual total final.




Figura 52 – Danos anuais normalizados, superfície externa, TDZ do SCR

Tabela 20 – Contribuição dos casos de carregamento ao dano total final, TDZ do SCR

<i>Ponto na superfície externa a 0°</i>				
Caso de carregamento	AEF		AEF-RN	
	Dano Acumulado (%)	Caso de carregamento	Dano Acumulado (%)	Dif. Rel. Dano (%)
NN06	10.00%	NN06	9.99%	4.44%
NN05	19.29%	NN05	19.70%	0.17%
NN07	26.66%	NN07	27.28%	1.69%
NN08	31.40%	NN08	32.34%	2.35%
NN04	36.04%	NN04	36.86%	6.80%
NW06	39.86%	NW06	41.19%	8.59%
NW05	43.36%	NW05	44.69%	4.35%
SS06	46.29%	SS06	47.41%	11.13%
SS07	49.10%	SS07	50.12%	7.87%
NW07	51.88%	NW07	52.76%	9.06%
NN09	54.45%	NN09	55.28%	5.93%
SW06	56.99%	SW06	57.71%	8.28%

Como esperado, a complexa interação entre a estrutura e o fundo marinho resulta numa acurácia um pouco menor da metodologia AEF-RN na predição dos esforços globais no TDZ, como pode ser observado pelos parâmetros estatísticos dos esforços globais apresentados no Anexo B.

Apesar disso, os valores das diferenças relativas dos danos anuais totais nos diversos pontos podem ser considerados adequados em termos práticos (menores que 5%). A comparação e comentários finais dos resultados, relacionando a economia de esforço computacional, são deixados para o item 5.4.

A seguir é apresentado uma investigação a fim de avaliar o comportamento da resposta predita no TDZ com a introdução de um sinal não-linear no treino e predição das redes neurais.

5.2.3-D Teste com Rede Neural Modificada

Pensando em estudar o comportamento das redes no TDZ com a introdução de um sinal não-linear, uma alteração nas entradas das redes foi investigada. Um sinal adicional foi empregado, constituído do movimento vertical no topo elevado ao quadrado (Z^2).

Deste modo, as redes neurais empregadas nesta investigação possuem 8 tipos de entradas: os 3 movimentos de translação globais, os 3 movimentos rotacionais, o movimento vertical quadrático adicional e o atraso da resposta estrutural considerada. Na Figura 53 é observada uma amostra das séries temporais normalizadas utilizadas nos treinos das redes neurais para o TDZ.




Figura 53 – Séries temporais de treino - redes modificadas, caso de carregamento NW04, TDZ do SCR

Um estudo de sensibilidade foi conduzido da mesma forma que o realizado para as redes com as entradas usuais (item 5.2.3-A anterior). Os resultados dos estudos de sensibilidade levam às mesmas conclusões dos realizados para as redes com os sinais de entrada usuais: a performance das redes é mais sensível à arquitetura da rede neural. Desta forma, um procedimento de treino iterativo por tentativa e erro foi aplicado para o treinamento das redes.

As redes neurais treinadas com o sinal não-linear adicional apresentaram uma performance um pouco superior na predição dos esforços globais, quando comparadas com as redes com sinais de entrada usuais. A Tabela 21 apresenta os valores médios e desvios padrões (considerando todos os casos de carregamento) das diferenças relativas percentuais e dos coeficientes de correlação entre os parâmetros estatísticos das respostas globais preditos pelas duas configurações de rede (em relação à AEF).

Em geral, os valores médios indicam que as diferenças relativas dos parâmetros estatísticos são menores para os esforços preditos pelas redes neurais com a adição do sinal não-linear (Z^2). O valor médio do coeficiente de correlação é maior para as redes com o sinal adicional e os desvios padrões são menores, indicando que as diferenças relativas possuem menos dispersão, também.

Tabela 21 – Comparação das diferenças relativas entre redes, TDZ do SCR

Valores médios e desvios padrões das diferenças relativas dos parâmetros estatísticos dos esforços obtidos pelas redes usuais e a modificada (comparadas com a AEF)

Esforço	Parâmetro Estatístico	Redes Modificadas (Z^2)		Redes Usuais	
		Valor médio	Desvio padrão	Valor médio	Desvio padrão
Tração T	Média	0.04%	0.15%	0.04%	0.15%
	Desvio padrão	-0.23%	1.55%	1.20%	2.13%
	Coef. Correlação	0.9906	0.012	0.9893	0.0139
Momento MY	Média	-0.19%	1.03%	-0.07%	0.86%
	Desvio padrão	2.29%	9.26%	3.05%	11.24%
	Coef. Correlação	0.9587	0.091	0.9409	0.1372

Os danos totais anuais finais são então obtidos através das redes neurais treinadas com o sinal adicional (Z^2). A Figura 54 apresenta os danos relativos finais e na Tabela 22 são encontradas as diferenças relativas dos danos anuais finais.




Figura 54 – Danos relativos - redes modificadas (Z^2), TDZ do SCR

Tabela 22 – Diferenças relativas AEF-RN - redes modificadas, TDZ do SCR

<i>Diferenças relativas dos danos anuais AEF-RN (%)</i>								
	0°	45°	90°	135°	180°	225°	270°	315°
Superfície Externa	0.45	3.53	3.48	3.53	0.45	3.37	3.36	3.37
Superfície Interna	0.45	3.47	3.46	3.47	0.45	3.23	3.42	3.23

Observa-se que a melhoria obtida para as predições da tração diminuiu consideravelmente a diferença relativa dos danos nos pontos localizados a 0° e 180°, onde só há influência da tração.

Para os pontos sobre influência também do momento M_y , a diferença relativa é maior que os obtidos com as redes de entradas usuais, apesar da melhora da predição dos esforços em geral. Isto ocorre porque o dano final para esses pontos da seção transversal é composto pela participação relevante de poucos casos de carregamento e para estes casos, a performance das redes com o sinal não-linear adicional foi inferior à das redes de configuração usual, conforme pode ser observado na Tabela 23 (ponto na superfície externa a 270°).

As diferenças relativas dos danos anuais finais máximas registradas para as análises realizadas com as duas configurações de redes neurais possuem a mesma ordem de grandeza (4.3% e 3.5%). Desta forma, para efeito prático final, pode-se considerar que não há diferença em adicionar um sinal não-linear na entrada das redes neurais na avaliação do dano final de fadiga.

Tabela 23 – Contribuição dos casos de carregamento - redes modificadas, TDZ do SCR

<i>Ponto na superfície externa à 270°</i>					
Caso	Redes Modificadas (Z^2)		Caso	Redes Usuais	
	Dano Acumulado (%)	Dif. Dano Acumulado (%)		Dano Acumulado (%)	Dif. Dano Acumulado (%)
SW06	19.55%	4.83%	SW06	18.00%	8.02%
SW05	35.12%	3.83%	SW05	34.51%	2.74%
SW07	50.50%	4.37%	SW07	49.76%	1.98%
SW08	59.85%	4.50%	SW08	59.55%	0.87%
NE06	66.31%	4.11%	NE06	66.24%	0.85%
SW04	72.70%	3.91%	SW04	72.45%	1.28%
NE05	78.06%	3.46%	NE05	78.32%	1.04%
NE07	83.41%	3.55%	NE07	83.65%	1.00%
SW09	87.90%	3.50%	SW09	88.05%	1.17%
NE08	91.29%	3.53%	NE08	91.37%	1.22%
NE04	93.80%	3.34%	NE04	93.84%	1.44%
SW10	95.87%	3.35%	SW10	95.99%	1.35%

5.3 Riser rígido em configuração lazy wave – SLWR

5.3.1 Modelo

Neste segundo exemplo, o *riser* rígido se encontra numa configuração *lazy wave* – SLWR, conectado à uma plataforma do tipo FPSO. A lâmina de água é de 2200m. A Tabela 24 apresenta as propriedades estruturais do SLWR.

Tabela 24 – Propriedades do SLWR

<i>Parâmetro</i>	<i>Valor</i>
Diâmetro Externo (m)	0.610 (24.00")
Diâmetro Interno (m)	0.530 (21.00")
Diâmetro Hidrodinâmico (m)	0.610 (24.00")
Módulo Elasticidade (kN/m ²)	2.07E+08
Peso Específico (kN/m ³)	77.00
Fluido Interno (kN/m ³)	9.00 (Óleo)
Pressão no topo (MPa)	26.00
Rigidez do Solo (kN/m)	1000.00
Ângulo de topo	6°
Azimute do <i>riser</i>	90°

A Figura 55 apresenta uma visão esquemática do SLWR, assim como o FPSO e os respectivos posicionamentos, e a Tabela 25 apresenta a malha de elementos finitos utilizada. O modelo do *riser* inclui uma mísula e uma *flexjoint* no topo. O

comportamento dos RAO para *heave*, para algumas direções de incidência, foi apresentado no Capítulo 3, Figura 55.




Figura 55 – Visão esquemática do SLWR

Tabela 25 – Malha de elementos finitos do SLWR

Seg.	Comprimento (m)	Quantidade de elementos	Comp. inicial do elemento (m)	Comp. final do elemento (m)
1	15	150	0.10	0.10
2	200	364	0.10	1.00
3	4007	4007	1.00	1.00

Os casos de carregamento são os mesmos empregados no estudo de caso do SCR, e apresentados no item 5.1. Porém, devido à lâmina de água ser maior no presente caso, o perfil de corrente foi expandido até a profundidade do atual modelo, conforme a Tabela 26. Os *offsets* aplicados seguem a mesma regra do SCR (expressão 5.1), porém utilizando a lâmina de água do atual modelo (2200m).

Tabela 26 – Perfil da corrente empregada, SLWR

<i>LDA (m)</i>	<i>Velocidade (m/s)</i>	<i>Azimute de Propagação (°)</i>
0	0.35	160
50	0.40	165
100	0.50	163
150	0.40	150
250	0.30	161
350	0.20	159
450	0.20	194
550	0.15	171
650	0.10	207
750	0.20	204
900	0.15	159
1050	0.20	180
1220	0.10	180
1298	0.10	180
1299.5	0.10	180
1300	0.10	180
2200	0.00	--

5.3.2 Topo do SLWR

A metodologia AEF-RN é empregada e avaliada numa seção transversal de um elemento no topo do SLWR, após a mísula e à aproximadamente 5.1m da conexão do *riser*.

5.3.2-A Redes Neurais

Como nos estudos de caso anteriores, um estudo de sensibilidade é realizado para avaliar as possíveis arquiteturas de rede mais adequadas. O estudo é realizado primeiramente para a quantidade de nós da camada oculta, e sua organização é apresentada na Tabela 27. A quantidade de nós na camada oculta é variada entre 2 a 30 nós.

Tabela 27 – Estudo de sensibilidade de nós, topo do SLWR

topo do SLWR									
Parâmetro:			Nós na Camada Oculta						
Quantidade de Nós:									
2	5	7	10	12	15	18	20	25	30
Casos avaliados:									
EE11	NN04		NW06		SE05		SW08		WW11
Detalhes:			15 iterações para cada valor de nó; máximo de 500 épocas por treino; 5 atrasos nas séries temporais em todos os casos.						

Como um exemplo, o resultado do estudo dos nós para o caso SW08 é exibido na Figura 56. Para o caso apresentado, um aumento da quantidade de nós na camada oculta diminui rapidamente o erro quadrático médio de validação durante o treino, para os esforços de tração T e momento local Mz. O aumento contínuo da quantidade de nós não apresenta melhora substancial da rede, para esse caso e estes esforços (T e Mz). Para o momento local My, o erro quadrático médio tende a ser reduzido com o aumento da quantidade de nós de maneira bem mais suave.




Figura 56 – Estudo de sensibilidade de nós, caso de carregamento SW08

Em seguida, um estudo é efetuado para avaliar a quantidade de atrasos das séries temporais na rede neural NARX. O sumário do estudo é encontrado na Tabela 28. A quantidade de atrasos das séries temporais é avaliada de 2 a 40 atrasos.

Tabela 28 – Estudo de sensibilidade de atrasos, topo do SLWR

topo do SLWR						
Parâmetro:		Atrasos da Série Temporal				
Valores dos Atrasos:						
2	5	10	15	20	30	40
Casos avaliados:						
EE11	NN04	NW06	SE05	SW08	WW11	
Detalhes:		15 iterações para cada valor de nó; máximo de 200 épocas por treino. Nós na camada oculta: 10 para a tração T e 12 para os momentos M _y /M _z				

O resultado do estudo dos atrasos é apresentado na Figura 57, também para o caso SW08. Para os três esforços estruturais preditos, observa-se que o comportamento é similar: um pequeno aumento inicial da quantidade de atrasos reduz significativamente o erro quadrático médio de validação. Posteriormente, com elevadas quantidades de atrasos, o erro volta a crescer (T e My) ou não apresenta melhora significativa (Mz).




Figura 57 – Estudo de sensibilidade de atrasos, caso de carregamento SW08

Os demais resultados dos estudos de sensibilidade estão disponíveis no Anexo A, ao final do documento. Comportamento geral similar ao ocorrido para o topo e o TDZ do SCR é observado. Em geral, o erro quadrático médio de validação diminui até certa quantidade de nós/atrasos, apresentando crescimento em seguida. Em determinados casos não há tendência clara da influência da arquitetura sobre a performance da rede.

Os estudos de sensibilidade e a aplicação das redes em alguns casos para teste indicam que, para a maioria dos casos:

- Para a tração T: 10 nós na camada oculta e 10 atrasos são adequados;
- Para os momentos locais My e Mz: 12 nós na camada oculta e 10 atrasos são adequados;

Apesar dessas arquiteturas gerais indicadas, em alguns casos a predição das redes não foi adequada, tanto na tração como nos momentos. Sendo assim, utilizou-se um processo de treinamento similar ao empregado no TDZ do SCR. Algumas configurações selecionadas são treinadas em processo iterativo sequencial. Algumas configurações empregadas foram (Nós/Atrasos): 10/5, 15/5; 10/2, 3/20, 3/20, 5/2.

5.3.2-B Esforços Preditos

Utilizando as redes treinadas anteriormente, os esforços globais são preditos do final do treino, 500 segundos, até 3600 segundos. As Figuras 58 a 60 apresentam janelas das séries temporais preditas via AEF-RN, comparadas com os valores da análise dinâmica de elementos finitos completa, AEF. A tração é apresentada com um intervalo temporal menor para melhor visualização das séries.




Figura 58 – Séries temporais de tração T, caso de carregamento EE08




Figura 59 – Séries temporais do momento My, caso de carregamento EE08




Figura 60 – Séries temporais do momento M_z , caso de carregamento EE08

Os valores estatísticos de média e desvio padrão das previsões e das respostas estruturais são apresentados nas Figuras 61 a 63, para casos de carregamento com ondas vindas da direção Sudoeste (SW).




Figura 61 – Valores estatísticos da tração T , casos com ondas da direção SW




Figura 62 – Valores estatísticos do momento M_y , casos com ondas da direção SW




Figura 63 – Valores estatísticos do momento M_z , casos com ondas da direção SW

O valor médio da tração não apresenta diferença perceptível entre os casos de carregamento, uma vez que a configuração *lazy wave* da linha faz com que o comprimento suspenso não sofra influência perceptível nos gráficos pelo *offset* aplicado.

Os resultados apontam que as diferenças da metodologia híbrida AEF-RN aplicada no topo do SLWR são maiores em relação às encontradas no topo do SCR. Na Tabela 29 são encontrados os valores de correlação das respostas estruturais para os

casos de carregamento com ondas vindas da direção Sudeste. Os valores dos demais parâmetros estatísticos e as diferenças percentuais são encontradas no Anexo B, ao final.

Tabela 29 – Correlação entre respostas, casos com ondas da direção SE

<i>Correlação respostas globais, topo do SLWR</i>			
Caso de carregamento	T	MY	MZ
SE01	1.000	0.904	0.982
SE02	0.997	0.991	0.992
SE03	1.000	0.984	0.997
SE04	0.997	0.982	0.997
SE05	1.000	0.990	0.997
SE06	0.999	0.997	0.991
SE07	0.999	0.996	0.996
SE08	0.998	0.999	0.998
SE09	0.989	0.998	0.968
SE10	0.997	0.999	0.996
SE11	0.999	1.000	0.964

De modo geral, as redes apresentaram maiores dificuldades na predição dos esforços. As correlações apresentaram valores relativamente baixos para alguns casos (Anexo B), principalmente para os momentos locais.

Possíveis justificativas para tal são a utilização do modelo de *flexjoint*, permitindo rotações relativas no topo (diferentes das impostas pelo RAO) e o diâmetro elevado do *riser* que pode resultar em carregamento hidrodinâmico pelas ondas mais relevante ao longo do *riser*. Em ambos os casos, as rotações relativas observadas no topo da linha e o carregamento das ondas sobre o comprimento do duto não são representados diretamente como entradas das redes neurais *NARX*.

5.3.2-C Tensões e Danos

As tensões para os pontos da seção transversal são obtidas com as respostas globais preditas pela metodologia híbrida, expressão (3.19). A Figura 64 apresenta uma janela da série temporal de tensão para o caso WW06, como um exemplo.




Figura 64 – Tensão na superfície externa a 315°, caso de carregamento WW06

Apesar das maiores limitações das previsões das respostas globais da metodologia híbrida AEF-RN para alguns casos, há grande concordância da série temporal de tensão para o caso apresentado, por exemplo. Ainda, na Figura 65 são observados os valores estatísticos para a tensão num ponto na superfície externa a 270°, para os casos com ondas vindas da direção Nordeste. Já a Tabela 30 apresenta os coeficientes de correlação dos sinais de tensão para os pontos na superfície externa, carregamentos da direção Norte.




Figura 65 – Valores estatísticos de tensão, superfície externa a 270°, casos com ondas da direção NE

Tabela 30 – Correlação tensão, casos com ondas da direção NN

<i>Topo do SLWR, superfície externa</i>								
	0°	45°	90°	135°	180°	225°	270°	315°
NN01	0.754	0.751	0.752	0.758	0.765	0.772	0.771	0.762
NN02	0.665	0.681	0.715	0.699	0.689	0.719	0.744	0.703
NN03	0.922	0.929	0.939	0.935	0.932	0.940	0.947	0.935
NN04	0.999	0.999	1.000	0.999	0.999	0.999	1.000	0.999
NN05	0.998	0.999	1.000	0.999	0.998	0.999	1.000	0.999
NN06	0.981	0.980	0.979	0.978	0.979	0.981	0.982	0.982
NN07	0.998	0.999	1.000	0.999	0.998	0.999	1.000	0.999
NN08	0.998	0.999	0.999	0.998	0.998	0.998	0.999	0.999
NN09	0.996	0.997	0.997	0.996	0.995	0.996	0.997	0.997
NN10	0.998	0.998	0.999	0.998	0.997	0.998	0.999	0.999
NN11	0.994	0.993	0.992	0.990	0.990	0.992	0.994	0.994

Para a direção Norte, pode-se concluir que as tensões não apresentam boas concordâncias para os casos de carregamento com pouca excitação dinâmica. Porém, espera-se que tais casos resultem em danos de baixas magnitudes e que, combinados com suas respectivas baixas frequências de ocorrências (Tabela 5), contribuam pouco para o dano total anual.

Para a avaliação final, o dano total anual é computado. Na Figura 66 são apresentados os danos totais relativos para os pontos da seção transversal, enquanto a diferença relativa dos danos da metodologia híbrida é encontrada na Tabela 31.




Figura 66 – Danos relativos, topo do SLWR

Tabela 31 – Diferenças relativas AEF-RN, topo do SLWR

<i>Diferenças relativas dos danos anuais AEF-RN (%)</i>								
	0°	45°	90°	135°	180°	225°	270°	315°
Superfície Externa	0.56	0.59	1.49	1.41	0.54	0.61	1.18	1.14
Superfície Interna	0.29	0.40	1.07	1.50	0.60	0.33	1.01	0.99

A maior diferença relativa observada possui valor de 1.50% e ocorre para o ponto na superfície interna a 135°. A ordem de grandeza é a mesma da máxima diferença relativa registrada com o emprego da metodologia AEF-RN no topo do SCR (1.58%). Apesar adversidade um pouco maior da predição dos esforços globais, principalmente para os momentos, a diferença relativa final apresenta valor baixo. Comentários são realizados no próximo item.

5.4 Resumo dos Resultados

Neste item um resumo dos resultados dos estudos de caso é realizado em conjunto com comentários.

A Tabela 32 apresenta as maiores e menores diferenças relativas dos danos anuais totais de fadiga obtidos através da aplicação da metodologia híbrida (AEF-RN) nos estudos de caso, em relação à análise de elementos finitos completa (AEF).

Tabela 32 – Resumo comparativo dos resultados

<i>Diferenças relativas danos anuais AEF-RN</i>		
<i>Local e riser</i>	<i>Diferença relativa máxima</i>	<i>Ponto da seção transversal</i>
Topo do SCR	1.58%	45°, sup. interna
TDZ do SCR	4.27%	0° e 180°, sup. ext./int.
	3.53% (redes Z ²)	45°, sup. externa
Topo do SLWR	1.50%	135°, sup. interna
<i>Local e riser</i>	<i>Diferença relativa mínima</i>	<i>Ponto da seção transversal</i>
Topo do SCR	0.00%	270°, sup. externa
TDZ do SCR	1.40%	225° e 315°, sup. interna
	0.45% (redes Z ²)	0° e 180°, sup. int./ext.
Topo do SLWR	0.29%	0°, sup. interna

Pode-se observar que não há como determinar previamente o ponto da seção transversal que apresentará a maior diferença relativa, uma vez que a tensão é determinada pela combinação de esforços globais (T, My e Mz) preditos e o dano é obtido pela contagem temporal dos ciclos de variação de tensão.

O mais importante, entretanto, é que as diferenças relativas máximas apresentam valores baixos (sempre menores que 5%), enquanto a menor diferença relativa mínima é nula até a segunda casa decimal percentual. As diferenças se tornam ainda menores quando se tem em mente que o valor do fator de segurança empregado para o dano em projeto à fadiga pode chegar a 10 (DNV-OS-F201, 2010).

As predições temporais dos esforços pelas redes neurais foram realizadas de 500 até 3600 segundos nos dois estudos de caso do presente trabalho. Utiliza-se 500 segundos de análise por elementos finitos, para cada caso de carregamento, para fornecer as respostas estruturais utilizadas nos treinos das redes. Assim a economia de tempo é expressa por:

$$\eta_{tempo} = \frac{T_s}{T_T} = \frac{3600}{500} = 7.20 \quad (5.2)$$

Porém, as séries de curto prazo poderiam ser obtidas para períodos maiores (a partir de séries de movimentos determinados pelo RAO mais longas). Desse modo, respostas de 10800 segundos (3 horas) poderiam ser obtidas facilmente e a economia de tempo é de:

$$\eta_{tempo} = \frac{T_s}{T_T} = \frac{10800}{500} = 21.60 \quad (5.3)$$

Ou seja, a redução do custo computacional obtido com a metodologia híbrida AEF-RN é superior à 20 vezes (para predições de 3 horas). Considerando as diferenças relativas dos danos anuais de fadiga observadas nos estudos de caso, conclui-se que a metodologia cumpre com a diminuição do tempo total de análise, sem descaracterizar os resultados finais da análise de fadiga.

Num estudo inicial ocorreram dificuldades na aplicação das redes neurais para predição dos momentos na região da corcova inferior (*sag bend*) do SLWR (já a predição da tração axial nessa região pôde ser realizada facilmente). Devido à exequibilidade dentro do prazo, a análise dessa região não pôde ser finalizada.

Capítulo 6

Conclusões e Trabalhos Futuros

Neste trabalho redes neurais foram empregadas na predição da resposta estrutural de *risers* metálicos, a fim de reduzir o esforço computacional na avaliação de fadiga. Utilizando uma pequena amostra dos esforços estruturais provida pela análise de elementos finitos, rede neurais foram treinadas e utilizadas para predição do restante da série temporal de resposta, em que tal procedimento é denominado metodologia híbrida AEF-RN.

Duas configurações de *risers* rígidos foram avaliadas: um SCR e um SLWR. No SCR foram analisadas uma seção transversal no topo e outra na região do TDZ. Para o SLWR, uma seção no topo da linha foi verificada. As respostas estruturais preditas foram a tração axial T e os momentos fletores nas direções locais M_y e M_z , utilizados para determinação da tensão em 16 pontos da seção transversal do *riser* (nas superfícies internas e externas). Com as séries temporais de tensões obtidas pelos esforços preditos, os danos foram determinados pela soma linear de *Miner* através da contagem de ciclos *rainflow* para os casos de carregamento considerados. Os danos anuais finais foram então comparados com os obtidos através da análise dinâmica completa por elementos finitos.

A maior diferença relativa entre os danos anuais finais observados foi de 4.3%, na seção transversal do duto na região do TDZ do SCR. A economia do esforço computacional atingida com a metodologia empregada é superior a 20 vezes, para predições dos esforços para casos de carregamento de 3 horas. A principal conclusão é de que o emprego de redes neurais na análise de fadiga é capaz de reduzir o custo computacional com adequada acurácia.

De maneira geral, as redes neurais apresentam facilidade no treino, e predição muita boa do esforço axial T (mesmo para regiões como o TDZ), enquanto a predição dos momentos requer mais atenção. Isto pode ser atribuído à maior não linearidade da resposta dos momentos, quando comparada com a tração.

Para a região do TDZ do SCR, uma investigação adicional foi conduzida para avaliar o comportamento das redes quando um sinal adicional não-linear é utilizado na

entrada das redes. Apesar de uma pequena melhora na predição dos esforços globais pelas redes que utilizam o sinal adicional, os valores das diferenças relativas dos danos anuais finais são da mesma ordem de grandeza com os observados a partir das redes com entradas usuais.

Neste trabalho, redes neurais foram treinadas para cada esforço estrutural (T, My e Mz) e para cada caso de carregamento. A economia computacional atingida pode ser ainda maior empregando a metodologia utilizada por CHRISTIANSEN *et al.* (2013) e CHAVES (2015). Para cada direção, alguns casos de carregamento selecionados compõe uma amostra de treino mista e uma rede neural é treinada para a resposta estrutural de todos os carregamentos daquela direção. Ou seja, as respostas dos demais casos do diagrama de dispersão são preditas pela mesma rede treinada (uma rede por esforço e por direção). Assim é possível alcançar reduções de tempo da ordem de 40 a 600 vezes.

Assim, como sugestões para estudos e investigações futuras, têm-se:

- Elaboração e implementação de uma metodologia para treinamento automático das redes neurais, eliminando o trabalho de seleção manual da arquitetura das redes;
- Estudo de uma forma de estimar a performance da rede na predição, sem as respostas provindas da AEF;
- Aplicação da metodologia híbrida AEF-RN para seções nas regiões das corcovas e região dos flutuadores do SLWR;
- Estender a avaliação da acurácia e aplicação das redes neurais para um conjunto de seções na zona do TDZ, de modo a investigar a metodologia híbrida para um comprimento maior do duto nessa região;
- Avaliar a região do TDZ de *risers* flexíveis;
- Investigar o emprego da metodologia híbrida utilizada por CHRISTIANSEN *et al.* (2013) e CHAVES (2015) para *risers* rígidos considerando todos os pontos críticos para fadiga;
- Investigar uso de uma única rede para predição simultânea da tração axial T e momentos My e Mz;
- Empregar metodologia híbrida AEF-RN para análise de extremos, em *risers* flexíveis e metálicos.

Referências Bibliográficas

ALMAR-NAESS, A., 1985, *Fatigue Handbook Offshore Steel Structures*. Tapir Publishers, Noruega.

API 5L, 2000. *API 5L Specification for Line Pipe*. American Petroleum Institute. Washington, EUA.

BAHIENSE, R.A., 2007. *Implementação e Avaliação de uma Metodologia Fortemente Acoplada para Análise de Sistemas Flutuantes Offshore*, Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil.

BATALHA, A.F., 2009. *Análise de Fadiga de Estruturas Offshore Tipo Topside*, Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil.

CAIRE, M.; SOUZA, C.E.S.; CORTINA, J.P.R., 2015. The Influence of Wind-Energy Spreading on the Riser System Response of a Spread-Moored FPSO. *Marine Systems & Ocean Technology*, Volume 10, p. 26-37.

CHAVES, V.; SAGRILO, L.V.S.; DA SILVA, V.R.M.; VIGNOLES, M.A., 2015. "Artificial Neural Networks Applied to Flexible Pipes Fatigue Calculations". *34th International Conference on Ocean, Offshore and Arctic Engineering - OMAE2015*. St. John's, Newfoundland, Canada.

CHAVES, V.V., 2015. *Artificial Neural Networks Applied to the Analysis of Flexible Pipes*, Dissertação de Mestrado, COPPE/UFRJ, Brasil.

CHEN, S.; BILLINGS, A., 1989. *Representations of Non-Linear Systems: The NARMAX model*. International Journal of Control, Volume 49, p. 1013-1032.

CHRISTIANSEN, N.H.; VOIE, P.E.T.; HOGSBERG, J.; SODAHL, N., 2013. "Efficient Mooring Line Fatigue Analysis Using a Hybrid Method Time Domain Simulation Scheme". *International Conference on Ocean, Offshore and Arctic Engineering OMAE2013*, Nantes, França.

CHRISTIANSEN, N.H.; VOIE, P.E.T.; HOGSBERG, J.; SODAHL, N., 2014. "Optimized Mooring Line Simulation Using a Hybrid Method Time Domain Scheme". *International Conference on Ocean, Offshore and Arctic Engineering OMAE2014*, São Francisco, EUA.

CYBENKO, G., 1989. Approximation by Superpositions of a Sigmoidal Function. *Mathematical Control, Signals, and Systems*, Volume 2, p. 303-314.

DANTAS, C.M.S., 2004. *Metodologia de Análise de Fadiga de Risers Rígidos no Domínio da Frequência com Utilização de Modelos Hidrodinâmicos Tridimensionais Linearizados*, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, Brasil.

DEAN, R.G.; DALRYMPLE, R.A., 2010, *Water Wave Mechanics for Engineers and Scientists*. World Scientific.

DNV-OS-F201, 2010. *Offshore Standard DNV-OS-F201 - Dynamic Risers*.

DNV-RP-C203, 2011. *Recommended Practice DNV-RP-C203 - Fatigue Design of Offshore Steel Structures*.

DNV-RP-F204, 2010. *Recommended Practice DNV-RP-F204 - Riser Fatigue*.

FALTINSEN, O.M., 1999, *Sea Loads on Ships and Offshore Structures*. Cambridge University Press.

FILHO, F.S.L., 2008. *Metodologia para Análise de Fadiga de Dutos Flexíveis Baseada em Confiabilidade Estrutural*, Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil.

GUARIZE, R., 2004. *Uso de Redes Neurais na Análise de Resposta Dinâmica de Estruturas*, Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil.

GUARIZE, R.; MATOS, N.A.F.; SAGRILO, L.V.S.; LIMA, E.C.P., 2007. Neural Networks in the Dynamic Response Analysis of Slender Marine Structures. *Applied Ocean Research*, Volume 29, p. 191-198.

HAGAN, M.T.; DEMUTH, H.B.; BEALE, M.H.; DE JESÚS, O., ISBN 0-9717321-0-8, *Neural Network Design*.

HAYKIN, S., 2005, *Neural Networks - A Comprehensive Foudation*. Prentice Hall.

HOPFIELD, J. J., 1982, "Neural Networks and Physical System with Emergent Collective Properties". *Procedings of the National Academy of Sciences of the USA*, Volume 79.

HORN, J.M.; DE JESÚS, O.; HAGAN, M.T., 2009. Spurious Valleys in the Error Surface of Recurrent Networks - Analysis and Avoidance. *IEEE Transactions on Neural Networks*, Volume 20, p. 686-700.

HORNIK, K., 1993. Some New Results on Neural Network Approximation. *Neural Networks*, Volume 6, p. 1069-1072.

LE CUN, I., 1987. *Modeles Connexionnistes de l'apprentissage*, Tese de Doutorado, Universite de Paris VI.

LI, F.Z.; LOW, Y.M., 2012. Fatigue Reliability Analysis of a Steel Catenary Riser at the Touchdown Point Incorporating Soil Model Uncertainties. *Applied Ocean Research*, Volume 38, p. 100-110.

MATHWORKS, 2014. *Neural Network Toolbox™ User's Guide*. EUA, Volume 8.2.

MATOS, N.A.F, 2005. *Predição de Séries Temporais para Análise Dinâmica de Estruturas Offshore*, Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, Brasil.

MATSUISHI, M.; ENDO, T., 1968. Fatigue of metals subjected to varying stress. *Japan Society of Mechanical Engineers*.

MCCULLOCH, W.; PITTS, W., 1943. A Logical Calculus of the Ideas Immanent in Nervous Activities. *Bulletin of Mathematical Biophysics*, Volume 5, p. 115-133.

MINSKY, M.L.; PAPERT, S.A., 1969, *Perceptrons*. MIT Press, EUA.

MOURELLE, M.M., 1993. *Análise de Sistemas Estruturais Constituídos por Linhas Marítimas*, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, Brasil.

NAESS, A.; MOAN, T., 2013, *Stochastic Dynamics of Marine Structures*. Cambridge University Press, EUA.

NEMOH, 2014. *NEMOH, Boundary Element Methods code dedicated to the computation of first order wave loads on offshore structures*. Ecole Centrale de Nantes. Nantes, França.

NGUYEN, D.; WIDROW, B., 1990, "Improving the Learning Speed of 2-Layer Neural Networks by Choosing Initial Values of the Adaptative Weights". *Proceeding of the International Joint Conference on Neural Networks*, Volume 3, p. 21-26.

PAPALEO, A., 2009. *Metodologia para Definição de Casos de Carregamentos Ambientais Equivalentes para o Projeto de Risers em Catenária*, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, Brasil.

PINA, A.C.; PINA, A.A.; ALBRECHT, C.H.; LIMA, B.S.L.P.; JACOB, B.P., 2013. ANN-based Surrogate Models for the Analysis of Mooring Lines and Risers. *Applied Ocean Research*, Volume 41, p. 76-86.

ROSENBLATT, F., 1960, "Perceptron Simulation Experiments". *Proceedings of the Institute of Radio Engineers*, p. 301-309.

RUMELHART, D.E.; MCCLELLAND, J.L., 1986, *Parallel Distributed Processing*. The MIT Press, Massachusetts, EUA.

SAGRILO, L.V.S.; LIMA, E.C.P.; SOUSA, F.J.M.; DANTAS, C.M.S.; SIQUEIRA, M.Q.; TORRES, A.L.F.L., 2005. “Steel Lazy Wave Riser Design: API-RP-2RD and DNV-OS-F201 Criteria”. *proceedings of the OMAE Conference, OMAE05/67040*, Halkidiki, Grécia.

SAINT-MARCOUX, J.; LEGRAS, J., 2014. “Impact on Risers and Flowlines Design of the FPSO Mooring in Deepwater and Ultra Deepwater”. *Offshore Technology Conference – OTC2014*, Houston, Texas.

SERTÃ, O.B.; MOURELLE, M.M.; GREALISH, F.W.; HARBERT, S.J.; SOUZA, L.F.A., 1996. “Steel Catenary Riser for the Marlim Field FPS P-XVIII”. *Proceedings of the 28th Offshore Tecnology Conference, OTC 8069*, Houston, Texas.

SMITH, M., 1993, *Neural Networks For Statistical Modeling*. Van Nostrand Reinhold, EUA.

SOUSA, F.J.M., 2005. *Estatística de Longo Prazo da Resposta Aplicada à Análise de Risers Metálicos*, Dissertação de Mestrado, COPPE/UFRJ, Rio de Jnaeiro, Brasil.

SPARKS, C.P., 1984. The Influence of Tension, Pressure and Weight on Pipe and Riser Deformations and Stresses. *Journal of Energy Resources Technology*, Volume 106, p. 46-54.

WAMIT, 2015. *WAMIT User Manual*. Massachusetts, EUA.

WERBOS, P., 1974. *Beyond Regression: New Tools for prediction and analysis in the behavioral Sciences*, Tese de Doutorado, Havard University, EUA.

WIDROW, B.; HOFF, M.E., 1960. Adaptative Switching Circuits. *IRE WESCON Convention Record*, Volume 4, p. 96-104.

Anexo A

Estudos de Sensibilidade

Neste anexo os resultados dos estudos de sensibilidade das arquiteturas de rede são apresentados para os casos selecionados, no topo e TDZ do SCR e no topo do SLWR.

A.1 Topo do SCR




Figura 67 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento NE02




Figura 68 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento NE02




Figura 69 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento NN04




Figura 70 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento NN04




Figura 71 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento SE06




Figura 72 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento SE06




Figura 73 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento SW03




Figura 74 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento SW03




Figura 75 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento WW07




Figura 76 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento WW07




Figura 77 – Estudo de sensibilidade de nós, topo do SCR, caso de carregamento EE11




Figura 78 – Estudo de sensibilidade de atrasos, topo do SCR, caso de carregamento EE11

A.2 TDZ do SCR




Figura 79 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento EE10




Figura 80 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento EE10




Figura 81 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento NE11




Figura 82 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento NE11




Figura 83 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento NN05




Figura 84 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento NN05




Figura 85 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento NW04




Figura 86 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento NW04




Figura 87 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento SE03




Figura 88 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento SE03




Figura 89 – Estudo de sensibilidade de nós, TDZ do SCR, caso de carregamento WW08




Figura 90 – Estudo de sensibilidade de atrasos, TDZ do SCR, caso de carregamento WW08

A.3 Topo do SLWR




Figura 91 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento EE11




Figura 92 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento EE11




Figura 93 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento NN04




Figura 94 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento NN04




Figura 95 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento NW06




Figura 96 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento NW06




Figura 97 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento SE05




Figura 98 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento SE05




Figura 99 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento SW08




Figura 100 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento SW08




Figura 101 – Estudo de sensibilidade de nós, topo do SLWR, caso de carregamento WW11




Figura 102 – Estudo de sensibilidade de atrasos, topo do SLWR, caso de carregamento WW11

Anexo B

Parâmetros Estatísticos Respostas Globais

Neste anexo os valores dos parâmetros estatísticos das respostas globais (T, My, Mz) são apresentados para cada caso de carregamento e local de aplicação da metodologia híbrida.

Os parâmetros estatísticos apresentados são: média μ , desvio padrão σ , coeficiente de assimetria (*skewness*) γ , coeficiente de curtose (*kurtosis*) κ e o valor do coeficiente de correlação ρ .

Os valores dos parâmetros estatísticos das respostas das análises completas de elementos finitos (AEF) são exibidos em cada coluna e a coluna imediatamente a seguir exibe a diferença relativa observada pela metodologia híbrida. A diferença relativa é determinada através da expressão:

$$\varepsilon_X = \frac{X_{AEF} - X_{AEF-RN}}{X_{AEF}} \cdot 100\% \quad (B.1)$$

onde X é o parâmetro estatístico avaliado.

B.1 Topo do SCR

Tabela 33 – Parâmetros estatísticos, tração T, topo do SCR

Tração T, topo do SCR									
Caso	μ	ε_μ	σ	ε_σ	γ	ε_γ	κ	ε_κ	ρ
NN01	1201.7	0.00%	0.3	0.95%	0.002	-457%	2.98	-2.15%	0.994
NN02	1199.7	0.00%	2.1	-0.20%	0.000	707%	2.85	0.00%	1.000
NN03	1197.6	0.00%	4.9	0.00%	0.009	-140%	3.01	0.19%	1.000
NN04	1195.5	0.00%	10.1	-0.01%	0.017	-14%	2.96	0.01%	1.000
NN05	1193.3	0.00%	14.2	-0.03%	0.025	-27%	2.95	0.04%	1.000
NN06	1191.1	0.00%	18.1	0.05%	0.032	24%	2.85	0.40%	1.000
NN07	1188.9	0.00%	21.4	0.13%	0.035	7%	2.76	0.57%	1.000
NN08	1186.7	0.00%	24.4	-0.03%	0.037	-29%	2.67	0.40%	1.000
NN09	1184.6	0.00%	27.0	-0.11%	0.046	4%	2.65	-0.14%	1.000
NN10	1182.5	0.00%	29.4	0.06%	0.063	10%	2.70	0.55%	1.000
NN11	1180.5	0.00%	31.5	0.01%	0.090	13%	2.79	1.22%	1.000
NE01	1202.8	0.00%	0.2	0.07%	0.000	-2791%	3.09	0.93%	0.999
NE02	1202.8	0.00%	1.7	0.01%	0.000	-1222%	2.89	0.15%	1.000
NE03	1202.8	0.00%	3.5	0.03%	0.003	-51%	2.95	0.12%	1.000
NE04	1202.8	0.00%	6.6	-0.02%	0.006	11%	2.93	-0.02%	1.000
NE05	1202.8	0.00%	9.1	0.05%	0.004	-2%	2.91	0.32%	1.000
NE06	1202.7	0.00%	11.8	0.01%	0.001	274%	2.82	0.42%	1.000

NE07	1202.6	0.00%	14.5	0.03%	-0.001	-819%	2.73	0.80%	1.000
NE08	1202.5	0.00%	17.1	-0.04%	-0.005	-16%	2.66	-0.22%	1.000
NE09	1202.4	0.00%	19.4	0.07%	-0.004	-110%	2.67	0.25%	1.000
NE10	1202.3	0.00%	21.6	0.04%	0.007	-13%	2.75	0.25%	1.000
NE11	1202.3	0.00%	23.6	0.26%	0.024	-1%	2.86	0.62%	1.000
EE01	1203.9	0.00%	0.5	7.33%	0.002	-838%	2.86	-11.6%	0.941
EE02	1205.9	0.00%	3.2	-0.06%	0.000	400%	2.88	1.11%	1.000
EE03	1208.0	0.00%	6.3	0.02%	0.005	57%	2.90	-0.03%	1.000
EE04	1210.1	0.00%	9.5	-0.06%	0.014	-1%	2.95	-0.10%	1.000
EE05	1212.2	0.00%	11.8	-0.08%	0.020	-4%	2.98	-0.09%	1.000
EE06	1214.2	0.00%	14.2	-0.05%	0.018	15%	2.93	-0.09%	1.000
EE07	1216.3	0.00%	16.7	0.00%	0.009	16%	2.86	0.27%	1.000
EE08	1218.4	0.00%	19.2	-0.03%	-0.002	245%	2.82	0.13%	1.000
EE09	1220.5	0.00%	21.5	-0.05%	-0.012	31%	2.84	0.38%	1.000
EE10	1222.6	0.00%	23.5	-0.07%	-0.015	-21%	2.87	0.08%	1.000
EE11	1224.7	0.00%	25.5	0.14%	0.022	-9%	3.04	1.25%	1.000
SE01	1204.2	0.00%	0.2	0.34%	0.003	-84%	3.04	0.72%	0.999
SE02	1207.2	0.00%	1.7	0.03%	0.010	-41%	2.98	0.92%	1.000
SE03	1210.3	0.00%	4.3	-0.03%	0.011	19%	3.03	0.26%	1.000
SE04	1213.1	0.00%	9.6	-0.08%	0.016	-8%	2.95	0.14%	1.000
SE05	1216.0	0.00%	13.3	-0.09%	0.018	-17%	2.94	-0.22%	1.000
SE06	1218.8	0.00%	16.8	-0.05%	0.013	10%	2.85	0.03%	1.000
SE07	1221.8	0.00%	20.1	0.07%	0.003	-53%	2.75	0.17%	1.000
SE08	1224.7	0.00%	23.2	0.01%	-0.007	31%	2.68	0.18%	1.000
SE09	1227.6	0.00%	26.0	-0.12%	-0.012	-27%	2.67	-0.34%	1.000
SE10	1230.6	0.00%	28.7	-0.20%	-0.009	-83%	2.73	-0.10%	0.999
SE11	1233.6	0.02%	31.1	-0.07%	-0.003	-190%	2.83	0.33%	1.000
SS01	1203.9	0.00%	0.3	-0.28%	0.002	-84%	3.35	4.94%	0.991
SS02	1205.9	0.00%	1.6	-1.42%	-0.005	-48%	2.82	2.91%	0.985
SS03	1208.0	0.00%	3.6	-0.02%	-0.005	9%	2.95	-0.02%	1.000
SS04	1210.0	0.00%	7.8	-0.02%	-0.006	14%	2.92	-0.09%	1.000
SS05	1212.0	0.00%	11.4	0.03%	-0.002	-26%	2.88	0.06%	1.000
SS06	1214.0	0.00%	15.2	-0.05%	0.003	97%	2.80	-0.34%	1.000
SS07	1215.9	0.00%	18.7	0.15%	0.005	161%	2.71	0.42%	1.000
SS08	1217.8	0.00%	22.0	-0.06%	0.005	-69%	2.62	0.15%	1.000
SS09	1219.7	-0.01%	25.0	0.22%	0.009	33%	2.60	0.79%	1.000
SS10	1221.7	0.00%	27.8	0.05%	0.018	50%	2.68	0.52%	0.999
SS11	1223.7	0.00%	30.4	0.27%	0.036	38%	2.81	1.21%	1.000
SW01	1202.8	0.00%	0.2	0.19%	-0.003	15%	2.87	0.26%	1.000
SW02	1202.8	0.00%	1.5	-0.17%	0.004	-55%	2.82	-1.06%	0.998
SW03	1202.8	0.00%	3.3	-0.09%	0.014	7%	2.96	-0.12%	1.000
SW04	1202.7	0.00%	6.4	-0.16%	0.031	-7%	2.98	0.00%	1.000
SW05	1202.7	0.00%	9.3	-0.09%	0.040	-17%	2.94	0.21%	1.000
SW06	1202.5	0.00%	12.2	0.02%	0.041	4%	2.83	0.16%	1.000
SW07	1202.4	0.00%	15.0	-0.03%	0.037	17%	2.73	-0.10%	1.000
SW08	1202.3	0.00%	17.6	0.01%	0.036	-1%	2.64	-0.17%	1.000
SW09	1202.2	0.00%	19.9	0.08%	0.041	9%	2.64	0.39%	1.000
SW10	1202.0	0.00%	22.1	0.06%	0.058	5%	2.72	0.41%	1.000
SW11	1201.9	0.00%	24.1	0.06%	0.088	5%	2.85	-0.35%	1.000
WW01	1201.7	0.00%	0.6	0.19%	0.000	4867%	3.09	3.58%	0.997
WW02	1199.7	0.00%	3.2	-0.09%	-0.002	58%	2.89	-0.09%	1.000
WW03	1197.6	0.00%	5.9	-0.09%	-0.001	357%	2.88	0.15%	1.000
WW04	1195.5	0.00%	9.5	-0.09%	0.009	-13%	2.98	0.20%	1.000
WW05	1193.4	0.00%	12.6	0.04%	0.025	20%	2.99	0.16%	1.000
WW06	1191.2	0.00%	15.7	-0.13%	0.043	-25%	2.91	-0.87%	1.000
WW07	1189.1	0.01%	18.4	-0.10%	0.054	-1%	2.82	-0.36%	1.000
WW08	1187.0	0.00%	20.8	0.04%	0.061	-10%	2.75	1.41%	1.000
WW09	1184.9	0.02%	22.9	-0.20%	0.068	28%	2.73	2.11%	0.995
WW10	1182.9	0.00%	24.7	-0.24%	0.078	18%	2.76	1.29%	0.998
WW11	1180.9	0.02%	26.5	0.23%	0.100	21%	2.81	0.20%	0.999
NW01	1201.3	0.00%	0.3	0.11%	0.001	-314%	2.93	0.49%	0.999

NW02	1198.5	0.00%	1.7	0.03%	0.010	-22%	2.92	0.39%	1.000
NW03	1195.5	0.00%	4.2	-0.11%	0.019	5%	3.00	-0.10%	1.000
NW04	1192.5	0.00%	9.9	-0.06%	0.027	0%	2.94	-0.09%	1.000
NW05	1189.5	0.00%	14.2	-0.05%	0.040	-5%	2.92	0.01%	1.000
NW06	1186.6	0.00%	18.2	0.01%	0.048	-1%	2.84	-0.25%	1.000
NW07	1183.5	0.00%	21.9	-0.12%	0.052	-13%	3.12	0.05%	1.000
NW08	1180.6	0.00%	24.5	-0.03%	0.053	-2%	2.65	0.33%	1.000
NW09	1177.7	0.00%	27.0	0.14%	0.058	4%	2.63	0.07%	1.000
NW10	1174.8	0.01%	29.3	0.02%	0.072	8%	2.67	0.18%	1.000
NW11	1172.0	-0.01%	31.4	0.58%	0.099	14%	2.76	2.39%	0.999

Tabela 34 – Parâmetros estatísticos, momento M_y , topo do SCR

<i>Momento M_y, topo do SCR</i>									
Caso	μ	ε_μ	σ	ε_σ	γ	ε_γ	κ	ε_κ	ρ
NN01	-7.9	0.00%	0.1	0.00%	-0.016	-1%	3.02	-0.29%	1.000
NN02	-6.6	0.00%	0.3	-0.07%	-0.073	6%	3.11	-0.82%	1.000
NN03	-5.3	0.00%	0.7	-0.12%	-0.039	13%	3.04	-0.23%	1.000
NN04	-4.0	-0.08%	1.8	-0.06%	-0.045	4%	2.83	-0.88%	0.999
NN05	-2.8	0.08%	2.9	0.14%	-0.083	-7%	2.77	-0.14%	0.999
NN06	-1.8	0.18%	4.1	0.09%	-0.130	7%	2.71	0.46%	1.000
NN07	-0.8	-2.81%	5.4	0.03%	-0.162	7%	2.64	0.22%	0.999
NN08	0.2	47.82%	6.8	0.10%	-0.186	-7%	2.62	0.11%	0.999
NN09	1.0	0.65%	8.2	0.07%	-0.224	-1%	2.74	0.12%	1.000
NN10	1.9	-0.78%	9.7	0.19%	-0.269	2%	2.98	2.06%	0.999
NN11	2.8	-1.95%	11.2	0.42%	-0.294	-6%	3.23	3.21%	0.999
NE01	-8.6	0.00%	0.0	-0.22%	-0.008	-49%	3.03	-0.18%	1.000
NE02	-8.7	0.00%	0.2	0.08%	0.003	-257%	2.93	0.53%	1.000
NE03	-8.7	0.00%	0.4	0.01%	-0.004	82%	3.01	-0.37%	1.000
NE04	-8.7	-0.02%	0.8	0.12%	-0.030	1%	3.01	-0.10%	1.000
NE05	-8.8	-0.03%	0.9	-0.08%	-0.061	-15%	3.09	-0.77%	1.000
NE06	-9.0	0.03%	1.1	-0.04%	-0.062	11%	3.07	-0.76%	0.999
NE07	-9.2	-0.01%	1.3	-0.29%	-0.034	-114%	3.00	-0.64%	0.999
NE08	-9.4	-0.24%	1.4	-1.20%	-0.031	-132%	2.98	-4.82%	0.994
NE09	-9.7	-0.07%	1.7	0.16%	-0.104	13%	3.08	-0.97%	0.999
NE10	-10.0	0.01%	2.0	0.05%	-0.231	15%	3.30	-0.21%	0.999
NE11	-10.2	-0.04%	2.4	0.25%	-0.351	6%	3.52	4.04%	0.995
EE01	-9.3	0.00%	0.1	0.26%	-0.022	4%	3.05	-0.26%	1.000
EE02	-10.7	0.00%	0.3	0.01%	-0.070	3%	3.06	-0.52%	1.000
EE03	-12.1	-0.01%	0.7	-0.05%	-0.018	-11%	2.97	-0.37%	1.000
EE04	-13.6	-0.01%	1.8	-0.05%	-0.022	14%	2.89	0.13%	1.000
EE05	-15.0	0.02%	2.8	-0.06%	-0.071	13%	2.85	-0.19%	1.000
EE06	-16.6	0.13%	3.8	0.12%	-0.124	31%	2.79	0.94%	1.000
EE07	-18.2	-0.14%	4.9	-0.33%	-0.165	0%	2.74	-0.82%	1.000
EE08	-19.8	-0.03%	6.0	-0.30%	-0.201	-9%	2.72	-1.12%	1.000
EE09	-21.5	-0.59%	7.0	-0.57%	-0.244	-4%	2.83	-1.63%	0.999
EE10	-23.2	-2.25%	8.1	-5.64%	-0.299	-61%	3.09	-5.44%	0.924
EE11	-24.8	-0.87%	9.1	-0.94%	-0.329	-19%	3.22	-2.29%	0.995
SE01	-9.6	0.00%	0.1	0.01%	-0.015	-3%	2.92	-0.16%	1.000
SE02	-11.5	0.00%	0.3	0.04%	-0.029	1%	2.97	-0.05%	1.000
SE03	-13.6	0.00%	0.9	0.08%	-0.046	-3%	3.03	-0.02%	1.000
SE04	-15.6	-0.02%	2.6	0.08%	-0.102	-2%	2.87	0.13%	1.000
SE05	-17.7	0.01%	4.2	0.10%	-0.166	2%	2.83	0.37%	1.000
SE06	-20.0	0.04%	6.0	0.12%	-0.231	1%	2.79	0.86%	1.000
SE07	-22.5	0.06%	7.8	-0.21%	-0.281	-4%	2.77	-1.34%	1.000
SE08	-24.9	0.00%	9.7	-0.12%	-0.324	-1%	2.78	-0.47%	1.000

SE09	-27.5	0.00%	11.6	-0.11%	-0.383	-1%	2.96	-0.60%	1.000
SE10	-30.1	-0.08%	13.6	0.06%	-0.457	0%	3.32	0.90%	1.000
SE11	-32.6	0.02%	15.6	0.03%	-0.526	-2%	3.72	0.17%	1.000
SS01	-9.3	0.00%	0.1	0.02%	-0.021	-11%	3.44	-0.02%	1.000
SS02	-10.7	0.00%	0.3	0.06%	-0.038	-8%	2.66	-0.06%	1.000
SS03	-12.1	-0.01%	0.7	0.03%	-0.049	1%	3.05	-0.19%	1.000
SS04	-13.6	-0.07%	1.8	-0.90%	-0.107	-11%	2.85	-0.32%	0.999
SS05	-15.1	-0.02%	3.0	-0.12%	-0.192	-2%	2.81	0.07%	1.000
SS06	-16.7	0.02%	4.3	0.14%	-0.280	5%	2.79	1.30%	1.000
SS07	-18.5	-0.10%	5.7	-0.24%	-0.344	-8%	2.78	-2.77%	0.999
SS08	-20.4	0.06%	7.2	0.12%	-0.398	4%	2.82	1.31%	1.000
SS09	-22.3	-0.16%	8.8	-0.01%	-0.464	1%	3.03	0.65%	1.000
SS10	-24.3	0.94%	10.4	0.98%	-0.543	8%	3.42	4.30%	0.996
SS11	-26.2	0.30%	12.0	1.60%	-0.613	27%	3.84	15.28%	0.990
SW01	-8.6	0.00%	0.0	-0.08%	-0.012	-41%	2.98	0.09%	0.999
SW02	-8.6	0.01%	0.2	1.52%	-0.005	26%	2.93	0.63%	0.999
SW03	-8.6	0.00%	0.4	0.14%	-0.007	62%	3.02	-0.22%	1.000
SW04	-8.7	0.00%	0.7	0.05%	-0.042	-15%	3.02	0.84%	1.000
SW05	-8.8	0.01%	0.9	0.36%	-0.083	0%	3.10	0.04%	0.999
SW06	-8.9	0.00%	1.0	0.11%	-0.074	-4%	3.12	-1.78%	0.999
SW07	-9.1	-0.07%	1.1	0.01%	-0.019	-19%	3.08	-1.90%	0.995
SW08	-9.3	-0.22%	1.3	-0.63%	-0.013	-50%	3.09	-1.58%	0.998
SW09	-9.6	-0.31%	1.5	-0.14%	-0.126	-7%	3.28	-0.50%	0.999
SW10	-9.8	0.30%	1.8	0.81%	-0.318	37%	3.68	4.45%	0.995
SW11	-10.1	-0.21%	2.1	1.22%	-0.488	12%	4.09	8.78%	0.996
WW01	-7.9	0.00%	0.1	0.02%	-0.015	-1%	3.18	-0.03%	1.000
WW02	-6.6	0.00%	0.3	0.15%	-0.056	-2%	3.05	0.48%	1.000
WW03	-5.3	-0.01%	0.7	0.12%	-0.013	23%	2.96	0.17%	1.000
WW04	-3.9	-0.12%	1.8	0.10%	-0.008	-56%	2.89	0.07%	1.000
WW05	-2.7	0.01%	2.7	0.10%	-0.024	9%	2.85	0.10%	1.000
WW06	-1.5	-0.32%	3.7	-0.31%	-0.043	-23%	2.77	-1.38%	1.000
WW07	-0.3	-3.11%	4.7	-0.11%	-0.055	-14%	2.68	-0.31%	1.000
WW08	0.9	-0.82%	5.7	0.02%	-0.062	15%	2.63	-0.50%	1.000
WW09	2.0	2.03%	6.7	0.04%	-0.082	-27%	2.69	0.24%	1.000
WW10	3.1	0.96%	7.6	0.03%	-0.112	-12%	2.86	0.14%	1.000
WW11	4.2	0.25%	8.5	0.20%	-0.134	10%	3.04	1.50%	1.000
NW01	-7.7	0.00%	0.1	-0.10%	-0.015	-9%	2.92	-0.32%	1.000
NW02	-5.8	0.00%	0.3	0.10%	0.011	-15%	2.99	0.03%	1.000
NW03	-3.8	0.00%	0.9	0.15%	0.001	592%	3.04	-0.04%	1.000
NW04	-2.0	-0.07%	2.6	0.10%	-0.049	8%	2.87	0.05%	1.000
NW05	-0.3	-2.78%	4.2	0.05%	-0.098	6%	2.82	0.16%	1.000
NW06	1.3	-0.53%	5.8	-0.27%	-0.143	11%	2.75	-0.34%	1.000
NW07	2.8	-0.79%	7.6	-0.01%	-0.207	4%	3.11	-0.26%	1.000
NW08	4.3	0.68%	9.2	0.05%	-0.187	1%	2.64	0.85%	1.000
NW09	5.6	0.45%	10.9	0.01%	-0.212	-1%	2.73	0.45%	1.000
NW10	7.0	-0.10%	12.7	0.06%	-0.241	-3%	2.95	0.52%	1.000
NW11	8.4	1.48%	14.4	0.10%	-0.258	17%	3.18	1.53%	0.999

Tabela 35 – Parâmetros estatísticos, momento M_z , topo do SCR

Momento M_z , topo do SCR									
Caso	μ	ε_μ	σ	ε_σ	γ	ε_γ	κ	ε_κ	ρ
NN01	-3.7	0.00%	0.1	-0.03%	-0.018	-15%	3.03	-0.02%	1.000
NN02	-3.2	-0.01%	0.3	-0.04%	-0.085	0%	3.14	-1.83%	0.999
NN03	-2.8	-0.04%	0.6	0.07%	-0.050	5%	3.05	0.19%	1.000
NN04	-2.4	0.02%	1.6	-0.32%	-0.059	9%	2.84	0.07%	0.999
NN05	-2.1	-0.40%	2.6	-0.10%	-0.109	-28%	2.78	-0.55%	0.999
NN06	-2.0	-1.68%	3.8	-0.10%	-0.161	-1%	2.73	-0.21%	1.000
NN07	-1.9	-0.40%	5.0	-0.08%	-0.189	-4%	2.67	-0.77%	0.999
NN08	-1.9	3.15%	6.3	-0.48%	-0.200	31%	2.65	-4.03%	0.997
NN09	-1.9	-0.53%	7.6	0.01%	-0.223	-6%	2.78	-0.32%	0.999
NN10	-1.9	3.10%	9.0	0.10%	-0.248	0%	3.05	0.25%	0.999
NN11	-1.9	1.17%	10.4	0.05%	-0.253	18%	3.32	1.33%	0.998
NE01	-3.6	0.00%	0.1	-0.02%	-0.013	-12%	2.91	-0.25%	1.000
NE02	-2.9	0.00%	0.3	0.14%	0.019	-13%	2.93	-0.11%	1.000
NE03	-2.2	-0.01%	0.8	0.09%	0.006	25%	3.01	0.07%	1.000
NE04	-1.6	0.07%	2.3	0.04%	-0.048	-3%	2.86	0.05%	1.000
NE05	-1.0	-0.40%	3.7	-0.03%	-0.089	-4%	2.81	-0.10%	1.000
NE06	-0.6	-0.29%	5.2	-0.04%	-0.119	4%	2.75	0.04%	1.000
NE07	-0.2	10.88%	6.8	-0.05%	-0.130	-8%	2.68	-0.29%	1.000
NE08	0.2	34.53%	8.3	-0.05%	-0.131	-7%	2.66	-0.47%	1.000
NE09	0.5	-1.49%	10.0	0.05%	-0.135	-4%	2.76	-0.03%	1.000
NE10	0.9	4.55%	11.6	0.02%	-0.138	-1%	2.98	0.03%	1.000
NE11	1.3	-5.80%	13.2	0.02%	-0.134	36%	3.23	0.92%	1.000
EE01	-3.7	0.00%	0.1	0.20%	0.004	-65%	3.05	-0.30%	1.000
EE02	-3.2	-0.02%	0.3	-0.05%	-0.008	39%	3.03	-0.17%	1.000
EE03	-2.7	-0.05%	0.7	-0.14%	-0.021	18%	2.96	0.06%	1.000
EE04	-2.2	0.03%	1.7	0.13%	-0.029	13%	2.90	0.13%	1.000
EE05	-1.8	-0.53%	2.6	-0.05%	-0.026	-44%	2.87	-0.44%	1.000
EE06	-1.3	-0.56%	3.5	0.01%	-0.021	-74%	2.81	-0.16%	1.000
EE07	-0.9	-2.05%	4.5	-0.24%	-0.014	-31%	2.74	-1.19%	1.000
EE08	-0.5	-13.5%	5.5	-0.67%	-0.005	-122%	2.71	-5.83%	0.995
EE09	0.0	-662%	6.5	-5.98%	-0.005	-3411%	2.81	-17.8%	0.931
EE10	0.4	47.97%	7.4	-0.05%	-0.007	-544%	3.04	0.91%	0.998
EE11	0.8	-12.8%	8.4	-0.30%	-0.017	266%	3.19	-0.71%	0.998
SE01	-4.0	0.00%	0.0	-0.04%	-0.013	118%	3.00	0.29%	1.000
SE02	-3.9	0.00%	0.2	0.10%	-0.010	32%	2.86	0.47%	1.000
SE03	-3.9	0.03%	0.5	-0.07%	-0.018	-74%	2.99	-1.00%	1.000
SE04	-4.0	0.06%	0.9	0.20%	-0.028	-56%	3.02	0.13%	0.999
SE05	-4.0	-0.18%	1.1	0.21%	-0.044	11%	3.09	-0.90%	0.998
SE06	-4.1	0.01%	1.3	0.11%	-0.059	-59%	3.05	-2.20%	0.997
SE07	-4.2	0.71%	1.4	0.08%	-0.075	35%	3.00	-1.05%	0.998
SE08	-4.3	0.81%	1.6	-0.87%	-0.095	-9%	3.01	-1.72%	0.994
SE09	-4.5	-9.53%	1.8	-11.0%	-0.151	-26%	3.11	3.07%	0.930
SE10	-4.7	-1.45%	2.1	-2.29%	-0.249	-23%	3.33	1.25%	0.976
SE11	-4.9	-0.57%	2.4	0.82%	-0.361	2%	3.66	6.47%	0.992
SS01	-4.2	0.00%	0.1	0.29%	-0.024	6%	3.43	0.35%	1.000
SS02	-4.7	-0.01%	0.3	0.31%	-0.044	-16%	2.66	-0.70%	0.999
SS03	-5.3	-0.02%	0.6	0.02%	-0.057	8%	3.05	-0.11%	1.000
SS04	-5.8	-0.04%	1.7	-0.21%	-0.121	-2%	2.85	-0.46%	1.000
SS05	-6.5	-0.10%	2.8	-0.09%	-0.216	2%	2.83	-0.21%	1.000
SS06	-7.3	0.93%	4.0	-0.16%	-0.303	17%	2.82	1.00%	0.998
SS07	-8.3	0.72%	5.3	-0.30%	-0.355	10%	2.80	-0.34%	0.996
SS08	-9.3	-25.5%	6.7	-8.07%	-0.390	43%	2.84	3.64%	0.939
SS09	-10.2	1.83%	8.1	-0.22%	-0.433	2%	3.04	0.41%	0.995
SS10	-11.2	-0.48%	9.6	0.52%	-0.489	13%	3.42	6.84%	0.996
SS11	-12.2	-3.62%	11.2	1.56%	-0.541	33%	3.83	16.07%	0.981
SW01	-4.3	0.00%	0.1	-0.23%	-0.012	-56%	2.95	-0.53%	1.000
SW02	-5.0	-0.15%	0.3	-0.39%	-0.024	-64%	3.00	-0.95%	0.998

SW03	-5.8	0.01%	0.9	0.07%	-0.042	2%	3.05	-0.13%	1.000
SW04	-6.6	-0.03%	2.5	0.06%	-0.076	4%	2.89	0.26%	1.000
SW05	-7.5	-0.14%	4.0	0.01%	-0.111	-16%	2.85	-0.04%	1.000
SW06	-8.4	-0.32%	5.6	-0.35%	-0.140	-14%	2.77	-1.53%	1.000
SW07	-9.4	-0.01%	7.2	-0.13%	-0.160	-7%	2.70	-0.84%	1.000
SW08	-10.5	-0.04%	8.9	-0.13%	-0.177	-10%	2.68	-0.86%	1.000
SW09	-11.5	0.42%	10.6	0.00%	-0.209	-3%	2.79	-0.46%	1.000
SW10	-12.6	-0.85%	12.3	-0.01%	-0.255	2%	3.05	0.24%	1.000
SW11	-13.6	-0.65%	13.9	-0.33%	-0.300	-6%	3.33	-0.57%	1.000
WW01	-4.2	0.00%	0.1	-0.02%	-0.004	57%	3.18	-0.31%	1.000
WW02	-4.8	0.00%	0.3	-0.37%	-0.015	47%	3.04	-1.18%	1.000
WW03	-5.3	-0.06%	0.7	-0.22%	-0.014	-25%	2.96	-0.11%	1.000
WW04	-5.8	-0.07%	1.6	0.30%	-0.018	-70%	2.90	-0.89%	1.000
WW05	-6.4	-0.15%	2.5	-0.03%	-0.037	-51%	2.87	-0.09%	1.000
WW06	-7.0	-0.08%	3.4	0.00%	-0.055	41%	2.79	-0.36%	0.999
WW07	-7.6	0.24%	4.3	-0.11%	-0.068	9%	2.71	-0.38%	1.000
WW08	-8.2	-0.07%	5.2	-0.03%	-0.077	-3%	2.67	-0.52%	1.000
WW09	-8.8	0.52%	6.2	-0.09%	-0.085	3%	2.73	-0.50%	1.000
WW10	-9.4	-0.20%	7.1	-0.26%	-0.097	14%	2.92	-1.17%	0.999
WW11	-10.0	-0.30%	7.9	-3.22%	-0.118	16%	3.13	-17.8%	0.962
NW01	-4.0	0.00%	0.0	-0.81%	-0.004	-257%	3.01	-1.66%	0.999
NW02	-4.0	0.00%	0.1	0.11%	-0.001	886%	3.03	0.25%	1.000
NW03	-4.0	0.01%	0.3	0.10%	-0.001	-3236%	3.05	-0.32%	0.999
NW04	-4.1	-0.15%	0.5	0.41%	-0.012	-146%	3.00	0.00%	0.997
NW05	-4.2	-0.32%	0.6	-0.37%	-0.018	69%	3.06	-1.58%	0.990
NW06	-4.3	-0.10%	0.7	-0.67%	-0.003	-587%	3.08	-0.18%	0.979
NW07	-4.5	-0.23%	0.8	-2.56%	-0.087	-47%	3.04	-2.03%	0.985
NW08	-4.6	-0.31%	1.0	-0.23%	-0.100	-33%	3.18	-1.89%	0.991
NW09	-4.8	-0.69%	1.3	-0.63%	-0.251	9%	3.38	3.56%	0.993
NW10	-5.1	-0.90%	1.6	0.73%	-0.403	-4%	3.65	5.35%	0.994
NW11	-5.3	1.03%	2.0	0.88%	-0.503	24%	3.83	6.44%	0.993

B.2 TDZ do SCR

Tabela 36 – Parâmetros estatísticos, tração T, TDZ do SCR

<i>Tração T, TDZ do SCR</i>									
Caso	μ	ε_μ	σ	ε_σ	γ	ε_γ	κ	ε_κ	ρ
NN01	222.8	0.00%	0.1	0.18%	0.007	22.1%	2.98	3.68%	0.992
NN02	220.3	0.00%	0.5	0.14%	0.013	-144%	2.85	0.04%	1.000
NN03	218.6	0.01%	1.1	0.83%	0.061	-4.4%	3.13	3.82%	0.999
NN04	217.0	0.01%	2.5	0.67%	0.150	46.8%	3.40	7.81%	0.998
NN05	215.0	0.03%	3.6	-0.18%	0.197	-66.0%	3.52	-0.15%	0.996
NN06	212.9	0.03%	4.8	0.86%	0.199	-68.6%	3.40	0.39%	0.998
NN07	210.9	0.10%	6.0	1.15%	0.148	-36.8%	3.35	0.76%	0.998
NN08	208.8	0.29%	7.1	1.00%	0.115	-75.5%	3.42	-5.60%	0.996
NN09	206.6	0.49%	8.2	2.19%	0.119	-49.3%	3.67	-4.35%	0.986
NN10	204.4	0.45%	9.3	2.11%	0.102	-30.3%	4.26	-2.94%	0.988
NN11	201.8	0.19%	10.5	-1.47%	0.153	-71.4%	5.21	1.20%	0.984
NE01	224.3	0.00%	0.1	0.77%	-0.002	-95.2%	3.06	1.36%	0.999
NE02	224.4	0.02%	0.4	1.49%	0.138	188.9%	2.68	-6.65%	0.939
NE03	224.4	0.00%	0.8	4.28%	0.054	8.2%	2.94	9.28%	0.993
NE04	224.4	0.00%	1.6	2.17%	0.087	29.3%	3.14	8.24%	0.998
NE05	224.3	-0.02%	2.3	3.05%	0.118	60.4%	3.18	10.27%	0.996
NE06	224.3	-0.01%	3.1	2.31%	0.154	-9.4%	3.13	6.83%	0.991

NE07	224.2	-0.02%	4.1	1.66%	0.196	19.1%	3.16	10.64%	0.994
NE08	224.1	-0.03%	5.2	1.25%	0.232	6.1%	3.27	1.73%	0.997
NE09	224.0	-0.05%	6.4	0.97%	0.276	3.1%	3.61	3.92%	0.995
NE10	223.8	0.02%	7.8	1.82%	0.350	-36.4%	4.40	11.14%	0.987
NE11	223.7	-0.07%	9.3	1.20%	0.405	13.6%	5.31	10.18%	0.993
EE01	225.4	0.00%	0.1	0.34%	-0.004	-357%	3.08	0.95%	0.998
EE02	227.5	0.00%	0.8	4.73%	0.018	96.9%	2.84	6.40%	0.995
EE03	229.6	0.00%	1.5	2.32%	0.051	53.9%	2.86	8.04%	0.996
EE04	231.7	0.00%	2.4	3.17%	0.107	43.0%	3.16	6.68%	0.992
EE05	233.8	-0.01%	3.1	2.67%	0.137	40.1%	3.30	11.42%	0.996
EE06	236.0	-0.02%	3.9	2.94%	0.154	46.4%	3.26	12.05%	0.995
EE07	238.1	0.00%	4.9	4.26%	0.177	9.8%	3.25	11.21%	0.981
EE08	240.4	-0.03%	6.1	0.23%	0.212	-10.3%	3.36	1.14%	0.978
EE09	242.6	-0.04%	7.4	4.42%	0.260	-29.8%	3.67	6.81%	0.983
EE10	244.9	0.00%	8.8	4.75%	0.318	-7.9%	4.24	11.73%	0.973
EE11	247.3	0.17%	10.4	-1.50%	0.344	-85.0%	4.87	1.11%	0.960
SE01	225.8	0.00%	0.0	0.44%	-0.002	-300%	3.08	1.04%	0.995
SE02	228.8	-0.01%	0.4	2.14%	0.022	-360%	3.02	7.04%	0.994
SE03	231.9	0.00%	1.1	1.26%	0.068	-1.6%	3.21	4.44%	0.998
SE04	234.8	-0.02%	2.5	2.33%	0.151	55.6%	3.36	9.53%	0.995
SE05	237.8	-0.02%	3.7	2.57%	0.205	32.8%	3.53	11.61%	0.996
SE06	240.8	-0.03%	5.1	3.84%	0.231	36.4%	3.45	13.93%	0.995
SE07	244.0	-0.04%	6.6	3.02%	0.252	40.6%	3.44	12.33%	0.985
SE08	247.1	-0.03%	8.3	0.94%	0.267	0.2%	3.49	4.57%	0.997
SE09	250.3	0.05%	10.2	-1.43%	0.290	-20.1%	3.75	-4.05%	0.996
SE10	253.8	0.02%	12.1	1.31%	0.325	-22.2%	4.31	5.94%	0.998
SE11	257.2	0.16%	14.2	-0.79%	0.357	-59.8%	5.07	6.09%	0.990
SS01	225.4	0.00%	0.1	-1.67%	0.005	216.6%	2.84	3.18%	0.974
SS02	227.5	0.00%	0.4	0.51%	0.007	17.0%	2.90	1.05%	0.996
SS03	229.6	0.00%	0.9	1.11%	0.034	178.7%	3.08	7.01%	0.996
SS04	231.7	0.00%	2.0	3.18%	0.111	22.9%	3.22	11.64%	0.995
SS05	233.7	-0.02%	3.1	3.14%	0.170	17.1%	3.29	10.74%	0.992
SS06	235.7	0.01%	4.5	3.13%	0.218	-28.3%	3.31	7.81%	0.992
SS07	237.7	-0.04%	6.0	1.54%	0.258	15.3%	3.37	5.93%	0.997
SS08	239.8	-0.14%	7.8	2.09%	0.288	17.9%	3.44	3.93%	0.991
SS09	241.9	-0.10%	9.7	2.71%	0.334	-4.1%	3.75	3.95%	0.995
SS10	244.0	-0.03%	11.7	4.87%	0.404	-8.4%	4.48	7.55%	0.992
SS11	246.2	-0.34%	13.9	2.06%	0.491	51.3%	5.50	4.65%	0.983
SW01	224.3	0.00%	0.1	0.79%	0.001	7.1%	3.07	3.05%	0.999
SW02	224.2	0.00%	0.3	0.68%	0.236	45.1%	2.63	10.07%	0.973
SW03	224.2	0.00%	0.7	0.63%	0.153	45.9%	3.07	2.98%	0.994
SW04	224.2	-0.01%	1.5	0.32%	0.170	-6.4%	3.30	1.14%	0.998
SW05	224.2	-0.02%	2.3	0.91%	0.200	27.3%	3.29	1.88%	0.997
SW06	224.1	-0.02%	3.2	2.01%	0.212	41.0%	3.20	7.62%	0.997
SW07	224.0	-0.02%	4.3	0.78%	0.231	2.2%	3.18	0.82%	0.999
SW08	223.9	-0.01%	5.4	0.08%	0.246	-15.8%	3.22	-1.28%	0.998
SW09	223.7	-0.03%	6.6	1.30%	0.282	-7.9%	3.51	3.00%	0.999
SW10	223.6	-0.03%	7.9	1.05%	0.377	-7.4%	4.23	0.81%	0.998
SW11	223.5	-0.05%	9.4	1.33%	0.510	12.7%	5.26	5.71%	0.998
WW01	222.3	0.00%	0.1	0.21%	-0.002	462.6%	3.07	3.67%	0.993
WW02	217.1	0.00%	0.7	5.64%	0.021	-53.9%	2.87	7.27%	0.979
WW03	213.0	0.03%	1.2	-3.19%	0.054	-52.5%	2.87	1.61%	0.917
WW04	210.3	-0.01%	2.0	3.56%	0.183	27.3%	3.37	15.01%	0.981
WW05	208.2	-0.08%	2.7	1.86%	0.284	-16.0%	3.52	6.43%	0.984
WW06	206.7	0.04%	3.5	-2.02%	0.330	-46.4%	3.45	-3.40%	0.960
WW07	205.8	0.01%	4.3	-2.59%	0.368	-89.8%	3.50	-12%	0.985
WW08	205.7	0.03%	5.1	2.94%	0.426	-11.8%	3.54	-2.57%	0.965
WW09	205.0	0.20%	6.6	-7.30%	0.375	-150%	3.61	-43%	0.959
WW10	203.9	0.14%	7.8	-3.24%	0.301	-28.6%	3.94	-17.7%	0.973
WW11	202.6	0.43%	8.8	-5.26%	0.266	-17.4%	4.50	-6.97%	0.958
NW01	221.8	0.00%	0.1	0.25%	0.004	-30.8%	2.94	0.67%	1.000

NW02	215.5	0.00%	0.4	0.85%	-0.001	322.5%	2.99	2.54%	0.999
NW03	210.3	0.01%	0.8	0.36%	0.004	407.6%	3.25	-0.50%	0.999
NW04	206.5	0.09%	2.1	-0.10%	0.040	-68.0%	3.43	0.96%	0.998
NW05	203.3	0.16%	3.0	0.86%	0.060	-267%	3.67	4.30%	0.994
NW06	200.5	0.18%	4.0	-2.53%	0.127	-256%	3.74	-14.4%	0.991
NW07	198.3	0.19%	4.9	1.95%	0.207	-27.3%	3.81	5.14%	0.995
NW08	196.6	0.10%	6.1	3.47%	0.281	-2.5%	3.79	6.40%	0.995
NW09	194.7	0.11%	7.2	0.56%	0.313	-32.3%	3.91	-5.15%	0.998
NW10	192.3	0.20%	8.3	1.00%	0.330	16.4%	4.37	-6.09%	0.993
NW11	190.4	0.92%	9.3	3.07%	0.314	-21.7%	4.85	-2.44%	0.986

Tabela 37 – Parâmetros estatísticos, momento M_y , TDZ do SCR

<i>Momento M_y, TDZ do SCR</i>									
Caso	μ	ε_μ	σ	ε_σ	γ	ε_γ	κ	ε_κ	ρ
NN01	-6.2	0.00%	0.03	-0.48%	0.002	489.4%	2.88	0.38%	0.998
NN02	-0.7	0.26%	0.10	2.40%	-0.097	-0.5%	3.28	8.08%	0.968
NN03	0.3	-0.16%	0.01	11.78%	-2.490	29.0%	12.82	44.34%	0.959
NN04	0.0	3.17%	0.09	0.37%	0.241	14.7%	2.99	4.34%	0.996
NN05	-0.2	-0.38%	0.04	10.25%	2.026	26.2%	9.03	41.39%	0.970
NN06	-0.3	2.15%	0.01	13.12%	4.540	94.8%	43.40	95.70%	0.100
NN07	-0.3	0.60%	0.01	-4.01%	-0.529	-16.5%	2.72	12.49%	0.959
NN08	-0.3	0.62%	0.01	0.02%	-1.638	-7.1%	6.25	-8.32%	0.963
NN09	-0.3	0.36%	0.01	19.09%	-1.435	33.3%	7.48	24.02%	0.625
NN10	-0.3	-0.75%	0.01	41.50%	-1.030	38.6%	6.00	45.83%	0.740
NN11	-0.4	-1.36%	0.01	43.87%	-0.549	13.8%	3.36	7.06%	0.549
NE01	-11.6	0.00%	0.04	2.95%	-0.001	-4205%	2.94	6.29%	0.958
NE02	-11.7	0.00%	0.31	6.26%	0.051	73.0%	2.90	9.71%	0.938
NE03	-11.9	-0.05%	0.72	5.45%	0.143	79.1%	3.06	19.10%	0.985
NE04	-12.0	-0.18%	1.57	2.94%	0.386	18.1%	3.34	11.93%	0.983
NE05	-12.1	-0.55%	2.38	0.86%	0.452	32.9%	3.18	3.69%	0.993
NE06	-12.2	-0.41%	3.35	0.19%	0.444	-2.8%	2.87	-0.15%	0.996
NE07	-12.3	-0.36%	4.37	0.26%	0.397	-18.1%	2.58	-6.45%	0.983
NE08	-12.3	0.84%	5.35	-0.10%	0.319	8.5%	2.34	1.08%	0.961
NE09	-12.5	-0.22%	6.21	0.48%	0.248	-23.5%	2.18	-2.53%	0.970
NE10	-12.7	0.20%	6.94	2.72%	0.200	-28.7%	2.10	1.66%	0.963
NE11	-13.1	-2.24%	7.60	-0.87%	0.158	1.5%	2.02	-2.37%	0.984
EE01	-16.2	0.00%	0.07	4.03%	0.010	22.2%	3.08	2.02%	0.971
EE02	-23.2	0.16%	0.31	-28.5%	0.293	-165.8%	2.79	-69.4%	0.678
EE03	-27.8	-0.05%	0.46	4.71%	0.236	82.6%	3.04	15.88%	0.975
EE04	-30.9	-0.04%	0.56	4.76%	0.362	36.7%	3.45	15.73%	0.977
EE05	-32.9	-0.03%	0.56	2.54%	0.229	29.8%	3.31	9.94%	0.993
EE06	-34.1	-0.03%	0.62	3.64%	-0.018	-148.8%	3.07	9.96%	0.995
EE07	-34.8	0.00%	0.75	0.76%	-0.191	-1.4%	3.09	3.68%	0.998
EE08	-35.1	0.00%	0.97	0.72%	-0.309	2.6%	3.27	4.24%	0.996
EE09	-35.1	0.00%	1.22	0.75%	-0.422	6.5%	3.63	4.83%	0.998
EE10	-35.0	0.00%	1.50	0.87%	-0.568	-3.0%	4.27	-0.02%	0.997
EE11	-34.8	0.08%	1.78	1.93%	-0.737	4.3%	5.14	4.03%	0.996
SE01	-17.7	0.00%	0.02	2.04%	0.010	591.7%	2.99	-0.41%	0.970
SE02	-26.1	-0.02%	0.16	11.52%	-0.063	75.8%	2.92	7.06%	0.960
SE03	-31.0	-0.01%	0.24	4.25%	0.199	66.0%	3.33	11.87%	0.988
SE04	-33.5	-0.03%	0.43	0.22%	0.118	145.4%	3.24	4.11%	0.995
SE05	-34.7	0.00%	0.58	3.86%	-0.131	46.8%	3.29	17.24%	0.992
SE06	-35.1	0.02%	0.82	4.16%	-0.291	28.4%	3.38	12.98%	0.993
SE07	-35.1	-0.01%	1.14	0.27%	-0.412	-17.0%	3.47	0.51%	0.997
SE08	-34.8	0.06%	1.47	0.89%	-0.521	-1.3%	3.60	3.00%	0.988

SE09	-34.4	-0.05%	1.78	0.58%	-0.660	3.4%	4.00	4.46%	0.998
SE10	-33.8	0.01%	2.07	1.10%	-0.875	-2.0%	5.03	2.43%	0.997
SE11	-33.3	-0.08%	2.33	0.62%	-1.164	6.1%	6.82	12.93%	0.992
SS01	-16.2	0.00%	0.04	0.08%	0.007	-196.5%	2.86	-0.73%	0.999
SS02	-23.2	0.00%	0.18	-1.01%	0.091	45.8%	2.82	-3.24%	0.997
SS03	-27.8	0.01%	0.28	2.83%	0.213	79.7%	3.05	13.33%	0.953
SS04	-30.9	-0.01%	0.51	0.30%	0.342	-25.0%	3.38	-6.30%	0.987
SS05	-32.8	-0.02%	0.61	-0.20%	0.327	1.1%	3.31	-2.49%	0.998
SS06	-34.0	-0.01%	0.72	3.75%	0.100	-42.1%	3.07	10.84%	0.996
SS07	-34.7	-0.01%	0.91	1.39%	-0.156	2.5%	3.00	5.62%	0.998
SS08	-35.1	-0.02%	1.20	1.09%	-0.313	7.3%	3.13	5.27%	0.996
SS09	-35.2	-0.01%	1.55	-0.40%	-0.446	-0.6%	3.48	1.03%	0.998
SS10	-35.1	0.01%	1.93	0.74%	-0.633	-4.4%	4.25	0.66%	0.998
SS11	-34.9	0.03%	2.33	0.44%	-0.915	6.0%	5.66	3.05%	0.998
SW01	-11.5	0.00%	0.04	1.00%	0.002	3084.1%	2.91	-4.29%	0.978
SW02	-11.6	0.04%	0.27	2.99%	0.065	50.1%	2.87	11.98%	0.957
SW03	-11.7	-0.02%	0.66	2.09%	0.127	67.8%	3.09	11.58%	0.971
SW04	-11.7	-0.12%	1.56	1.30%	0.378	4.1%	3.27	7.76%	0.992
SW05	-11.8	-0.18%	2.48	-1.03%	0.455	-17.1%	3.14	-4.56%	0.994
SW06	-11.8	-0.74%	3.53	2.78%	0.423	6.8%	2.77	2.18%	0.986
SW07	-11.8	-0.44%	4.58	-0.30%	0.349	-12.2%	2.44	-1.00%	0.987
SW08	-11.9	-2.96%	5.53	-1.93%	0.269	41.7%	2.21	-12.6%	0.974
SW09	-12.0	-1.65%	6.34	1.53%	0.200	-43.7%	2.07	-0.52%	0.979
SW10	-12.3	-1.71%	7.01	-0.56%	0.147	-6.9%	2.00	-3.58%	0.985
SW11	-12.6	-2.24%	7.62	-1.40%	0.102	-103.5%	1.94	-5.77%	0.968
WW01	-6.2	-0.01%	0.07	-0.69%	0.012	331.8%	3.15	2.67%	0.970
WW02	-0.6	-0.03%	0.14	4.64%	-0.136	38.1%	3.32	11.61%	0.977
WW03	0.4	0.51%	0.02	-33.8%	-2.066	15.0%	9.19	25.45%	0.829
WW04	0.0	0.02%	0.08	-0.11%	0.271	32.8%	3.09	10.68%	0.980
WW05	-0.2	-0.25%	0.04	4.48%	1.821	25.7%	7.87	38.44%	0.981
WW06	-0.2	-0.05%	0.01	-11.5%	3.469	-86.6%	25.08	-237%	0.907
WW07	-0.2	-0.33%	0.01	-3.83%	-0.450	22.7%	2.26	-2.35%	0.973
WW08	-0.2	-0.07%	0.00	-1.76%	-2.100	8.4%	8.68	8.70%	0.964
WW09	-0.2	0.00%	0.00	1.22%	-1.864	18.9%	14.35	29.14%	0.841
WW10	-0.2	0.66%	0.00	18.36%	-0.184	53.0%	3.75	21.08%	0.812
WW11	-0.3	4.06%	0.01	63.41%	0.359	201.6%	1.78	-113%	0.323
NW01	-4.5	0.00%	0.0265	0.66%	0.007	16.5%	2.91	5.13%	0.974
NW02	0.3	0.05%	0.0178	8.60%	-0.497	12.5%	4.41	17.52%	0.950
NW03	0.0	-1.48%	0.0314	1.91%	0.111	-0.8%	3.33	5.25%	0.997
NW04	-0.2	-0.06%	0.0087	8.22%	2.752	29.8%	14.86	53.22%	0.953
NW05	-0.2	-0.03%	0.0053	-0.97%	-0.352	8.4%	2.61	0.23%	0.996
NW06	-0.2	0.04%	0.0015	16.04%	-3.538	33.5%	20.63	54.65%	0.872
NW07	-0.2	0.01%	0.0009	-2.38%	-0.239	17.3%	2.50	-0.22%	0.967
NW08	-0.2	0.03%	0.0008	-0.44%	0.168	-114.9%	3.39	-9.24%	0.972
NW09	-0.2	0.01%	0.0007	1.17%	-0.231	-21.8%	3.64	5.61%	0.969
NW10	-0.2	-0.06%	0.0007	-2.13%	-0.366	7.6%	3.56	6.84%	0.971
NW11	-0.2	-0.22%	0.0007	-2.71%	-0.376	20.0%	3.81	19.65%	0.951

B.3 Topo do SLWR

Tabela 38 – Parâmetros estatísticos, tração T , topo do SLWR

Tração T , topo do SLWR									
Caso	μ	ε_μ	σ	ε_σ	γ	ε_γ	κ	ε_κ	ρ
NN01	15472.7	0.00%	2.4	12.7%	0.013	160%	3.04	-1.4%	0.762
NN02	15472.7	0.00%	9.5	-12.4%	-0.018	78%	2.99	0.2%	0.730
NN03	15472.8	0.00%	25.1	7.0%	-0.001	-661%	2.99	7.6%	0.943
NN04	15472.9	0.00%	69.8	-0.1%	0.004	-22%	3.02	0.2%	1.000
NN05	15472.9	0.00%	110.7	0.4%	-0.001	-423%	3.55	4.3%	1.000
NN06	15472.7	0.02%	147.0	-2.2%	-0.002	-1%	3.14	13.9%	0.981
NN07	15473.0	0.00%	182.6	0.3%	-0.005	4%	3.37	1.4%	1.000
NN08	15473.0	0.00%	211.5	0.4%	-0.007	363%	3.27	1.3%	0.999
NN09	15473.1	0.00%	242.6	1.0%	-0.009	324%	3.23	5.1%	0.997
NN10	15473.1	0.00%	275.8	1.4%	-0.009	133%	3.21	4.5%	0.999
NN11	15473.3	0.01%	309.6	0.9%	-0.010	61%	3.17	2.0%	0.993
NE01	15473.9	0.00%	4.6	5.6%	-0.021	34%	3.04	3.6%	0.909
NE02	15476.2	0.00%	17.0	-26.6%	-0.007	210%	2.81	9.7%	0.631
NE03	15478.6	0.00%	40.8	0.0%	-0.011	32%	2.91	0.6%	1.000
NE04	15481.1	0.00%	99.4	-1.4%	-0.002	-5340%	2.94	-21.4%	0.972
NE05	15483.4	0.00%	145.8	0.0%	-0.001	-2079%	3.36	0.8%	0.999
NE06	15485.8	0.00%	189.7	0.2%	-0.002	-82%	3.33	0.8%	1.000
NE07	15488.3	-0.03%	233.2	-0.4%	-0.005	27%	3.23	1.0%	0.984
NE08	15490.8	0.01%	278.9	-2.9%	-0.007	-75%	3.13	6.4%	0.960
NE09	15493.4	0.00%	324.0	0.0%	-0.009	35%	3.12	0.1%	1.000
NE10	15496.1	-0.02%	368.8	-3.9%	-0.011	673%	3.12	4.7%	0.938
NE11	15498.8	-0.14%	416.4	-3.9%	-0.014	507%	3.09	8.3%	0.889
EE01	15474.3	0.00%	33.2	0.1%	0.004	28%	3.00	0.1%	1.000
EE02	15477.6	0.00%	76.1	0.0%	-0.011	5%	3.00	-0.1%	1.000
EE03	15481.0	0.00%	136.6	-0.1%	-0.009	-15%	2.92	-0.5%	1.000
EE04	15484.4	0.00%	251.0	0.2%	-0.011	9%	3.13	-0.2%	1.000
EE05	15487.9	0.00%	349.8	0.1%	-0.002	-230%	3.27	1.4%	1.000
EE06	15491.6	0.00%	438.6	0.3%	0.007	-96%	3.26	3.5%	0.999
EE07	15495.4	0.00%	520.0	0.1%	0.012	-98%	3.20	1.4%	0.999
EE08	15499.2	0.01%	606.1	0.3%	0.015	-158%	3.14	0.9%	1.000
EE09	15503.3	0.01%	697.4	0.4%	0.017	-266%	3.12	3.0%	0.998
EE10	15507.4	0.00%	792.0	0.9%	0.020	-112%	3.08	4.4%	0.996
EE11	15511.5	0.01%	893.5	0.9%	0.022	-65%	3.05	3.5%	0.998
SE01	15473.9	0.00%	3.1	-0.2%	0.033	-2%	2.99	0.0%	1.000
SE02	15476.2	0.00%	12.1	0.0%	-0.010	19%	2.94	0.2%	0.997
SE03	15478.6	0.00%	30.5	0.0%	-0.003	-41%	2.71	0.0%	1.000
SE04	15481.0	0.00%	79.0	1.4%	-0.002	-20%	2.85	3.9%	0.997
SE05	15483.4	0.00%	135.5	0.3%	0.000	2620%	2.98	1.3%	1.000
SE06	15485.8	0.00%	214.1	1.4%	0.000	-1747%	3.07	5.8%	0.999
SE07	15488.4	0.00%	302.6	1.7%	-0.001	226%	3.08	6.1%	0.999
SE08	15491.0	-0.01%	392.3	1.5%	-0.002	-1763%	3.08	5.1%	0.998
SE09	15493.6	0.00%	479.7	2.9%	-0.002	13%	3.13	6.9%	0.989
SE10	15496.2	0.00%	567.9	1.8%	-0.003	146%	3.13	4.7%	0.997
SE11	15499.0	0.00%	661.1	1.2%	-0.003	558%	3.10	4.1%	0.999
SS01	15472.7	-0.01%	0.7	8.8%	0.021	-352%	3.00	-1.9%	0.918
SS02	15472.7	0.00%	3.5	-0.2%	0.023	-4%	2.90	0.4%	1.000
SS03	15472.7	0.00%	10.1	-2.6%	0.006	-389%	2.82	-0.6%	0.985
SS04	15472.8	0.00%	31.6	0.0%	0.000	-248%	2.59	0.1%	1.000
SS05	15472.8	0.00%	54.3	0.0%	0.002	1250%	3.22	-0.3%	1.000
SS06	15472.9	0.00%	80.3	0.1%	0.001	-285%	3.16	0.1%	1.000
SS07	15472.9	0.00%	100.2	0.3%	0.002	9%	3.15	1.4%	1.000
SS08	15473.1	0.00%	116.9	0.7%	0.002	-59%	3.13	3.0%	1.000
SS09	15473.2	0.00%	139.9	0.3%	0.003	-265%	3.12	2.2%	1.000

SS10	15473.3	0.00%	173.7	1.5%	0.003	-60%	3.07	6.1%	0.999
SS11	15473.5	0.00%	215.0	1.4%	0.003	204%	3.00	6.7%	0.999
SW01	15471.6	0.00%	2.0	-1.3%	-0.009	415%	2.99	2.6%	0.980
SW02	15469.3	-0.08%	5.6	-11.5%	0.002	5303%	2.99	-8.4%	0.914
SW03	15467.1	0.00%	12.7	-0.2%	0.006	-36%	2.84	-0.2%	1.000
SW04	15464.8	0.00%	33.2	1.1%	-0.001	-318%	3.13	-1.8%	0.989
SW05	15462.6	0.00%	52.4	0.2%	0.000	2393%	3.09	2.3%	1.000
SW06	15460.6	0.02%	70.0	-4.8%	-0.002	619%	2.94	3.4%	0.967
SW07	15458.5	0.00%	93.8	-4.4%	-0.003	-290%	2.89	-13.1%	0.954
SW08	15456.5	0.00%	126.5	0.6%	-0.004	722%	2.93	5.2%	0.997
SW09	15454.4	0.00%	160.8	0.9%	-0.003	793%	2.97	3.8%	0.999
SW10	15452.5	0.00%	191.9	0.9%	-0.002	939%	2.99	6.4%	0.998
SW11	15450.5	0.00%	219.2	0.8%	-0.001	1177%	3.01	8.2%	0.991
WW01	15471.1	0.00%	1.6	0.0%	0.029	-1%	3.02	0.0%	1.000
WW02	15467.9	0.00%	19.7	0.2%	-0.003	-121%	3.06	1.3%	1.000
WW03	15464.8	0.00%	57.3	0.1%	-0.004	7%	3.17	0.9%	1.000
WW04	15461.8	0.00%	161.9	0.4%	-0.002	180%	3.48	3.5%	1.000
WW05	15458.8	-0.01%	252.5	-0.5%	-0.001	-3641%	3.50	-10.6%	0.982
WW06	15455.9	0.00%	340.3	0.3%	-0.001	-836%	3.40	3.2%	1.000
WW07	15452.9	0.00%	414.6	0.4%	-0.002	-277%	3.31	3.5%	1.000
WW08	15450.0	0.00%	475.2	0.4%	-0.003	-224%	3.22	3.0%	0.999
WW09	15447.1	0.00%	522.7	0.5%	-0.001	-635%	3.24	3.6%	0.998
WW10	15444.2	0.00%	560.3	1.1%	0.003	582%	3.28	5.9%	0.999
WW11	15441.4	0.00%	594.5	0.9%	0.007	-125%	3.26	5.1%	0.999
NW01	15471.6	0.00%	9.2	-17.6%	0.001	-1290%	2.99	-5.2%	0.753
NW02	15469.3	0.00%	24.5	-0.3%	-0.031	8%	2.97	-0.5%	1.000
NW03	15467.1	0.00%	50.5	-0.1%	0.003	-116%	2.84	-0.3%	1.000
NW04	15464.8	0.00%	112.7	0.1%	0.002	41%	3.29	1.8%	1.000
NW05	15462.6	0.00%	178.4	0.2%	0.005	67%	3.34	2.1%	1.000
NW06	15460.5	-0.01%	255.2	-1.2%	0.007	-72%	3.27	6.6%	0.975
NW07	15458.3	0.00%	326.3	1.1%	0.008	41%	3.23	6.3%	0.999
NW08	15456.2	0.00%	387.6	-0.2%	0.009	-114%	3.17	-0.5%	0.995
NW09	15454.1	-0.01%	442.5	0.9%	0.008	273%	3.18	4.4%	0.999
NW10	15452.0	0.00%	493.9	1.6%	0.006	479%	3.19	6.2%	0.998
NW11	15450.0	0.00%	543.2	0.2%	0.003	-53%	3.14	2.0%	0.997

Tabela 39 – Parâmetros estatísticos, momento M_y , topo do SLWR

<i>Momento M_y, topo do SLWR</i>									
Caso	μ	ε_μ	σ	ε_σ	γ	ε_γ	κ	ε_κ	ρ
NN01	-17.5	-0.01%	0.0	3.1%	-1.865	102%	62.81	95.6%	0.860
NN02	-17.5	0.00%	0.1	-6.6%	0.019	-385%	2.82	0.9%	0.909
NN03	-17.5	0.00%	0.2	1.0%	-0.023	-117%	3.15	4.0%	0.988
NN04	-17.5	-0.01%	0.4	1.9%	0.020	43%	2.90	-4.4%	0.988
NN05	-17.5	-0.02%	0.8	0.2%	0.027	-110%	3.23	4.8%	0.984
NN06	-17.5	0.14%	1.2	-1.8%	0.028	-441%	3.10	-16.9%	0.959
NN07	-17.5	0.03%	1.8	0.6%	0.023	94%	3.11	7.4%	0.993
NN08	-17.5	-0.64%	2.6	0.4%	0.017	-37%	2.94	8.1%	0.973
NN09	-17.5	0.08%	3.7	0.3%	0.018	-99%	2.77	2.1%	0.998
NN10	-17.5	-0.36%	5.0	-0.2%	0.019	144%	2.67	-0.3%	0.997
NN11	-17.5	-0.13%	6.6	-0.3%	0.019	129%	2.60	-0.5%	0.999
NE01	-17.8	0.00%	0.1	-4.0%	-0.033	-688%	3.16	12.3%	0.715
NE02	-18.6	0.02%	0.4	-7.1%	-0.011	296%	2.75	-0.5%	0.812
NE03	-19.3	-0.03%	0.8	-5.3%	0.004	131%	2.68	2.1%	0.913
NE04	-20.0	0.05%	1.4	-1.8%	0.001	-7239%	2.98	6.1%	0.931
NE05	-20.8	-0.06%	1.9	-4.1%	0.016	194%	3.17	7.3%	0.929

NE06	-21.5	0.01%	2.6	-1.8%	0.006	818%	3.18	5.9%	0.976
NE07	-22.3	0.24%	3.6	-5.2%	-0.001	34471%	3.12	-68.4%	0.940
NE08	-23.1	0.07%	5.0	-6.5%	0.006	-780%	3.01	-16.7%	0.905
NE09	-23.9	-0.01%	6.8	1.3%	0.019	174%	2.87	4.8%	0.992
NE10	-24.6	-0.44%	9.3	1.0%	0.033	-88%	2.72	4.9%	0.982
NE11	-25.4	-0.22%	12.2	0.2%	0.045	8%	2.62	1.6%	0.996
EE01	-18.0	0.00%	0.2	-1.2%	0.024	-127%	3.09	-0.1%	0.987
EE02	-19.0	0.02%	0.7	-2.4%	-0.053	-25%	2.94	-1.0%	0.963
EE03	-20.0	0.01%	1.3	-1.8%	-0.083	-17%	2.76	0.6%	0.978
EE04	-21.1	-0.03%	1.8	-0.9%	-0.032	28%	2.82	4.2%	0.988
EE05	-22.2	0.03%	2.7	-2.1%	0.033	-83%	3.09	-1.5%	0.990
EE06	-23.2	0.04%	4.6	1.5%	0.039	99%	3.16	9.5%	0.988
EE07	-24.3	0.09%	8.1	1.1%	0.027	-84%	3.02	3.6%	0.997
EE08	-25.3	0.02%	13.6	1.9%	0.033	98%	2.85	8.4%	0.997
EE09	-26.3	0.44%	20.8	0.1%	0.047	-71%	2.74	2.1%	0.998
EE10	-27.2	0.08%	29.5	0.2%	0.061	-13%	2.67	1.1%	0.999
EE11	-28.1	-0.08%	39.6	0.3%	0.075	0%	2.61	2.1%	1.000
SE01	-17.8	0.00%	0.1	-3.2%	0.013	-82%	3.01	-0.2%	0.904
SE02	-18.6	0.00%	0.3	-0.1%	-0.007	-175%	2.76	2.1%	0.991
SE03	-19.3	0.00%	0.6	0.2%	0.014	-126%	2.71	-1.4%	0.984
SE04	-20.0	-0.01%	1.2	-0.7%	0.048	16%	3.14	4.5%	0.982
SE05	-20.7	0.07%	2.0	0.9%	0.057	3%	3.20	5.6%	0.990
SE06	-21.4	-0.04%	3.7	1.1%	0.039	116%	3.08	3.8%	0.997
SE07	-22.2	0.17%	6.7	-0.4%	0.030	-131%	2.97	-0.7%	0.996
SE08	-23.0	-0.17%	11.2	0.9%	0.032	24%	2.85	4.0%	0.999
SE09	-23.8	-0.24%	17.0	1.1%	0.039	19%	2.76	5.3%	0.998
SE10	-24.5	-0.23%	24.1	0.5%	0.047	-14%	2.70	2.1%	0.999
SE11	-25.2	0.43%	32.1	0.1%	0.055	1%	2.65	-0.3%	0.999
SS01	-17.5	-0.01%	0.0	12.6%	0.294	133%	15.60	80.5%	0.826
SS02	-17.5	0.00%	0.1	-0.5%	0.006	338%	2.76	-3.2%	0.950
SS03	-17.5	0.00%	0.2	-1.9%	0.015	-361%	2.94	-4.0%	0.938
SS04	-17.5	-0.02%	0.5	-2.5%	0.030	8%	3.10	2.4%	0.942
SS05	-17.5	-0.18%	0.7	-13.3%	0.066	112%	3.05	-8.3%	0.921
SS06	-17.5	-0.03%	1.1	-1.1%	0.062	-185%	3.00	2.8%	0.981
SS07	-17.5	0.03%	1.7	0.4%	0.039	40%	2.93	4.7%	0.987
SS08	-17.5	0.03%	2.6	-0.5%	0.024	-51%	2.78	3.2%	0.995
SS09	-17.5	0.11%	3.8	0.2%	0.021	57%	2.66	4.6%	0.997
SS10	-17.5	-0.10%	5.4	1.8%	0.024	-38%	2.60	5.5%	0.994
SS11	-17.5	-0.02%	7.2	0.7%	0.027	65%	2.57	2.4%	0.997
SW01	-17.1	0.00%	0.1	14.0%	-0.018	-626%	2.97	-30.1%	0.670
SW02	-16.4	0.00%	0.4	2.7%	-0.001	1447%	2.69	4.3%	0.966
SW03	-15.7	0.01%	0.7	-1.3%	0.001	166%	2.92	-4.4%	0.915
SW04	-15.0	-0.05%	1.3	-1.4%	-0.005	-891%	3.34	5.6%	0.968
SW05	-14.4	-0.05%	1.8	1.7%	0.010	-887%	3.19	7.4%	0.942
SW06	-13.7	0.01%	2.6	0.8%	0.022	-116%	3.09	9.2%	0.979
SW07	-13.0	0.16%	3.6	4.1%	0.023	331%	3.18	12.2%	0.949
SW08	-12.4	-0.34%	5.0	4.4%	0.021	88%	3.17	10.8%	0.977
SW09	-11.7	-0.04%	6.8	2.8%	0.018	203%	3.10	11.6%	0.991
SW10	-11.0	-0.37%	9.1	2.1%	0.010	68%	2.96	5.5%	0.993
SW11	-10.4	-0.10%	11.9	1.1%	0.000	-25415%	2.82	4.2%	0.998
WW01	-17.0	0.00%	0.2	3.7%	0.043	-95%	2.99	-0.1%	0.983
WW02	-16.0	-0.02%	0.7	1.6%	-0.010	-27%	2.84	4.3%	0.991
WW03	-15.0	0.01%	1.6	0.8%	-0.031	71%	2.70	0.9%	0.995
WW04	-14.0	-0.13%	2.9	0.1%	0.014	242%	3.03	3.3%	0.995
WW05	-12.9	-0.03%	3.9	1.5%	0.076	40%	3.22	9.0%	0.991
WW06	-11.9	-0.15%	5.3	0.7%	0.124	23%	3.11	5.3%	0.996
WW07	-10.8	0.00%	8.2	-0.6%	0.115	-35%	2.91	-7.1%	0.993
WW08	-9.8	0.24%	13.1	0.5%	0.085	-23%	2.74	-0.1%	0.998
WW09	-8.8	1.30%	19.9	0.4%	0.063	28%	2.65	0.9%	0.998
WW10	-7.8	0.08%	28.2	0.1%	0.047	0%	2.60	-0.1%	0.999
WW11	-6.8	-0.45%	37.9	0.5%	0.037	14%	2.57	0.6%	1.000

NW01	-17.2	-0.01%	0.1	1.0%	0.024	11%	3.09	-0.4%	0.952
NW02	-16.4	0.00%	0.5	2.4%	-0.040	9%	2.74	1.8%	0.988
NW03	-15.7	0.02%	1.0	-3.8%	0.025	1%	2.80	1.9%	0.969
NW04	-15.0	-0.05%	1.6	0.2%	0.012	431%	2.79	5.3%	0.989
NW05	-14.2	-0.37%	2.5	1.4%	0.064	29%	3.03	2.7%	0.979
NW06	-13.5	-1.39%	4.2	2.4%	0.069	16%	3.11	11.0%	0.909
NW07	-12.7	-1.50%	7.1	5.1%	0.051	96%	3.04	8.7%	0.979
NW08	-12.0	2.38%	11.3	-0.2%	0.041	11%	2.94	6.9%	0.975
NW09	-11.3	0.96%	16.6	2.6%	0.039	132%	2.83	7.8%	0.991
NW10	-10.6	-0.15%	23.1	-1.5%	0.038	258%	2.74	0.1%	0.934
NW11	-9.8	-7.25%	30.5	0.9%	0.036	222%	2.67	2.0%	0.986

Tabela 40 – Parâmetros estatísticos, momento M_z , topo do SLWR

<i>Momento M_z, topo do SLWR</i>									
Caso	μ	ε_μ	σ	ε_σ	γ	ε_γ	κ	ε_κ	ρ
NN01	-0.9	0.88%	0.1	32.8%	-0.007	-4039%	3.06	-26.5%	0.751
NN02	-0.6	0.78%	0.5	-59.4%	0.003	1731%	2.87	12.1%	0.445
NN03	-0.2	-2.55%	0.8	-8.3%	0.013	-280%	2.72	-4.0%	0.716
NN04	0.2	-2.58%	1.1	-2.0%	-0.002	964%	2.71	-10.5%	0.925
NN05	0.7	-10.8%	1.4	-11.7%	-0.038	-244%	2.87	7.8%	0.856
NN06	1.1	-0.54%	1.7	-0.5%	-0.010	247%	2.89	-3.4%	0.863
NN07	1.6	-5.50%	2.2	-10.7%	-0.056	175%	3.03	9.7%	0.805
NN08	2.0	0.52%	3.1	0.3%	-0.034	107%	3.05	12.1%	0.906
NN09	2.5	-4.62%	4.2	-2.4%	-0.004	1603%	2.98	3.3%	0.925
NN10	2.9	-5.02%	5.6	-2.2%	0.016	558%	2.90	-1.1%	0.923
NN11	3.3	0.61%	7.3	3.1%	0.019	-124%	2.84	6.7%	0.978
NE01	-1.0	0.74%	0.1	-22.0%	-0.021	1498%	3.08	-3.5%	0.438
NE02	-0.7	-0.12%	0.4	-45.8%	-0.001	-1342%	2.79	20.6%	0.629
NE03	-0.5	37.53%	0.8	-48.7%	-0.010	1011%	2.76	2.8%	0.660
NE04	-0.2	76.56%	1.6	-30.8%	-0.026	-409%	2.87	20.0%	0.707
NE05	0.1	-16.5%	2.3	-4.7%	-0.016	595%	3.14	0.5%	0.883
NE06	0.4	-15.0%	3.1	-8.5%	-0.016	-912%	3.09	9.8%	0.891
NE07	0.7	-6.27%	4.1	-2.9%	-0.036	66%	3.05	7.7%	0.953
NE08	1.0	2.85%	5.5	-4.6%	-0.060	-40%	3.06	8.9%	0.930
NE09	1.2	-8.92%	7.1	-0.4%	-0.075	195%	3.10	3.6%	0.983
NE10	1.4	-6.95%	8.7	2.0%	-0.079	116%	3.11	11.1%	0.991
NE11	1.6	-3.70%	10.2	0.2%	-0.077	-35%	3.12	3.4%	0.992
EE01	-1.1	0.00%	0.1	-0.3%	0.001	-780%	3.13	0.3%	0.999
EE02	-1.1	0.06%	0.5	0.1%	0.047	-12%	2.84	0.1%	1.000
EE03	-1.1	0.94%	1.3	0.8%	0.016	-3%	2.97	2.7%	0.999
EE04	-1.3	-1.99%	3.3	-0.2%	-0.075	-1%	3.45	1.9%	0.999
EE05	-1.4	6.69%	5.1	0.1%	-0.123	30%	3.51	2.2%	0.999
EE06	-1.6	2.55%	7.0	-0.2%	-0.141	6%	3.44	1.3%	0.999
EE07	-1.7	5.84%	8.6	0.0%	-0.131	9%	3.36	1.0%	0.999
EE08	-1.8	1.56%	9.9	0.6%	-0.103	1%	3.28	3.6%	0.999
EE09	-1.9	2.69%	11.2	1.1%	-0.071	21%	3.26	5.9%	0.998
EE10	-2.0	1.86%	12.4	0.0%	-0.037	101%	3.25	4.8%	0.998
EE11	-2.0	-2.01%	13.8	1.2%	-0.003	-778%	3.19	4.7%	0.998
SE01	-1.2	-0.02%	0.1	1.6%	-0.007	-240%	2.89	3.2%	0.982
SE02	-1.5	-0.10%	0.3	0.4%	-0.004	-79%	2.68	0.3%	0.992
SE03	-1.8	0.26%	0.7	0.2%	-0.023	-27%	2.61	1.3%	0.997
SE04	-2.0	0.33%	1.5	0.5%	-0.041	42%	2.75	1.0%	0.997
SE05	-2.3	1.10%	2.5	1.5%	-0.059	68%	2.92	3.1%	0.997
SE06	-2.7	2.18%	3.9	2.0%	-0.088	100%	3.08	6.7%	0.991
SE07	-3.1	2.45%	5.6	1.2%	-0.115	65%	3.14	6.3%	0.996

SE08	-3.7	1.44%	7.2	1.0%	-0.132	-27%	3.18	0.7%	0.998
SE09	-4.2	-0.33%	8.8	4.0%	-0.142	20%	3.27	10.5%	0.968
SE10	-4.8	-0.22%	10.2	2.1%	-0.141	-34%	3.27	4.3%	0.996
SE11	-5.4	3.59%	11.8	1.0%	-0.138	23%	3.20	-20.1%	0.964
SS01	-1.3	0.01%	0.1	-1.6%	-0.011	19%	2.94	0.2%	0.972
SS02	-1.7	0.11%	0.5	-0.5%	0.001	-1380%	2.75	-3.7%	0.921
SS03	-2.0	0.21%	0.9	3.3%	0.020	-248%	3.03	-0.4%	0.908
SS04	-2.3	-0.09%	1.4	0.7%	0.061	305%	3.18	-4.1%	0.974
SS05	-2.6	-1.71%	1.8	-32.2%	0.041	207%	2.84	2.9%	0.306
SS06	-2.9	-1.09%	2.4	3.5%	0.063	135%	2.96	7.7%	0.965
SS07	-3.2	-1.29%	3.3	-0.5%	0.120	-27%	3.09	-0.9%	0.968
SS08	-3.4	-2.61%	4.6	6.5%	0.181	110%	3.21	13.1%	0.867
SS09	-3.7	-2.74%	6.2	4.4%	0.216	60%	3.28	5.3%	0.938
SS10	-4.1	-5.95%	8.1	7.2%	0.214	43%	3.29	7.5%	0.937
SS11	-4.5	-6.85%	10.2	-1.2%	0.182	135%	3.31	-1.2%	0.948
SW01	-1.3	0.85%	0.1	37.9%	-0.028	-856%	3.01	17.3%	0.515
SW02	-1.5	0.11%	0.3	-0.4%	0.007	-877%	2.88	-9.8%	0.918
SW03	-1.7	-0.54%	0.6	2.4%	0.029	22%	3.04	7.2%	0.922
SW04	-2.0	0.82%	1.0	-1.5%	0.092	-26%	3.11	7.1%	0.953
SW05	-2.2	0.93%	1.7	-0.4%	0.029	118%	3.08	5.5%	0.963
SW06	-2.4	1.03%	2.7	2.9%	0.081	-58%	3.14	5.4%	0.972
SW07	-2.6	2.32%	4.3	0.9%	0.083	-110%	3.15	0.2%	0.967
SW08	-2.8	-0.92%	6.2	4.1%	0.072	183%	3.19	8.2%	0.988
SW09	-3.1	-4.10%	8.5	7.5%	0.054	176%	3.23	11.3%	0.970
SW10	-3.4	2.87%	11.0	4.7%	0.031	-334%	3.25	8.5%	0.986
SW11	-3.8	5.04%	13.6	3.5%	0.006	-2593%	3.26	-1.0%	0.977
WW01	-1.1	0.03%	0.1	1.5%	0.021	-136%	3.11	0.5%	0.988
WW02	-1.1	0.32%	0.3	-0.7%	0.039	98%	2.92	0.3%	0.991
WW03	-1.1	-0.07%	0.5	0.1%	0.011	-99%	2.88	2.3%	0.994
WW04	-1.2	1.36%	1.1	-0.7%	-0.047	32%	3.34	3.5%	0.990
WW05	-1.2	0.82%	1.8	-0.6%	-0.060	35%	3.34	3.1%	0.993
WW06	-1.3	3.43%	2.7	-0.3%	-0.053	143%	3.30	1.8%	0.989
WW07	-1.4	5.49%	3.8	0.5%	-0.040	16%	3.24	4.5%	0.994
WW08	-1.5	0.72%	5.1	1.5%	-0.043	-35%	3.13	5.7%	0.997
WW09	-1.6	3.80%	6.7	1.4%	-0.056	82%	3.08	6.1%	0.996
WW10	-1.8	2.70%	8.5	2.2%	-0.066	-34%	3.02	7.1%	0.998
WW11	-1.9	6.52%	10.5	1.8%	-0.072	-8%	2.93	5.8%	0.998
NW01	-1.0	0.36%	0.1	-4.6%	0.065	-12%	3.07	7.5%	0.964
NW02	-0.7	0.44%	0.3	-0.1%	0.029	-144%	2.82	-0.8%	0.960
NW03	-0.5	-1.63%	0.6	-5.1%	-0.004	1183%	2.90	-2.8%	0.943
NW04	-0.2	5.35%	1.4	-2.2%	-0.016	-188%	2.97	-1.5%	0.970
NW05	0.1	-59.3%	2.4	-5.0%	-0.032	-674%	3.10	-26.1%	0.942
NW06	0.2	-13.4%	3.8	1.5%	-0.054	53%	3.16	-0.6%	0.990
NW07	0.4	-7.7%	5.5	0.6%	-0.078	-39%	3.14	9.4%	0.968
NW08	0.4	-20.7%	7.2	1.1%	-0.101	72%	3.15	8.9%	0.992
NW09	0.5	-36.3%	8.8	5.7%	-0.117	26%	3.23	9.9%	0.985
NW10	0.6	-76.9%	10.3	5.2%	-0.121	-37%	3.24	11.0%	0.956
NW11	0.6	-6.35%	11.9	4.5%	-0.119	-17%	3.18	8.6%	0.985

Anexo C

Coefficientes de Correlação, Tensões

Neste anexo os valores dos coeficientes de correlação entre as séries temporais de tensão obtidas pelas análises de elementos finitos completas e pela metodologia híbrida são apresentados para todos os pontos da seção transversal e todos os casos de carregamento.

C.1 Topo do SCR

Tabela 41 – Coeficientes de correlação, tensão superfície externa topo do SCR

<i>Valores do coeficiente de correlação, tensões superfície externa, topo do SCR</i>								
Caso	0°	45°	90°	135°	180°	225°	270°	315°
NN01	1.000	1.000	1.000	0.993	1.000	1.000	1.000	0.993
NN02	0.999	1.000	1.000	0.996	0.999	1.000	1.000	0.997
NN03	1.000	1.000	1.000	0.997	1.000	1.000	1.000	0.998
NN04	0.998	0.999	0.999	0.986	0.999	1.000	1.000	0.994
NN05	0.999	1.000	0.999	0.980	1.000	1.000	0.999	0.993
NN06	0.999	1.000	1.000	0.989	1.000	1.000	1.000	0.997
NN07	0.999	0.999	0.999	0.972	0.999	1.000	1.000	0.992
NN08	0.996	0.999	0.999	0.916	0.998	0.999	0.999	0.971
NN09	0.999	1.000	0.999	0.974	0.999	1.000	1.000	0.992
NN10	0.999	0.999	0.999	0.972	0.999	1.000	1.000	0.992
NN11	0.998	0.999	0.999	0.938	0.999	0.999	0.999	0.979
NE01	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
NE02	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NE03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NE04	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NE05	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NE06	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
NE07	1.000	1.000	0.997	1.000	1.000	1.000	0.999	1.000
NE08	1.000	0.999	0.989	1.000	1.000	0.999	0.997	0.999
NE09	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
NE10	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
NE11	1.000	0.999	0.991	1.000	1.000	1.000	0.997	0.999
EE01	0.990	0.931	0.992	0.995	0.992	0.950	0.991	0.995
EE02	1.000	0.999	1.000	1.000	1.000	0.999	1.000	1.000
EE03	1.000	0.998	1.000	1.000	1.000	0.999	1.000	1.000
EE04	1.000	0.998	1.000	1.000	1.000	0.999	1.000	1.000
EE05	1.000	0.994	1.000	1.000	1.000	0.997	1.000	1.000
EE06	1.000	0.992	0.999	1.000	1.000	0.996	1.000	1.000
EE07	1.000	0.984	1.000	1.000	1.000	0.992	1.000	1.000
EE08	0.995	0.901	1.000	0.999	0.995	0.945	1.000	0.999
EE09	0.933	0.528	0.999	0.983	0.932	0.675	0.999	0.983
EE10	0.998	0.498	0.925	0.978	0.998	0.537	0.925	0.978
EE11	0.998	0.930	0.996	0.998	0.998	0.951	0.995	0.998
SE01	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
SE02	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
SE03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000

SE04	1.000	1.000	1.000	1.000	0.997	1.000	1.000	1.000
SE05	0.999	1.000	1.000	1.000	0.994	1.000	1.000	1.000
SE06	0.999	1.000	1.000	1.000	0.989	1.000	1.000	1.000
SE07	0.999	1.000	1.000	1.000	0.993	1.000	1.000	1.000
SE08	0.998	1.000	1.000	1.000	0.979	1.000	1.000	1.000
SE09	0.971	0.998	1.000	0.998	0.821	0.998	1.000	0.998
SE10	0.990	0.999	1.000	0.999	0.935	0.999	1.000	0.999
SE11	0.997	1.000	1.000	1.000	0.978	1.000	1.000	1.000
SS01	0.999	1.000	0.999	0.987	0.999	1.000	1.000	0.991
SS02	0.998	0.999	0.999	0.974	0.999	0.999	0.999	0.981
SS03	1.000	1.000	1.000	0.997	1.000	1.000	1.000	0.998
SS04	1.000	1.000	1.000	0.991	1.000	1.000	0.999	0.994
SS05	1.000	1.000	1.000	0.989	1.000	1.000	1.000	0.994
SS06	0.998	0.999	1.000	0.970	0.998	0.999	1.000	0.983
SS07	0.996	0.999	0.999	0.908	0.996	0.999	0.999	0.941
SS08	0.947	0.985	1.000	0.407	0.932	0.983	1.000	0.666
SS09	0.995	0.998	1.000	0.909	0.994	0.998	0.999	0.936
SS10	0.997	0.997	0.996	0.935	0.996	0.997	0.996	0.951
SS11	0.983	0.989	0.991	0.812	0.978	0.987	0.989	0.814
SW01	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
SW02	0.999	0.997	0.997	0.999	0.998	0.996	0.999	0.999
SW03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
SW04	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
SW05	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
SW06	1.000	1.000	0.998	1.000	1.000	1.000	0.999	1.000
SW07	1.000	1.000	0.995	0.999	1.000	1.000	0.998	1.000
SW08	1.000	1.000	0.998	1.000	1.000	1.000	0.999	1.000
SW09	1.000	1.000	0.999	1.000	1.000	1.000	0.999	1.000
SW10	1.000	1.000	0.996	0.999	1.000	1.000	0.996	1.000
SW11	1.000	1.000	0.997	0.999	0.999	1.000	0.996	0.999
WW01	0.999	0.996	0.997	0.998	0.997	0.997	1.000	1.000
WW02	1.000	0.999	0.999	1.000	0.999	0.999	1.000	1.000
WW03	1.000	0.998	1.000	1.000	0.999	0.998	1.000	1.000
WW04	1.000	0.997	1.000	1.000	1.000	0.998	1.000	1.000
WW05	1.000	0.996	1.000	1.000	1.000	0.998	1.000	1.000
WW06	1.000	0.983	0.999	1.000	0.999	0.994	1.000	1.000
WW07	1.000	0.991	1.000	1.000	0.999	0.997	1.000	1.000
WW08	1.000	0.989	1.000	1.000	0.999	0.996	1.000	1.000
WW09	1.000	0.980	0.999	1.000	0.999	0.992	1.000	1.000
WW10	0.999	0.981	0.999	0.999	0.999	0.993	1.000	1.000
WW11	0.970	0.561	1.000	0.988	0.948	0.739	1.000	0.992
NW01	0.999	1.000	1.000	1.000	0.998	1.000	1.000	1.000
NW02	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NW03	1.000	1.000	1.000	1.000	0.998	1.000	1.000	1.000
NW04	0.999	1.000	1.000	1.000	0.993	1.000	1.000	1.000
NW05	0.997	0.999	1.000	0.999	0.986	1.000	1.000	1.000
NW06	0.994	0.999	1.000	0.999	0.984	1.000	1.000	1.000
NW07	0.995	1.000	1.000	0.999	0.992	1.000	1.000	1.000
NW08	0.996	1.000	1.000	1.000	0.996	1.000	1.000	1.000
NW09	0.996	1.000	1.000	1.000	0.997	1.000	1.000	1.000
NW10	0.995	1.000	1.000	0.999	0.997	1.000	1.000	1.000
NW11	0.993	0.999	0.999	0.999	0.997	0.999	1.000	0.999

Tabela 42 – Coeficientes de correlação, tensão superfície interna topo do SCR

<i>Valores do coeficiente de correlação, tensões superfície interna, topo do SCR</i>								
Caso	0°	45°	90°	135°	180°	225°	270°	315°
NN01	1.000	1.000	1.000	0.993	1.000	1.000	1.000	0.993
NN02	0.999	1.000	1.000	0.997	0.999	1.000	1.000	0.997
NN03	1.000	1.000	1.000	0.998	1.000	1.000	1.000	0.999
NN04	0.998	0.999	0.999	0.990	0.999	1.000	1.000	0.995
NN05	0.999	0.999	0.999	0.986	1.000	1.000	0.999	0.994
NN06	0.999	1.000	1.000	0.993	1.000	1.000	1.000	0.998
NN07	0.999	0.999	0.999	0.981	0.999	1.000	1.000	0.994
NN08	0.996	0.999	0.999	0.942	0.998	0.999	0.999	0.977
NN09	0.999	1.000	0.999	0.983	1.000	1.000	1.000	0.994
NN10	0.999	0.999	0.999	0.981	0.999	1.000	1.000	0.994
NN11	0.998	0.999	0.999	0.957	0.999	0.999	0.999	0.983
NE01	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
NE02	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NE03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NE04	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NE05	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NE06	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
NE07	1.000	1.000	0.997	1.000	1.000	1.000	0.999	1.000
NE08	1.000	0.999	0.989	1.000	1.000	0.999	0.997	0.999
NE09	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
NE10	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
NE11	1.000	0.999	0.991	1.000	1.000	1.000	0.998	0.999
EE01	0.988	0.932	0.989	0.994	0.989	0.949	0.989	0.994
EE02	1.000	0.999	1.000	1.000	1.000	0.999	1.000	1.000
EE03	1.000	0.999	1.000	1.000	1.000	0.999	1.000	1.000
EE04	1.000	0.999	1.000	1.000	1.000	0.999	1.000	1.000
EE05	1.000	0.996	1.000	1.000	1.000	0.998	1.000	1.000
EE06	1.000	0.995	0.999	1.000	1.000	0.997	1.000	1.000
EE07	1.000	0.988	0.999	1.000	1.000	0.993	1.000	1.000
EE08	0.995	0.923	1.000	0.999	0.995	0.955	1.000	0.999
EE09	0.933	0.564	0.999	0.983	0.932	0.706	0.999	0.983
EE10	0.998	0.538	0.926	0.978	0.998	0.575	0.925	0.978
EE11	0.998	0.941	0.996	0.998	0.998	0.959	0.995	0.998
SE01	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
SE02	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
SE03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
SE04	1.000	1.000	1.000	1.000	0.996	1.000	1.000	1.000
SE05	0.999	1.000	1.000	1.000	0.992	1.000	1.000	1.000
SE06	0.999	1.000	1.000	1.000	0.987	1.000	1.000	1.000
SE07	0.999	1.000	1.000	1.000	0.992	1.000	1.000	1.000
SE08	0.998	1.000	1.000	1.000	0.977	1.000	1.000	1.000
SE09	0.974	0.998	1.000	0.998	0.806	0.998	1.000	0.998
SE10	0.991	0.999	1.000	0.999	0.930	0.999	1.000	0.999
SE11	0.997	1.000	1.000	1.000	0.976	1.000	1.000	1.000
SS01	0.998	0.999	0.999	0.988	0.999	1.000	1.000	0.992
SS02	0.997	0.999	0.998	0.977	0.999	0.999	0.999	0.982
SS03	1.000	1.000	1.000	0.998	1.000	1.000	1.000	0.998
SS04	1.000	1.000	1.000	0.993	1.000	1.000	0.999	0.995
SS05	1.000	1.000	1.000	0.992	1.000	1.000	1.000	0.995
SS06	0.998	0.999	1.000	0.978	0.998	0.999	1.000	0.986
SS07	0.997	0.999	0.999	0.930	0.996	0.999	0.999	0.953
SS08	0.948	0.986	1.000	0.470	0.931	0.983	1.000	0.705
SS09	0.995	0.999	1.000	0.928	0.994	0.998	0.999	0.948
SS10	0.997	0.997	0.997	0.949	0.996	0.997	0.996	0.961
SS11	0.983	0.989	0.991	0.844	0.978	0.987	0.989	0.846
SW01	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
SW02	0.999	0.997	0.996	0.999	0.998	0.996	0.999	0.999
SW03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000

SW04	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
SW05	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
SW06	1.000	1.000	0.998	1.000	1.000	1.000	0.999	1.000
SW07	1.000	1.000	0.995	0.999	1.000	1.000	0.998	1.000
SW08	1.000	1.000	0.999	1.000	1.000	1.000	0.999	1.000
SW09	1.000	1.000	0.999	1.000	1.000	1.000	0.999	1.000
SW10	1.000	1.000	0.997	0.999	1.000	1.000	0.996	1.000
SW11	1.000	1.000	0.998	0.999	0.999	1.000	0.997	0.999
WW01	0.999	0.996	0.996	0.998	0.996	0.997	1.000	1.000
WW02	1.000	0.999	0.999	1.000	0.999	0.999	1.000	1.000
WW03	1.000	0.998	0.999	1.000	0.999	0.999	1.000	1.000
WW04	1.000	0.998	1.000	1.000	1.000	0.999	1.000	1.000
WW05	1.000	0.997	1.000	1.000	0.999	0.999	1.000	1.000
WW06	1.000	0.988	0.999	1.000	0.999	0.995	1.000	1.000
WW07	1.000	0.994	1.000	1.000	0.999	0.997	1.000	1.000
WW08	1.000	0.992	0.999	1.000	0.999	0.996	1.000	1.000
WW09	1.000	0.984	0.999	1.000	0.999	0.993	1.000	1.000
WW10	0.999	0.985	0.999	0.999	0.999	0.994	1.000	1.000
WW11	0.972	0.623	0.999	0.987	0.946	0.775	1.000	0.992
NW01	0.999	1.000	1.000	1.000	0.998	1.000	1.000	1.000
NW02	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NW03	1.000	1.000	1.000	1.000	0.998	1.000	1.000	1.000
NW04	0.999	1.000	1.000	1.000	0.994	1.000	1.000	1.000
NW05	0.998	0.999	1.000	0.999	0.989	1.000	1.000	1.000
NW06	0.995	0.999	1.000	0.999	0.987	1.000	1.000	1.000
NW07	0.996	1.000	1.000	0.999	0.993	1.000	1.000	1.000
NW08	0.997	1.000	1.000	1.000	0.997	1.000	1.000	1.000
NW09	0.997	1.000	1.000	0.999	0.997	1.000	1.000	1.000
NW10	0.996	1.000	1.000	0.999	0.997	1.000	1.000	1.000
NW11	0.994	0.999	0.999	0.999	0.997	0.999	1.000	0.999

C.2 TDZ do SCR

Tabela 43 – Coeficientes de correlação, tensão superfície externa TDZ do SCR

<i>Valores do coeficiente de correlação, tensões superfície externa, TDZ do SCR</i>								
Caso	0°	45°	90°	135°	180°	225°	270°	315°
NN01	0.992	0.998	0.998	0.998	0.992	0.998	0.998	0.998
NN02	1.000	0.970	0.968	0.970	1.000	0.973	0.971	0.973
NN03	0.999	0.998	0.996	0.998	0.999	0.998	0.997	0.998
NN04	0.998	0.998	0.998	0.998	0.998	0.997	0.997	0.997
NN05	0.996	0.995	0.995	0.995	0.996	0.995	0.994	0.995
NN06	0.998	0.997	0.996	0.997	0.998	0.997	0.997	0.997
NN07	0.998	0.997	0.997	0.997	0.998	0.998	0.998	0.998
NN08	0.996	0.996	0.996	0.996	0.996	0.996	0.996	0.996
NN09	0.986	0.986	0.986	0.986	0.986	0.986	0.987	0.986
NN10	0.988	0.988	0.988	0.988	0.988	0.988	0.988	0.988
NN11	0.984	0.984	0.984	0.984	0.984	0.984	0.984	0.984
NE01	0.999	0.960	0.959	0.960	0.999	0.957	0.958	0.957
NE02	0.939	0.940	0.939	0.940	0.939	0.937	0.937	0.937
NE03	0.993	0.986	0.986	0.986	0.993	0.985	0.985	0.985
NE04	0.998	0.983	0.983	0.983	0.998	0.983	0.983	0.983
NE05	0.996	0.993	0.993	0.993	0.996	0.993	0.993	0.993
NE06	0.991	0.996	0.996	0.996	0.991	0.996	0.996	0.996
NE07	0.994	0.982	0.983	0.982	0.994	0.983	0.983	0.983

NE08	0.997	0.960	0.960	0.960	0.997	0.962	0.962	0.962
NE09	0.995	0.969	0.969	0.969	0.995	0.971	0.971	0.971
NE10	0.987	0.963	0.963	0.963	0.987	0.964	0.963	0.964
NE11	0.993	0.983	0.984	0.983	0.993	0.985	0.985	0.985
EE01	0.998	0.972	0.972	0.972	0.998	0.970	0.970	0.970
EE02	0.995	0.707	0.698	0.707	0.995	0.655	0.661	0.655
EE03	0.996	0.979	0.977	0.979	0.996	0.973	0.973	0.973
EE04	0.992	0.984	0.982	0.984	0.992	0.970	0.972	0.970
EE05	0.996	0.994	0.994	0.994	0.996	0.991	0.992	0.991
EE06	0.995	0.996	0.996	0.996	0.995	0.989	0.991	0.989
EE07	0.981	0.996	0.997	0.996	0.981	0.993	0.997	0.993
EE08	0.978	0.994	0.995	0.994	0.978	0.987	0.993	0.987
EE09	0.983	0.997	0.998	0.997	0.983	0.992	0.996	0.992
EE10	0.973	0.996	0.997	0.996	0.973	0.984	0.991	0.984
EE11	0.960	0.995	0.996	0.995	0.960	0.977	0.988	0.977
SE01	0.995	0.972	0.971	0.972	0.995	0.969	0.969	0.969
SE02	0.994	0.966	0.964	0.966	0.994	0.956	0.957	0.956
SE03	0.998	0.991	0.990	0.991	0.998	0.985	0.986	0.985
SE04	0.995	0.997	0.997	0.997	0.995	0.989	0.992	0.989
SE05	0.996	0.994	0.994	0.994	0.996	0.983	0.987	0.983
SE06	0.995	0.994	0.994	0.994	0.995	0.989	0.991	0.989
SE07	0.985	0.997	0.997	0.997	0.985	0.989	0.994	0.989
SE08	0.997	0.992	0.991	0.992	0.997	0.975	0.980	0.975
SE09	0.996	0.998	0.998	0.998	0.996	0.995	0.996	0.995
SE10	0.998	0.998	0.997	0.998	0.998	0.993	0.995	0.993
SE11	0.990	0.993	0.993	0.993	0.990	0.984	0.987	0.984
SS01	0.974	0.998	0.999	0.998	0.974	0.998	0.999	0.998
SS02	0.996	0.997	0.997	0.997	0.996	0.997	0.997	0.997
SS03	0.996	0.960	0.958	0.960	0.996	0.948	0.949	0.948
SS04	0.995	0.989	0.989	0.989	0.995	0.984	0.984	0.984
SS05	0.992	0.998	0.998	0.998	0.992	0.996	0.997	0.996
SS06	0.992	0.997	0.997	0.997	0.992	0.990	0.993	0.990
SS07	0.997	0.999	0.999	0.999	0.997	0.993	0.996	0.993
SS08	0.991	0.997	0.997	0.997	0.991	0.984	0.991	0.984
SS09	0.995	0.999	0.999	0.999	0.995	0.994	0.997	0.994
SS10	0.992	0.997	0.998	0.997	0.992	0.995	0.997	0.995
SS11	0.983	0.997	0.998	0.997	0.983	0.990	0.995	0.990
SW01	0.999	0.979	0.979	0.979	0.999	0.976	0.977	0.976
SW02	0.973	0.959	0.958	0.959	0.973	0.956	0.957	0.956
SW03	0.994	0.971	0.971	0.971	0.994	0.971	0.971	0.971
SW04	0.998	0.992	0.992	0.992	0.998	0.992	0.992	0.992
SW05	0.997	0.994	0.994	0.994	0.997	0.994	0.994	0.994
SW06	0.997	0.986	0.986	0.986	0.997	0.986	0.986	0.986
SW07	0.999	0.987	0.987	0.987	0.999	0.987	0.987	0.987
SW08	0.998	0.973	0.973	0.973	0.998	0.975	0.975	0.975
SW09	0.999	0.978	0.978	0.978	0.999	0.980	0.979	0.980
SW10	0.998	0.984	0.984	0.984	0.998	0.985	0.985	0.985
SW11	0.998	0.967	0.967	0.967	0.998	0.970	0.970	0.970
WW01	0.993	0.971	0.970	0.971	0.993	0.970	0.970	0.970
WW02	0.979	0.981	0.979	0.981	0.979	0.974	0.974	0.974
WW03	0.917	0.916	0.913	0.916	0.917	0.907	0.900	0.907
WW04	0.981	0.982	0.982	0.982	0.981	0.979	0.979	0.979
WW05	0.984	0.984	0.984	0.984	0.984	0.984	0.984	0.984
WW06	0.960	0.960	0.960	0.960	0.960	0.960	0.960	0.960
WW07	0.985	0.984	0.984	0.984	0.985	0.985	0.985	0.985
WW08	0.965	0.965	0.965	0.965	0.965	0.966	0.966	0.966
WW09	0.959	0.958	0.958	0.958	0.959	0.959	0.959	0.959
WW10	0.973	0.972	0.972	0.972	0.973	0.973	0.973	0.973
WW11	0.958	0.958	0.958	0.958	0.958	0.958	0.958	0.958
NW01	1.000	0.975	0.974	0.975	1.000	0.973	0.973	0.973
NW02	0.999	0.978	0.967	0.978	0.999	0.985	0.978	0.985

NW03	0.999	0.998	0.998	0.998	0.999	0.999	0.998	0.999
NW04	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.998
NW05	0.994	0.994	0.994	0.994	0.994	0.994	0.994	0.994
NW06	0.991	0.991	0.991	0.991	0.991	0.991	0.991	0.991
NW07	0.995	0.995	0.995	0.995	0.995	0.995	0.995	0.995
NW08	0.995	0.995	0.995	0.995	0.995	0.995	0.995	0.995
NW09	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.998
NW10	0.993	0.993	0.993	0.993	0.993	0.993	0.993	0.993
NW11	0.986	0.986	0.986	0.986	0.986	0.986	0.986	0.986

Tabela 44 – Coeficientes de correlação, tensão superfície interna TDZ do SCR

<i>Valores do coeficiente de correlação, tensões superfície interna, TDZ do SCR</i>								
Caso	0°	45°	90°	135°	180°	225°	270°	315°
NN01	0.992	0.998	0.998	0.998	0.992	0.998	0.998	0.998
NN02	1.000	0.970	0.969	0.970	1.000	0.974	0.972	0.974
NN03	0.999	0.998	0.997	0.998	0.999	0.998	0.997	0.998
NN04	0.998	0.998	0.998	0.998	0.998	0.998	0.997	0.998
NN05	0.996	0.996	0.995	0.996	0.996	0.996	0.995	0.996
NN06	0.998	0.997	0.996	0.997	0.998	0.998	0.997	0.998
NN07	0.998	0.997	0.997	0.997	0.998	0.998	0.998	0.998
NN08	0.996	0.996	0.996	0.996	0.996	0.996	0.996	0.996
NN09	0.986	0.986	0.986	0.986	0.986	0.986	0.986	0.986
NN10	0.988	0.988	0.988	0.988	0.988	0.988	0.988	0.988
NN11	0.984	0.984	0.984	0.984	0.984	0.984	0.984	0.984
NE01	0.999	0.960	0.960	0.960	0.999	0.957	0.957	0.957
NE02	0.939	0.940	0.939	0.940	0.939	0.936	0.937	0.936
NE03	0.993	0.986	0.986	0.986	0.993	0.985	0.985	0.985
NE04	0.998	0.983	0.983	0.983	0.998	0.983	0.983	0.983
NE05	0.996	0.993	0.993	0.993	0.996	0.993	0.993	0.993
NE06	0.991	0.996	0.996	0.996	0.991	0.996	0.996	0.996
NE07	0.994	0.982	0.983	0.982	0.994	0.983	0.983	0.983
NE08	0.997	0.959	0.960	0.959	0.997	0.962	0.962	0.962
NE09	0.995	0.969	0.969	0.969	0.995	0.972	0.971	0.972
NE10	0.987	0.963	0.963	0.963	0.987	0.964	0.964	0.964
NE11	0.993	0.983	0.984	0.983	0.993	0.985	0.985	0.985
EE01	0.998	0.972	0.972	0.972	0.998	0.970	0.970	0.970
EE02	0.995	0.713	0.702	0.713	0.995	0.652	0.658	0.652
EE03	0.996	0.979	0.978	0.979	0.996	0.972	0.973	0.972
EE04	0.992	0.985	0.983	0.985	0.992	0.969	0.971	0.969
EE05	0.996	0.995	0.994	0.995	0.996	0.991	0.992	0.991
EE06	0.995	0.996	0.996	0.996	0.995	0.987	0.990	0.987
EE07	0.981	0.996	0.997	0.996	0.981	0.988	0.995	0.988
EE08	0.978	0.994	0.995	0.994	0.978	0.980	0.991	0.980
EE09	0.983	0.997	0.997	0.997	0.983	0.987	0.994	0.987
EE10	0.973	0.996	0.996	0.996	0.973	0.977	0.988	0.977
EE11	0.960	0.994	0.995	0.994	0.960	0.967	0.984	0.967
SE01	0.995	0.972	0.971	0.972	0.995	0.969	0.969	0.969
SE02	0.994	0.967	0.965	0.967	0.994	0.956	0.957	0.956
SE03	0.998	0.992	0.991	0.992	0.998	0.984	0.985	0.984
SE04	0.995	0.997	0.997	0.997	0.995	0.987	0.991	0.987
SE05	0.996	0.995	0.994	0.995	0.996	0.979	0.986	0.979
SE06	0.995	0.995	0.994	0.995	0.995	0.987	0.991	0.987
SE07	0.985	0.997	0.997	0.997	0.985	0.985	0.992	0.985
SE08	0.997	0.993	0.992	0.993	0.997	0.971	0.978	0.971
SE09	0.996	0.998	0.998	0.998	0.996	0.993	0.996	0.993

SE10	0.998	0.998	0.997	0.998	0.998	0.992	0.994	0.992
SE11	0.990	0.993	0.993	0.993	0.990	0.981	0.986	0.981
SS01	0.974	0.998	0.998	0.998	0.974	0.998	0.998	0.998
SS02	0.996	0.997	0.997	0.997	0.996	0.997	0.997	0.997
SS03	0.996	0.961	0.959	0.961	0.996	0.948	0.949	0.948
SS04	0.995	0.990	0.989	0.990	0.995	0.983	0.984	0.983
SS05	0.992	0.998	0.998	0.998	0.992	0.995	0.996	0.995
SS06	0.992	0.997	0.997	0.997	0.992	0.988	0.992	0.988
SS07	0.997	0.999	0.999	0.999	0.997	0.991	0.995	0.991
SS08	0.991	0.997	0.997	0.997	0.991	0.978	0.989	0.978
SS09	0.995	0.998	0.999	0.998	0.995	0.992	0.996	0.992
SS10	0.992	0.997	0.998	0.997	0.992	0.993	0.996	0.993
SS11	0.983	0.997	0.998	0.997	0.983	0.986	0.993	0.986
SW01	0.999	0.979	0.979	0.979	0.999	0.976	0.977	0.976
SW02	0.973	0.959	0.958	0.959	0.973	0.956	0.957	0.956
SW03	0.994	0.971	0.971	0.971	0.994	0.971	0.971	0.971
SW04	0.998	0.992	0.992	0.992	0.998	0.992	0.992	0.992
SW05	0.997	0.994	0.994	0.994	0.997	0.994	0.994	0.994
SW06	0.997	0.986	0.986	0.986	0.997	0.986	0.986	0.986
SW07	0.999	0.987	0.987	0.987	0.999	0.988	0.987	0.988
SW08	0.998	0.973	0.973	0.973	0.998	0.975	0.975	0.975
SW09	0.999	0.978	0.978	0.978	0.999	0.980	0.980	0.980
SW10	0.998	0.984	0.984	0.984	0.998	0.985	0.985	0.985
SW11	0.998	0.966	0.967	0.966	0.998	0.971	0.970	0.971
WW01	0.993	0.971	0.970	0.971	0.993	0.970	0.970	0.970
WW02	0.979	0.981	0.980	0.981	0.979	0.974	0.974	0.974
WW03	0.917	0.917	0.914	0.917	0.917	0.909	0.904	0.909
WW04	0.981	0.982	0.982	0.982	0.981	0.979	0.979	0.979
WW05	0.984	0.984	0.984	0.984	0.984	0.984	0.984	0.984
WW06	0.960	0.960	0.960	0.960	0.960	0.960	0.960	0.960
WW07	0.985	0.984	0.984	0.984	0.985	0.985	0.985	0.985
WW08	0.965	0.965	0.965	0.965	0.965	0.966	0.966	0.966
WW09	0.959	0.958	0.958	0.958	0.959	0.959	0.959	0.959
WW10	0.973	0.972	0.972	0.972	0.973	0.973	0.973	0.973
WW11	0.958	0.958	0.958	0.958	0.958	0.958	0.958	0.958
NW01	1.000	0.975	0.975	0.975	1.000	0.973	0.973	0.973
NW02	0.999	0.982	0.972	0.982	0.999	0.987	0.981	0.987
NW03	0.999	0.999	0.998	0.999	0.999	0.999	0.999	0.999
NW04	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.998
NW05	0.994	0.994	0.994	0.994	0.994	0.994	0.994	0.994
NW06	0.991	0.991	0.991	0.991	0.991	0.991	0.991	0.991
NW07	0.995	0.995	0.995	0.995	0.995	0.995	0.995	0.995
NW08	0.995	0.995	0.995	0.995	0.995	0.995	0.995	0.995
NW09	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.998
NW10	0.993	0.993	0.993	0.993	0.993	0.993	0.993	0.993
NW11	0.986	0.986	0.986	0.986	0.986	0.986	0.986	0.986

C.3 Topo do SLWR

Tabela 45 – Coeficientes de correlação, tensão superfície externa topo do SLWR

<i>Valores do coeficiente de correlação, tensões superfície externa, topo do SLWR</i>								
Caso	0°	45°	90°	135°	180°	225°	270°	315°
NN01	0.754	0.751	0.752	0.758	0.765	0.772	0.771	0.762
NN02	0.665	0.681	0.715	0.699	0.689	0.719	0.744	0.703
NN03	0.922	0.928	0.939	0.935	0.932	0.940	0.947	0.935
NN04	0.999	0.999	1.000	0.999	0.999	0.999	1.000	0.999
NN05	0.998	0.999	1.000	0.999	0.998	0.999	0.999	0.999
NN06	0.981	0.980	0.979	0.978	0.979	0.981	0.982	0.982
NN07	0.998	0.999	1.000	0.999	0.998	0.999	1.000	0.999
NN08	0.998	0.999	0.999	0.998	0.998	0.998	0.999	0.999
NN09	0.996	0.997	0.997	0.996	0.995	0.996	0.997	0.997
NN10	0.998	0.998	0.999	0.998	0.997	0.998	0.999	0.999
NN11	0.994	0.993	0.992	0.990	0.990	0.992	0.994	0.994
NE01	0.904	0.911	0.912	0.904	0.898	0.899	0.900	0.900
NE02	0.665	0.643	0.620	0.597	0.587	0.609	0.650	0.672
NE03	0.990	0.993	0.998	0.992	0.986	0.992	0.998	0.994
NE04	0.971	0.971	0.969	0.962	0.959	0.967	0.973	0.973
NE05	0.998	0.998	0.998	0.997	0.997	0.998	0.999	0.998
NE06	0.998	0.999	1.000	0.998	0.998	0.999	1.000	0.999
NE07	0.986	0.984	0.981	0.979	0.979	0.982	0.985	0.987
NE08	0.966	0.961	0.952	0.946	0.948	0.956	0.963	0.967
NE09	1.000	1.000	1.000	0.999	0.999	1.000	1.000	1.000
NE10	0.952	0.941	0.924	0.912	0.920	0.937	0.950	0.955
NE11	0.914	0.892	0.860	0.839	0.855	0.890	0.914	0.921
EE01	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
EE02	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
EE03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
EE04	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
EE05	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
EE06	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
EE07	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
EE08	1.000	1.000	0.999	0.999	1.000	1.000	1.000	1.000
EE09	0.998	0.998	0.998	0.998	0.998	0.999	0.999	0.999
EE10	0.996	0.995	0.995	0.995	0.996	0.997	0.997	0.997
EE11	0.998	0.997	0.997	0.997	0.998	0.998	0.999	0.998
SE01	0.999	0.998	0.997	0.998	0.999	0.998	0.996	0.998
SE02	0.997	0.998	0.997	0.997	0.996	0.996	0.997	0.997
SE03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
SE04	0.998	0.997	0.997	0.996	0.997	0.997	0.997	0.998
SE05	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
SE06	0.999	0.999	0.999	0.998	0.999	0.999	0.999	0.999
SE07	0.999	0.999	0.998	0.998	0.998	0.998	0.999	0.999
SE08	0.999	0.998	0.998	0.997	0.998	0.998	0.999	0.999
SE09	0.991	0.988	0.985	0.983	0.987	0.991	0.992	0.992
SE10	0.997	0.996	0.995	0.995	0.996	0.998	0.998	0.998
SE11	0.998	0.997	0.997	0.997	0.998	0.999	0.999	0.999
SS01	0.943	0.929	0.906	0.934	0.947	0.939	0.922	0.935
SS02	0.956	0.969	0.997	0.971	0.962	0.976	0.998	0.970
SS03	0.958	0.967	0.982	0.971	0.966	0.976	0.986	0.970
SS04	0.997	0.998	0.999	0.998	0.998	0.999	0.999	0.998
SS05	0.943	0.967	0.999	0.970	0.949	0.975	0.999	0.973
SS06	0.998	0.999	1.000	0.999	0.998	0.999	1.000	0.999
SS07	0.998	0.999	1.000	0.999	0.998	0.999	1.000	0.999
SS08	0.991	0.994	0.999	0.993	0.988	0.994	1.000	0.996
SS09	0.995	0.997	1.000	0.995	0.992	0.997	1.000	0.998

SS10	0.994	0.996	0.999	0.993	0.989	0.995	0.999	0.997
SS11	0.995	0.996	0.998	0.990	0.987	0.995	0.999	0.997
SW01	0.954	0.968	0.966	0.953	0.955	0.969	0.963	0.951
SW02	0.918	0.915	0.923	0.923	0.910	0.906	0.921	0.927
SW03	0.990	0.990	0.987	0.988	0.991	0.990	0.985	0.985
SW04	0.986	0.987	0.989	0.989	0.988	0.986	0.985	0.985
SW05	0.998	0.998	0.997	0.996	0.998	0.997	0.996	0.996
SW06	0.973	0.971	0.966	0.961	0.958	0.962	0.969	0.973
SW07	0.967	0.960	0.947	0.934	0.931	0.943	0.958	0.966
SW08	0.997	0.996	0.994	0.991	0.992	0.994	0.996	0.997
SW09	0.997	0.997	0.997	0.993	0.990	0.996	0.998	0.997
SW10	0.997	0.997	0.997	0.993	0.992	0.996	0.998	0.998
SW11	0.993	0.993	0.990	0.977	0.973	0.987	0.993	0.994
WW01	0.998	0.994	0.989	0.993	0.999	0.997	0.995	0.996
WW02	1.000	0.999	0.999	0.999	1.000	1.000	0.999	1.000
WW03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
WW04	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
WW05	0.983	0.981	0.979	0.979	0.981	0.983	0.985	0.985
WW06	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
WW07	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
WW08	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
WW09	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.998
WW10	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
WW11	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
NW01	0.747	0.741	0.741	0.749	0.760	0.767	0.765	0.757
NW02	0.999	0.999	1.000	1.000	1.000	1.000	1.000	1.000
NW03	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
NW04	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NW05	0.999	0.999	1.000	0.999	0.999	0.999	1.000	1.000
NW06	0.979	0.975	0.970	0.968	0.971	0.974	0.977	0.979
NW07	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.998
NW08	0.996	0.994	0.992	0.992	0.994	0.995	0.995	0.996
NW09	0.999	0.998	0.998	0.998	0.998	0.998	0.998	0.999
NW10	0.998	0.993	0.987	0.991	0.996	0.994	0.993	0.995
NW11	0.997	0.995	0.993	0.994	0.996	0.997	0.997	0.997

Tabela 46 – Coeficientes de correlação, tensão superfície interna topo do SLWR

<i>Valores do coeficiente de correlação, tensões superfície interna, topo do SLWR</i>								
Caso	0°	45°	90°	135°	180°	225°	270°	315°
NN01	0.755	0.752	0.754	0.758	0.765	0.770	0.770	0.762
NN02	0.677	0.690	0.717	0.706	0.699	0.723	0.742	0.709
NN03	0.927	0.932	0.940	0.937	0.935	0.942	0.947	0.937
NN04	0.999	0.999	1.000	0.999	0.999	0.999	1.000	0.999
NN05	0.999	0.999	1.000	0.999	0.998	0.999	1.000	0.999
NN06	0.981	0.980	0.979	0.979	0.979	0.981	0.982	0.982
NN07	0.998	0.999	1.000	0.999	0.998	0.999	1.000	0.999
NN08	0.998	0.999	0.999	0.999	0.998	0.999	0.999	0.999
NN09	0.997	0.997	0.997	0.996	0.996	0.997	0.997	0.997
NN10	0.998	0.999	0.999	0.998	0.997	0.998	0.999	0.999
NN11	0.994	0.993	0.992	0.991	0.991	0.992	0.994	0.994
NE01	0.905	0.911	0.912	0.906	0.901	0.901	0.902	0.902
NE02	0.661	0.642	0.620	0.601	0.593	0.613	0.647	0.666
NE03	0.992	0.995	0.998	0.994	0.990	0.994	0.998	0.995
NE04	0.972	0.971	0.969	0.964	0.962	0.968	0.973	0.973
NE05	0.998	0.999	0.999	0.998	0.998	0.998	0.999	0.998

NE06	0.999	0.999	1.000	0.999	0.998	0.999	1.000	0.999
NE07	0.986	0.984	0.982	0.980	0.980	0.983	0.985	0.986
NE08	0.966	0.961	0.953	0.948	0.949	0.956	0.963	0.967
NE09	1.000	1.000	1.000	0.999	0.999	1.000	1.000	1.000
NE10	0.950	0.940	0.926	0.916	0.922	0.937	0.949	0.953
NE11	0.911	0.892	0.864	0.847	0.860	0.890	0.911	0.918
EE01	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
EE02	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
EE03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
EE04	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
EE05	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
EE06	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
EE07	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
EE08	1.000	1.000	0.999	0.999	1.000	1.000	1.000	1.000
EE09	0.998	0.998	0.998	0.998	0.998	0.999	0.999	0.999
EE10	0.996	0.995	0.995	0.995	0.996	0.997	0.997	0.997
EE11	0.998	0.997	0.997	0.997	0.998	0.998	0.999	0.998
SE01	1.000	0.998	0.998	0.999	1.000	0.998	0.997	0.998
SE02	0.997	0.998	0.997	0.997	0.997	0.997	0.997	0.997
SE03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
SE04	0.998	0.997	0.997	0.997	0.997	0.997	0.997	0.998
SE05	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
SE06	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
SE07	0.999	0.999	0.998	0.998	0.998	0.999	0.999	0.999
SE08	0.999	0.998	0.998	0.998	0.998	0.998	0.999	0.999
SE09	0.990	0.988	0.985	0.984	0.987	0.990	0.992	0.992
SE10	0.997	0.996	0.995	0.995	0.996	0.997	0.998	0.998
SE11	0.998	0.998	0.998	0.998	0.998	0.999	0.999	0.999
SS01	0.939	0.926	0.908	0.931	0.943	0.936	0.922	0.932
SS02	0.962	0.975	0.998	0.976	0.967	0.980	0.998	0.975
SS03	0.963	0.971	0.983	0.974	0.969	0.978	0.986	0.973
SS04	0.998	0.999	0.999	0.999	0.998	0.999	0.999	0.999
SS05	0.957	0.976	0.999	0.977	0.961	0.980	0.999	0.980
SS06	0.998	0.999	1.000	0.999	0.999	0.999	1.000	0.999
SS07	0.998	0.999	1.000	0.999	0.998	0.999	1.000	0.999
SS08	0.993	0.995	1.000	0.994	0.991	0.996	1.000	0.997
SS09	0.996	0.997	1.000	0.996	0.994	0.997	1.000	0.998
SS10	0.995	0.997	0.999	0.994	0.992	0.996	0.999	0.997
SS11	0.996	0.997	0.998	0.993	0.990	0.996	0.999	0.998
SW01	0.960	0.970	0.969	0.959	0.961	0.972	0.966	0.957
SW02	0.918	0.915	0.921	0.921	0.910	0.907	0.920	0.924
SW03	0.992	0.992	0.990	0.990	0.993	0.993	0.988	0.988
SW04	0.986	0.988	0.989	0.989	0.988	0.986	0.986	0.986
SW05	0.998	0.998	0.997	0.997	0.998	0.998	0.997	0.997
SW06	0.973	0.971	0.966	0.962	0.960	0.963	0.969	0.972
SW07	0.966	0.960	0.948	0.937	0.935	0.945	0.958	0.965
SW08	0.997	0.996	0.994	0.993	0.993	0.995	0.996	0.997
SW09	0.997	0.997	0.998	0.994	0.993	0.997	0.998	0.998
SW10	0.997	0.998	0.997	0.995	0.994	0.997	0.998	0.998
SW11	0.993	0.993	0.990	0.981	0.978	0.988	0.993	0.994
WW01	0.999	0.995	0.991	0.995	0.999	0.998	0.996	0.997
WW02	1.000	1.000	0.999	1.000	1.000	1.000	1.000	1.000
WW03	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
WW04	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
WW05	0.983	0.981	0.979	0.979	0.981	0.983	0.984	0.984
WW06	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
WW07	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
WW08	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
WW09	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.998
WW10	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
WW11	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999

NW01	0.748	0.742	0.743	0.750	0.759	0.765	0.764	0.756
NW02	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NW03	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999
NW04	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
NW05	0.999	1.000	1.000	0.999	0.999	1.000	1.000	1.000
NW06	0.978	0.975	0.971	0.970	0.971	0.974	0.977	0.979
NW07	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.998
NW08	0.996	0.994	0.993	0.993	0.994	0.995	0.995	0.996
NW09	0.999	0.998	0.998	0.998	0.998	0.998	0.998	0.999
NW10	0.998	0.995	0.990	0.993	0.997	0.995	0.994	0.996
NW11	0.997	0.996	0.994	0.994	0.996	0.997	0.997	0.997
