



REDES NEURAIAS ARTIFICIAIS APLICADAS À ANÁLISE DO
COMPORTAMENTO DE SISTEMAS OCEÂNICOS

Jerver Elio Mañuico Vivanco

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia Oceânica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia Oceânica.

Orientador(es): Carlos Antonio Levi da Conceição
Antonio Carlos Fernandes

Rio de Janeiro
Outubro de 2020

REDES NEURAIAS ARTIFICIAIS APLICADAS À ANÁLISE DO
COMPORTAMENTO DE SISTEMAS OCEÂNICOS

Jerver Elio Mañuico Vivanco

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA DA
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM
CIÊNCIAS EM ENGENHARIA OCEÂNICA.

Orientador(es): Carlos Antonio Levi da Conceição
Antonio Carlos Fernandes

Aprovada por: Prof. Antonio Carlos Fernandes
Prof. Carlos Antonio Levi da Conceição
Prof. Jean David Job Emmanuel Marie Caprace
Prof. Joel Sena Sales Junior
Prof. Gilberto Bruno Ellwanger
Prof. Celso Kazuyuki Morooka

RIO DE JANEIRO, RJ – BRASIL
OUTUBRO DE 2020

Vivanco, Jerver Elio Mañuico

Redes Neurais Artificiais Aplicadas à Análise do Comportamento de Sistemas Oceânicos / Jerver Elio Mañuico Vivanco. – Rio de Janeiro: UFRJ/COPPE, 2020.

XVII, 204 p.: il.; 29,7 cm.

Orientadores: Carlos Antonio Levi da Conceição
Antonio Carlos Fernandes

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia Oceânica, 2020.

Referências Bibliográficas: p. 107-122.

1. Sistemas Oceânicos. 2. Redes Neurais Artificiais. 3. Roll Paramétrico. 4. Predição do Comportamento. I. Conceição, Carlos Antonio Levi da *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Oceânica. III. Título.

AGRADECIMENTOS

Ao Prof. Carlos Antonio Levi da Conceição, pela valiosa orientação, amizade e consideração brindadas nestes últimos anos ao longo do desenvolvimento desta tese.

Ao Prof. Antonio Carlos Fernandes, pela orientação e aconselhamento na realização da tese.

Ao Prof. Marcelo de Almeida Santos Neves, pela orientação na fase inicial deste trabalho do doutorado, e fraterna amizade aos longos de todos esses anos da minha passagem pelo Programa de Engenharia Oceânica - PENO.

Aos professores, amigos e colegas do DENO e do PENO, com destaque para todo o pessoal da Área de Hidrodinâmica, em especial, ao Professor Juan Wanderley pelo seu apoio constante em todos esses anos.

À Agência Nacional do Petróleo, Gás e Biocombustíveis (ANP) pelo apoio financeiro durante parte do desenvolvimento da minha pesquisa.

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

REDES NEURAIAS ARTIFICIAIS APLICADAS À ANÁLISE DO COMPORTAMENTO DE SISTEMAS OCEÂNICOS

Jerver Elio Mañuico Vivanco

Outubro/2020

Orientadores: Carlos Antonio Levi da Conceição

Antonio Carlos Fernandes

Programa: Engenharia Oceânica

O presente trabalho desenvolve pesquisas envolvendo a aplicação de redes neurais artificiais (RNAs) na predição do comportamento do movimento de roll do navio, operando em mar irregular, principalmente, à amplificação e diminuição de roll de embarcações decorrente do fenômeno da ressonância paramétrica. A importância do estudo da ressonância paramétrica excitada por ondas longitudinais é um problema bastante real que afeta muitos navios, podendo levar a consequências catastróficas. Para isso, foi desenvolvida um código no MATLAB baseados em RNAs capaz de realizar predições rápidas, e suficientemente fidedignos da progressão de movimentos exagerados. Numa fase preliminar, analisou-se a previsão do comportamento do próprio mar real, elemento indutor do movimento dos sistemas oceânicos. E a título de ilustração, discutiu-se a sua aplicação na predição do deslocamento vertical e da força de excitação de um sistema WEC (Wave Energy Converter). Os objetivos da tese puderam ser demonstrados através da análise das predições do comportamento de um navio porta-contentor, operando no mar real, cobrindo janelas de tempo de predição longas, suficientes (~ 60s) para viabilizar medidas corretivas para evitar o aparecimento do roll paramétrico. A motivação prática da tese pretendeu fornecer elementos para a instalação a bordo de um sistema inteligente online, para orientar a tripulação na detecção do aparecimento da ressonância paramétrica, evitando que este perigoso fenômeno tenha condições de se desenvolver.

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

ARTIFICIAL NEURAL NETWORKS APPLIED TO THE ANALYSIS OF THE
BEHAVIOR OF OCEANIC SYSTEMS

Jerver Elio Mañuico Vivanco

October/2020

Advisors: Carlos Antonio Levi da Conceição
Antonio Carlos Fernandes

Department: Ocean Engineering

The present work develops research involving the application of artificial neural networks (ANNs) in the prediction of the ship's roll movement behavior, operating in an irregular sea, focus to the amplification and decrease of roll of vessels due to the phenomenon of parametric resonance. The importance of this topic, parametric resonance excited by longitudinal waves, is a real problem that affects many ships and can lead to catastrophic consequences. For this, a code was developed in MATLAB based on RNAs capable of making fast predictions, and sufficiently reliable of the progression of exaggerated movements. Previously, the prediction of the behavior of the real sea itself, an element that induces the movement of oceanic systems, was analyzed. As an illustration, it is discussed the application in the prediction of the vertical displacement and the excitation force of a WEC (Wave Energy Converter) system. The objectives of the thesis could be demonstrated through the analysis of the predictions of the behavior of a container ship, operating in the real sea, covering windows of long prediction time, sufficient (~ 60s) to enable corrective measures to prevent the appearance of the parametric roll. The practical motivation of the thesis intended to provide elements for the installation on board an intelligent online system, to guide the crew in detecting the appearance of parametric resonance, preventing this dangerous phenomenon from being able to develop.

ÍNDICE

1	INTRODUÇÃO	1
2	REVISÃO BIBLIOGRÁFICA	10
2.1	Antecedentes e Cenário Atual da Estabilidade Dinâmica de Navios em Ondas	11
2.2	Antecedentes das Redes Neurais Aplicadas à Engenharia Naval	19
3	SISTEMAS DINÂMICOS E REDES NEURAS ARTIFICIAIS – RNAs	21
3.1	Sistemas Dinâmicos	21
3.2	Sistema Determinístico	22
3.3	Sistema Estocástico	22
3.3.1	Processo Aleatório Estacionário	23
3.3.2	Processo Aleatório Ergódico	23
3.4	Redes Neurais Artificiais – RNAs: Breve Introdução e Descrição	26
3.4.1	Redes Feedforward	29
3.4.2	<i>Perceptron</i> de Múltiplas Camadas (PMC)	30
3.4.3	Linguagem de Aprendizagem Backpropagation	32
4	ARQUITETURA DA REDE NEURAL ARTIFICIAL - RNA	33
4.1	Metodologia Proposta	34
4.2	Pré-Processamento dos Dados de Entrada	36
4.2.1	Normalização dos Dados	37
4.2.2	Extração de Tendência	37
4.2.3	Extração de Sazonalidades	38
4.2.4	Validação Cruzada	38
4.3	Arquitetura da Rede Neural Artificial	40
4.3.1	Seleção da Estrutura Neural Feedforward	40
4.3.1.1	Seleção de Número de Camadas da Rede PMC	40
4.3.1.2	Seleção do Número de Entradas/ <i>Inputs</i> (Atrasos)	43
4.3.1.3	Seleção do Número de Neurônios por Camada Escondida	48
4.3.1.4	Seleção dos Valores Iniciais dos Pesos Sinápticos	51
5	APLICAÇÃO PARA A PREDIÇÃO DE MAR ALEATÓRIO E UM CASO ESTACIONÁRIO	53
5.1	Introdução	53
5.2	Predição de Ondas em Mar Real	55
5.2.1	Análise de Sensibilidade	55
5.2.2	Análise de Qualidade da Predição da Onda Irregular	59
5.2.2.1	Filtragem da Série Temporal	61

5.2.3	Possibilidades e Limitações na Predição de Ondas Irregulares	66
5.3	Aplicação das RNAs para Respostas de Flutuantes no Mar Real	67
5.3.1	Conversor de Energia de Ondas tipo <i>Point Absorber</i> com <i>Latching</i>	68
5.3.2	Geração das Séries Temporais para o Treinamento da Rede Neural Artificial	69
6	RNAS NA APLICAÇÃO NA PREDIÇÃO DO COMPORTAMENTO DE UMA EMBARCAÇÃO COM ROLL PARAMÉTRICO	74
6.1	Introdução	74
6.2	Características do Navio SAFEDOR	77
6.3	Predição da Ressonância Paramétrica em Mar real	80
6.3.1	Resultados para JONSWAP $H_s = 4.8\text{m}$, $T_p = 10.63\text{ s}$	82
6.3.2	Resultados para JONSWAP $H_s = 5\text{ m}$, $T_p = 10.63\text{ s}$	87
6.3.3	Resultados para JONSWAP $H_s = 5\text{ m}$, $T_p = 8\text{ s}$	92
7	CONCLUSÕES E RECOMENDAÇÕES	98
7.1	Generalidades	98
7.2	Conclusões e Recomendações Gerais	100
7.2.1	Rede Neural para a Elevação da Onda	101
7.2.2	Rede Neural para Sistema WEC	102
7.2.3	Rede Neural para a Ressonância Paramétrica em Mar Irregular	103
7.3	Trabalhos Futuros	105
	REFERÊNCIAS BIBLIOGRÁFICAS	107
	ANEXO A: Redes Neurais Artificiais – RNAs: Breve Descrição	123
	ANEXO B: Ressonância Paramétrica de Embarcações	163
	ANEXO C: Resultados Totais das Previsões da Ressonância Paramétrica	170

LISTA DE FIGURAS

Figura 2.1: Predição do número de manchas solares para intervalos de predição (a) seis meses (b) doze meses (Han <i>et al.</i> , 2004)	18
Figura 2.2: Predição da série temporal para uma observação de volume de tráfego de 5 minutos (Tlelo-Cuautle, 2001)	19
Figura 3.1: Representação dos vários tipos de processos aleatórios.....	24
Figura 3.2: Modelo básico de neurônio artificial, Haykin (2008).....	27
Figura 3.3: Rede neural recorrente - RNA de Elman com uma camada oculta.....	28
Figura 3.4: Rede neural feedforward.....	30
Figura 3.5: Arquitetura da rede perceptron de múltiplas camadas (PMC), (Barbosa, 2010)	31
Figura 4.1: Diagrama do processo predição da série temporal de roll.....	35
Figura 4.2: SAFEDOR: Roll: Predição feita para uma rede com duas camadas escondidas de 40 neurônios, e uma camada de saída de um neurônio (40-40-1).....	41
Figura 4.3: SAFEDOR: Roll: Predição com uma única camada escondida de 60 neurônios e uma camada de saída de um neurônio (60-1).....	41
Figura 4.4: SAFEDOR: Roll: Predição Rede com uma camada escondida – Espectro de Mar III.....	43
Figura 4.5: Lagplot para o mapa Hénon com atrasos de 1 a 9 - reproduzidos de Ferreira (2006).....	44
Figura 4.6: RNA: Predição Roll; Janela de Tempo: 30s: 25 inputs.....	47
Figura 4.7: RNA: Predição Roll; Janela de Tempo: 30s: 30 inputs.....	47
Figura 4.8: RNA: Predição Roll; Janela de Tempo: 30s: 35 inputs.....	47
Figura 4.9: RNA: Predição Roll; Janela de Tempo: 30s: 40 inputs.....	48
Figura 4.10: SAFEDOR: Roll: rede com duas camadas escondidas e com 40 neurônios por camada e uma camada de saída de um neurônio (40-40-1)	50
Figura 4.11: SAFEDOR: Roll: rede com duas camadas escondidas e com 30 neurônios por camada.....	50
Figura 4.12: SAFEDOR: Roll: rede com duas camadas escondidas e com 50 neurônios por camada.....	51
Figura 5.1: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 10s: 5 séries temporais utilizadas no treinamento.....	57

Figura 5.2: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 10s: 10 séries temporais utilizadas no treinamento.....	57
Figura 5.3: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 10s: 20 series temporais utilizadas no treinamento.....	58
Figura 5.4: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 10s: 30 séries temporais utilizadas no treinamento.....	58
Figura 5.5: Variação da percentagem do erro em função do número de séries utilizadas no treinamento.....	59
Figura 5.6: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 10 s.....	60
Figura 5.7: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 20 s.....	60
Figura 5.8: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): original e filtrada.....	61
Figura 5.9: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s); Séries Filtradas: Janela de predição = 10 s.....	62
Figura 5.10: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s); Série Original Filtrada: Janela de predição = 20 s.....	62
Figura 5.11: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s); Série Original Filtrada: Janela de predição = 10 s.....	63
Figura 5.12: Onda irregular (JONSWAP: $H_s = 2.0$ m; $T_p = 10$ s); Série Original Filtrada: Janela de predição = 20 s.....	64
Figura 5.13: Onda irregular (JONSWAP: $H_s = 4.0$ m; $T_p = 10$ s); Série Original Filtrada: Janela de predição = 10 s.....	65
Figura 5.14: Onda irregular (JONSWAP: $H_s = 4.0$ m; $T_p = 10$ s); Série Original Filtrada: Janela de predição = 20 s.....	65
Figura 5.15: Ilustração Esquemática: WEC tipo Point Absorber (um grau de liberdade - heave; PTO e latching (Shadman, 2017).....	69
Figura 5.16: WEC: Força de Excitação (JONSWAP: $H_s=2.0$ m, $T_p=5.5$ s): Janela de Predição: 30 s.....	70
Figura 5.17: WEC: Deslocamento Vertical (JONSWAP: $H_s=2.0$ m, $T_p=5.5$ s): Janela de Predição: 30 s.....	70
Figura 5.18: WEC: Força de Excitação (JONSWAP: $H_s=2.0$ m, $T_p=6,0$ s): Janela de Predição: 30 s.....	71

Figura 5.19: WEC: Deslocamento Vertical (JONSWAP: Hs=2.0 m, Tp=6,0 s): Janela de Predição: 30 s.....	71
Figura 6.1: Fluxograma da metodologia da predição do <i>roll</i> paramétrico em mar real....	76
Figura 6.2: Plano de Balizas do porta-contentor SAFEDOR, Rodríguez (2010)	77
Figura 6.3: SAFEDOR: <i>roll, heave, pitch</i> excitados por onda irregular (JONSWAP: Hs = 4.8 m, Tp = 10.63 s, $\gamma = 3.3$ e ângulo de incidência = 180°)	78
Figura 6.4: SAFEDOR: registro da onda irregular (JONSWAP: Hs = 4.8 m, Tp = 10.63 s, $\gamma = 3.3$, ângulo de incidência = 180°).....	78
Figura 6.5: Espectro JONSWAP com Hs=4.8 m, Tp=10.63 s, $\gamma = 3.3$	83
Figura 6.6: SAFEDOR: <i>Roll</i> : Série Temporal 01: Janela de Predição 60 s.....	84
Figura 6.7: SAFEDOR: Transformada de Fourier - <i>Roll</i> : Série Temporal 01: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s.....	84
Figura 6.8: SAFEDOR: <i>Roll</i> : Série Temporal 02: Janela de Tempo de Predição 60 s.....	85
Figura 6.9: SAFEDOR: Transformada de Fourier - <i>Roll</i> : Série Temporal 02: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s.....	85
Figura 6.10: SAFEDOR: <i>Roll</i> : Série Temporal 03: Janela de Predição 60 s.....	86
Figura 6.11: SAFEDOR: Transformada de Fourier - <i>Roll</i> : Série Temporal 03: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s.....	86
Figura 6.12: Espectro JONSWAP com Hs=5.0 m, Tp=10.63 s, $\gamma = 3.3$	88
Figura 6.13: SAFEDOR: <i>Roll</i> : Série Temporal 01: Janela de Predição 60 s.....	89
Figura 6.14: SAFEDOR: Transformada de Fourier - <i>Roll</i> : Série Temporal 01: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s.....	89
Figura 6.15: SAFEDOR: <i>Roll</i> : Série Temporal 02: Janela de Predição 60 s.....	90
Figura 6.16: SAFEDOR: Transformada de Fourier - <i>Roll</i> : Série Temporal 02: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s.....	90
Figura 6.17: SAFEDOR: <i>Roll</i> : Série Temporal 03: Janela de Predição 60 s.....	91
Figura 6.18: SAFEDOR: Transformada de Fourier - <i>Roll</i> : Série Temporal 03: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s.....	91
Figura 6.19: Espectro JONSWAP com Hs=5.0 m, Tp=8 s, $\gamma = 3.3$	93
Figura 6.20: SAFEDOR: <i>Roll</i> : Série Temporal 01: Janela de Predição 60 s.....	94
Figura 6.21: SAFEDOR: Transformada de Fourier - <i>Roll</i> : Série Temporal 01: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s.....	94
Figura 6.22: SAFEDOR: <i>Roll</i> : Série Temporal 02: Janela de Predição 60 s.....	95

Figura 6.23: SAFEDOR: Densidade espectral <i>Roll</i> : Série Temporal 02: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s.....	95
Figura 6.24: SAFEDOR: <i>Roll</i> : Série Temporal 03: Janela de Predição 60 s.....	96
Figura 6.25: SAFEDOR: Transformada de Fourier - <i>Roll</i> : Série Temporal 03: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s.....	96

LISTA DE TABELAS

Tabela 4.1: RNA: Erros para diferentes números de camadas escondidas.....	41
Tabela 4.2: Treinamento Roll/SAFEDOR: erro para diferentes no. de inputs.....	48
Tabela 4.3: Erro com diferentes números de neurônios na camada escondida.....	51
Tabela 4.4: Erros para a rede com valores iniciais aleatórios (MSE: Mean Squared Error).....	52
Tabela 5.1: Percentagem do erro das séries temporais preditas.....	61
Tabela 5.2: Percentagem do erro das séries temporais (original filtrada e predita) (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s).....	63
Tabela 5.3: Percentagem do erro das séries temporais (original filtrada e predita) (JONSWAP: $H_s = 2.0$ m; $T_p = 10$ s)	64
Tabela 5.4: Percentagem do erro das séries temporais (original filtrada e predita) (JONSWAP: $H_s = 4.0$ m; $T_p = 10$ s)	65
Tabela 5.5: Percentagem do erro das séries temporais preditas do deslocamento vertical (referência: série original) (JONSWAP: $H_s = 2.0$ m; $T_p = 5.5$ e 6.0 s)	72
Tabela 5.6: Percentagem do erro das séries temporais preditas da força de excitação (referência: série original) (JONSWAP: $H_s = 2.0$ m; $T_p = 5.5$ e 6.0 s)	72
Tabela 6.1: Características principais do navio SAFEDOR.....	77
Tabela 6.2: Porcentagem do erro para as previsões feitas com janela de 60 segundos..	86
Tabela 6.3: Porcentagem do erro: previsões para janela de 60 segundos.....	91
Tabela 6.4: Porcentagem do erro: previsões para janela de 60 segundos.....	97

LISTA DE ABREVIATURAS E NOMENCLATURAS

RNAs – Redes Neurais Artificiais;
TS – *Transom Stern*;
RS – round stern;
WEC – *Wave Energy Conversor*;
PMC – Perceptron de múltiplas camadas;
GNL – Gás natural liquefeito;
MLP – *Multilayer perceptron*;
MSE – *Mean Squared Error*;
VI – Valores iniciais;
EQM – Erro Quadrático Médio;
VQM – Valor Quadrático Médio;
PTO – *Power Take Off*;
GM – Altura metacêntrica;
Hs – Altura significativa;
Tp – Período pico;
GM – Altura metacêntrica transversal;
Fn – *Número de Froude*;
 ω_{n4} – Frequência natural de rol;
ksi – Ângulo de incidência;
IA – Inteligência artificial;
XOR – Ou exclusivo;
IMO – *International Maritime Organization*;
GZ – Braços de endireitamento;
Msereg – *Erro quadrático médio com regularização*;
TDNN – *Time Delay Neural Network*.

LISTA DE SÍMBOLOS

w_{ij} – Pesos sinápticos;

θ_j – Limiar de ativação;

z^{-1} – Operador de atraso unitário;

v_k – Poder de ativação;

$\varphi(.)$ – Função de ativação;

y_k – Saída do neurônio artificial;

$x_1 \dots x_m$ – Valores da camada de entrada;

u_{ij} – Dados de entrada;

y_i – Valor da série original;

y_p – Valor da série predita;

B – Amortecimento;

K – Rigidez;

γ – Parâmetro de pico;

Na⁺ – Iões de sódio;

K⁺ – Iões de potássio.

TERMOS EM INGLES

Slamming;

Roll;

Machine learning;

Online;

Backpropagation;

Wave Energy Conversor;

Point Absorver;

Latching;

Heave;

Pitch;

Transom stern;

Flares;

Round stern;

Sway;

Yaw;

Sloshing;

Feedforward;

Feedback;

Multilayer perceptron;

Forward;

Backward;

Input;

Output;

Offset;

Mean Squared Error;

Underfitting;

Lags;

Phase portrait;

Lagplot;

Time step;

Power Take Off;

Overfitting;
deep learning;
offshore;
The Organization of Behaviour;
Adaptive Linear Element;
Radial basis functions;
Threshold;
Bias;
Target;
Time Delay Neural Network;
International Maritime Organization;
Broaching.

CAPÍTULO 1

1. INTRODUÇÃO

Operações a se realizarem no oceano estarão sempre condicionadas aos fatores ambientais (ondas, vento, correntes marinhas) e sujeitas a ocorrências e consequências específicas (exemplos: embarque de água no convés da embarcação, *slamming* na proa do navio, entre outras). No caso de estruturas flutuantes, estes efeitos podem gerar a perda da sua estabilidade e/ou provocarem movimentos exagerados, colocando em graves riscos o meio ambiente, a segurança da tripulação e/ou passageiros e/ou acarretando perdas patrimoniais e de receitas operacionais.

Esses efeitos, potencialmente negativos, destacam a importância do estudo da estabilidade de corpos flutuantes em ondas, incluindo, no caso de embarcações, o seu crítico movimento de *roll*, devido à possibilidade de ressonância com mares típicos e aos pequenos efeitos do amortecimento envolvido.

O estudo da estabilidade dinâmica de sistemas flutuantes em mar real, em geral, e a excitação do movimento do *roll* de embarcações causado pela ação de ondas, em particular, sempre geraram justificado interesse dos pesquisadores e instituições técnicas do setor naval. Analisar a estabilidade e a sensibilidade do navio a fatores externos que possam pôr em risco a sua segurança, principalmente, quando envolvem, como dito, condições ressonantes com baixo amortecimento, que acarretem ângulos exagerados de *roll*, têm sido objeto de grande interesse e intensas investigações. Navios com formas de casco típicas de porta-contentores e de passageiros, reportaram a ocorrência de ampliações severas do movimento de *roll*. Esse comportamento foi identificado como ressonância paramétrica e provocou significativas perdas materiais, comprometendo a operação e colocando em alto risco a segurança dessas embarcações (**France et al., 2003, Hua et al., 2006**). Portanto, a possibilidade de se antecipar com adequado nível de confiabilidade fenômenos potencialmente perigosos para a segurança do navio, como o foco do presente trabalho, têm sido cada vez mais objeto de investigação por tratar-se de uma demanda técnica bastante relevante e atual.

Metodologias contemporâneas, como no caso das Redes Neurais Artificiais - **RNAs**, podem tornar essa predição possível, de modo a permitir que a tripulação tenha condições de adotar tempestivas decisões corretivas, evitando eventuais ocorrências de efeitos indesejáveis ou perigosos.

De uma maneira geral, modelar e prever comportamentos de sistemas do mundo físico real pode ser considerado, em tese, uma tarefa de alta demanda, mas quase sempre, também, de grande complexidade, (**Svarear, 1994**). Técnicas de modelagem convencionais, baseadas em modelos estatísticos ou em modelos matemáticos

determinísticos, apresentam limitações e desvantagens decorrentes, principalmente, do alto grau de subjetividade relacionada à estrutura do modelo e, também, à sua limitada base de informação. Por outro lado, em muitos problemas reais não se dispõe de informações e/ou condições suficientes e/ou confiáveis para se construir equações que simulem de forma qualificada o comportamento das variáveis que se desejam prever. Na ausência de informações que permitam a geração de equações governantes confiáveis, uma abordagem que se tem mostrado bastante atrativa baseia-se em Redes Neurais Artificiais – **RNAs**.

Esta tese explora as potencialidades e possibilidades das Redes Neurais Artificiais – RNAs, na solução de problemas de engenharia na predição de séries temporais. Em particular, problemas envolvendo a ação de ondas nos sistemas oceânicos cujo comportamento aleatório é não linear, podem se beneficiar das características não lineares presentes nos algoritmos de solução tipo RNAs.

A tese se insere no conjunto de investigações sobre estabilidade dinâmica do navio que vêm sendo desenvolvidas há mais de três décadas, na Universidade Federal do Rio de Janeiro, sob a liderança do Prof. Marcelo de Almeida Santos Neves (**Neves, 2016**). No decorrer desse período, várias teses e artigos científicos foram publicados, cobrindo diferentes aspectos teóricos e experimentais da estabilidade dinâmica do navio, em geral, e da ocorrência de ressonância paramétrica no movimento de *roll* das embarcações, em particular [por exemplo: **Neves et al. (1999)**, **Neves et al. (2003)**, **Neves e Rodríguez (2006)**, **Neves e Rodríguez (2007)**, **Neves et al. (2011)**, **Rodríguez et al. (2016)**]. Alguns trabalhos dessa equipe de pesquisa têm explorado as possibilidades do uso das RNAs na previsão da ocorrência da ressonância paramétrica [**Míguez et al. (2010)**, **Bellec et al.**

(2011), Míguez (2012)]. Até aqui os resultados obtidos vinham conseguindo produzir uma adequada previsão, mas sempre limitada a janelas de tempo insuficientes para que se pudessem adotar eventuais medidas corretivas, na operação do navio. Para isso, foi desenvolvido um código no **MATLAB** baseado em **RNA**, que permite trabalhar com um número grande de dados (40 séries temporais de 1200 segundos, com um intervalo de 0.08 segundos), e permite controlar grande quantidade de variáveis (coisa que o toolbox não permite, limitando a base de dados para o treinamento da rede, como foi apresentado no trabalho de Míguez, Míguez (2012)). Foi implementada uma correta metodologia para seleção da melhor estrutura/topologia da rede neural artificial que permitirá fazer previsões alongadas e fidedignas.

O foco central desta tese, portanto, priorizou o estabelecimento de metodologia, baseada na aplicação das RNAs para a previsão da ocorrência da ressonância paramétrica do movimento de *roll* do navio em mar real, que fosse capaz de ampliar a janela de tempo a intervalos compatíveis (60 segundos) com as aplicações práticas de interesse que permitiriam correções tempestivas da ocorrência de fenômenos não desejados.

Nas últimas décadas, a modelagem de sistemas dinâmicos se desenvolveu bastante, muito por conta do aproveitamento de novas e poderosas ferramentas de análise e algoritmos de otimização, e, obviamente, também pela acelerada expansão da capacidade de processamento computacional. Dentre as ferramentas de cálculo atualmente disponíveis, merecem reconhecido destaque aquelas que oferecem eficiente suporte ao desenvolvimento das estratégias adotadas nas aplicações da inteligência artificial: algoritmos genéticos, lógica *fuzzy*, *machine learning* em seus diferentes algoritmos de aprendizagem, incluindo as Redes Neurais Artificiais - RNAs, entre outros.

Nesta tese, discutem-se também, estratégias de predições de séries temporais características de respostas de sistemas flutuantes em mar real por meio de algoritmos de Redes Neurais Artificiais - RNAs. Justifica-se esta escolha por conta da eficiente capacidade de predição de séries temporais apresentada pelas RNAs, potencializada em grande medida por sua possibilidade e habilidade de aprendizagem, capacidade de operar com comportamentos não-lineares, e ainda pela sua relativa facilidade de implementação.

A expectativa de se desenvolver a aplicação aqui proposta se fortalece pelo inquestionável interesse prático de se garantir maior segurança e conforto a bordo das embarcações e de outros sistemas oceânicos sujeitos à ação de ondas. A capacidade real de se dispor de algoritmos precisos, confiáveis e eficientes para gerar adequadas previsões dos efeitos decorrentes da ação do mar real motiva a possibilidade de se disponibilizar um sistema a ser instalado a bordo para a previsão de ocorrências indesejáveis ou perigosas, funcionando de forma *online*. Dessa maneira, seria possível antecipar eventos críticos decorrentes de condições hostis ou adversas de mar que possam colocar em risco a segurança dos tripulantes/passageiros e/ou a integridade estrutural das embarcações, em consequência de eventos relacionados ao seu comportamento dinâmico em presença de ondas. A identificação da ocorrência desses efeitos com alguma antecedência poderia proporcionar o tempo necessário para uma eventual adoção de medidas de prevenção e/ou correção (aumento da velocidade e mudança do rumo do navio), evitando-se movimentos exagerados ou bruscos, riscos de acidentes, entre outras potenciais consequências e possíveis riscos à segurança da tripulação/passageiros, ao meio ambiente e ao patrimônio ocasionado por algum comportamento dinâmico exagerado da estrutura oceânica.

As Redes Neurais Artificiais - RNAs adotam uma abordagem baseada em modelos matemáticos nos quais uma rede pode ser treinada de modo a que se possa prescindir das equações geradoras (generalização) de uma série temporal. Portanto, ao invés de se deduzir equações que descrevam o comportamento fundamental do sistema em estudo, constrói-se um modelo não-linear, utilizando-se algoritmo de aprendizagem neural capaz de aproximar/substituir as correspondentes equações determinísticas. As redes neurais são particularmente atrativas para modelar sistemas não-lineares, porque são inerentemente não-lineares, porque as não linearidades estão presentes nas suas próprias funções de ativação. As RNAs se apresentam, portanto, como uma poderosa ferramenta, com grandes possibilidades de permitir uma predição confiável de séries temporais típicas de respostas em mar real.

Estudo de Caso

A tese discute a arquitetura adotada na construção das RNAs e os correspondentes resultados da predição de respostas características do comportamento dinâmico de sistemas flutuantes em mar real.

Utiliza como sua principal aplicação o ângulo de roll de um navio porta-contentor em presença de mar real, incluindo a possibilidade de ocorrência de ressonância paramétrica. Os consistentes resultados aqui obtidos confirmam a eficiência do algoritmo de predição, inicialmente, em condições de mar regular, e em seguida, também para diferentes espectros representativos do mar real.

O **Capítulo 2** apresenta uma revisão bibliográfica concisa, focalizando os dois principais temas abordados nesta tese: estabilidade dinâmica de navios, principalmente, sob o efeito do fenômeno da ressonância paramétrica; e os conceitos e estratégias adotados no desenvolvimento das Redes Neurais Artificiais - RNAs.

O **Capítulo 3** introduz conceitos envolvidos na definição dos Sistemas Dinâmicos e apresenta uma breve discussão sobre os fundamentos das Redes Neurais Artificiais - RNAs. Mostra, também, os tipos de arquiteturas possíveis de serem adotadas na construção das RNAs (exemplo: rede neural tipo perceptron de múltiplas camadas com um algoritmo de treinamento tipo *backpropagation*), além de apresentar a metodologia de treinamento e predição de dados dinâmicos (séries temporais) e os diferentes tipos de funções de ativação para o treinamento das RNAs. O objetivo principal da aplicação das RNAs - fazer a predição mais próximas possível das séries temporais em estudo - priorizou, nas aplicações desta tese, as respostas de sistemas oceânicos em mar real, principalmente, decorrentes do movimento de *roll* das embarcações sujeitas, inclusive, à ocorrência de ressonância paramétrica, em ondas longitudinais, em mar real.

O **Capítulo 4** apresenta uma análise para seleção da arquitetura da rede neural apresentada na tese, na escolha da melhor topologia. Nesse sentido foram feitas predições com uma e duas camadas escondidas, diferentes números de neurônios na camada escondida e diferentes números de atrasos, escolhendo-se a que produz a melhor generalização (critério de menor erro). Além disso, definiu-se o pré-processamento de dados, com a finalidade de aperfeiçoar o treinamento da rede, e discutiu-se a metodologia do atraso no tempo, utilizado para realizar a predição de séries temporais.

O **Capítulo 5** discute as características do comportamento do mar real e o seu caráter aleatório. A partir da representação do mar real pelo seu espectro de energia, demonstram-se, preliminarmente, as potencialidades e adequação das RNAs às aplicações características de ondas típicas do mar real, realizando-se a predição de séries temporais da elevação da onda definidas por um espectro de mar específico, do tipo **JONSWAP**.

Para ampliar o escopo das aplicações de interesse prático e demonstrar a eficiência da metodologia adotada na previsão de respostas de sistemas flutuantes excitados por ondas do mar real, o Capítulo 5 analisa também o uso das RNAs para a predição de séries temporais adotadas no controle com predição de um sistema Conversor de Energia de Ondas (WEC – *Wave Energy Converter*), tipo *Point Absorber*, verificando a qualidade das predições para janelas distintas de tempo de predição. Neste caso, as séries temporais consideradas no exemplo de validação descrevem diretamente as forças de excitação estimadas a partir das ondas atuantes que podem ser utilizadas no controle com predição do travamento da boia (sistema conhecido por *latching* – **Hals et al. (2002)**, **Sheng et al. (2015a)**, **Sheng et al. (2015b)**, **Shadman et al. (2015)**, **Shadman (2017)**, COPPE - Eng. Oceânica) e o próprio movimento vertical (*heave*) da boia, de modo a permitir adoção tempestiva de ações que evitem a ocorrência de deslocamentos muito exagerados.

O **Capítulo 6** analisa e compara a predição da série temporal de *roll* do navio **SAFEDOR** para condições de mar real. A predição, realizada por meio das RNAs, utiliza uma arquitetura do tipo perceptron de múltiplas camadas (**PMC**). Discute-se, também, a predição considerando-se três diferentes espectros de mar, do tipo **JONSWAP**, comparando a série original de *roll* com a série predita pela RNA, para diferentes janelas

de predição. As séries temporais adotadas nas análises incluem a ocorrência de ressonância paramétrica.

O **Capítulo 7**, por fim, apresenta as conclusões finais dos estudos desenvolvidos nesta tese, comentando as recomendações relacionadas a possíveis aplicações das **RNAs** para a implementação de um sistema *online* a bordo da embarcação, além de considerar a aplicação de outros tipos de estruturas de redes neurais que possam aperfeiçoar ainda mais a predição das respostas de estruturas flutuantes em presença de mar real.

O **Anexo A** apresenta detalhes relacionados aos fundamentos e algoritmos desenvolvidos para a implementação das Redes Neurais Artificiais – RNAs discutidas na tese; o **Anexo B** discute, de forma abrangente e detalhada, os aspectos mais relevantes do fenômeno da Ressonância Paramétrica do movimento de *roll* do navio; enquanto, o **Anexo C** apresenta o conjunto completo das predições feitas para os seis diferentes tempos de predição (10, 20, 30, 40, 50, 60 s) utilizadas na análise das séries temporais de *roll* para o navio porta-contentor SAFEDOR em condições de ocorrência do fenômeno da ressonância paramétrica.

CAPÍTULO 2

2. REVISÃO BIBLIOGRÁFICA

Este Capítulo apresenta, inicialmente, uma breve revisão bibliográfica sobre a estabilidade dinâmica de navios em ondas, e a seguir, elenca referências que discutem os fundamentos das RNAs e algumas das suas possíveis aplicações na engenharia.

Os primeiros trabalhos sobre estabilidade dinâmica de navios em ondas consideravam as respostas da embarcação em presença de ondas regulares como base para a posterior descrição de respostas mais realísticas produzidas pelas ondas irregulares. O principal objetivo dos trabalhos sobre estudos da dinâmica do navio em ondas visavam, principalmente, o entendimento do papel dos diferentes parâmetros envolvidos no fenômeno e a sua respectiva determinação, de modo a garantir a segurança do navio, evitando níveis exagerados de deslocamentos e acelerações, e uma eventual ocorrência de emborcamento, **Neves (2016)**.

2.1 Antecedentes e Cenário Atual da Estabilidade Dinâmica de Navios em Ondas

Foi **William Froude** quem pela primeira vez, ainda nos idos de 1863, reconheceu que o problema de estabilidade de *roll* em ondas deveria adotar uma análise dinâmica e não, puramente, estática. Foi ele também um dos primeiros investigadores a identificar a existência do fenômeno da ressonância paramétrica em ondas longitudinais, no qual os navios podem apresentar movimentos não desejados em *roll* quando os seus períodos em *heave* e/ou *pitch* coincidem com a metade do valor do período natural de *roll*, provocando complexos movimentos acoplados entre si. A complexidade e a importância dos efeitos não lineares ali envolvidos, no entanto, exigem avançadas análises dinâmicas não-lineares.

Kerwin (1955) demonstrou que para navios em ondas longitudinais, em certas frequências de encontro, ocorre a perda da estabilidade, em consequência do surgimento de intensos movimentos de *roll*.

Paulling e Rosemberg (1959) apresentaram um modelo matemático para o estudo da excitação paramétrica, descrito por uma equação não linear do movimento do navio, identificando frequências que geram instabilidades quando a frequência de excitação alcança duas vezes o valor da frequência natural de *roll*, confirmando as observações de Froude.

Paulling (1960) mostrou que a variação do momento de restauração, como consequência da presença da crista da onda na meia nau do navio, implica na redução da sua estabilidade instantânea. Em seguida, **Paulling (1961)** apresentou uma metodologia para determinar os momentos de restauração para navios em ondas, que afetam a sua estabilidade em

ondas longitudinais; e mais adiante, **Paulling (1972)** descreveu o fenômeno da ressonância paramétrica e identificou três possíveis modos de perda da estabilidade no desempenho de um navio em ondas: perda simples de estabilidade, *broaching*, e instabilidade paramétrica.

Kuo, C., Welaya, Y., (1981) discutiram o emborcamento de navios em ondas regulares e irregulares, e definiram critérios de estabilidade, a partir da recopilção dos principais trabalhos desenvolvidos à época sobre estabilidade intacta.

Cardo et al. (1984) incorporaram termos não lineares até terceira ordem na avaliação da restauração hidrostática do navio. Os autores identificaram zonas de instabilidade para o *roll*, e a presença de biarmônicos, no caso de grandes deslocamentos angulares de *roll*.

Bloki (1980) trabalhou com um modelo com três graus de liberdade (*heave, pitch e roll*) para desenvolver o seu estudo sobre excitação paramétrica no domínio da frequência, em mar regular e irregular.

Himeno (1981) estudou o efeito do amortecimento no movimento de *roll* estimado a partir das características geométricas do casco.

Skomedal (1982) analisou as influências da excitação paramétrica na estabilidade do navio, desacoplando a equação de *roll*, e assumindo a variação periódica da restauração hidrostática.

No trabalho apresentado por **Hamamoto e Nomoto (1982)**, resultados de testes experimentais permitiram avaliar a influência da onda sobre as características restaurativas do navio.

Perez (1985), COPPE - Eng. Oceânica, realizou ensaios experimentais envolvendo comparação entre dois modelos de embarcações pesqueiras que permitiram a avaliação da influência da forma do casco no fenômeno da ressonância paramétrica.

Sanguinetti (1985), COPPE - Eng. Oceânica, desenvolveu modelo analítico da estabilidade de *roll*, considerando duas embarcações pesqueiras de dimensões similares, em ondas regulares, incluindo a condição de velocidade de avanço nula. Os seus resultados demonstraram, numericamente, a existência de novas frequências ressonantes que poderiam também levar ao emborcamento do navio.

Pernambuco (1990), COPPE - Eng. Oceânica, estendeu os estudos desenvolvidos por **Sanguinetti (1985)**, para os seis graus de liberdade, confirmando que a incorporação das não-linearidades na restauração hidrostática promove o acoplamento do *roll* aos movimentos de *heave e pitch*, responsável pelas novas frequências ressonantes que podem levar ao emborcamento da embarcação em poucos ciclos.

Valerio (1994), COPPE - Eng. Oceânica, estudou a excitação paramétrica do movimento de *roll* e os limites de estabilidade de dois navios típicos, incorporando forças viscosas no amortecimento não-linear de *roll* e efeitos não-lineares até segunda ordem na restauração. Seus resultados demonstraram a importante influência da forma da popa, no fenômeno da ressonância paramétrica. Em seguida, **Valerio (2000)** determinou os limites

de estabilidade do navio, e identificou a influência de diferentes parâmetros na sua estabilidade dinâmica (i.e. amortecimento, altura metacêntrica transversal e velocidade de avanço) quando submetido à excitação paramétrica.

Hsieh *et al.* (1994) apresentaram método probabilístico não-linear para prever emborcamento de embarcações em mar irregular de través.

Lorca (2001), COPPE – Engenharia Oceânica, obteve resultados analíticos e experimentais referentes à estabilidade dinâmica de dois navios pesqueiros, avaliando a influência da velocidade de avanço na estabilidade dos navios em ondas regulares.

France *et al.* (2003) investigaram o acidente ocorrido em 1998 com o porta-contentor tipo Post-Panamax, analisando a possibilidade de ocorrência de ressonância paramétrica em ondas longitudinais (mar de proa). Esse trabalho inaugurou uma nova etapa na investigação da ressonância paramétrica, até então, limitada, principalmente, a pequenas embarcações, e restritas, salvo raras exceções, a estudos teóricos. O trabalho confirmou as condições de ocorrência da ressonância paramétrica e a susceptibilidade de navios com popas do tipo *transom stern (TS)* e grandes *flares* de proa a desenvolverem o fenômeno.

Bulian, G., Francescutto, A., (2003) apresentaram modelo matemático não-linear simplificado para a predição da amplitude e, dos limites de estabilidade do *roll* paramétrico em mares regular e irregular, em ondas longitudinais e mar de proa. No caso do mar irregular, os autores apresentaram os valores limites de estabilidade.

Rodríguez (2004), COPPE - Eng. Oceânica, desenvolveu um modelo analítico não-linear para o estudo da ressonância paramétrica, incluindo termos até terceira ordem na restauração hidrostática com consideração dos efeitos da passagem da onda para dos tipos de navios pesqueiros tipo *transom stern* (**TS**) e *round stern* (**RS**), modelo com três graus de liberdade (*heave, roll e pitch*).

Merino (2006), COPPE - Eng. Oceânica, realizou a análise numérica da ressonância paramétrica, considerando uso de tanques de estabilização passivos do tipo U para atenuar o *roll* paramétrico, em dois navios pesqueiros.

Belenky et al. (2006) apresentaram procedimentos numéricos e experimental para a avaliação do *roll* paramétrico para um porta-contentor. Esta abordagem mostrou-se bastante eficiente, permitindo capturar fenômenos hidrodinâmicos críticos associados ao *roll* paramétrico.

Celis (2008), COPPE - Eng. Oceânica, adicionou efeitos devido à memória fluida nos estudos envolvendo um navio pesqueiro submetido *a* mar de frente, em ondas regulares.

Hong et al. (2009) avaliaram numericamente as características do *roll* paramétrico em mares regular e irregular, em ondas com diferentes direções de incidência e diversos valores de velocidade de avanço.

Vivanco (2009), COPPE - Eng. Oceânica, discutiu diferentes metodologias para o estudo da ressonância paramétrica, baseada em dinâmica não-linear da ressonância paramétrica:

mapeamento de Poincaré, diagramas de bifurcação, bacias de atração e expoentes de Lyapunov.

Rodríguez (2010), COPPE - Eng. Oceânica, apresentou estudos da ressonância paramétrica para vários navios, em ondas regulares e irregulares, considerando equações não-lineares acopladas; nos seis graus de liberdade.

Galeazzi et al. (2013) propuseram métodos não paramétricos para detectar o aparecimento da ressonância paramétrica em *roll*, utilizando soluções com dois graus de liberdade (*pitch* e *roll*).

Somayajula et al. (2014) analisaram a equação não-linear de *roll* simplificada, em ondas longitudinais e em mar irregular para um navio porta-contentor. Consideraram nessas análises, a variação da altura metacêntrica (**GM**) em ondas como função de transferência da série de Volterra.

Umeda et al. (2015) discutiram resultados numéricos para a predição da ressonância paramétrica em ondas regulares e oblíquas, em baixas velocidades de avanço, baseados num modelo matemático com cinco graus de liberdade (*sway*, *heave*, *pitch*, *roll*, *yaw*).

Neves (2016) fez uma ampla revisão dos trabalhos considerados relevantes, publicados nos últimos anos, sobre estabilidade dinâmica de navio em condições de mar regular e irregular.

O comportamento de um navio navegando sob a influência de um ambiente totalmente aleatório como no caso do mar real, requer a aplicação de análise estocástica para que se possa entender e interpretar adequadamente o movimento resultante. As respostas não lineares em *roll* se tornam especialmente complexas em ondas irregulares. Não há apenas questões teóricas desafiadoras envolvidas na análise desse problema, mas também ocorrem múltiplas e complexas questões de natureza numérica.

Arnold et al. (2003) desenvolveram uma consistente revisão de métodos estocásticos aplicados à dinâmica não-linear da estabilidade de navios, baseados em teoria de sistemas dinâmicos aleatórios.

Bulian et al. (2006) relataram estudos teórico, analítico e experimental sobre o efeito da ergodicidade na ressonância paramétrica para um navio em ondas longitudinais em mar irregular, concluindo que a excitação paramétrica de *roll* também apresenta comportamento ergódico.

Belenky et al. (2015) pesquisou metodologia para calcular a probabilidade de emborcamento do navio devido à perda de estabilidade em ondas irregulares.

Kennedy et al. (2018) apresentaram dois modelos de frequências discretas e um procedimento probabilístico de seleção de modelos bayesianos para antecipar a detecção de ocorrência da ressonância paramétrica em navios.

Han et al. (2004) apresentaram metodologia para prever uma série caótica (portanto não ergódica – ver Capítulo 3) de longo prazo, baseada numa rede neural recorrente, com

algoritmo de aprendizagem *backpropagation* auto-adaptativo no tempo, para realizar a predição da série temporal do número de manchas solares por mês. Ver **Figura 2.1**.

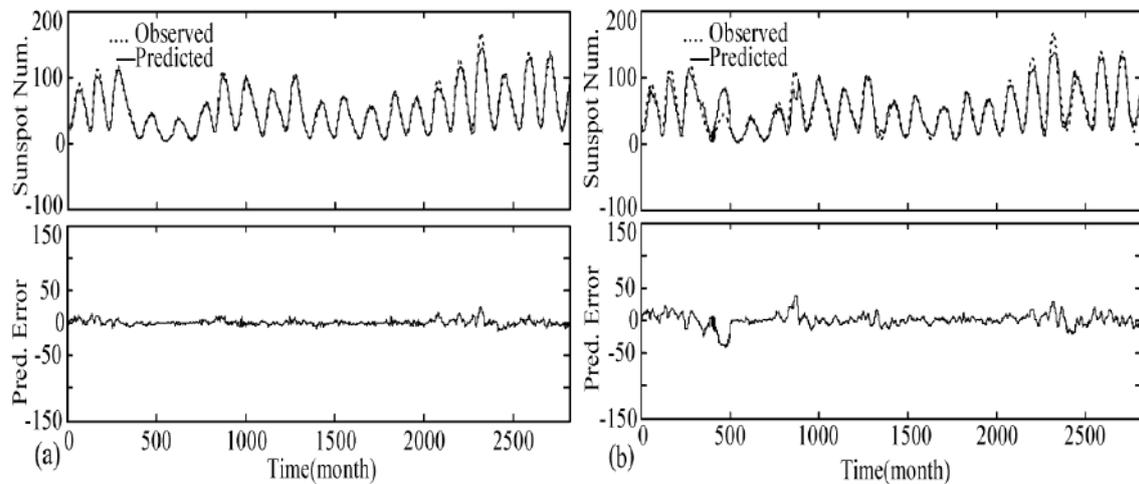


Figura 2.1: Predição do número de manchas solares para intervalos de predição (a) seis meses (b) doze meses (**Han et al., 2004**)

Os resultados obtidos para a predição de séries temporais caóticas sugerem uma grande possibilidade de se desenvolver uma Rede Neural Artificial (RNA) confiável, com um bom desempenho na predição da série temporal associada a efeitos decorrentes da ação do mar real.

Os bons resultados de previsão das respostas da embarcação em *heave*, *roll*, *pitch*, no domínio do tempo, obtidos anteriormente por **Rodríguez (2010)**, fortalecem a expectativa em relação à viabilidade do desenvolvimento de um modelo de rede neural capaz de prever outros efeitos decorrentes da ação de ondas aleatórias, independentemente do seu caráter ergódico ou não ergódico, para um horizonte de tempo de predição alongado.

2.2 Antecedentes das Redes Neurais Aplicadas à Engenharia Naval

Tlelo-Cuautle (2001) discute uma aplicação de RNAs que permite avaliar o enorme potencial dessa ferramenta. Ele trabalha com uma rede neural artificial tipo *feedforward* com algoritmo de treinamento de *backpropagation* com uma camada escondida, utilizada na predição de séries temporais caóticas de curto prazo representativa do volume de tráfego de uma estrada na cidade de Taiwan - China. Os dados, coletados pelo contador de tráfego de veículos, totalizam 10 dias úteis, em três escalas de tempo envolvidas: 5 min, 10 min, 15 min. Os resultados demonstram a eficácia da rede neural para prever a série caótica em curto prazo, **Figura 2.2**.

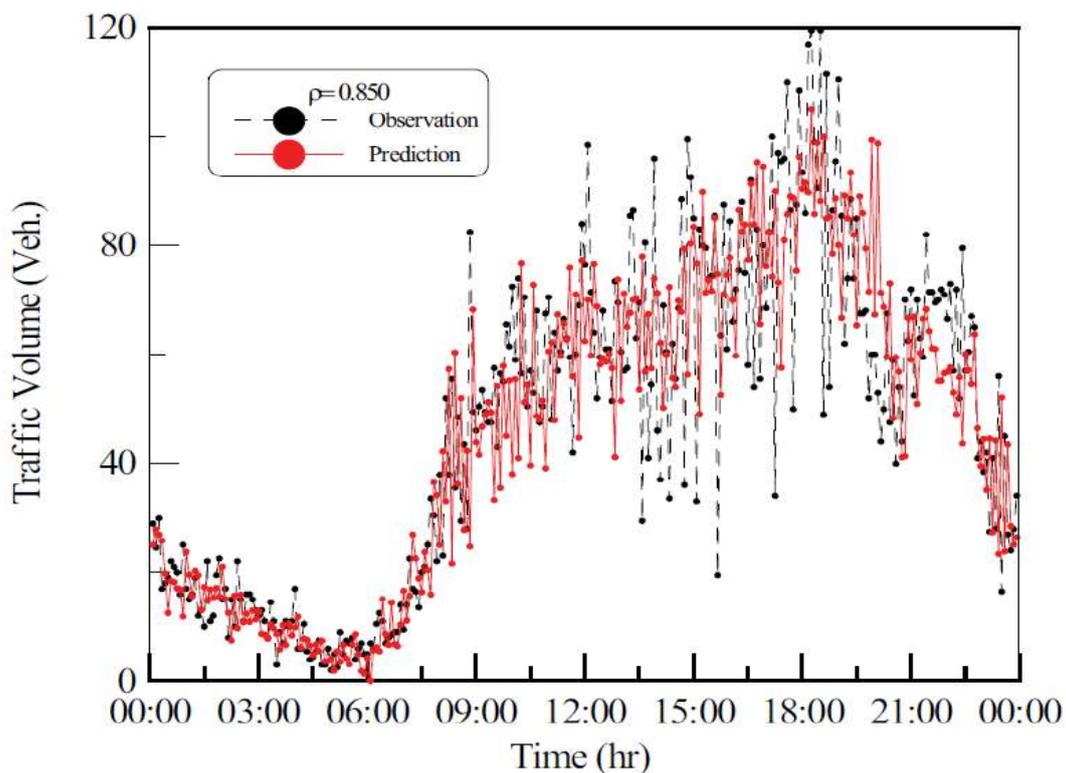


Figura 2.2: Predição da série temporal para uma observação de volume de tráfego de 5 minutos (Tlelo-Cuautle, 2001)

Aplicações de redes neurais artificiais na indústria naval, principalmente na análise do roll paramétrico, não são muitas, e, portanto, o tema apresenta um amplo e qualificado

espaço para aplicações práticas de alto retorno potencial, por conta do seu grande interesse prático.

Míguez (2012) utilizaram rede neural para a predição do *roll* paramétrico. No caso do mar regular, foram obtidas predições, ao longo de até 20 segundos de predição; enquanto para mar irregular, o tempo de predição ficou restrito a 10 segundos.

Parkes et al. (2018) utilizaram as RNAs para prever a potência das embarcações mercantes operando a nível mundial.

Ahn et al. (2019), na Universidade Nacional de Seul, interessados em analisar o fenômeno de *sloshing* em tanques de transporte de gás liquefeito (GNL), organizaram uma base de dados experimentais, contendo respostas de um número considerável de modelos em diferentes escalas, com seis graus de liberdade em mar irregular. Nesse artigo, os autores utilizaram uma RNA para treinar, validar e testar com a base de dados disponível, a predição da carga crítica de *sloshing* nas paredes dos tanques.

CAPÍTULO 3

3. SISTEMAS DINÂMICOS E REDES NEURAIS

ARTIFICIAIS – RNAs

Problemas físicos envolvendo a ação de ondas oceânicas caracterizam-se como sistemas dinâmicos cuja conceituação básica e algumas definições pertinentes serão resumidas a seguir.

3.1 Sistemas Dinâmicos

Denomina-se Sistema Dinâmico um conjunto de equações diferenciais, acopladas ou não, que define uma regra fixa para descrever a dinâmica de um "ponto", cujas coordenadas frequentemente representam uma situação física, em um espaço geométrico ao longo do tempo. De forma compacta, um sistema de equações diferenciais com n equações (ou seja, n dimensões) será descrito por vetores n -dimensionais:

$$\dot{\vec{x}} = \mathbf{f}(\mathbf{x}, t) \quad (3.1)$$

As componentes do vetor, \vec{x}_i , $i = 1, \dots, n$, representam as variáveis do sistema, enquanto $f_i(t, x_1, \dots, x_n)$, $i = 1, \dots, n$ representam as equações que descrevem o sistema.

Definem-se sistemas dinâmicos como sendo todo o sistema que evolui no tempo, qualquer que seja a sua natureza (exemplos: sistemas dinâmicos biológicos, químicos, econômicos, etc.). Esta evolução, geralmente, descrita em termos de equações diferenciais, pode ser classificada em duas classes distintas: **sistemas dinâmicos dissipativos**, quando apresentam algum tipo de atrito (amortecimento) acarretando perda de energia; e **sistemas dinâmicos conservativos ou hamiltonianos**, que não apresentam qualquer tipo de perda de energia, como por exemplo: a evolução de sistema solar, os sistemas quânticos etc.

3.2 Sistema Determinístico

Uma variável é dita determinística quando após lhe ser atribuído valores às variáveis independentes, com a utilização de um determinado método, espera-se encontrar sempre mesmos valores de saída, toda vez que o mesmo método for utilizado. Quer dizer, as mesmas entradas produziram invariavelmente as mesmas saídas, não se contemplando, nesse caso, a existência do azar, nem o princípio da incerteza.

O sistema determinístico é aquele no qual as partes interatuam de um jeito perfeitamente previsível, sem deixar qualquer margem para dúvidas. A partir do último estado do sistema e do programa de informação, se pode prever o seu estado seguinte, com risco de erro minimizado.

3.3 Sistema Estocástico

Um processo estocástico (ou aleatório) é representado pelo comportamento de uma variável aleatória no tempo. Um processo estocástico define uma família de variáveis

aleatórias $\{X(t), t \in I\}$, onde t é um parâmetro pertencente a um intervalo I . O intervalo I pode ser contínuo ou discreto, no conjunto dos reais ou dos inteiros.

Portanto, para cada instante de tempo t tem-se uma variável aleatória distinta, representada por $X(t)$, que permite que um processo estocástico possa ser interpretado como sendo uma sucessão de variáveis aleatórias cujas características podem variar ao longo do tempo.

3.3.1 Processo Aleatório Estacionário

Um processo aleatório é dito estacionário se as estatísticas de todas as distribuições de probabilidade conjuntas de qualquer ordem são invariantes no tempo. Quando o processo é estacionário para todas as ordens, diz-se que ele é estacionário no sentido estrito (rigoroso ou rígido). No processo estocástico estacionário, as características probabilísticas determinadas em diferentes instantes de tempo são as mesmas. Por isso, é suficiente determinar uma única característica dimensional probabilística, para avaliar essas características probabilísticas em qualquer tempo, (**Belenky et al., 1998**).

3.3.2 Processo Aleatório Ergódico

A ergodicidade do processo pode ser definida tendo em vista a necessidade de se obter estatísticas do processo a partir de uma única observação temporal, isto é, de um único sinal amostral $x(t)$. Dessa forma, um processo estocástico é dito ergódico se as suas médias no tempo são iguais às suas médias obtidas por apenas uma realização. Uma ilustração elucidativa segue na **Figura 3.1**.

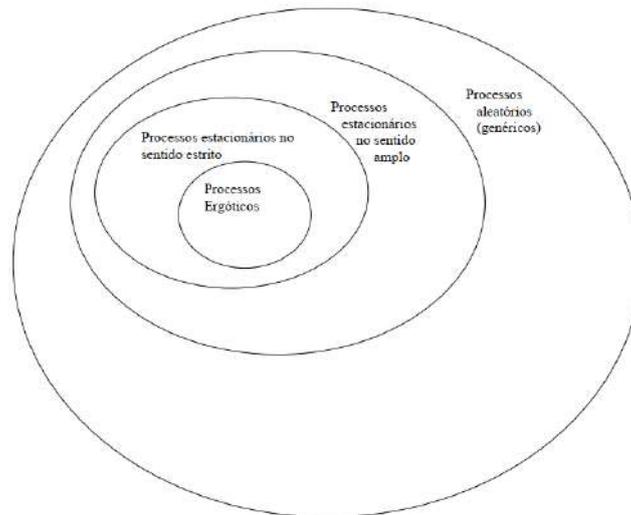


Figura 3.1: Representação dos vários tipos de processos aleatórios

Na prática, é difícil saber quando um processo é estacionário ou ergódico. A ergodicidade é uma qualidade de um processo estocástico estacionário, não se aplicando a processos não estacionários. Como dito, se o processo é ergódico, as suas características estatísticas podem ser avaliadas a partir de uma única realização. Se o processo é não ergódico, tem-se que considerar um número estatisticamente significativo de realizações, a fim de se obter estimativas estatísticas confiáveis.

Ondas irregulares em mar aberto (aqui também chamado de mar real) são reconhecidas como um processo ergódico, mas apenas dentro do seu período de quase-estacionariedade. Isto é, no intervalo de tempo para o qual o estado de mar pode ser considerado (estatisticamente) constante. É possível demonstrar-se que para um sistema dinâmico linear, a sua resposta a uma excitação ergódica também será ergódica. Por outro lado, a resposta de um sistema não linear pode ser não linear. Nesse caso, várias realizações seriam necessárias para se obter estimativas estatísticas confiáveis, (**Shin et al., 2004**).

Os modelos clássicos para a representação do mar real assumem a sua ergodicidade e, também, distribuição normal (ou gaussiana) do seu registro temporal. No caso do estudo das elevações de onda irregular, observações e registros validam essas hipóteses. Se, adicionalmente, o comportamento do corpo flutuante atuado por essa onda irregular for assumido linear, o teorema de Wiener-Khinchin estabelece que as respostas do flutuante serão também ergódicas e normais. Eventuais não linearidades existentes no sistema, quando significativas, comprometem a validade dessas hipóteses, **Rodríguez (2010)**.

O caráter não ergódico mostrou-se especialmente forte, no caso do *roll* paramétrico, principalmente, devido à existência de não linearidades (na restauração e no amortecimento de *roll*) no sistema que descreve o comportamento do navio. As ondas capazes de excitar o *roll* paramétrico podem ocorrer tanto em sequências diferentes, uma após a outra, quanto separadas por ondas menos energéticas. No último caso, a energia cinética será mais dispersa antes da próxima excitação paramétrica e, como resultado, a variância do *roll* difere significativamente entre os diferentes registros, **Belenky et al. (2006)**. No entanto, ainda assim foi possível demonstrar que o uso da arquitetura proposta foi capaz de gerar previsões satisfatórias.

O *roll* paramétrico não sendo ergódico significa que, para cada condição de onda (estado do mar, posição relativa corpo-onda, velocidade), grande número de simulações teria de ser realizadas para obtenção de estatísticas confiáveis, **Shin et al. (2004)**.

O problema da não-ergodicidade em *roll* paramétrico foi estudado por **Belenky et al. (2003)**. Em princípio, um processo tem que ser considerado não-ergódico até que uma prova de ergodicidade seja dada. No entanto, isso requer o conhecimento analítico de

funções de correlação de ordem elevada. Assim, em geral, essa prova não pode ser dada para sistemas não-lineares que, então, em princípio, devem ser considerados como não-ergódicos, **Bulian et al. (2006)**.

3.4 Redes Neurais Artificiais – RNAs: Breve Introdução e Descrição

Um modelo de Rede Neural Artificial (RNA) pode ser descrito como uma unidade de processamento que, na sua forma mais básica, possui uma ou várias entradas (na camada de entrada) e uma saída (na camada de saída), acionada por meio de funções de transferência da entrada para a saída, realizado por meio de conexões, denominadas sinapses. Essas conexões, por sua vez, são ponderadas por pesos, permitindo obter funções matemáticas que podem ser altamente complexas, aplicáveis à solução de diversificados e complexos problemas de interesse prático.

A **Figura 3.2** apresenta uma ilustração esquemática do neurônio artificial ou unidade de processamento. Na figura, as sinapses estão representadas por pesos, responsáveis pela soma ponderada das entradas x_i ; o núcleo da célula está representado por uma função de ativação, usada para comparar as entradas x_i ponderadas pelos pesos sinápticos w_{ij} , com o limiar do núcleo θ_j , e o axônio representado pela saída y_j do neurônio.

Nessa modelação, o núcleo foi expresso por (3.2):

$$y_j = F(u_j) = F(\sum w_{ij} x_i - \theta_j) \quad (3.2)$$

onde: $F(u_j)$ é a função de ativação do neurônio; w_{ij} são os pesos sinápticos (variáveis utilizadas para armazenar o conhecimento adquirido no treinamento); x_i ($i = 1, 2, \dots, p$) são

as p entradas; θ_j é o limiar de ativação do neurônio (variável que especifica qual será o patamar apropriado para que o resultado combinado (u_j) linear possa gear um valor) definindo se a saída será disparada, e y_j representa a saída do neurônio.

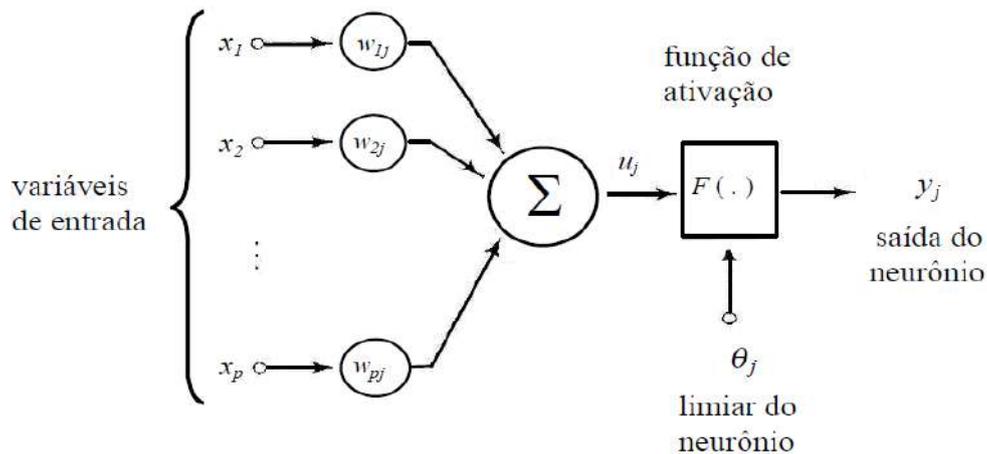


Figura 3.2: Modelo básico de neurônio artificial, **Haykin (2008)**

Segundo o tipo de conexão, as redes neurais podem ser classificadas como redes em camadas (*feedforward*) e redes recorrentes (*feedback*).

A **Figura 3.3** mostra a rede neural recorrente de Elman, que se diferencia das demais soluções temporais por conseguir que os dados anteriores a um dado instante de tempo t influenciem o processo no instante presente, devido à realimentação feita na camada escondida. Esta última faz com que os dados da amostra anterior modifiquem a saída, garantido maior influência para os dados mais recentes. Este tipo de RNA pode apresentar uma ou mais malhas de realimentação. Daí, suas conexões permitem que a rede memorize as informações atuais, na camada de contexto (cópia das saídas dos neurônios da camada oculta, no instante anterior), no momento seguinte, imediatamente, após a sequência investigada.

Na **Figura 3.3**, $x(n)$ é o vetor de entradas, formado pelos atrasos, pelo elemento atual $x(n)$ e pelos demais elementos de entrada, espaçados do intervalo de tempo τ . Nesse padrão de entrada, o sinal se propaga da entrada para a saída (alimentação à frente). Ainda na primeira iteração, os neurônios ocultos ativarão os neurônios da camada de contexto que armazenarão a saída dessa primeira iteração a ser utilizada no próximo ciclo.

A recorrência da Rede de Elman ocorre através da unidade de contexto, normalmente, uma estrutura de atraso do tipo z^{-1} (**Haykin, 2008**), que armazena a saída da primeira camada oculta por um passo de tempo. Dessa forma, a sua arquitetura permite a geração de padrões variáveis no tempo, habilitando a configuração neural para aplicações envolvendo séries temporais.

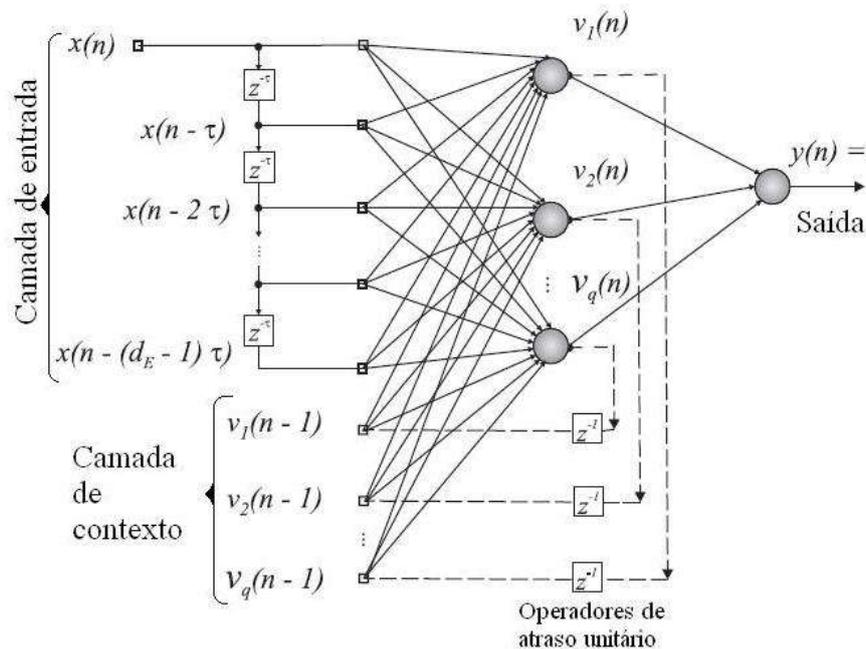


Figura 3.3: Rede neural recorrente - RNA de Elman com uma camada oculta

Da **Figura 3.3**, a RNA de Elman consta de duas camadas, uma camada de entrada

temporal $\{x(n)\}_{n=1}^N$, uma série temporal univariada formada por uma sequência ordenada e finita com N observações da variável x, espaçadas uma da outra de τ unidades de tempo ($Z^{-\tau}$). E a segunda camada chamada de contexto cujos valores são obtidos a partir da realimentação das saídas dos neurônios ocultos, no instante $n - 1$ (v_q), onde: q é quantidade de neurônios - vide: **Haykin (2008)**.

3.4.1 Redes Feedforward

São redes nas quais o processamento se dá sempre em sentido único, da entrada para a saída da rede, sem qualquer realimentação. Adotando-se a sua representação gráfica *horizontal*, esse processamento parte das entradas, situadas à esquerda, movendo-se para as saídas, à direita, e sem qualquer retorno.

A rede neural *feedforward* consiste em uma ou mais camadas de unidades de processamento que podem ser não-lineares. As conexões entre unidades de camadas adjacentes são definidas por um conjunto de pesos sinápticos. No entanto, para ser considerada *feedforward*, suas saídas devem se conectar somente com as unidades da próxima camada, **Reed and MarkII (1999)**. *Perceptron e Adaline* foram as primeiras redes tipo *feedforward* publicadas na literatura. As redes neurais de múltiplas camadas potencializaram as possibilidades das redes *feedforward*. A **Figura 3.4** esquematiza um exemplo de rede neural do tipo *feedforward*.

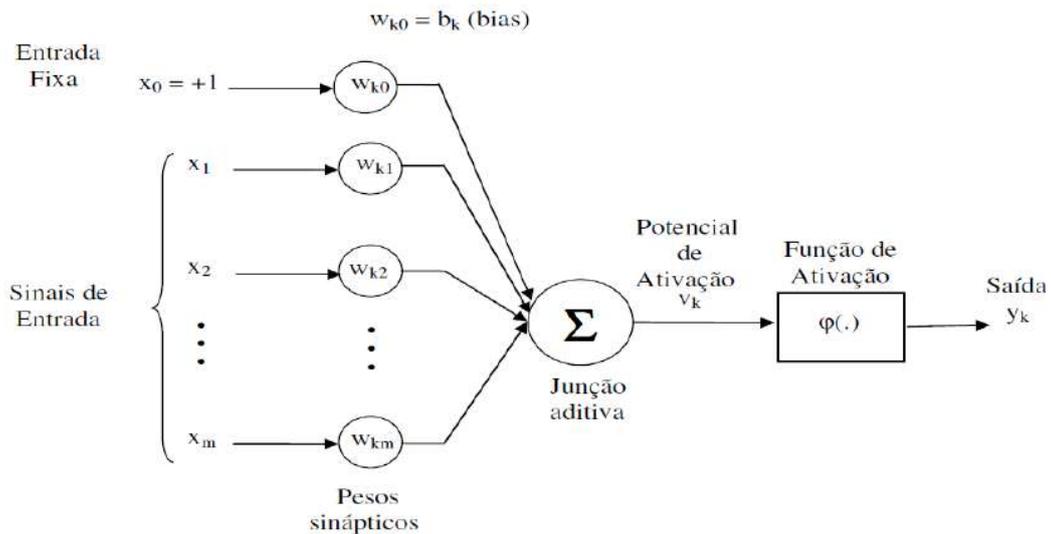


Figura 3.4: Rede neural feedforward, Haykin (2008)

Onde:

$x_1 \dots x_m$ são os valores da camada de entrada;

$w_{k0} \dots w_{km}$ são os pesos sinápticos;

Σ é a função aditiva do produto do sinal de entrada e os pesos sinápticos;

v_k é o poder de ativação ($\sum w_{ki} x_i$);

$\varphi(\cdot)$ é a função de ativação ($F(\sum w_{ki} x_i)$);

y_k é a saída da rede neural artificial.

3.4.2 Perceptron de Múltiplas Camadas (PMC)

As redes *PMC* (**Multilayer perceptron, (MLP)**) são formadas por múltiplas camadas de neurônios, utilizando o **perceptron** como unidade de processamento computacional. Depois do surgimento do algoritmo de treinamento conhecido como **retropropagação do erro** (*backpropagation*), expandindo as possibilidades de aplicação do **perceptron**

para o caso de múltiplas camadas (perceptron de múltiplas camadas-PMC), **Bishop (2006)**. As redes **PMC** destacam-se pela sua capacidade de lidar com problemas fortemente não-lineares, ao contrário das redes perceptron de camada única.

Este tipo de rede não apresenta conexões partindo de nós de uma determinada camada para as camadas anteriores (sem realimentação). Redes **PMC** apresentam poder computacional muito maior do que aqueles das redes sem camadas intermediárias, capazes de lidar apenas com problemas lineares. Redes com duas camadas intermediárias podem implementar, em princípio, qualquer função matemática, incluindo alto grau de complexidade decorrente de fortes não-linearidades, **Cybenko (1988)**.

Define-se uma **PMC (Figura 3.5)**, como uma rede com uma única camada de entrada (dados de entrada: (u_{ij}) , i = número da camada, j = número da entrada), uma ou mais camadas intermediárias (ocultas ou escondidas) e uma única camada de saída, Y_i (saída da rede, ver **Figura 3.5**). Conceitos mais aprofundados da teoria da rede neural artificial (RNAs) se encontram discutidos no Anexo A.

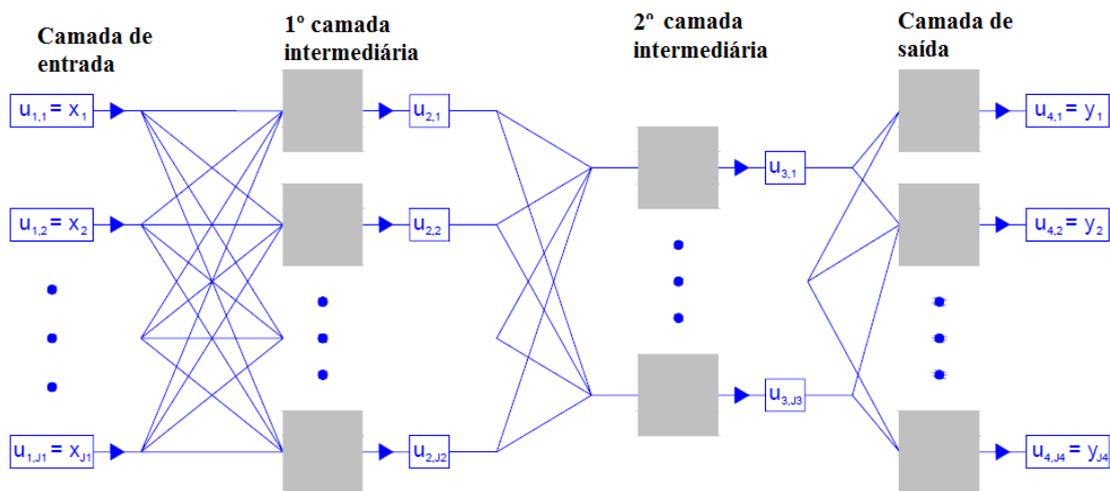


Figura 3.5: Arquitetura da rede perceptron de múltiplas camadas (PMC), (**Barbosa, 2010**)

3.4.3 Linguagem de Aprendizagem *Backpropagation*

O algoritmo *backpropagation* (**propagação de erro**) que responde pelo processo de treinamento supervisionado da rede PMC: treinamento com suas duas fases bem definidas, primeira fase *forward* (ou propagação adiante), onde o sinal da amostra dos dados de entrada se propaga da camada de entrada até a camada de saída, sem que exista realimentação.

Após o cálculo do erro e o ajuste dos pesos sinápticos, a segunda fase *backward* (ou propagação reversa) é acionada, realizando o processo da camada de saída até a camada de entrada.

O algoritmo de **Levenberg-Marquardt** (método de gradiente de segunda ordem) foi utilizado para acelerar o processo de treinamento *backpropagation*, aumentando de 10 a 100 vezes o processo *backpropagation* típico - ver **Nunes da Silva et al. (2010)**.

CAPÍTULO 4

4. ARQUITETURA DA REDE NEURAL ARTIFICIAL - RNA

A forma de como os neurônios estão arranjados uns em relação aos outros, e como essa estrutura funcionará através do direcionamento das conexões sinápticas dos neurônios, definirá o potencial de operação da rede e a sua capacidade de predição. A partir das discussões do **Capítulo 3**, a arquitetura básica escolhida apresenta uma rede *feedforward*, do tipo perceptron de múltiplas camadas (**PMC**), a escolha tem a haver com os resultados promissores para a previsão do roll paramétrico, um sistema não ergódico (**Míguez et al. (2010)**, **Bellec et al. (2011)**, **Míguez (2012)**). Este tipo de rede se caracteriza pela presença de pelo menos uma camada escondida de neurônios, sem nenhum tipo de realimentação.

O algoritmo de aprendizagem *backpropagation* (retropropagação do erro), utilizando o método de otimização de **Levenberg-Marquardt**, para os dados de entrada com atraso no tempo, será definido de acordo com a técnica de janela de tempo, de acordo com a metodologia apresentada a seguir (para detalhes, vide: Anexo A).

4.1 Metodologia Proposta

Aplicando-se a teoria da rede neural PMC com atraso no tempo e janela de tempo para a predição de séries temporais (para detalhes, vide: Anexo A). Definindo-se o treinamento e predição da rede da seguinte forma: com os 30 valores de *input*, geram-se os valores da saída a serem comparados para fins do cálculo do erro, e a posterior atualização dos pesos sinápticos (**algoritmo de propagação do erro**), de acordo com a rede neural explicada no Capítulo 3. O ajuste dos pesos sinápticos será efetuado em função do cálculo do erro. Esse processo se repete até completar a série temporal. Esse mesmo processo é repetido para as demais séries temporais, completando, assim, a etapa de treinamento da **RNA**.

Uma vez completada a fase de treinamento e ajustados os pesos sinápticos, a **RNA** está pronta para dar início a fase de predição. Nessa nova fase, para uma dada série temporal, agora, diferente das séries utilizadas para o treinamento, gera-se uma saída (predição), repetindo-se essa mesma metodologia. Na iteração seguinte, tomam-se, agora, apenas 29 valores anteriores, e agrega-se o valor predito na iteração anterior, permanecendo o total de 30 *inputs*), gerando-se uma nova saída (predição num passo à frente), (4.1). O processo se repetirá até completar o tempo total da predição (no caso desta tese: 10, 20, 30, 40, 50, 60 s). Uma vez completados os tempos de predição, a série predita até o tempo em questão pode ser atualizada com os valores reais da série temporal original a ser predita.

$$Z(t) = f(Z(t-1), \dots, Z(t-30))^* \quad (4.1)$$

Durante o processo se alimenta a rede com um conjunto de séries temporais. Uma vez treinada, a rede será capaz de gerar, a partir de dados de entrada, agora já se utilizando de valores diferentes dos valores adotados na fase de treinamento, uma saída com valores

tanto mais próximo da série temporal original quanto mais eficiente tiver sido o processo de treinamento.

A **Figura 4.1** ilustra a metodologia proposta. Com uma quantidade de 40 séries temporais (realizações do movimento de roll) para treinar a rede neural. Tem como input (30 atrasos) da RNA séries temporais de *roll* para a fase de treinamento da rede. A rede consta de uma camada de entrada com 30 dados de entrada (atrasos), duas camadas de neurônios escondidos (com 40 neurônios cada) e um camada de saída, valores obtidos empiricamente que permitem a rede neural melhores previsões (menor erro). E depois da fase de treinamento, obtém-se a predição de uma série temporal de *roll* diferente das séries temporais utilizadas para o treinamento, com janelas com tempos de predição variáveis, a seleção da arquitetura da rede neural artificial no item 4.3.

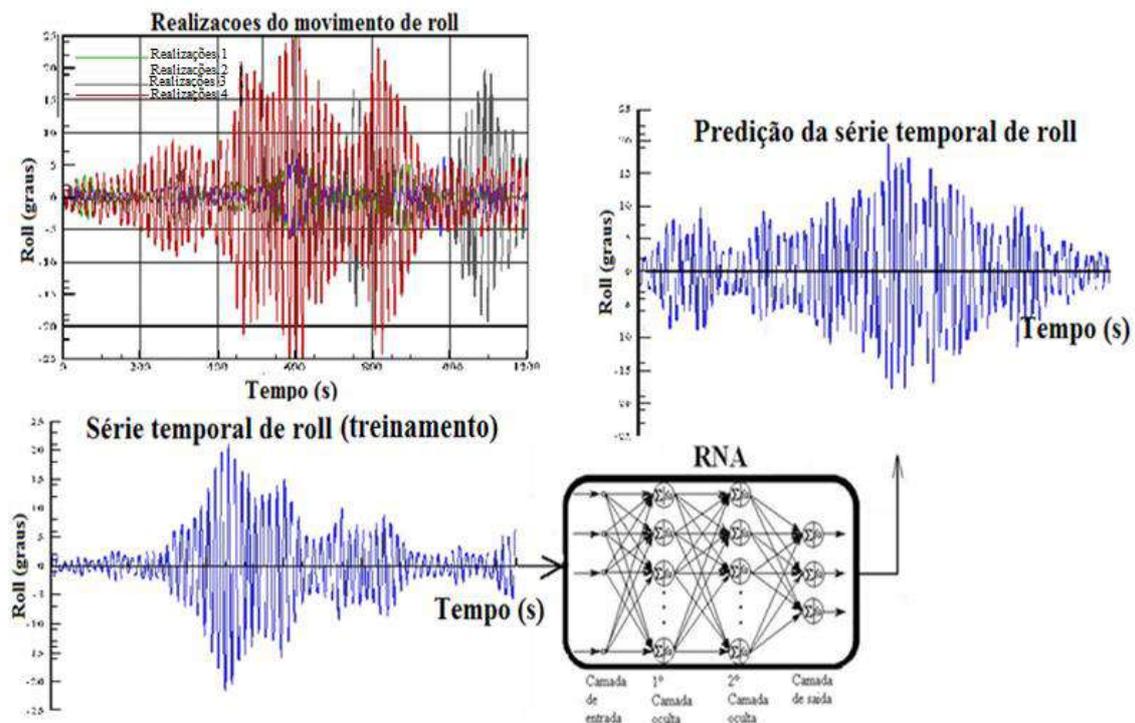


Figura 4.1: Diagrama do processo predição da série temporal de roll

Para isso, foi desenvolvido um código no *software* **MATLAB**, capaz de processar um grande número de informação (dados de entrada e saída), para séries com tempo total de 1200 segundos, correspondendo, por exemplo: a séries temporais de um navio em condições de mar regular e/ou irregular, com capacidade de processar de forma eficiente um adequado número de séries temporais de dados (amostras) para o treinamento e predição da série temporal em estudo. O código está dimensionado para permitir que se possa alimentar e treinar o algoritmo com dados reais por várias horas a fio. Uma vez treinada, a rede estará em condições de fazer predições do comportamento real da estrutura flutuante no mar. Uma das principais características do código proposto seria, portanto, a sua capacidade de processar uma grande quantidade de informação, incluindo sistemas de alta complexidade, fortemente não-lineares. Dessa maneira, o código poderá funcionar *online*, realizando treinamento e predição para um navio no mar, exposto a condições reais de operação. O código permite a sua adaptabilidade aos diferentes sistemas flutuantes de interesse, devido à possibilidade de mudança dos diferentes parâmetros para o treinamento, tais como: topologias, linguagem de aprendizado etc. A figura 4.1 ilustra as fases de treinamento (realizações de roll), iteração, estrutura da rede neural, predições, etc.; ou seja, uma RNA do tipo *feedforward*, perceptron de múltiplas camadas (PMC), com algoritmo de aprendizado de retropropagação do erro, **Haykin (2008)**.

4.2 Pré-Processamento dos Dados de Entrada

Para otimizar o processo de generalização das RNAs, adota-se pré-processamento, para melhorar a qualidade das predições e reduzir o tempo de treinamento. O pré-processamento permite que a fase de treinamento seja mais precisa, por utilizar apenas os dados identificados como importantes para o treinamento, levando a uma melhor

generalização. Um outro aspecto importante do pre-processamento refere-se à redução do tempo do treinamento.

4.2.1 Normalização dos Dados

Para evitar a influência da ordem de grandeza valores da amplitude do ângulo de *roll*, no processo de cálculo, adotou-se a normalização dos dados de entrada, que permite que os valores das séries temporais utilizadas estejam compreendidas entre o valor mínimo e máximo da função de ativação do neurônio (no caso da rede utilizada a tangente hiperbólica, -1, 1). No caso da normalização dos dados das séries temporais de *roll*, utilizou-se o maior valor de *roll* de cada série adotada na fase de treinamento. Por outro lado, a arquitetura escolhida para a solução do problema apresentado (**vide: 4.3**) considerou uma camada de entrada com 30 input (atrasos), duas camadas escondidas (de 40 neurônios cada uma) e uma camada de saída (output, com valor único, o valor obtido pela rede neural). As duas camadas escondidas de neurônios com função de ativação tangente hiperbólico (limites de funcionamento: [-1, 1]). Por último, define-se a camada de saída com um único neurônio e função de ativação linear (vide: Anexo A). Os resultados retornam para as variáveis físicas (sem normalização) após a saída da RNA).

4.2.2 Extração de Tendência

Assume-se que aqui todas as séries temporais de elevação de *roll* (dados da amostra) têm uma oscilação com média nula. Portanto, a tendência das séries temporais será nula (sem *offset*). De todas as séries utilizadas do movimento de *roll*, nenhuma série temporal apresenta emborcamento de *roll*.

4.2.3 Extração de Sazonalidades

A sazonalidade é o padrão de variação que ocorre em intervalos regulares de tempo. No caso do mar real, a **ITTC (2006)** recomenda o intervalo de tempo mínimo representativo para os espectros de mar irregular, correspondente a cerca de 100 vezes o período predominante das ondas. Esse intervalo pode ser considerado suficiente para que se possam desenvolver por completo os fenômenos associados aos movimentos do navio. Os três espectros trabalhados nesta tese têm como período de pico (T_p): 10.65 s. Adotou-se o tempo total da análise de 1200 s, cerca de 113 períodos predominantes das ondas, atendendo, portanto, a recomendação da **ITTC (2006)**.

4.2.4 Validação Cruzada

A especificação topológica – diferentes formas de arquitetura que a rede neural poderia assumir - mais apropriada na caracterização de um problema, o seu dimensionamento, depende de muitos fatores: algoritmo de aprendizagem, complexidade do problema, qualidade das amostras disponíveis. Por isso, é usual adotar-se a definição da sua topologia de maneira empírica.

Uma das técnicas estatísticas mais utilizadas para a seleção de topologias das redes é a validação cruzada - avalia os modelos das redes neurais através a codificação do mapeamento entrada-saída, por meio do treinamento de vários subconjuntos de dados de entrada disponíveis e divididos aleatoriamente em um conjunto de treinamento e um conjunto de teste, Haykin (2008)- que permite avaliar a capacidade de cada topologia quando as amostras totais são divididas em subconjuntos de treinamento e de validação.

Um tipo de validação cruzada, denominada Método de *Holdout* (**Haykin, 2009**) adotada nesta tese, será descrito em seguida.

Método *Holdout* (2-fold cross-validation)

Com a finalidade de se escolher a melhor topologia da rede, baseada na técnica da validação cruzada, dividiu-se o total dos dados de entrada em três grupos: 70% dos dados para o treinamento, 15% para o teste (utilizado para verificar a performance da rede sob condições reais de utilização) e 15% para validação (utilizado para verificar a eficiência da rede a capacidade de generalização durante o treinamento), de um total de 40 séries temporais do movimento de roll, para a validação, baseados no Método *Holdout* (**Haykin, 2009**).

O Método *Holdout* pode ser considerado como sendo uma variação mais simples da validação cruzada de *k-fold*, **Coulibaly et al. (2000)**. O Método *Holdout* pode ser entendido como o método *k-fold*, onde: $k=2$, com a particularidade de que a base de dados é dividida em duas partes: uma das partes é usada para o treino da rede; e a outra parte para o teste, sem a alteração que ocorre no Método *k-fold* típico.

Este processo é realizado apenas uma única vez, e como cada parte é usada tanto para o treino como para o teste, todas as partes passam por ambos os lados (dados para treinamento e dados para teste). A vantagem deste método é que quando as amostras de dados são muito grandes, a validação *Holdout* reduz o tempo necessário para a aprendizagem, em comparação o método *k-fold*, **Yadav and Shukla (2016)**.

4.3 Arquitetura da Rede Neural Artificial

Nesta tese, as **RNAs** serão treinadas com diferentes quantidades de neurônios por camada, e diferentes números de camadas escondidas, a fim de se melhorar e qualificar o processo de predição. Os resultados obtidos, tanto para o caso de mar regular, quanto mar irregular mostraram-se bastante promissores, apresentando predições com boa concordância, justificando assim as expectativas para o seu uso na predição da ressonância paramétrica.

4.3.1 Seleção da Estrutura Neural Feedforward

Após pré-processamento dos dados de entrada, define-se o número de camadas (ver fluxograma, Figura: 6.1) como explicado em seguida.

4.3.1.1 Seleção de Número de Camadas da Rede PMC

A **Tabela 4.1** apresenta os valores dos erros calculados a partir dos resultados apresentados nas **Figuras 4.2 e 4.3** obtidos pelas redes com duas camadas escondidas e com uma camada escondida, respectivamente. A rede de apenas uma camada (**Figura 4.3**) apresentou maior erro na fase de treinamento e, daí, tem maior dificuldade de extrair informação suficiente para fazer uma boa generalização. Essa mesma tendência ineficiente de generalização foi observada nas predições das demais séries temporais de *roll* feita por uma rede de uma só camada escondida. Nesta análise de seleção da estrutura neural, na qual se qualificará a solução na fase de treinamento, serão utilizados diretamente os valores do Erro Quadrático Médio (***MSE - Mean Squared Error***), como fornecidos pelo código de computador adotado da rede neural artificial desenvolvido no software **MATLAB**.

As previsões das **Figuras 4.2 e 4.3** referem-se às respostas de *roll* correspondentes ao espectro II (JONSWAP: $H_s=5.0$ m, $T_p=10.63$ s, $\gamma = 3.3$, (incidência 180°)). Todas previsões feitas foram para um input de 30 segundos.

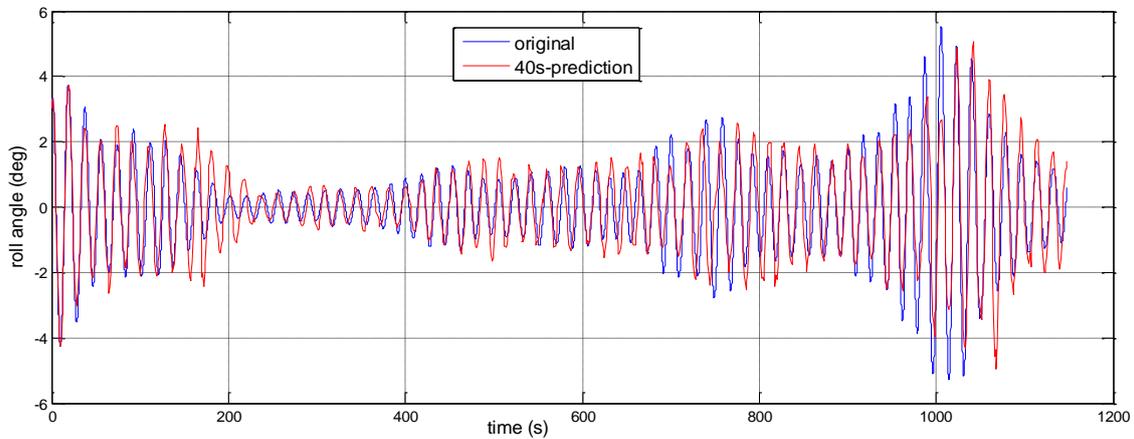


Figura 4.2: SAFEDOR: Roll: Predição feita para uma rede com duas camadas escondidas de 40 neurônios, e uma camada de saída de um neurônio (40-40-1)

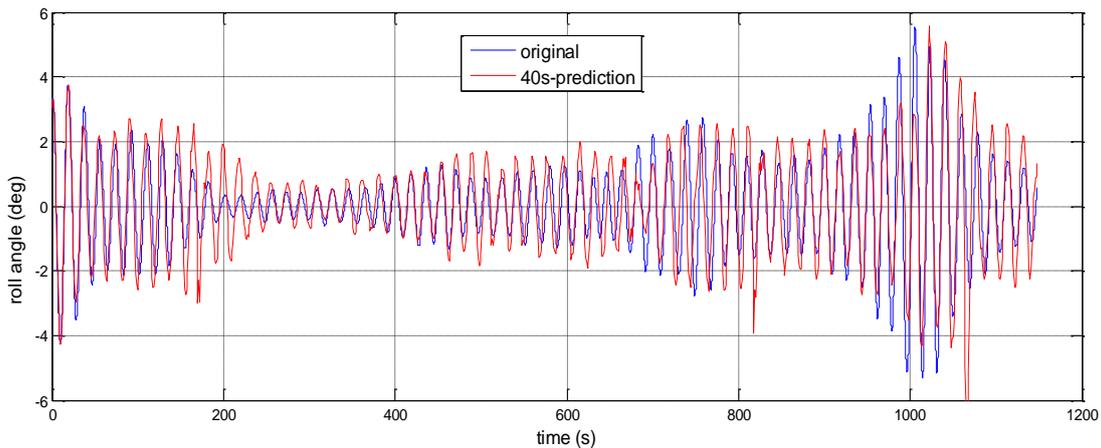


Figura 4.3: SAFEDOR: Roll: Predição com uma única camada escondida de 60 neurônios e uma camada de saída de um neurônio (60-1)

Tabela 4.1: RNA: Erros para diferentes números de camadas escondidas

Erro (MSE)	
RNA: 40-40-1 (duas camadas escondidas)	RNA: 60-1(uma camada escondida)
Treinamento 1 / 10 erro: 0.0024	Treinamento 1 / 10 erro: 0.0029
Treinamento 2 / 10	Treinamento 2 / 10

erro: 0.0021	erro: 0.0025
Treinamento 3 / 10 erro: 0.0019	Treinamento 3 / 10 erro: 0.0032
Treinamento 4 / 10 erro: 0.0022	Treinamento 4 / 10 erro: 0.0024
Treinamento 5 / 10 erro: 0.0024	Treinamento 5 / 10 erro: 0.0024
Treinamento 6 / 10 erro: 0.0015	Treinamento 6 / 10 erro: 0.0027
Treinamento 7 / 10 erro: 0.0027	Treinamento 7 / 10 erro: 0.0034
Treinamento 8 / 10 erro: 0.0016	Treinamento 8 / 10 erro: 0.0016
Treinamento 9 / 10 erro: 0.002	Treinamento 9 / 10 erro: 0.0025
Treinamento 10 / 10 erro: 0.0023	Treinamento 10 / 10 erro: 0.0027

*O cálculo do erro utilizado para treinamento da rede neural foi o erro quadrático médio (MSE) por obter melhores resultados em comparação com outros métodos do cálculo do erro (por exemplo: **msereg**: erro quadrático médio com regularização). Os valores pequenos dos erros são próprios do erro quadrático médio na fase de treinamento.*

As diferenças dos erros obtidas para as RNAs de duas e uma camada são, ligeiramente maiores para séries temporais, as quais, vale lembrar, apresentam alto grau de não-linearidade (em especial para as séries temporais de *roll* em mar real para o espectro de mar III), como se observou no caso das respostas correspondentes ao espectro de mar III (JONSWAP: $H_s=5.0$ m, $T_p=8.0$ s, $\gamma = 3.3$, (incidência 180°)) - ver **Figura 4.4**. No caso do espectro III, a RNA com uma camada escondida tem maior dificuldade em desenvolver a generalização, especialmente, nas regiões de ocorrência dos grandes picos associados à ressonância paramétrica (***underfitting***). As previsões com apenas uma

camada escondida têm maior dificuldade em produzir uma boa generalização (Figura 4.4), no caso de sistemas mais complexos.

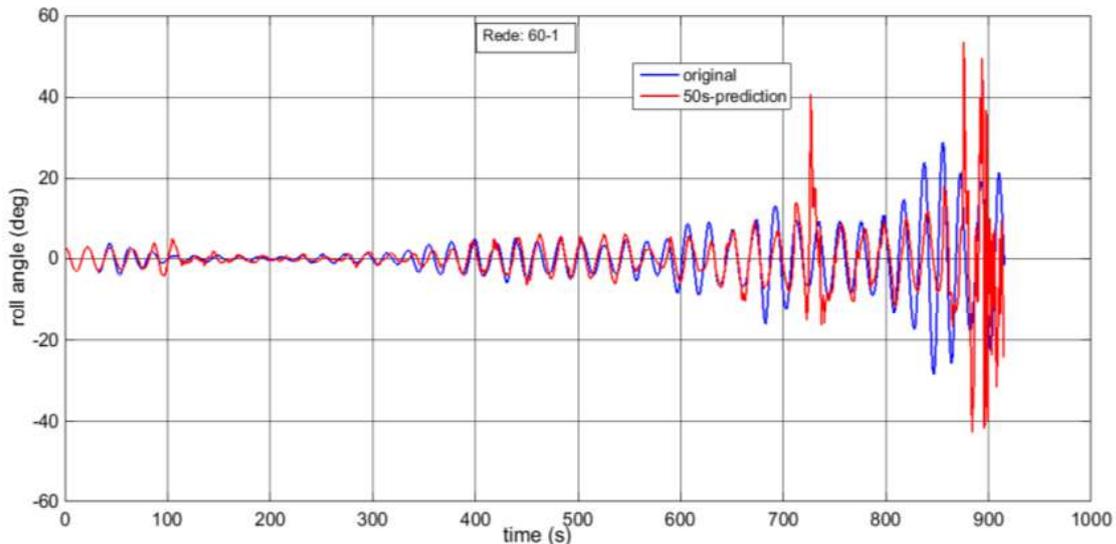


Figura 4.4: SAFEDOR: Roll: Predição Rede com uma camada escondida – Espectro de Mar III

A escolha do número de camadas escondidas baseou-se na avaliação de várias predições com uma e duas camadas escondidas, sendo que a predição com apenas uma camada escondida apresentou problemas ao não produzir uma boa aproximação dos valores da séries temporal, na sua parte final (problemas de *underfitting*), (Figura 4.4).

4.3.1.2 Seleção do Número de Entradas/Inputs (Atrasos)

A janela de tempo de predição é formada por um conjunto de pontos da série que trazem consigo informação suficiente para a determinação da predição. Como mencionado, anteriormente, os pontos que compõem a janela de tempo de predição são chamados de retardos ou atrasos temporais (*lags*), vide: **Anexo A**.

Um dos problemas mais críticos do processo de predição de séries temporais reside, exatamente, na escolha correta dos retardos temporais necessários para uma boa

caracterização da dinâmica do sistema. Para dados históricos de sistemas dinâmicos lineares, pode-se aplicar funções de autocorrelação e autocorrelação parcial para identificar as dependências relevantes entre os dados. Existem vários métodos apresentados na literatura para a definição dos retardos temporários – ver por exemplo: **Savit and Grenn (1991)**, **Pi and Peterson (1994)**, **Tanaka (2001)**. Outros exemplos de metodologias, totalmente gráficas, aplicadas à determinação dos atrasos temporais são conhecidas por: **lagplot** - ver **Percival and Walden (1998)** ou de **phase portrait** – ver **Kantz and Schreiber (2003)**. A **Figura 4.5** ilustra a aplicação do método **lagplot**. Esta técnica é bastante limitada por depender da interpretação humana dos gráficos, no entanto, mesmo sendo um método estimativo e pouco preciso é bastante utilizado devido à sua fácil implementação e bons resultados, **Ferreira (2006)**.

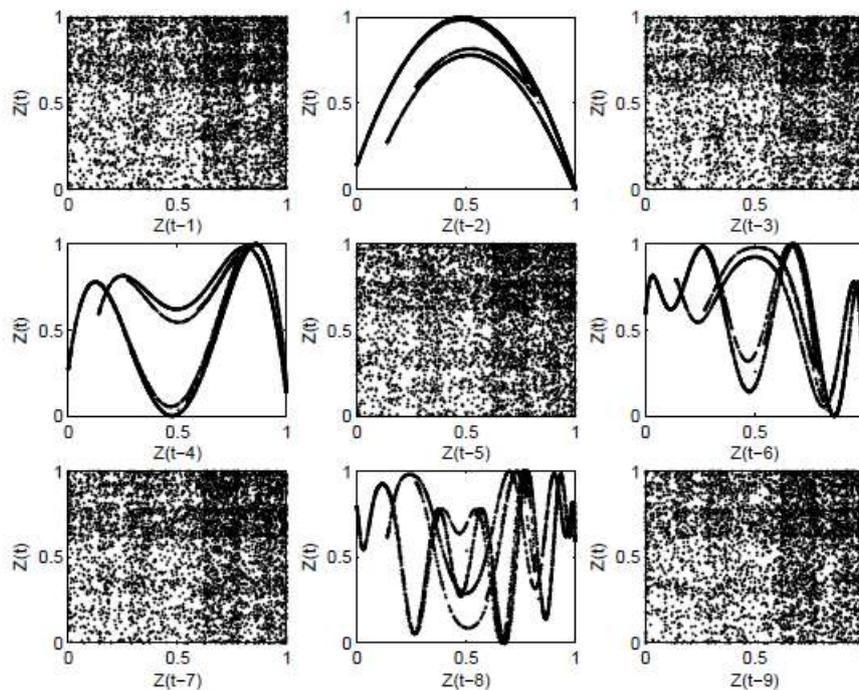


Figura 4.5: *Lagplot* para o mapa Hénon com atrasos de 1 a 9 - reproduzidos de **Ferreira (2006)**

O mapa do Hénon é um sistema dinâmico discreto no tempo. Trata-se de um mapa iterativo, em duas dimensões e com soluções caóticas: $z(t)$ é equação que representa o comportamento da mapa do Hénon; enquanto, $z(t-i)$ é o valor da mapa de Hénon com um dado número de atrasos (i atrasos), (detalhes vide: **Ferreira, 2006**).

Outra forma de determinar o número de atrasos para a rede neural utiliza a informação da correlação cruzada (r) entre duas séries temporais, para avaliar a combinação de série/atraso entre a série analisada que será atrasada e a série alvo para a modelagem da rede neural. A correlação cruzada entre as duas séries $z(t)$ (série temporal de *roll*) tomada no instante atual, e a série temporal $y(t)$ tomada com k unidades de tempo de atraso, $y(t)=z(t-k)$, **Calôba (2002)**. Se as duas variáveis x e z forem independentes e aleatórias, o valor esperado da correlação será zero, **Calôba (2002)**. Os valores de corte da correlação cruzada foram baseados na confiança de 95% (correspondente a distribuição normal), sendo o valor de corte igual: $|r| > \frac{2}{\sqrt{N}}$.

$$r_{zy}(k) = \frac{1}{\sigma_z \sigma_y} \frac{1}{N-K} \sum_{t=1}^{N-k} (z(t) - \mu_z)(y(t+k) - \mu_y) \quad (4.2)$$

Onde:

$r_{zy}(k)$ é a correlação cruzada entre $z(t)$ e $y(t)$

$\mu_z, \mu_y, \sigma_z, \sigma_y$: são as médias e desvios padrões de $z(t)$ e $y(t)$ respectivamente.

O gráfico de $r_{zy}(k)$ versus k é chamado correlograma, **Calôba (2002)**.

N é quantidade de valores da série temporal de *roll* utilizados para treinar a rede.

Tais regras, embora muito utilizadas, são apropriadas tão somente para tipos de problemas considerados bem comportados, **Nunes da Silva et al. (2010)**. Elas desconsideram atributos, a rigor, relevantes tais como: quantidades de dados de amostra (no caso, 40 séries temporais); e a complexidade do problema (as fortes não linearidades associadas ao *roll* paramétrico), **Nunes da Silva et al. (2010)**. Nesse caso, tais metodologias teóricas devem ser adotadas apenas como ponto de partida. O cálculo do número de atrasos da RNA levou em conta os resultados dos testes realizados com diferentes números de atrasos (atrasos de 25, 30, 35, 40). Dessa maneira, para a seleção do número de atraso ótimo (*input*) adotou-se o critério do menor erro obtido na fase de treinamento.

As **Figuras 4.6-4.9** apresentam previsões de *roll* feitas com diferentes números de *inputs*, para uma rede com 40 neurônios por duas camadas escondidas e 30 s de tempo de previsão. Os resultados apresentados na **Figura 4.7** (30 *inputs*) fornecem a melhor generalização (menor erro). Valores de *inputs* menores e maiores do que aqueles apresentados têm menor generalização (maior erro) em comparação com as previsões feitas com 25, 30, 35, 40 *inputs*. As previsões feitas correspondem às respostas de *roll* à excitação definida a partir do espectro I (JONSWAP: $H_s=4.8$ m, $T_p=10.63$ s, $\gamma = 3.3$, (incidência 180°), **Figuras 4.6-4.9**).

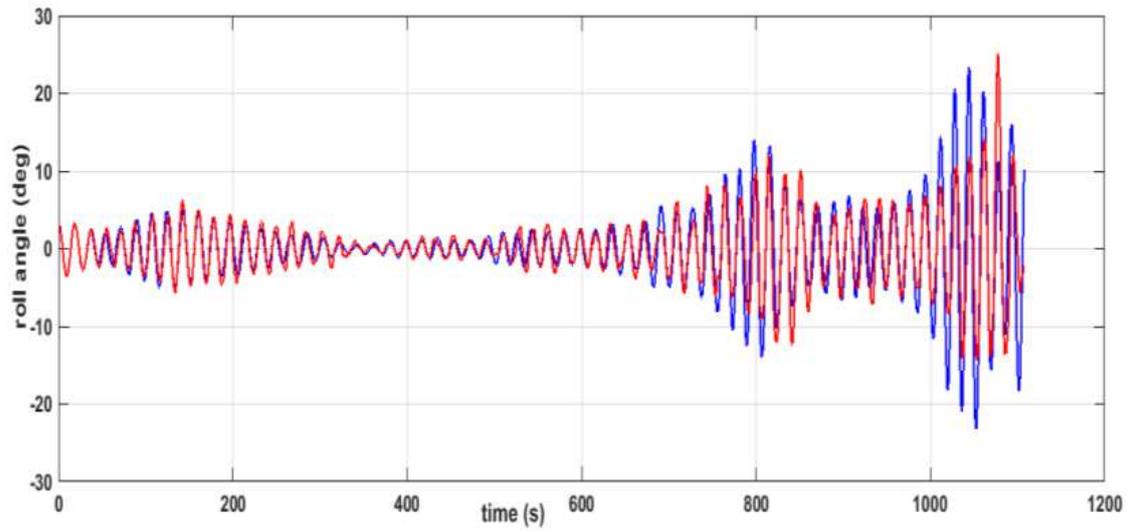


Figura 4.6: RNA: Predição Roll; Janela de Tempo: 30s: 25 inputs

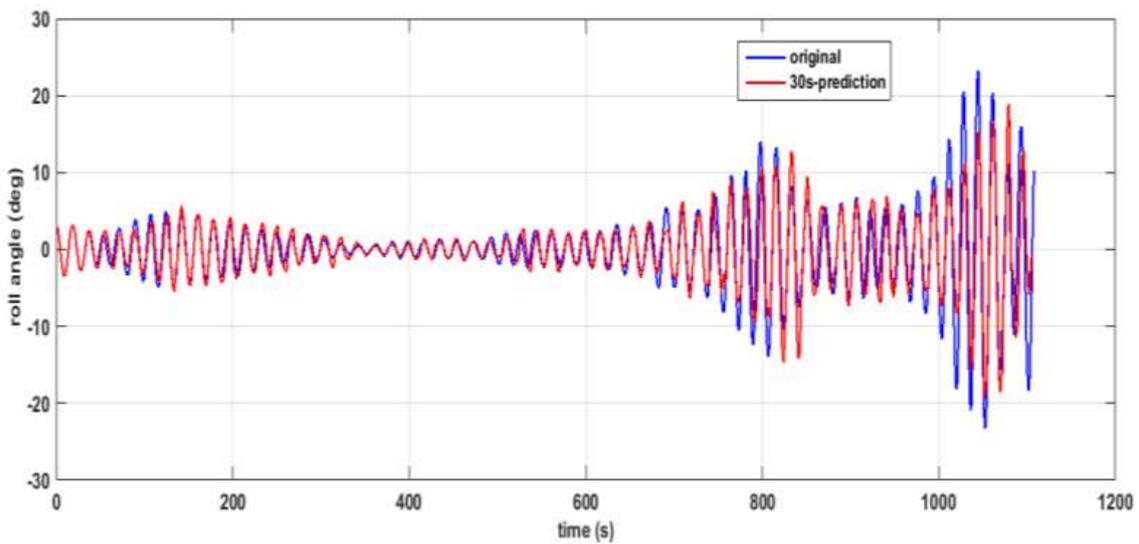


Figura 4.7: RNA: Predição Roll; Janela de Tempo: 30s: 30 inputs

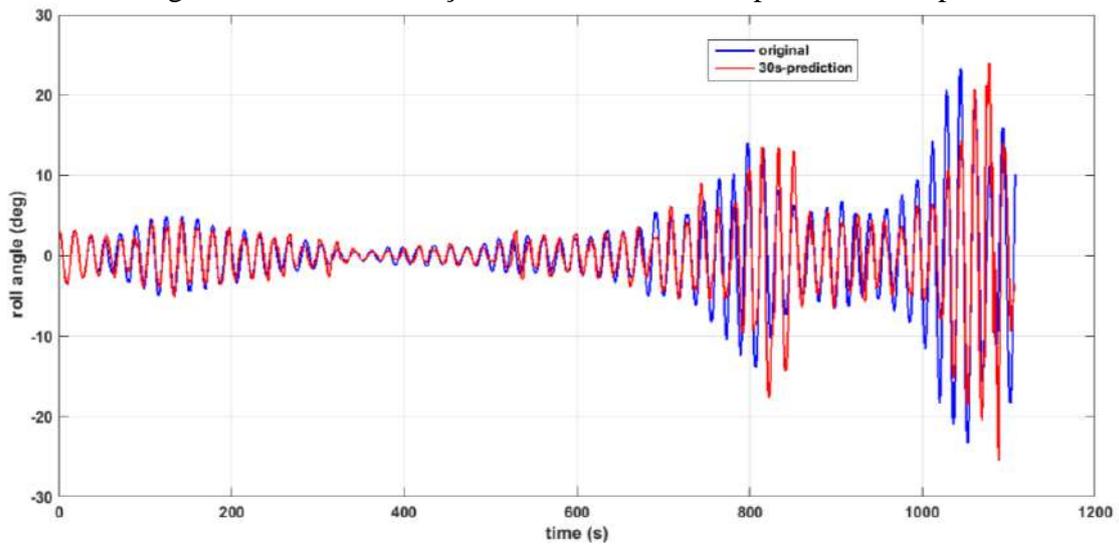


Figura 4.8: RNA: Predição Roll; Janela de Tempo: 30s: 35 inputs

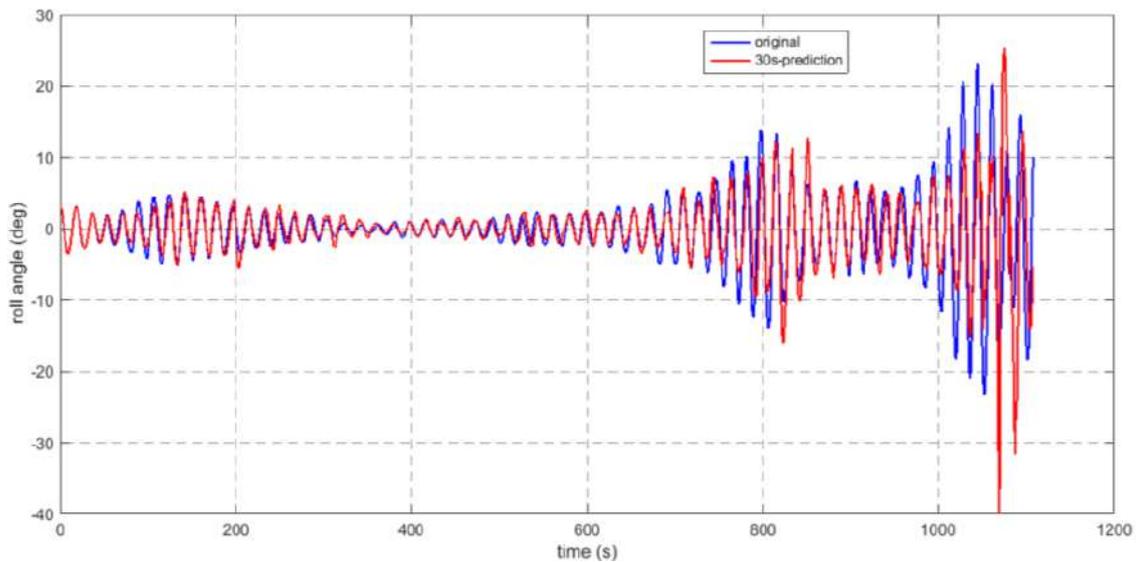


Figura 4.9: RNA: Predição Roll; Janela de Tempo: 30s: 40 inputs

Tabela 4.2: Treinamento Roll/SAFEDOR: erro para diferentes no. de inputs

Inputs:	25	30	35	40
Erro:	0.002	0.0017	0.0026	0.0037

4.3.1.3 Seleção do Número de Neurônios por Camada Escondida

O método da tentativa e erro mostrou ser a alternativa mais eficaz para a determinação da quantidade de neurônios nas camadas escondidas da RNA, do mesmo jeito que foi feito para determinar o número de camadas escondidas. Ainda assim, existem algumas regras heurísticas que auxiliam essa determinação. Uma dessas regras associa a quantidade de neurônios escondidos diretamente ao número de entradas significativas (atrasos), **Zhang and Patuwo (1998)**. Dessa forma, pode-se estimar os limites da quantidade de neurônios da rede usados para o treinamento.

Para redes com uma camada escondida existe a regra prática que indica a quantidade de neurônios escondidos por: $2n$, n , $n/2$, onde: n é o número de entradas da rede. Nesta tese,

adotou-se 30 entradas significativas, fornecendo 60, 30, 15 neurônios, nas camadas escondidas.

No caso de problemas bem-comportados (linear ou fracamente não linear) - **Nunes da Silva, et al.** (2010), podem ser encontradas, na literatura, outras formas de definição do número de neurônios como os método de Kolmogorov e Fletcher-Gloss – **Nunes da Silva, et al.** (2010), aqui indicado pelas expressões (4.3) e (4.4).

$$N_{hidden} = 2N_{in} + 1 \quad \{\text{método de Kolmogorov}\} \quad (4.3)$$

$$2\sqrt{N_{in}} + N_{out} \leq N_{hidden} \leq 2 \cdot N_{in} + 1 \quad \{\text{método de Fletcher-Gloss}\} \quad (4.4)$$

Onde:

N_{hidden} = número de neurônios escondidos

N_{in} = número de inputs

N_{out} = quantidade de neurônios na camada de saída (1 para a metodologia apresentada) uma vez escolhida a topologia com duas camadas, faz-se necessária a definição da melhor distribuição de neurônios por camada.

As **Figuras 4.10, 4.11, 4.12** mostram predições feitas com diferentes números de neurônios para uma rede com duas camadas escondidas.

Desse conjunto de predições, observa-se que a melhor generalização acontece com a rede com 40 neurônios por camada escondida (menor erro do treinamento – **Tabela 4.3**).

Dos resultados apresentados, conclui-se que no caso de topologias com número menor do que 30 e maior do que 50 neurônios ocorreriam uns maiores erros na predição da série temporal de *roll*. Os resultados aqui correspondem a respostas excitadas pelo espectro de mar I (JONSWAP: $H_s=4.8$ m, $T_p=10.63$ s, $\gamma = 3.3$, (incidência 180°)).

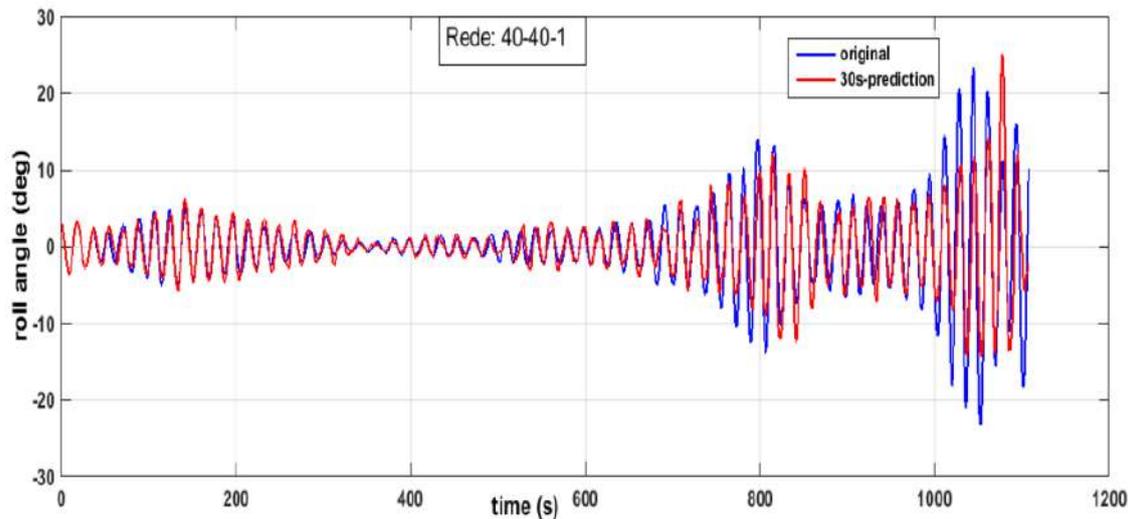


Figura 4.10: SAFEDOR: *Roll*: rede com duas camadas escondidas e com 40 neurônios por camada e uma camada de saída de um neurônio (40-40-1)

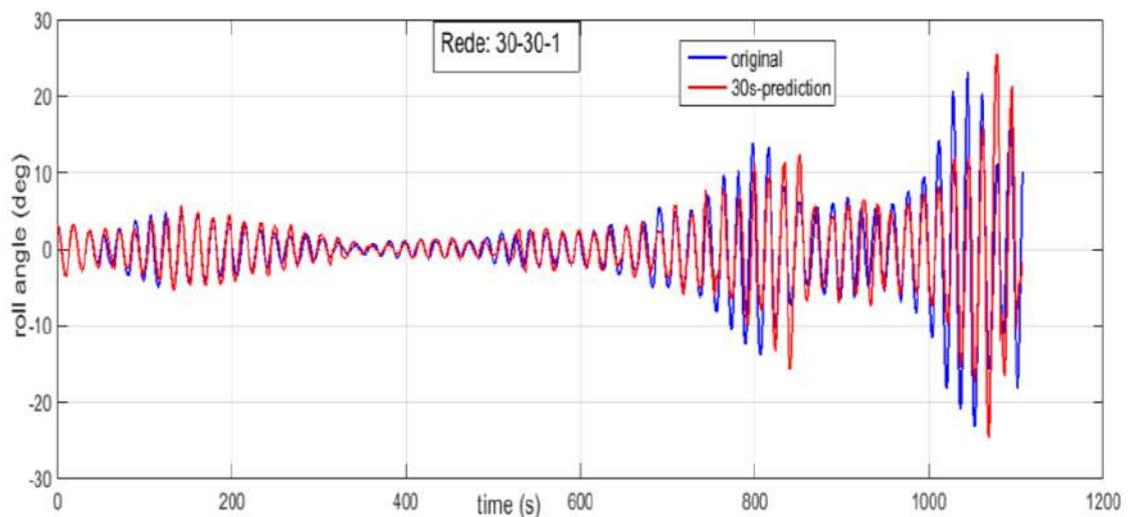


Figura 4.11: SAFEDOR: *Roll*: rede com duas camadas escondidas e com 30 neurônios por camada

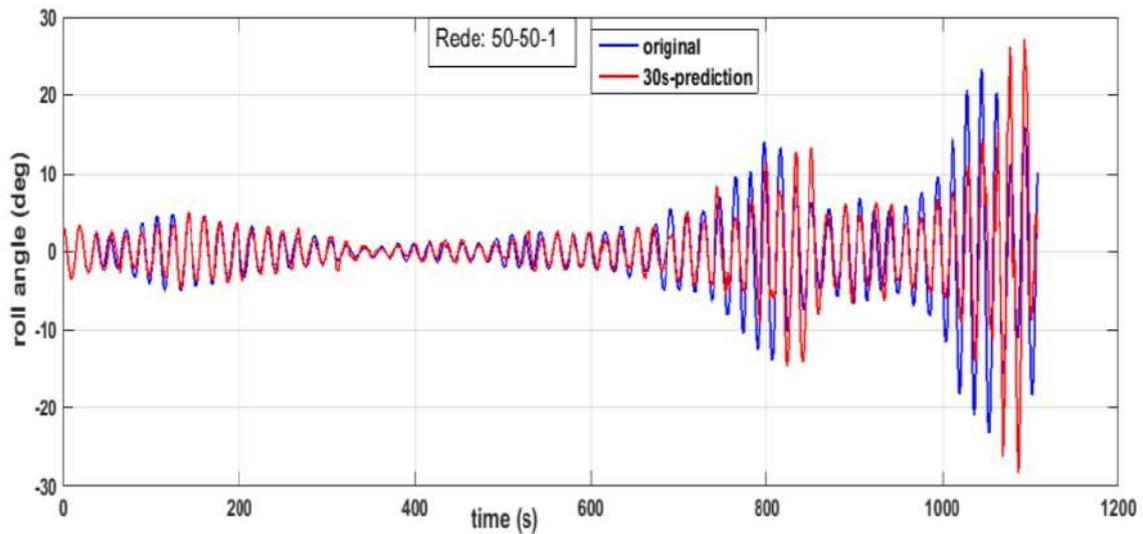


Figura 4.12: SAFEDOR: *Roll*: rede com duas camadas escondidas e com 50 neurônios por camada

Tabela 4.3: Erro com diferentes números de neurônios na camada escondida

Rede:	30-30-1	40-40-1	50-50=1
Erro Treinamento	0.003	0.002	0.0037

Os resultados parciais apresentados até aqui, ainda não permitem a seleção (quantidade de camadas escondidas, número de neurônios por camada escondida e o número de atrasos) da melhor topologia (menor erro na generalização) para a predição de séries temporais de *roll*.

4.3.1.4 Seleção dos Valores Iniciais dos Pesos Sinápticos

Uma boa escolha dos valores iniciais (**VI**) dos pesos pode acelerar bastante o processo de aprendizagem. O problema está em definir-se o que seria uma boa escolha. Valores elevados podem originar saturação da rede, atrasando o processo de aprendizagem. Por outro lado, valores demasiados pequenos fazem com que os algoritmos de retropropagação do erro operem numa área demasiadamente plana, no entorno da origem

da superfície de erro. Uma boa estratégia baseia-se em valores aleatórios (com média de zero) que dependam do número de conexões de um nó.

Nesta tese, se treinou a rede com 10 diferentes valores iniciais aleatórios, A **Tabela 4.4** mostra os valores do erro do treino relacionados ao comportamento de *roll* do navio SAFEDOR excitado pelo espectro de mar I (**JONSWAP**: (H_s) 4.8 m, (T_p) 10.63 s, $\gamma = 3.3$ e incidência = 180°).

Tabela 4.4: Erros para a rede com valores iniciais aleatórios (MSE: Mean Squared Error)

Rede 40-40-1	
Treinamento	Erro (MSE)
1 / 10	0.0606
2 / 10	0.0794
3 / 10	0.0207
4 / 10	0.0209
5 / 10	0.0223
6 / 10	0.0267
7 / 10	0.0474
8 / 10	0.1672
9 / 10	0.0853
10 / 10	0.0200

Na fase de treinamento, foram considerados 40 (quarenta) registros de 1200 segundos para cada uma das séries temporais, com a meta de se simular uma janela de tempo de 30 segundos. Serão informados, portanto, 30 valores de *input* (*time step*: 1s), cobrindo o mesmo intervalo de tempo definido para a janela de tempo considerada. Todos esses números são justificados no item 4.3: Estrutura da Rede Neural Artificial.

CAPÍTULO 5

5. APLICAÇÃO PARA A PREDIÇÃO DE MAR ALEATÓRIO E UM CASO ESTACIONÁRIO

5.1 Introdução

A metodologia proposta nesta tese adota o uso das Redes Neurais Artificiais - **RNAs** para prever séries temporais, em geral, e aquelas correspondentes a respostas de estruturas flutuantes decorrentes da ação das ondas oceânicas irregulares, em particular. Nesse caso, a tese destacará o movimento de *roll* das embarcações, operando em condições de mar real, por conta dos graves riscos associados à possível ocorrência de ressonância paramétrica (ver **Míguez et al., 2010, Míguez et al., 2011, Bellec et al., 2011, Míguez, 2012**).

As **RNAs** têm sido aplicadas com êxito na previsão de séries temporais, em diferentes campos de estudos (física, medicina, economia e engenharia) (ver **Xing e McCue (2009), Xing e McCue (2010)**). Na engenharia naval, foram realizadas aplicações em problemas

de estabilidade do navio, incluindo estudos de controle de *roll* (ver **Li e Guo et al., 2005, Jones e Roskilly et al., 2006, Alarcin e Gulez 2007**).

Neste Capítulo, os algoritmos de **RNAs** serão validados para aplicações na predição da própria representação de ondas irregulares típicas do mar real, e em respostas de estruturas flutuantes submetidas à ação dessas ondas, respostas além do *roll* paramétrico do navio porta-contentor SAFEDOR.

Essa discussão servirá de introdução às aplicações apresentadas no Capítulo 6, onde a mesma metodologia será, então, aplicada à detecção do aparecimento da ressonância paramétrica, cuja caracterização a partir da análise das séries temporais envolve aspectos de maior complexidade e não ergodicidade.

A partir dos conceitos discutidos no **Capítulo 3 e 4** e no **Anexo A**, a arquitetura básica da **RNA** escolhida para os presentes estudos, inclui a estrutura do tipo *feedforward*, na definição de uma rede neural **perceptron** de múltiplas camadas (PCM), cuja qualidade dos resultados será testada em diferentes situações de mar real. Outros autores (ver **Xing e McCue (2010), Míguez (2012)**) já demonstram a boa capacidade das **RNAs** lidarem com séries temporais do movimento de *roll* de embarcações, em mar irregular, mas a janela de predição ainda estava limitada a intervalos insuficientes para fins de aplicações práticas de interesse.

5.2 Predição de Ondas em Mar Real

Para validar a metodologia apresentada no **Capítulo 4**, serão discutidas e avaliadas, neste capítulo, a predição de séries temporais representativas da elevação da onda em mar irregular. A partir do espectro de onda **JONSWAP**, foram geradas várias séries temporais utilizadas para o treinamento e predição da elevação da onda em mar real. A análise da qualidade da predição das séries temporais para ondas considerou diferentes alturas significativas (**Hs**) e vários períodos picos (**Tp**). A rede neural será do tipo *feedforward*, perceptron de múltiplas camadas (PMC), com algoritmo de aprendizado de retropropagação do erro, como discutido no **Capítulo 3**.

5.2.1 Análise de Sensibilidade

De início, foi avaliada a sensibilidade dos resultados em função do número de séries temporais utilizados na fase do treinamento. Para isso, foi considerada a onda irregular gerada a partir do espectro **JONSWAP** para uma altura significativa $H_s = 1$ m e períodos picos $T_p = 10$ s, com um passo de 0.1 segundos. Foram, então, geradas um total de 30 séries temporais da elevação da onda, das quais utilizaram-se para treinamento sub-grupos de 5, 10, 20 e 30 séries temporais a fim de se identificar o número de séries temporais adequado para a melhor generalização (menor erro).

As **Figuras 5.1 – 5.4** apresentam as predições para a janela de predição de 10 s. Observe-se a óbvia influência crescente do número de séries temporais utilizadas no treinamento (5, 10, 20 e 30 séries). Essa influência está quantificada na **Figura 5.5**, onde estão apresentados os valores da **porcentagem do erro** como uma função do número de séries temporais utilizadas no treinamento da RNA.

A definição de **porcentagem do erro** (ver definição após o presente parágrafo) é calculada a partir das diferenças entre a série original e a série predita e será adotada ao longo das diversas análises desenvolvidas nesta tese. A comparação dos erros das diferentes análises de previsão deverá ser feita com base no mesmo intervalo total de tempo do registro.

Para garantir uma melhor qualidade da visualização dos resultados, as figuras apresentadas neste Capítulo vão se restringir a um intervalo de tempo menor (500 s) do que aquele efetivamente adotado para o intervalo de predição (1000 s), com a finalidade de melhor observação da qualidade das predições.

Porcentagem do Erro = $\sqrt{(\text{Erro Quadrático Médio (EQM)}/\text{Valor Quadrático Médio (VQM)})} \times 100$

ou seja $\text{erro}\% = \sqrt{\frac{\text{EQM}}{\text{VQM}}} * 100$

Onde:
$$\text{EQM} = \frac{\sum_{i=1}^n (y_i - y_p)^2}{n}$$

$$\text{VQM} = \frac{\sum_{i=1}^n y_i^2}{n}$$

y_i – Valor da série original;

y_p – Valor da série predita.

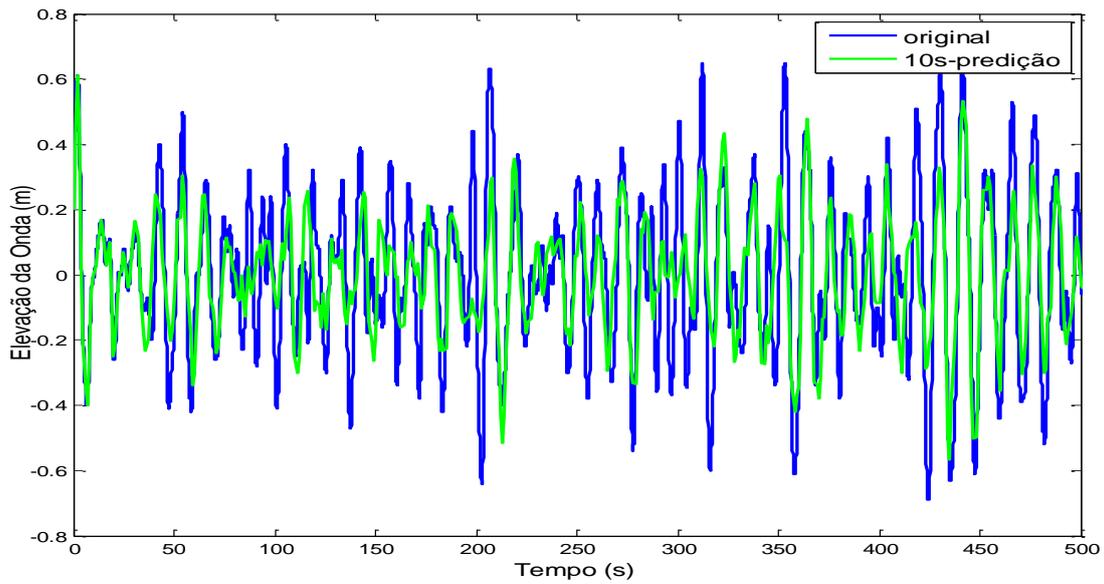


Figura 5.1: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 10s: 5 séries temporais utilizadas no treinamento

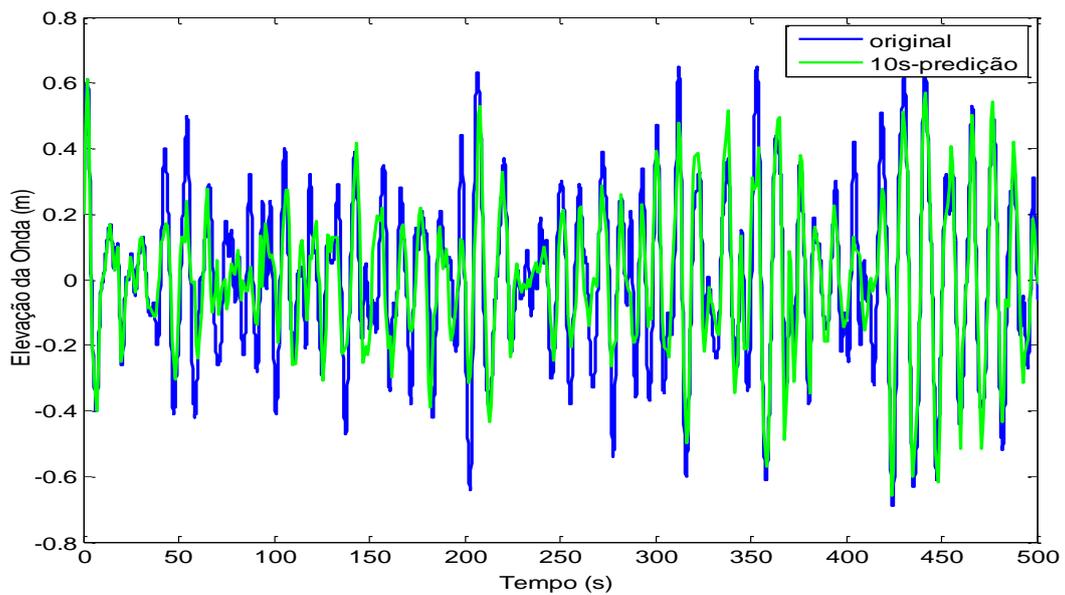


Figura 5.2: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 10s: 10 séries temporais utilizadas no treinamento

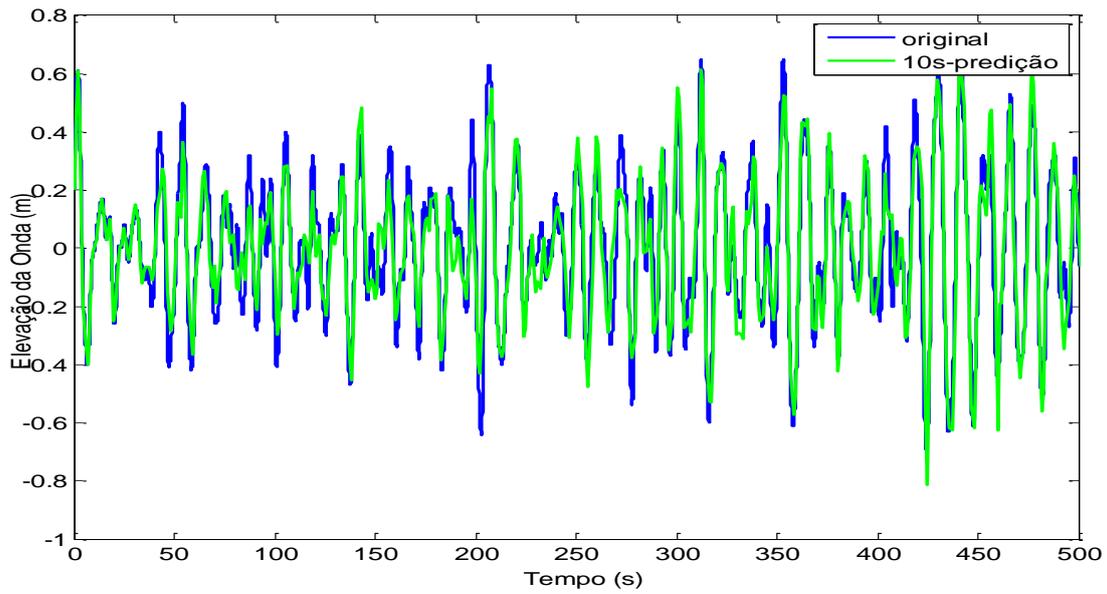


Figura 5.3: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 10s: 20 series temporais utilizadas no treinamento

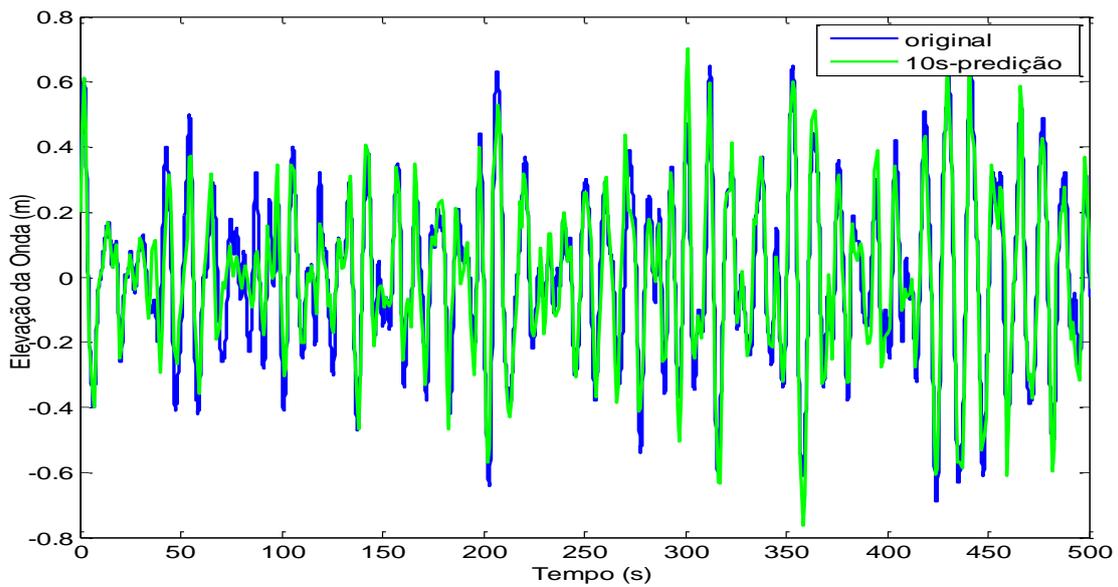


Figura 5.4: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 10s: 30 séries temporais utilizadas no treinamento

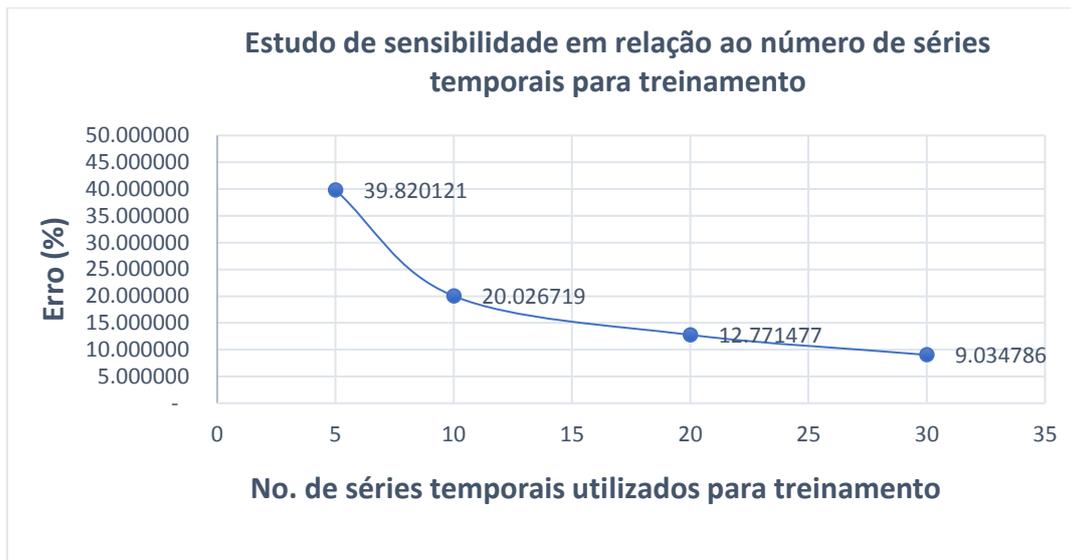


Figura 5.5: Variação da porcentagem do erro em função do número de séries utilizadas no treinamento

A análise de sensibilidade (**Figura 5.5**) indicou que a partir de 30 séries temporais (erro < 10%), os resultados foram considerados satisfatórios mesmo no caso de predição de séries temporais com fortes não linearidades.

5.2.2 Análise de Qualidade da Predição da Onda Irregular

Inicialmente, as séries temporais da elevação da onda foram geradas a partir do espectro JONSWAP, considerando-se altura significativa $H_s = 1.0$ m e período pico $T_p = 10$ s. Com passo = 0.1 s, foram geradas 30 séries temporais, utilizadas no treinamento e na subsequente análise de predição de uma das séries temporais escolhida aleatoriamente.

Na **Figura 5.6**, apresenta-se a predição da elevação da onda de 10 s. Nesse caso, a predição dos valores da série temporal e a série original apresentam pequenas diferenças nos picos, mas, em geral, observa-se uma boa concordância (Tabela 5.1).

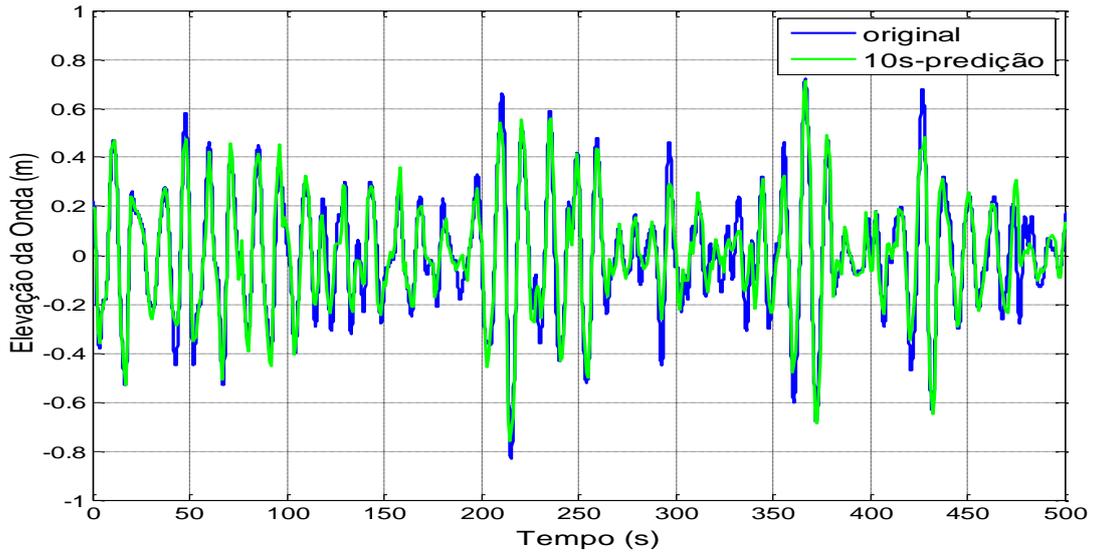


Figura 5.6: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 10 s

Figura 5.6 e Figura 5.4 representam duas séries temporais geradas a partir do mesmo espectro de mar: JONSWAP ($H_s = 1.0$ m; $T_p = 10$ s).

Na Figura 5.7, a predição para a janela de 20 s, no entanto, apresenta significativas diferenças na concordância geral, observando-se diferenças ainda mais pronunciadas nos seus picos (Tabela 5.1).

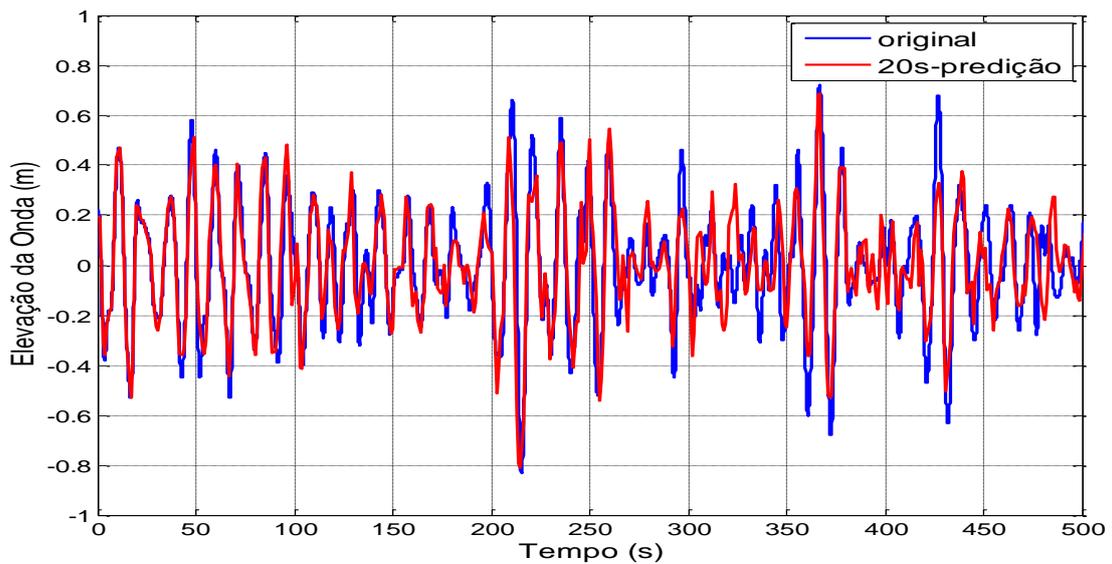


Figura 5.7: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): Janela de predição = 20 s

A **Tabela 5.1** apresenta os valores da percentagem do erro calculados para as séries temporais (original e predita), considerando-se as duas janelas de predição:

Tabela 5.1: Percentagem do erro das séries temporais preditas

Janela de Predição	Erro (%)
10 s	12.6762
20 s	17.2549

5.2.2.1 Filtragem da Série Temporal

Visando o aperfeiçoamento da metodologia de predição a tese uma estratégia incorpora o esquema de ruídos da série temporal original, **Calôba (2008)**. Um filtro do tipo passa-banda (**bpfilt**) permite filtrar as contribuições em faixas especificadas de frequências. No caso, a filtragem acarreta perdas da energia das ondas menores, consideradas desprezíveis e que, portanto, não deverão comprometer a análise das respostas no mar real. Na **Figura 5.8**, apresenta-se as séries temporais original e filtrada.

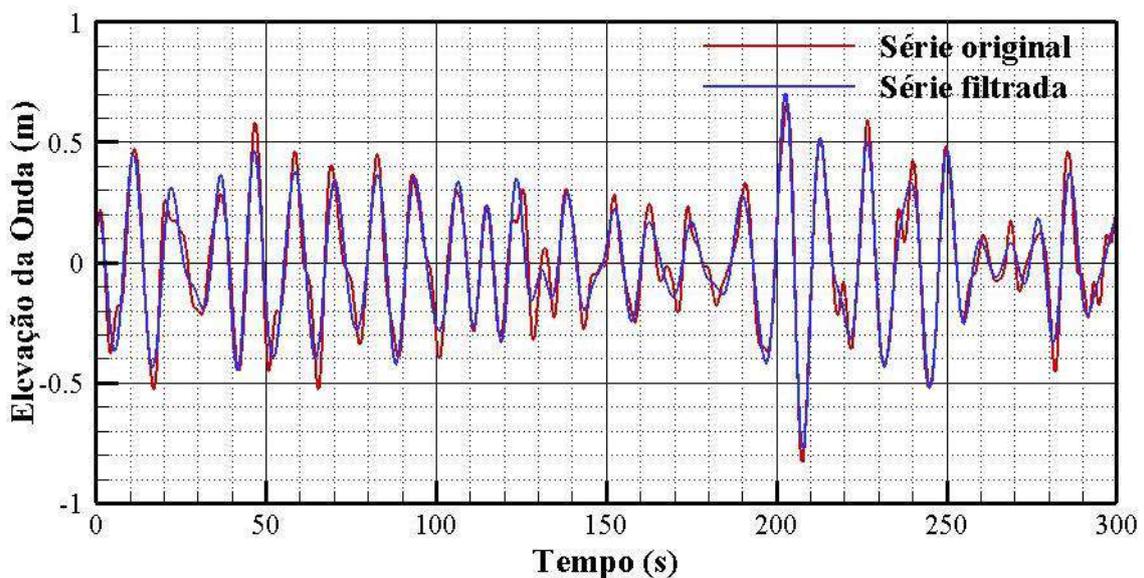


Figura 5.8: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s): original e filtrada

Refeitas as previsões das séries temporais agora filtradas - **Figura 5.9 e 5.10** - observa-se significativa melhora para os resultados das previsões. A previsão para a janela de 10s, praticamente, coincide com a série original; e, mesmo, no caso da previsão para a janela de 20s, os valores de picos também apresentam boa concordância.

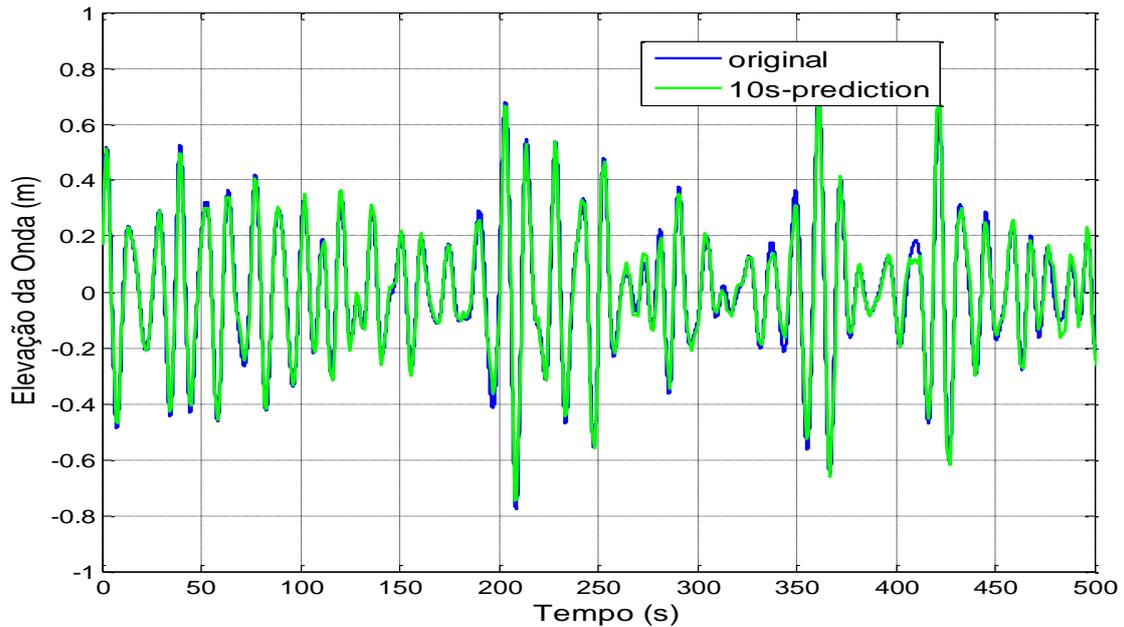


Figura 5.9: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s); Séries Filtradas: Janela de previsão = 10 s

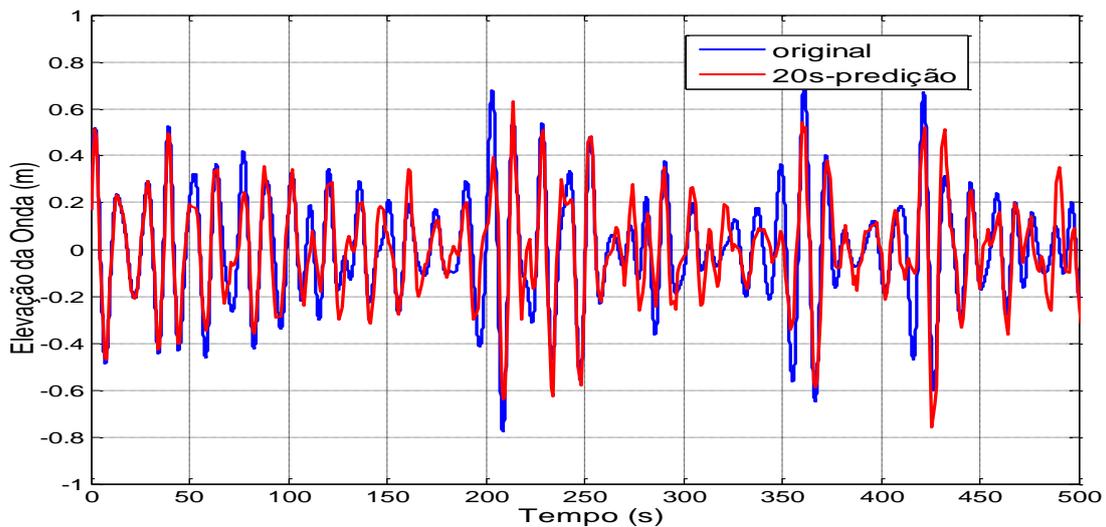


Figura 5.10: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s); Série Original Filtrada: Janela de previsão = 20 s

A **Tabela 5.2** quantifica essa melhora, apresentando os valores das porcentagens do erro para as séries temporais agora levando em conta o efeito da filtragem.

Tabela 5.2: *Porcentagem do erro das séries temporais (original filtrada e predita)*
(JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s)

Janela de Predição (s)	Erro (%)
10	2.7294
20	12.8208

O mesmo tipo de análise foi desenvolvido para as séries temporais geradas para $H_s=2.0$ e $T_p = 10$ s, com passo de 0.1 s. Novamente, foram geradas 30 séries temporais da elevação da onda utilizadas no treinamento e na predição de uma das séries temporais aleatoriamente escolhida.

Nas **Figuras 5.11 e 5.12**, apresentam-se os resultados para janelas de predição de 10 s e 20 s, já incorporando os efeitos da filtragem, observando-se uma adequada concordância para as predições realizadas (**Tabela 5.3**).

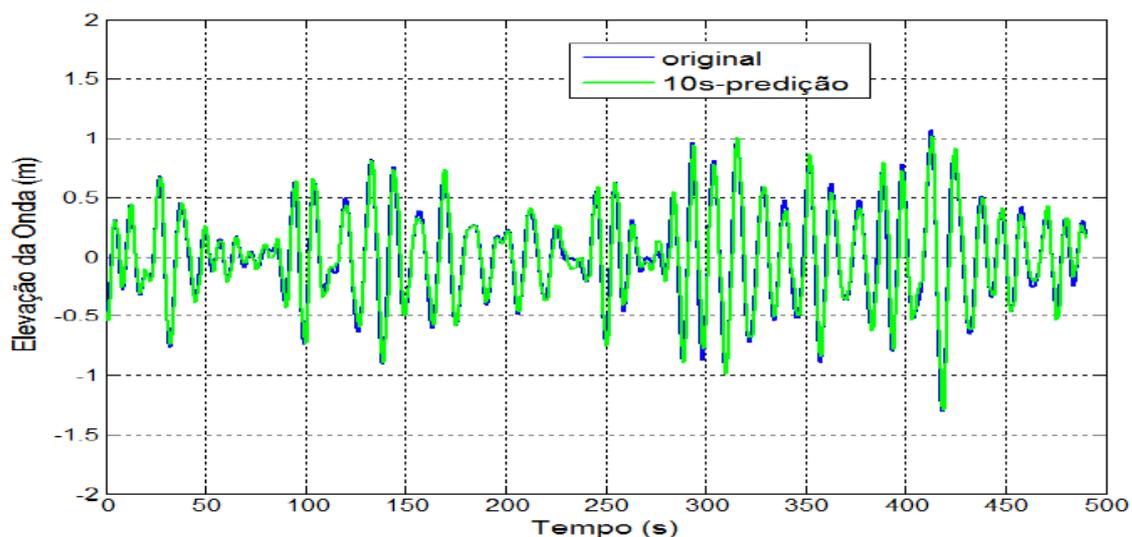


Figura 5.11: Onda irregular (JONSWAP: $H_s = 1.0$ m; $T_p = 10$ s); Série Original Filtrada: Janela de predição = 10 s

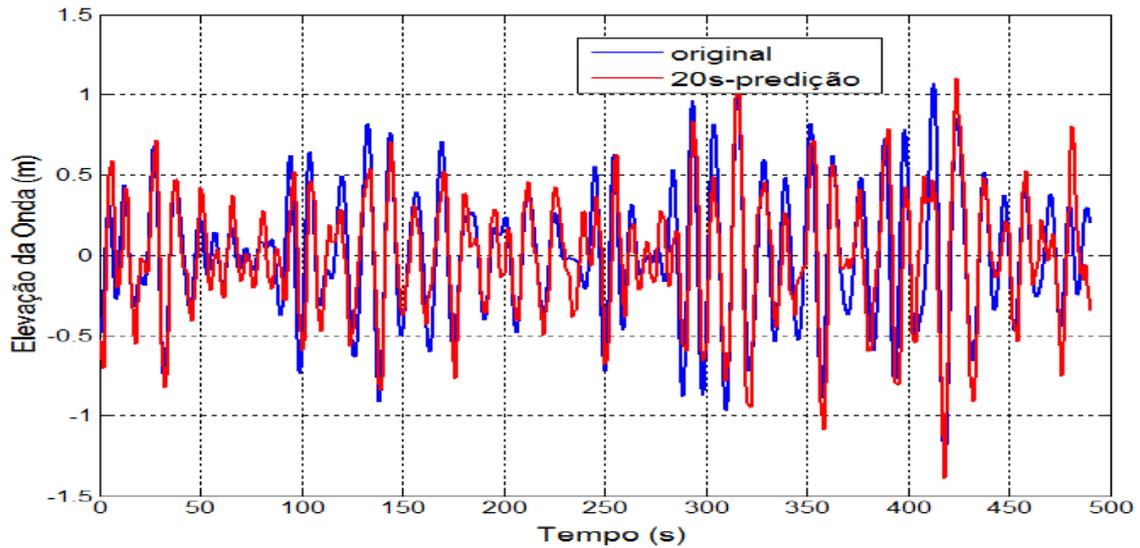


Figura 5.12: Onda irregular (JONSWAP: $H_s = 2.0$ m; $T_p = 10$ s); Série Original Filtrada: Janela de previsão = 20 s

Tabela 5.3: *Percentagem do erro das séries temporais (original filtrada e predita)*
(JONSWAP: $H_s = 2.0$ m; $T_p = 10$ s)

Janela de Predição (s)	Erro (%)
10	6.5848
20	18.0905

De maneira similar, considerando-se agora a altura significativa $H_s=4.0$, as previsões feitas para janelas de 10 s e 20 s produziram os resultados apresentadas nas **Figuras 5.13 e 5.14**, respectivamente, também já incorporando o benefício da filtragem nos resultados.

Na **Tabela 5.4** se pode observar a considerável diminuição das porcentagens do erro dos resultados preditos.

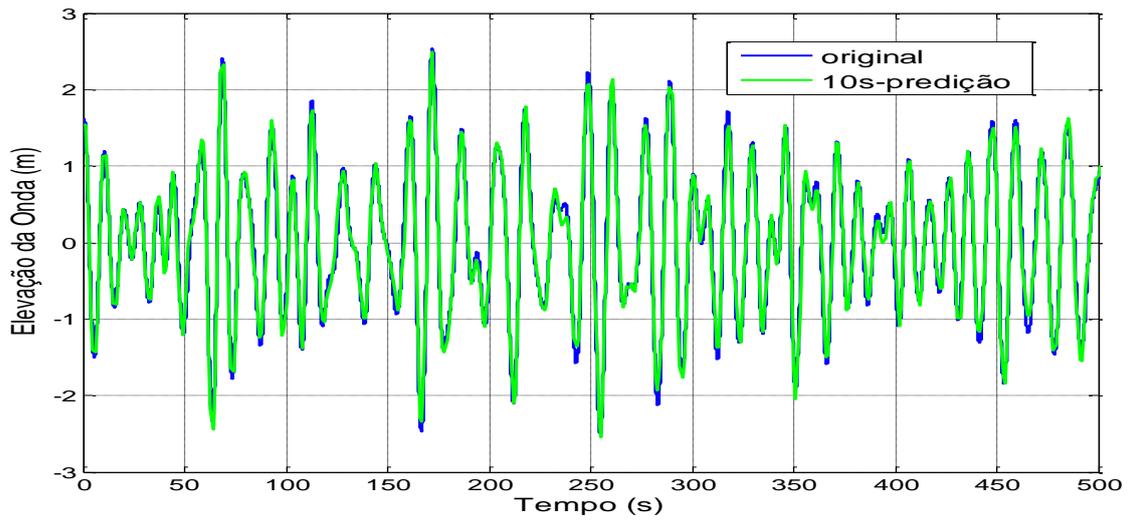


Figura 5.13: Onda irregular (JONSWAP: $H_s = 4.0$ m; $T_p = 10$ s); Série Original Filtrada: Janela de predição = 10 s

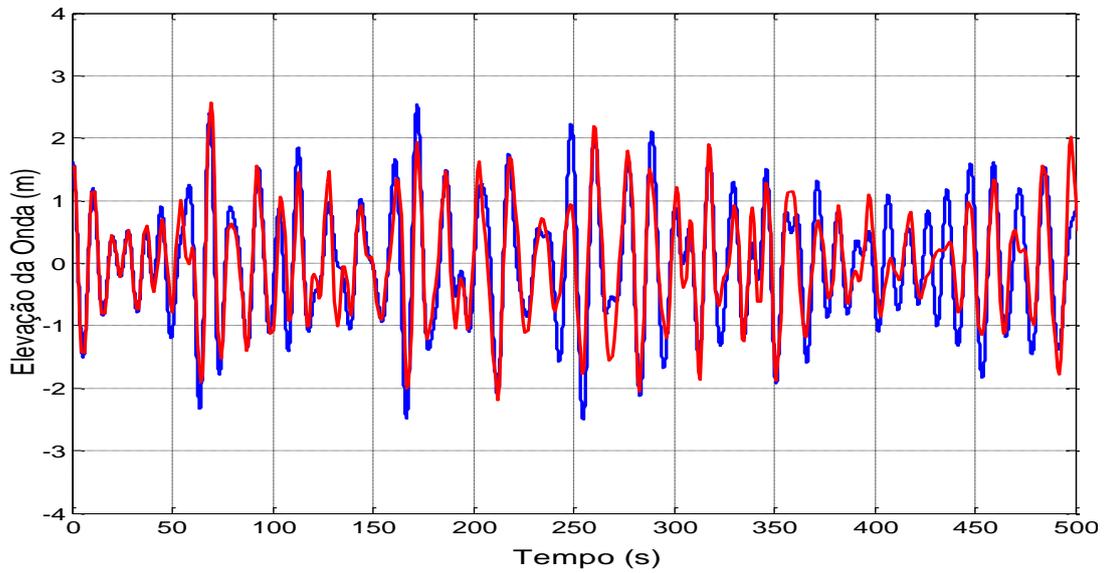


Figura 5.14: Onda irregular (JONSWAP: $H_s = 4.0$ m; $T_p = 10$ s); Série Original Filtrada: Janela de predição = 20 s

Tabela 5.4: Percentagem do erro das séries temporais (original filtrada e predita) (JONSWAP: $H_s = 4.0$ m; $T_p = 10$ s)

Janela de Predição (s)	Erro (%)
10	5.4004
20	25.8272

O valor da percentagem do erro da janela de predição de 20s é maior em comparação com as predições anteriores devido às ondas utilizadas apresentarem maiores declividades para um mesmo valor do período de pico.

5.2.3 Possibilidades e Limitações na Predição de Ondas Irregulares

A metodologia de predição de séries temporais baseada na aplicação das **RNAs** possibilita uma relativamente simples implementação computacional, produzindo uma promissora alternativa de predição. Como discutido nos itens anteriores deste capítulo, a elevação da onda pode ser predita com boa concordância, em janelas de tempo bastante generosas (na discussão apresentada, até 20 s) para o caso de predição da elevação da onda em mar real.

A elevação da onda real tem a sua representação definida por séries temporais complexas, com alto grau de aleatoriedade e ruídos (principalmente, na região dos picos). Ainda assim, as **RNAs** se demonstraram uma ferramenta bastante eficiente e confiável (**Figuras 5.9- 5.14 e Tabelas 5.3, 5.4**), capaz de fornecer predições qualificadas mesmo para janelas de predição mais alongadas, mesmo para o caso não-estacionário.

A estratégia de filtragem da série original incorporou significativa melhora nos resultados obtidos, tornando-se, portanto, uma alternativa eficiente para ampliar o intervalo de predição com qualidade.

De outra forma, a influência positiva do número de séries utilizadas no treinamento indica uma característica bastante poderosa das **RNAs**, na medida em que incorpora progressiva melhora na capacidade de predição, uma vez que o algoritmo pode ser continuamente treinado e aperfeiçoado ao longo da sua aplicação em operações reais.

5.3 Aplicação das RNAs para Respostas de Flutuantes no Mar Real

Com o objetivo de validar a aplicação da metodologia desenvolvida nesta tese, serão feitas previsões de séries temporais representativas de respostas de estruturas flutuantes excitada no mar real, optou-se por analisar o comportamento de um conversor de energia ondas oceânicas (*Wave Energy Converter – WEC*) do tipo *point absorber*. O mundo contemporâneo se desenvolve sustentado por uma crescente demanda de energia, impondo uma busca permanente por novas fontes de energias, se possível limpa e sustentável. Cresce, portanto, o interesse pelos estudos das energias renováveis, que evitem a contaminação ambiental e os seus consequentes danos às condições de vida no planeta Terra, contribuindo para reduzir os riscos associados às mudanças do clima, uma das principais preocupações do século XXI.

O mar representa uma fonte praticamente inesgotável de energia, cujo aproveitamento ainda ocorre em níveis bastante modestos. A geração de energia limpa e renovável a partir do aproveitamento e conversão da energia contida nas ondas se encontra num estágio ainda inicial, aguardando pelos próximos avanços tecnológicos capazes de alavancar o setor.

O chamado conversor de energia de ondas (*Wave Energy Converter - WEC*) do tipo *Point Absorber* (ver esquema ilustrativo - **Figura 5.15**) captura a energia contida nas ondas oceânicas através de uma boia oscilante utilizada no acionamento de um gerador elétrico (denominado genericamente por *Power Take Off – PTO*). As alternativas adotadas para garantir maior eficiência ao processo de conversão incluem o controle e sincronismo entre os movimentos da boia e as ondas incidentes. A incorporação de sistema de travamento (*latching*) do movimento da boia permite aumentar a sua capacidade de captura da energia

das ondas, **Falnes (1997)**, **Falnes (2001)**, **Estefen et al. (2014)**, **Shadman et al. (2015)**, **Shadman (2017)**. Nesse caso, a previsão do comportamento futuro da boia permitirá o controle eficiente do seu sistema de travamento (e destravamento), de modo a sincronizar a força de excitação das ondas atuantes com o movimento da boia. Portanto, a aplicação das RNAs para previsão do comportamento da boia incorpora um avanço tecnológico significativo para o desenvolvimento desse conceito de conversor.

5.3.1 Conversor de Energia de Ondas tipo *Point Absorber* com *Latching*

O sistema de controle de travamento tipo *latching* procura manter o movimento da boia em sintonia com a força de excitação da onda incidente, aumentando significativamente a eficiência da conversão de energia.

No sistema de conversão em energia (Power Take Off - **PTO**) a partir do sensoriamento do registro das ondas incidentes na boia, pode-se obter a definição das séries temporais representativas da força de excitação das ondas. A solução linearizada desse problema está bem discutida na literatura (por exemplo: **Falnes (2001)**, **Falcão (2008)**, **Falcão (2010)**, **Sheng et al. (2014)**), e por essa razão, evita-se aqui uma discussão mais aprofundada. Os resultados discutidos nesta tese utilizaram séries temporais da força de excitação e deslocamento vertical da boia obtidas pela metodologia de cálculo adotada por **Shadman (2017)**. Nessa referência, o autor apresenta a solução detalhada para o sistema boia oscilante (*heave*) - PTO, no domínio do tempo.

Portanto, as séries temporais correspondem ao comportamento de uma boia oscilante, excitada por ondas irregulares, em apenas um grau de liberdade (*heave*), submetida ao

controle de *latching*. O sistema PTO está esquematizado na **Figura 4.83**, através das suas características mecânicas: amortecimento (B) e rigidez (K).

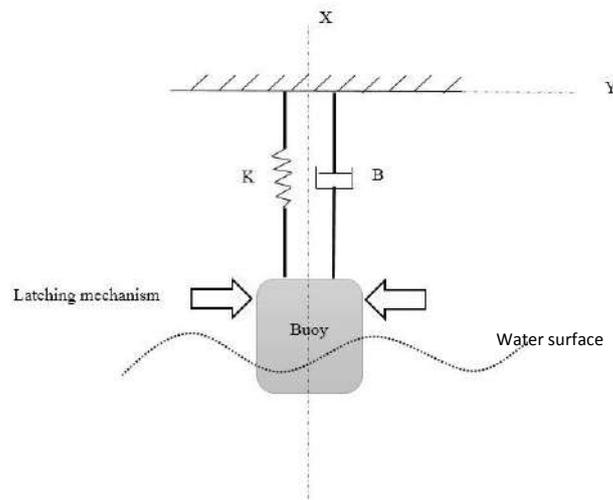


Figura 5.15: Ilustração Esquemática: WEC tipo Point Absorber (um grau de liberdade - heave; PTO e latching) (Shadman, 2017)

5.3.2 Geração das Séries Temporais para o Treinamento da Rede Neural Artificial

As séries temporais geradas pelo código proposto por **Shadman (2017)** representam a força de excitação decorrente da onda atuante e o correspondente deslocamento vertical (*heave*) de uma boia cilíndrica (diâmetro = 6m), oscilando em presença em mar irregular (**JONSWAP**: $H_s=2.0$ m e $T_p = 5.5$ s, e 6 s), com um passo de 0.1 seg. Para garantir a boa qualidade dos resultados da predição, foram geradas, a partir do espectro de energia adotado, 50 séries temporais distintas para o treinamento, escolhidas aleatoriamente.

A janela de tempo de predição de 30 s pode ser considerada mais do que suficiente para fins das aplicações práticas consideradas na tese (controle de *latching* e identificação de deslocamentos exagerados), uma vez que esse intervalo de tempo corresponde a mais do

que duas vezes o período das ondas mais energéticas predominantes no mar real (entre 8 s a 12 s).

a) Predição da série temporal para Espectro JONSWAP: $H_s=2.0$ m, $T_p=5.5$ seg.

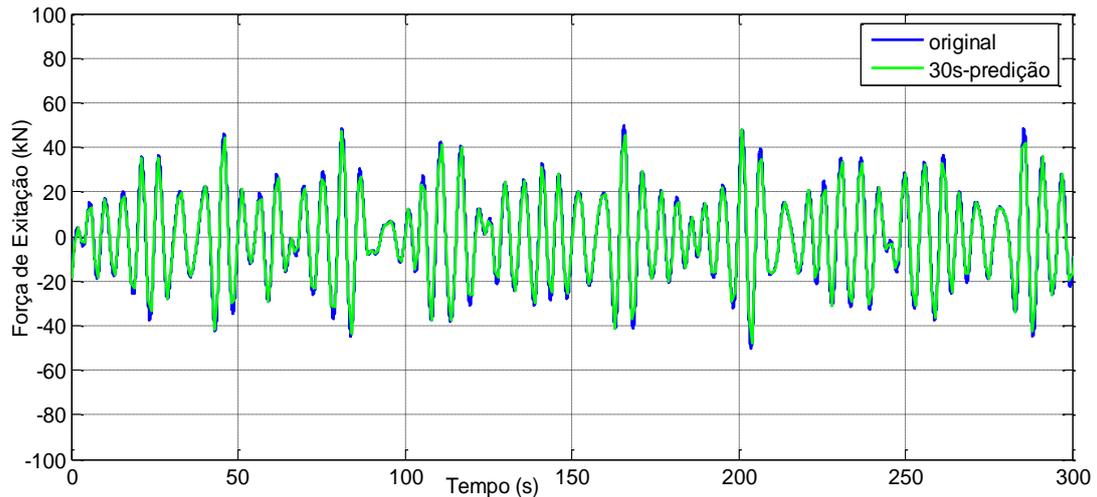


Figura 5.16: WEC: Força de Excitação (JONSWAP: $H_s=2.0$ m, $T_p=5.5$ s): Janela de Predição: 30 s

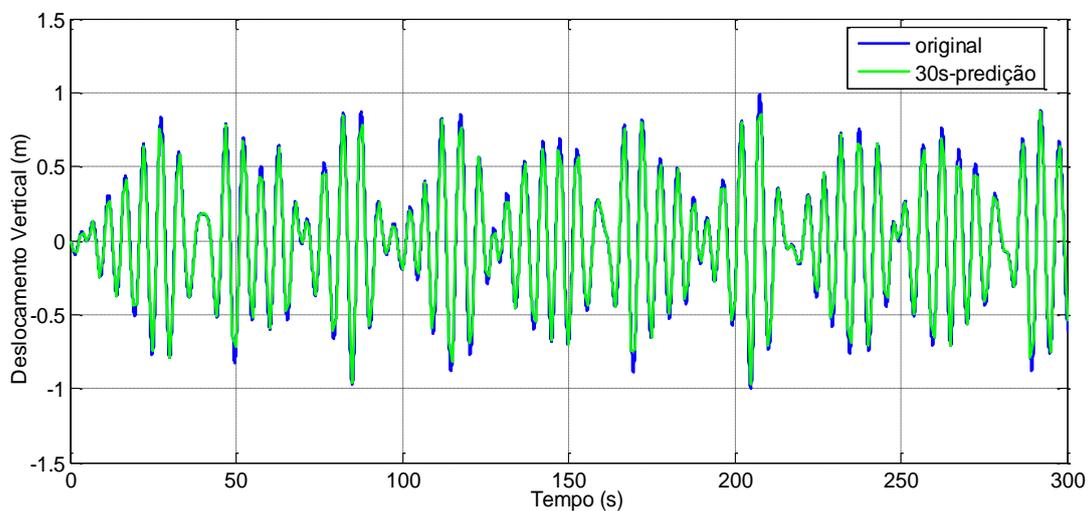


Figura 5.17: WEC: Deslocamento Vertical (JONSWAP: $H_s=2.0$ m, $T_p=5.5$ s): Janela de Predição: 30 s

As previsões para a janela de tempo de previsão de 30 segundos - **Figura 5.16 e 5.17** - acompanham de forma bastante próxima as respectivas séries originais, inclusive na definição dos picos.

b) Predição da série temporal para Espectro JONSWAP: $H_s=2.0$ m, $T_p=6.0$ seg.

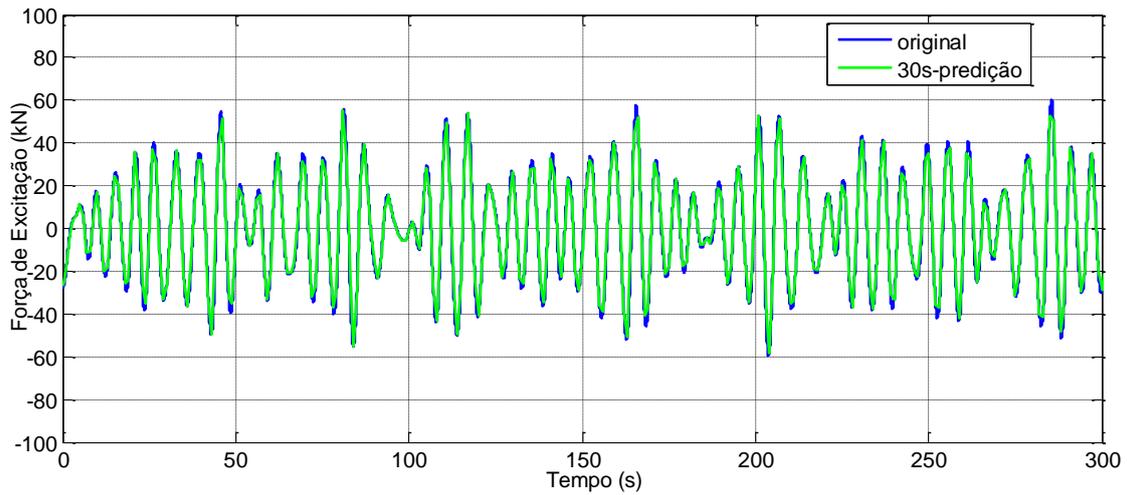


Figura 5.18: WEC: Força de Excitação (**JONSWAP: $H_s=2.0$ m, $T_p=6.0$ s**): Janela de Predição: 30 s

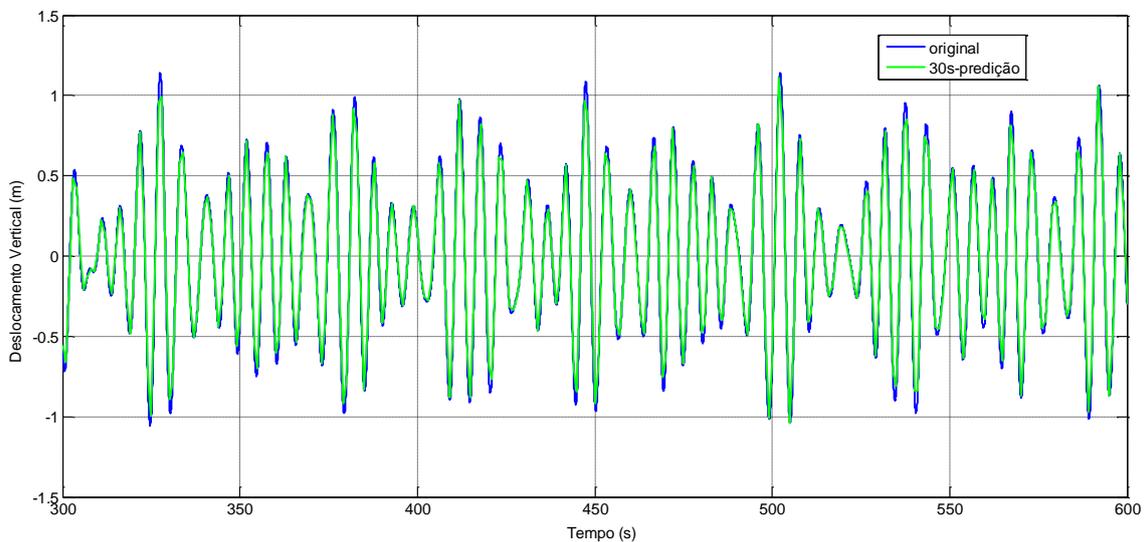


Figura 5.19: WEC: Deslocamento Vertical (**JONSWAP: $H_s=2.0$ m, $T_p=6.0$ s**): Janela de Predição: 30 s

Aqui também, as previsões para a janela de tempo de previsão de 30 segundos - **Figura 5.18 e 5.19**- acompanham de forma bastante próxima as respectivas séries originais, inclusive na definição dos picos.

As previsões têm uma boa concordância ao longo de toda a série temporal, incluindo os picos, como pode ser confirmado pelos baixos valores da porcentagem do erro (**Tabelas 5.5 e 5.6**).

Tabela 5.5: *Porcentagem do erro das séries temporais preditas do deslocamento vertical (referência: série original) (JONSWAP: Hs = 2.0 m; Tp = 5.5 e 6.0 s)*

Período de Pico (Tp) (s)	Erro (%)
5.5	1.9539
6.0	2.7485

Tabela 5.6: *Porcentagem do erro das séries temporais preditas da força de excitação (referência: série original) (JONSWAP: Hs = 2.0 m; Tp = 5.5 e 6.0 s)*

Período de Pico (Tp) (s)	Erro (%)
5.5	2.5157
6.0	2.8745

Neste capítulo foram apresentadas previsões para a elevação da onda (janelas de até 20s de previsão), previsões para dois espectros de onda do tipo JONSWAP. A rede neural teve alguma dificuldade para produzir boa generalização, devido as séries temporais apresentarem um alto grau de complexidade (ruído). Mesmo assim, a rede indicou valores

de erro moderados (**Tabelas 5.3, 5.4**). Predições para o sistema WEC, predições feitas para o deslocamento vertical da boia (**heave**) para dois espectros de onda do tipo JONSWAP (predição de 30 segundos), com boas generalizações (erros pequenos) como apresentados nas **Tabelas 5.5, 5.6**.

CAPÍTULO 6

6. RNAS NA APLICAÇÃO NA PREDIÇÃO DO COMPORTAMENTO DE UMA EMBARCAÇÃO COM *ROLL* PARAMÉTRICO

6.1 Introdução

A tese priorizou a determinação de resultados que pudessem subsidiar um sistema que funcionasse *online*, com janelas de predições de respostas cobrindo até, no mínimo, 60 segundos. Este intervalo é considerado suficiente para a adoção prática de medidas corretivas capazes de evitar a evolução dos efeitos decorrentes do fenômeno da ressonância paramétrica, passível de acontecer no movimento de *roll* de certos tipos de embarcação.

Portanto, baseado nas observações e avaliações empíricas envolvidas na operação do navio, seria de alta relevância para se garantir maior segurança a bordo antecipar o comportamento da embarcação, de modo a se dispor de intervalo de tempo necessário para se exercer o seu efetivo controle preditivo. A possibilidade de se dispor de tempo

suficiente para efetuar alguma ação que permitisse a dessincronização da condição ressonante (exemplos: mudança de rumo, aumento da velocidade, entre outras), evitaria uma eventual ocorrência de ressonância paramétrica em *roll*, o que poderia induzir grandes amplitudes e, até mesmo, levar ao emborcamento da embarcação. Do ponto de vista da prática operacional, considera-se, portanto, suficiente uma janela de predição que cubra cerca de 4 (quatro) períodos naturais (aproximadamente 4 ciclos de *roll* para desenvolver o *roll* paramétrico, **Pernambuco (1990)**) típicos de oscilação de *roll* do navio, no exemplo analisado neste capítulo, as séries temporais analisadas representam o movimento de *roll* do navio SAFEDOR cujo período natural de oscilação de *roll* é de cerca de 17s.

Os bons resultados discutidos no Capítulo 5 concentraram-se, principalmente, em predições de séries temporais representativas da elevação da onda do mar real e respostas lineares de estruturas flutuantes à ação dessas ondas. Nesse caso, as séries temporais das respostas tendem a acompanhar o padrão de comportamento das séries temporais da própria elevação da onda. Para fins de ilustração desse padrão de comportamento, a **Figura 6.3** mostra as respostas em *heave*, *roll* e *pitch* do navio em estudo, excitado por onda irregular definida a partir do espectro de mar I (**JONSWAP**: $H_s = 4.8$ m, $T_p = 10.63$ s, $\gamma = 3.3$, (incidência 180°)), a **Figura 6.4** mostra o registro da onda irregular para essas condições. As características principais do navio SAFEDOR serão listadas no item 6.2.

A **Figura 6.1** apresenta o fluxograma da metodologia adotada na realização do treinamento e predição de séries temporais de *roll* em ressonância paramétrica, em mar real.

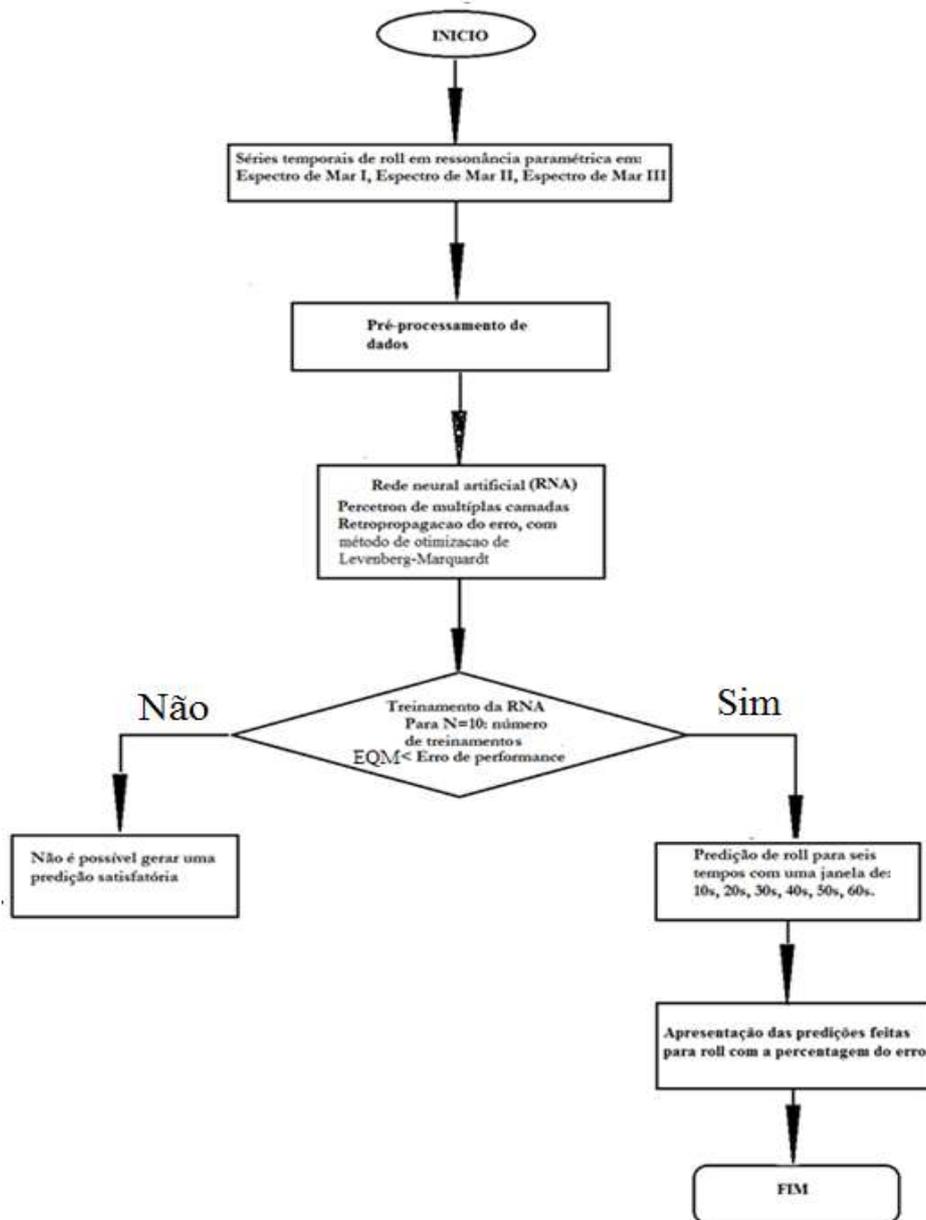


Figura 6.1: Fluxograma da metodologia da predição do *roll* paramétrico em mar real

Neste trabalho, a análise e predição de respostas de *roll* em ressonância paramétrica consideraram três espectros de mar distintos, todos do tipo JONSWAP:

Espectro de mar I ($H_s = 4.8 \text{ m}$, $T_p = 10.63 \text{ s}$, $\gamma = 3.3$, (incidência 180°))

Espectro de mar II ($H_s = 5.0 \text{ m}$, $T_p = 10.63 \text{ s}$, $\gamma = 3.3$ (incidência 180°))

Espectro de mar III ($H_s = 5.0 \text{ m}$, $T_p = 8 \text{ s}$, $\gamma = 3.3$, (incidência 180°))

6.2 Características do Navio SAFEDOR

O navio em estudo é um porta-contentor de médio porte, adotado nos estudos realizados pelo ITTC: Ship A-1 (similar ao porta-contentor post-Panamax classe C11), **Rodríguez (2010)**.

Tabela 6.1: Características principais do navio SAFEDOR

Denominação		Portacontentor SAFEDOR
Comprimento total	[m]	159.42
Comprimento entre perpendiculares	[m]	150.00
Boca	[m]	27.20
Pontal	[m]	13.50
Calado	[m]	8.50
Deslocamento	[t]	23768
Altura metacêntrica transversal	[m]	1.38; 1.00
Raio de gição transversal*	[m]	10.33
Raio de gição longitudinal*	[m]	37.50

**Valores em relação ao CG do navio*

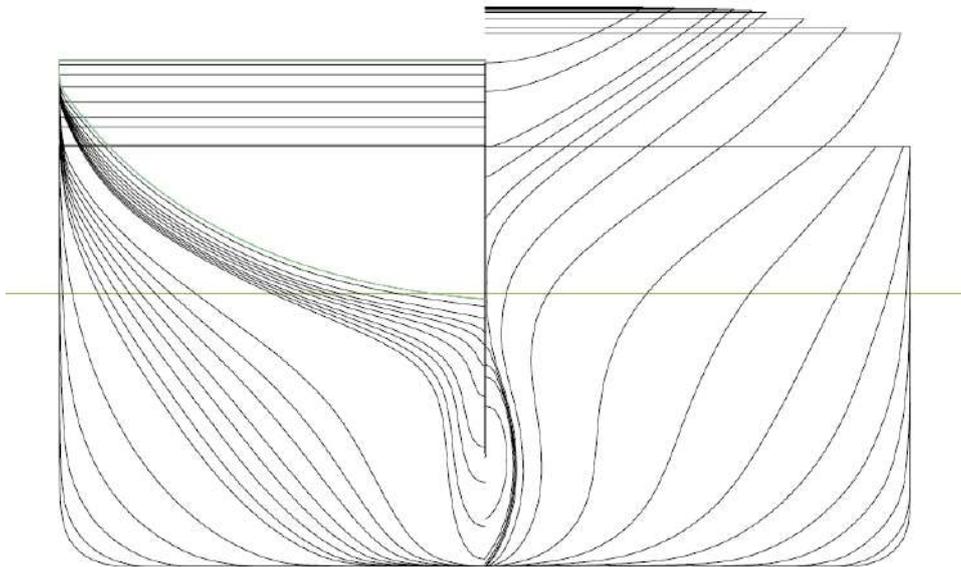


Figura 6.2: Plano de Balizas do porta-contentor SAFEDOR, **Rodríguez (2010)**

As condições adotadas nos estudos em mar irregular correspondem: número de Froude: $F_n=0.12$, altura metacêntrica transversal: $GM= 1.38$ m e $\omega_{n4}=0.330$ rad/s (frequência natural de *roll*).

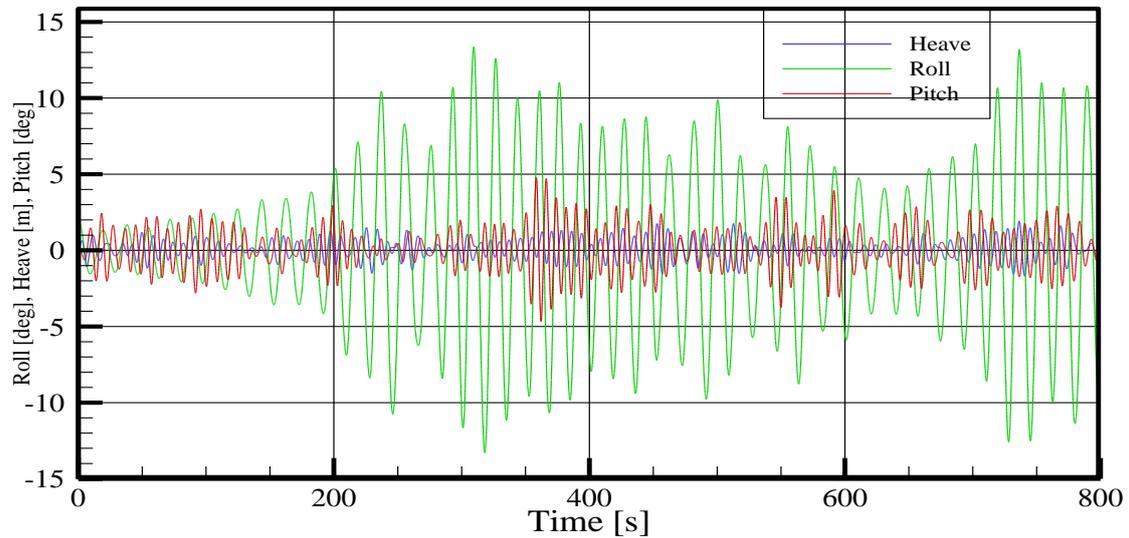


Figura 6.3: SAFEDOR: *roll*, *heave*, *pitch* excitados por onda irregular (JONSWAP: $H_s = 4.8$ m, $T_p = 10.63$ s, $\gamma = 3.3$ e ângulo de incidência = 180°)

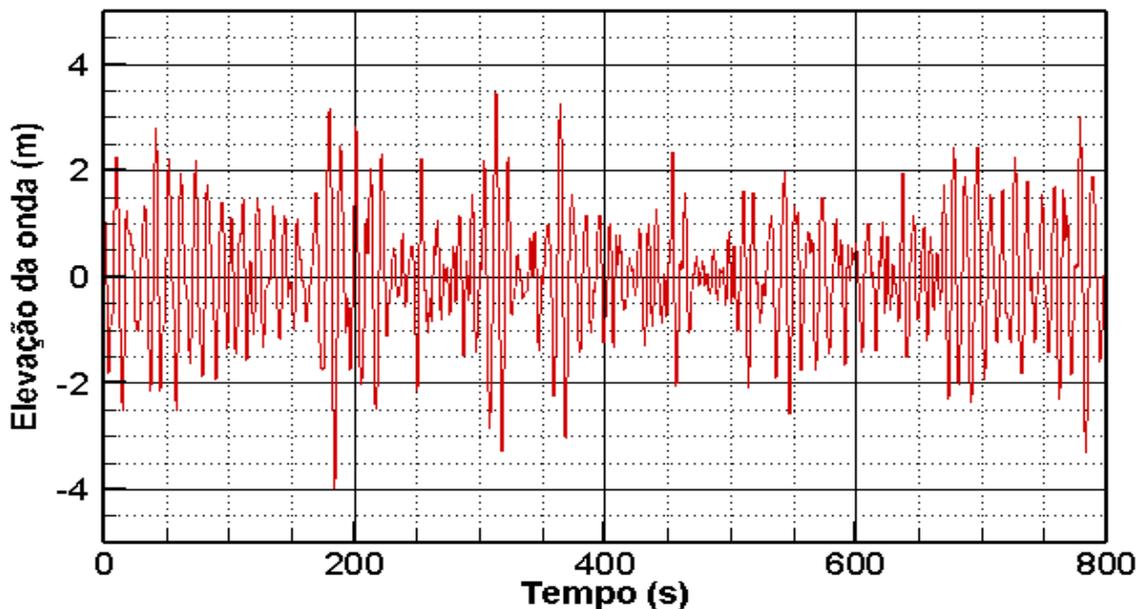


Figura 6.4: SAFEDOR: registro da onda irregular (JONSWAP: $H_s = 4.8$ m, $T_p = 10.63$ s, $\gamma = 3.3$, ângulo de incidência = 180°)

No entanto, no caso de registros temporais do movimento de *roll*, incorporando eventuais efeitos associados à ocorrência da ressonância paramétrica, caracterizados por contribuições fortemente não lineares e até mesmo caóticas contaminarão o registro e modificarão significativamente esse padrão. Nos estudos da elevação das ondas em mar real, assume-se válida a hipótese da ergodicidade, justificada pela teoria da linear, na qual as respostas do navio decorreriam de um sistema linear. A rigor, isso não se cumpre de forma estrita devido à existência de eventuais não linearidades no sistema que descreve o comportamento do navio, principalmente, no caso do movimento de *roll*. Vários autores (por exemplo: **Belenky et al. (2006)**, **Shin et al. (2004)**) consideram o caráter não ergódico do movimento de *roll* em condições de ressonância paramétrica em mar irregular. Nesse caso, o processo de previsão envolvendo janelas de tempo alongadas demandará estratégias e critérios de sensibilidade ainda mais apurados e de maior confiabilidade. Dessa maneira, a metodologia das **RNAs** como apresentada nos Capítulos 3 e 4, e validada no Capítulo 5, será, agora, adotada nas aplicações deste Capítulo 6, sendo revisitada em vários aspectos e reavaliada em alguns outros detalhes específicos.

Nesta tese, para fins de avaliação, a rede foi treinada com uma e duas camadas escondidas. Entretanto, a rede treinada com duas camadas de neurônios escondidos apresentou uma melhor topologia (melhor generalização), sendo, por essa razão, escolhida aqui também para gerar os resultados finais. As duas camadas foram definidas de modo que cada camada tem diferentes números de neurônios. Dos testes realizados, a rede com 40 neurônios por camada escondida apresentou capacidade considerada suficientemente adequada para garantir a qualidade da previsão (critério: menor erro quando comparado com a amostra de referência).

6.3 Predição da Ressonância Paramétrica em Mar Irregular

Como já enfatizado, o objetivo principal deste capítulo resume-se à análise de viabilidade da aplicação de RNAs na predição do movimento de *roll* do navio, operando em condições reais de mar, potencialmente, envolvendo a sua rápida amplificação.

As análises desenvolvidas nesta Seção 6.3 assume-se a rede neural do tipo *feedforward*, perceptron de múltiplas camadas, com um algoritmo de aprendizado de retropropagação e otimização de Levenberg-Macquardt.

A partir dos resultados obtidos nas análises e avaliações discutidas nos capítulos precedentes, a rede constará de duas camadas escondidas com 40-40 neurônios em cada camada escondida. Uma base de dados de 40 séries temporais será utilizada para a realização do necessário treinamento.

As predições consideraram três diferentes espectros em condição de mar irregular. As predições foram feitas para três espectros de onda, aumentando-se progressivamente os intervalos das janelas de predição (10, 20, 30, 40, 50, 60 s). O conjunto completo dos resultados utilizados para o desenvolvimento destes estudos estão apresentados no **Anexo C** da tese. Neste **Capítulo 6**, serão apresentados e avaliados apenas os resultados correspondentes à janela de tempo de maior interesse (60s). As séries temporais de *roll* (navio SAFEDOR) adotadas para treinamento e referência foram todas obtidas a partir da metodologia adotada para a simulação de *roll* paramétrico em ondas irregulares, utilizando-se código desenvolvido em **MATLAB**, como apresentada por **Rodríguez (2010)**.

A RNA adotada contém duas camadas ocultas de 40 neurônios por camada, com uma função de ativação de tangente hiperbólica nas camadas ocultas, e função de ativação linear na camada de saída.

A complexidade do problema é uma característica que não se pode controlar. Portanto, partir dessa premissa, para que garantir uma boa generalização (menor erro), mantém-se fixa a arquitetura da rede e investiga-se o tamanho do conjunto de amostras ideal, além de estabelecer um conjunto de treinamento fixo (número de dados de entrada) para investigar a melhor arquitetura de rede. Outra questão relevante é a escolha do universo de amostras que serão apresentadas à rede neural, **Calôba (2002)**. A parcela de amostras que será utilizada para treinamento deve possuir uma quantidade de dados (**vide: 4.3**) que represente as características do problema a ser solucionado. Se essa premissa não for seguida, a rede também perde sua capacidade de generalização, especializando-se nos dados de treinamento e sendo incapaz de reconhecer estímulos externos, se for apresentado a ela um número excessivo de estímulos nesta fase.

O cuidado na determinação da quantidade de neurônios nas camadas intermediárias se deve ao fato de que se houver um número excessivo de neurônios, a rede pode se tornar tão flexível que passa a ser especialista no conjunto de treinamento, caracterizando assim uma situação denominada *overfitting*, **Haykin (2008)**. Por outro lado, um número reduzido de neurônios levará a rede a lidar com um excesso de restrições na tentativa de modelar o problema, levando então muito tempo para encontrar a solução.

A validação cruzada é uma poderosa ferramenta estatística denominada para se evitar *overfitting*. Primeiramente, o universo dos dados de treinamento é subdividido em um subconjunto de treinamento e em um subconjunto de testes, de forma aleatória. Da mesma

maneira, realiza-se a divisão do subconjunto de treinamento em dois outros subconjuntos: estimação e validação. O treinamento, feito com o subconjunto de estimação é interrompido periodicamente e o erro da rede em relação ao subconjunto de validação é calculado. Quando o erro do subconjunto de validação começa a crescer, mesmo com o erro de treinamento decrescendo, decide-se por interromper o treinamento. Para garantir que não houve ajuste excessivo da rede para o conjunto de validação, testa-se diferentes subconjuntos de teste. Após essa etapa a rede pode ser considerada treinada.

Para mostrar que a RNA é uma ferramenta confiável e poderosa para a predição do aparecimento de *roll* com ressonância paramétrica, a RNA será testada para três tipos de espectros diferentes, desde um espectro de baixa energia ($H_s=4.8$ m, $T_p=10.63$ s) até espectro mais energético, com variação dos valores das séries temporais mais intensos ($H_s=5.0$ m, $T_p=8$ s).

6.3.1 Resultados para JONSWAP $H_s = 4.8m$, $T_p = 10.63$, $\gamma = 3.3$ (ângulo de incidência: 180°)

A RNA tem 40 neurônios em cada camada escondida e uma base de dados de 40 séries temporais, da qual se escolheu aleatoriamente três séries temporais para a predição.

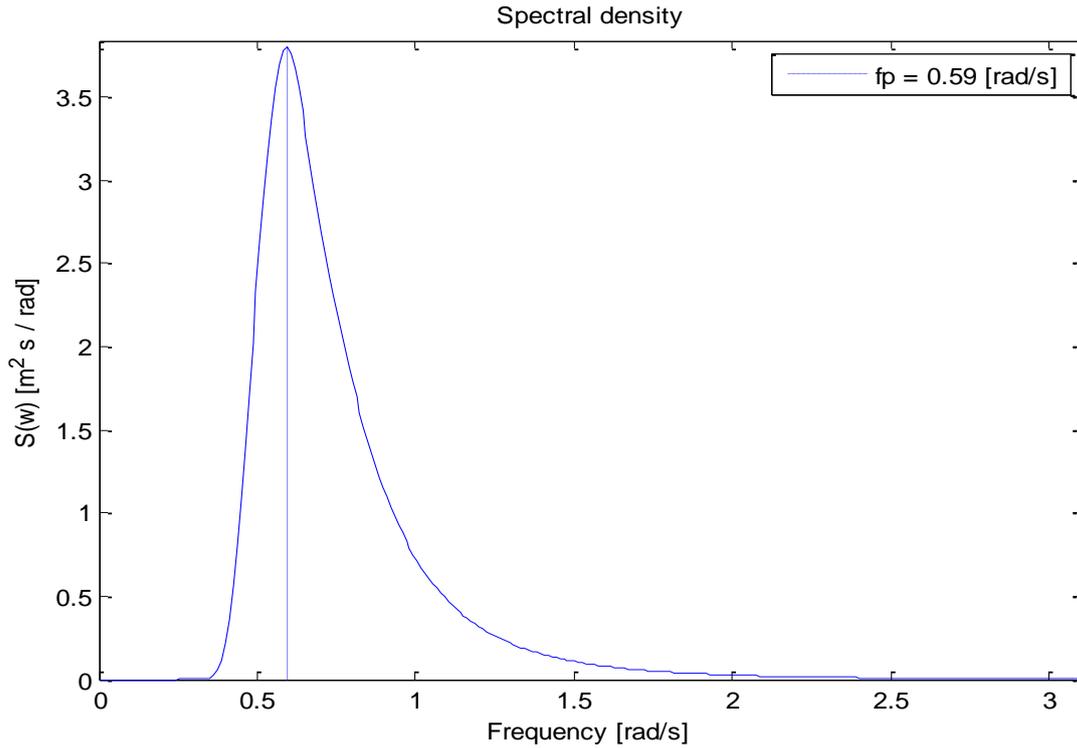


Figura 6.5: Espectro JONSWAP com $H_s=4.8$ m, $T_p=10.63$ s, $\gamma = 3.3$

Para este espectro de onda, com 40 dados de entrada (realizações de roll, decorrentes do fenômeno da ressonância paramétrica), foram realizadas previsões para três séries temporais de *roll* escolhidas aleatoriamente, com seis janelas de tempo de predição distintas: 10, 20, 30 40, 50, 60 s. A título de ilustração, as **Figuras** 6.6 (Série Temporal 01), 6.8 (Série Temporal 02) e 6.10 (Série Temporal 03) apresentam os resultados correspondentes à janela de predição de 60 s.

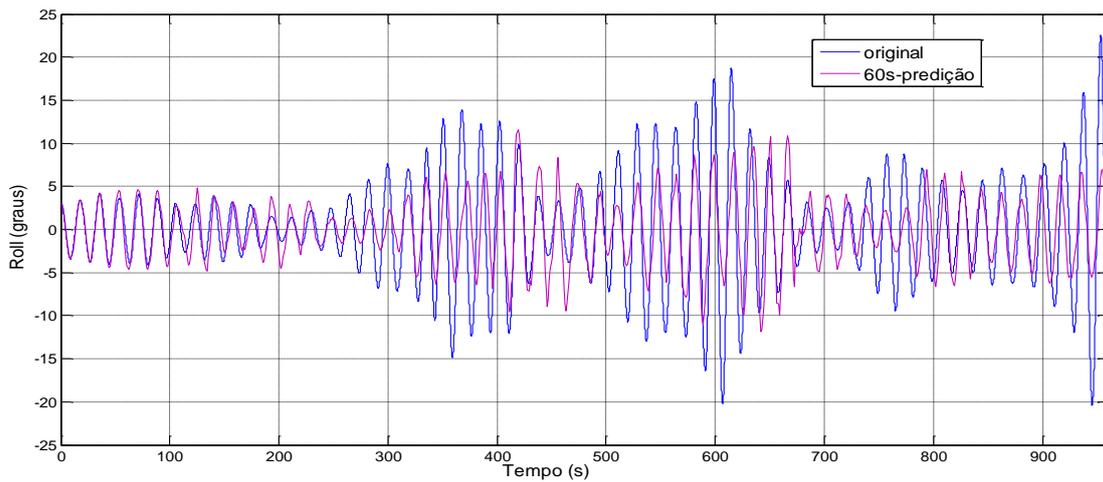


Figura 6.6: SAFEDOR: *Roll*: Série Temporal 01: Janela de Predição 60 s

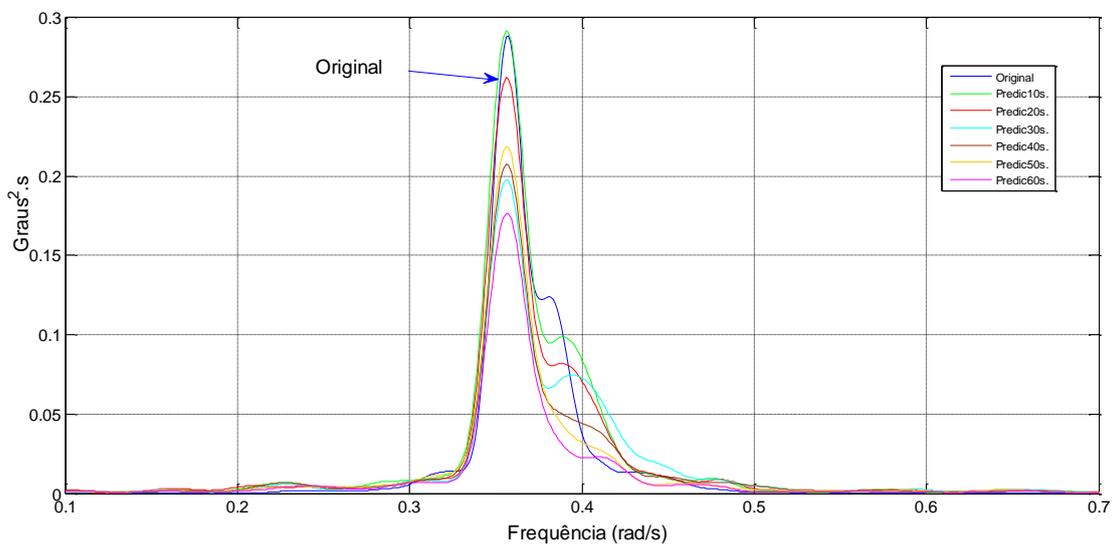


Figura 6.7: SAFEDOR: Transformada de Fourier - *Roll*: Série Temporal 01: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s

A título de resumo, as **Figura 6.7** (Série Temporal 01), **6.9** (Série Temporal 02) e **6.11** (Série Temporal 03), apresentam, para efeito de comparação apenas, as respectivas curvas de Transformada de Fourier das series temporais correspondentes às previsões do comportamento de *roll* para cada uma das seis janelas predições consideradas. As diferenças observadas nessas curvas permitem avaliar, de forma indireta, as imprecisões presentes nas predições correspondentes às diferentes janelas de tempo de predição.

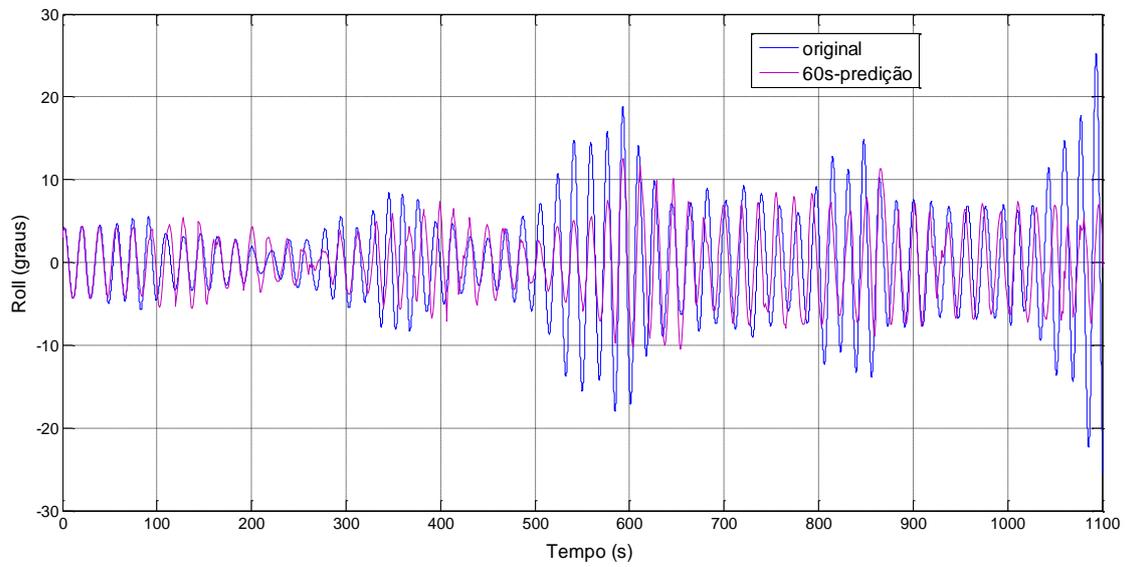


Figura 6.8: SAFEDOR: *Roll*: Série Temporal 02: Janela de Tempo de Predição 60 s

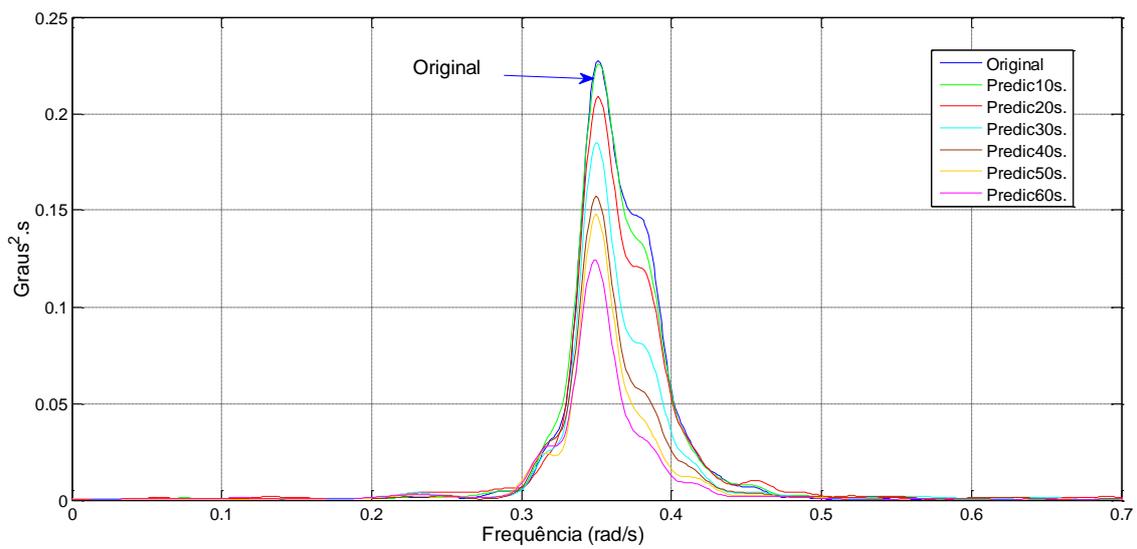


Figura 6.9: SAFEDOR: Transformada de Fourier - *Roll*: Série Temporal 02: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s

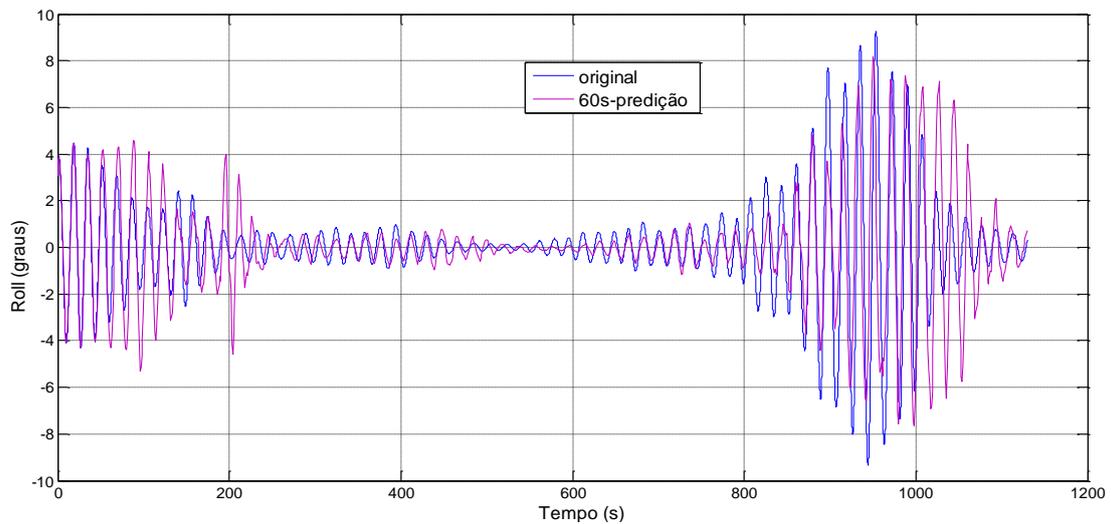


Figura 6.10: SAFEDOR: Roll: Série Temporal 03: Janela de Predição 60 s

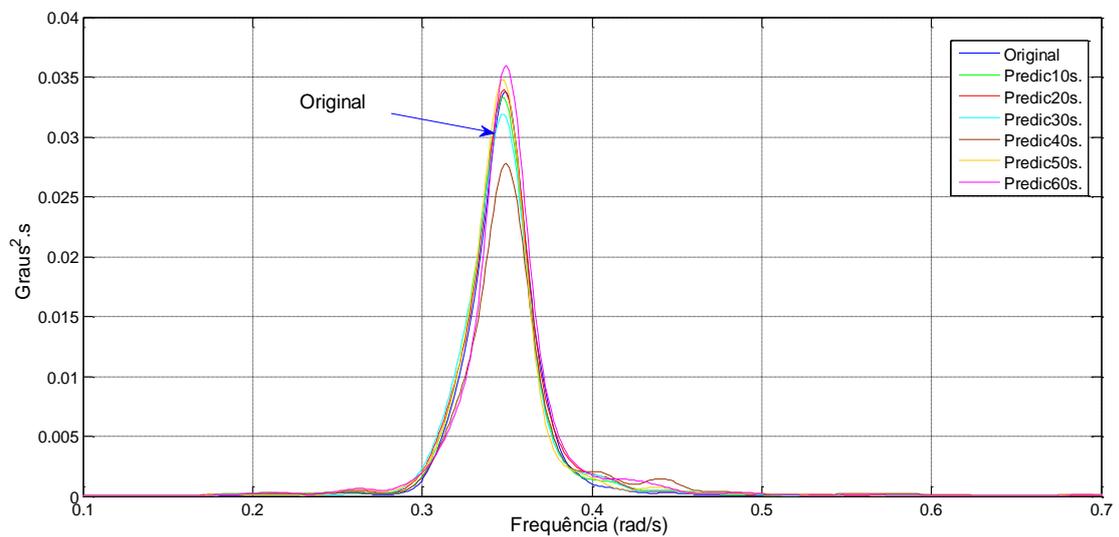


Figura 6.11: SAFEDOR: Transformada de Fourier - Roll: Série Temporal 03: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s

Tabela 6.2: Porcentagem do erro para as previsões feitas com janela de 60 segundos

Série predita	erro (%)
Série 1	20.8163
Série 2	13.2487
Série 3	15.8749

As 03 previsões (60 s) realizadas para esse primeiro espectro mostram o aparecimento de ressonância paramétrica, com a rápida amplificação do *roll* (**Figuras 6.6, 6.8, 6.10**).

As previsões conseguem prever o seu aparecimento e acompanham os valores da amplitude da série original, com erro em percentagem cujos valores podem ser considerados moderados (**Tabela 6.2**), confirmando a capacidade do algoritmo para prever o aparecimento da ressonância paramétrica apesar de não-estacionário. As curvas representativas da Transformada de Fourier (**Figuras 6.7, 6.9, 6.11**) das séries preditas de *roll* (para as janelas de tempo de 10, 20, 30, 40, 50, 60 s) se aproximam bem da Transformada de Fourier da série original, indicando uma adequada confiabilidade para a metodologia adotada.

6.3.2 Resultados para JONSWAP $H_s = 5.0$ m, $T_p = 10.63$ s, $\gamma = 3.3$ (incidência 180°)

Para demonstrar a possibilidade de generalização deste processo, o navio **SAFEDOR** foi testado para o espectro de mar **JONSWAP** com altura significativa (H_s) de 5.00 m, período de pico (T_p) de 10.63 s, $\gamma = 3.3$ e incidência 180° .

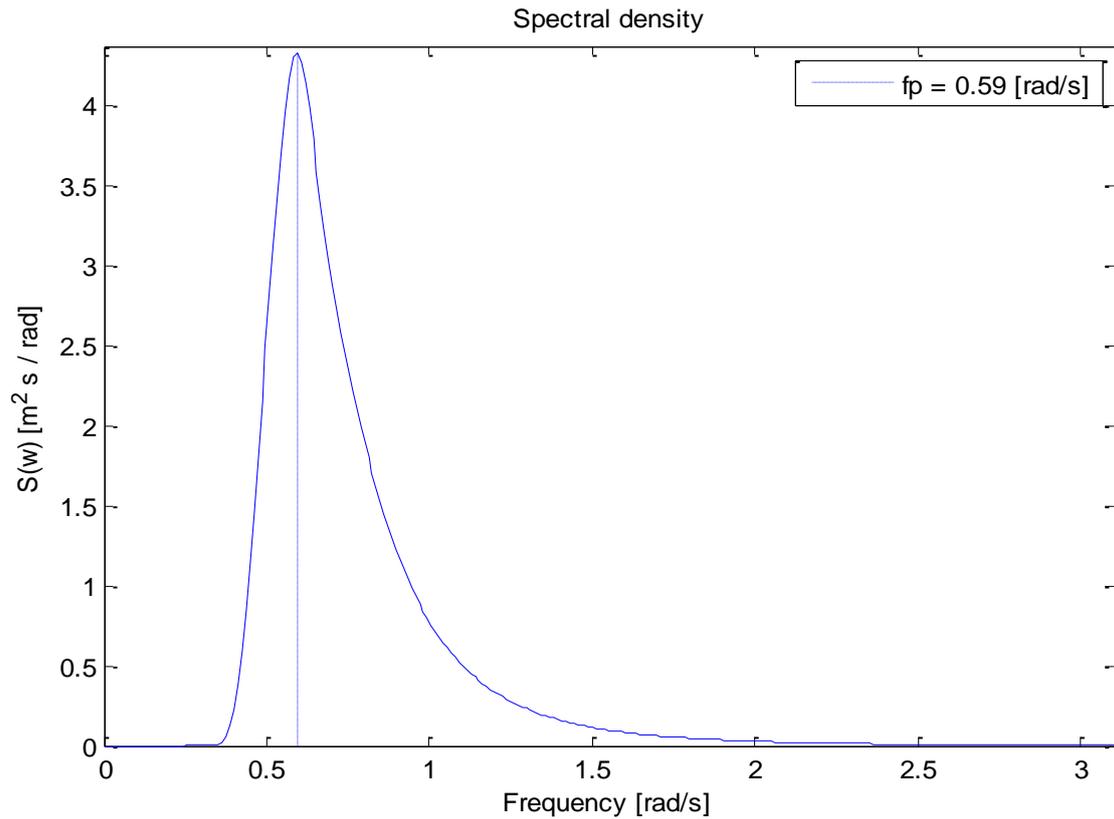


Figura 6.12: Espectro JONSWAP com $H_s=5.0$ m, $T_p=10.63$ s, $\gamma = 3.3$

Seguindo o mesmo procedimento adotado anteriormente, escolhem-se aleatoriamente três séries temporais para realizar a nova análise de predição. As **Figuras 6.13** (Série Temporal 01), **6.15** (Série Temporal 02) e **6.17** (Série Temporal 03) apresentam os resultados correspondentes à janela de predição de 60s.

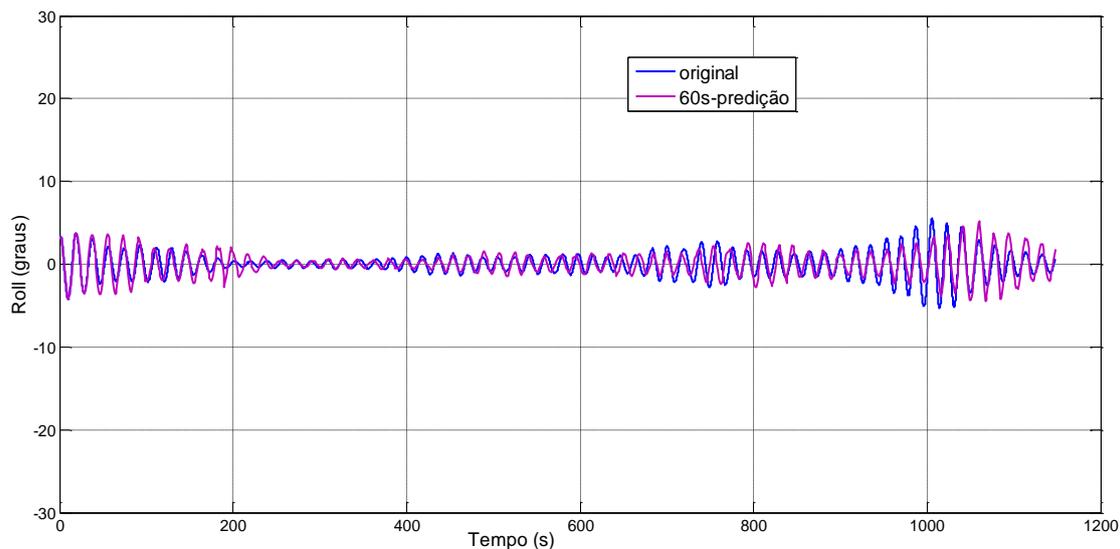


Figura 6.13: SAFEDOR: *Roll*: Série Temporal 01: Janela de Predição 60 s

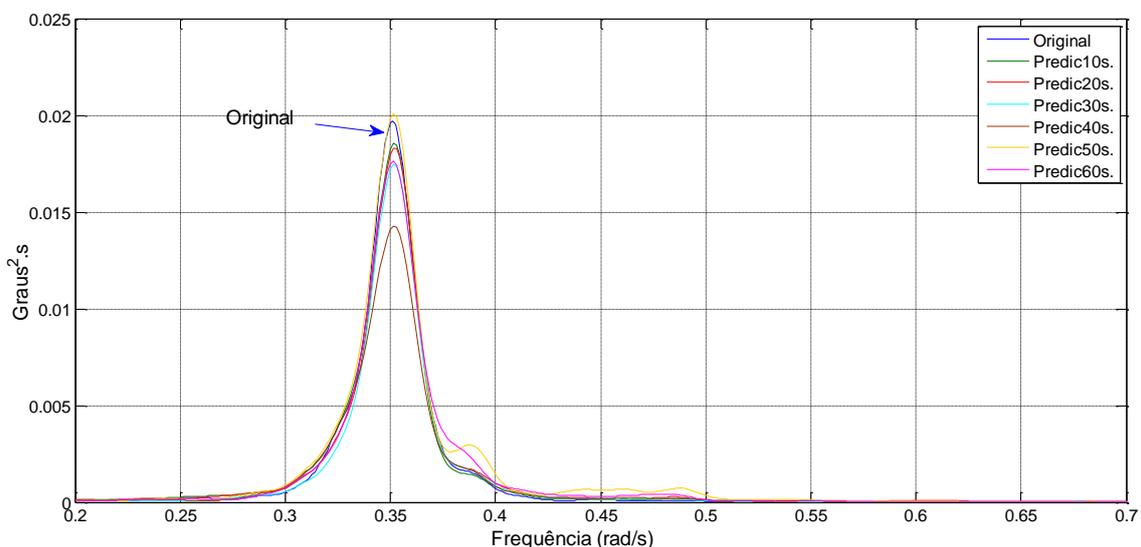


Figura 6.14: SAFEDOR: Transformada de Fourier - *Roll*: Série Temporal 01: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s

Aqui também a análise será resumida pelos resultados apresentados nas **Figura 6.14, 6.16** e **6.18** através das curvas da Transformada de Fourier para as seis janelas predições consideradas, para as três séries temporais escolhidas (Série Temporal 01, Série Temporal 02 e Série Temporal 03). As diferenças observadas nessas curvas permitem avaliar as imprecisões presentes em relação às predições correspondentes às diferentes janelas de tempo de predição.

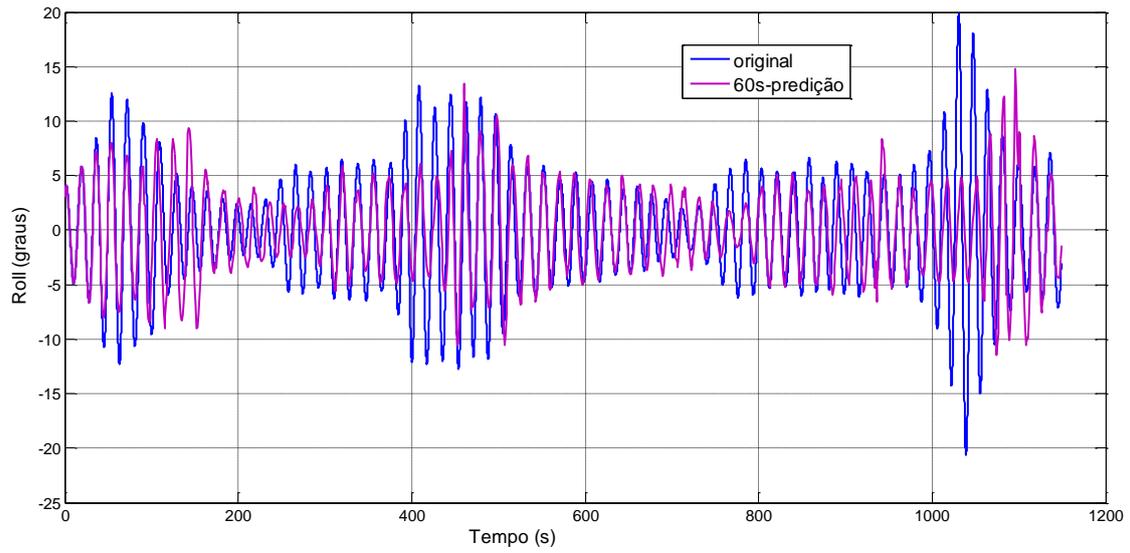


Figura 6.15: SAFEDOR: *Roll*: Série Temporal 02: Janela de Predição 60 s

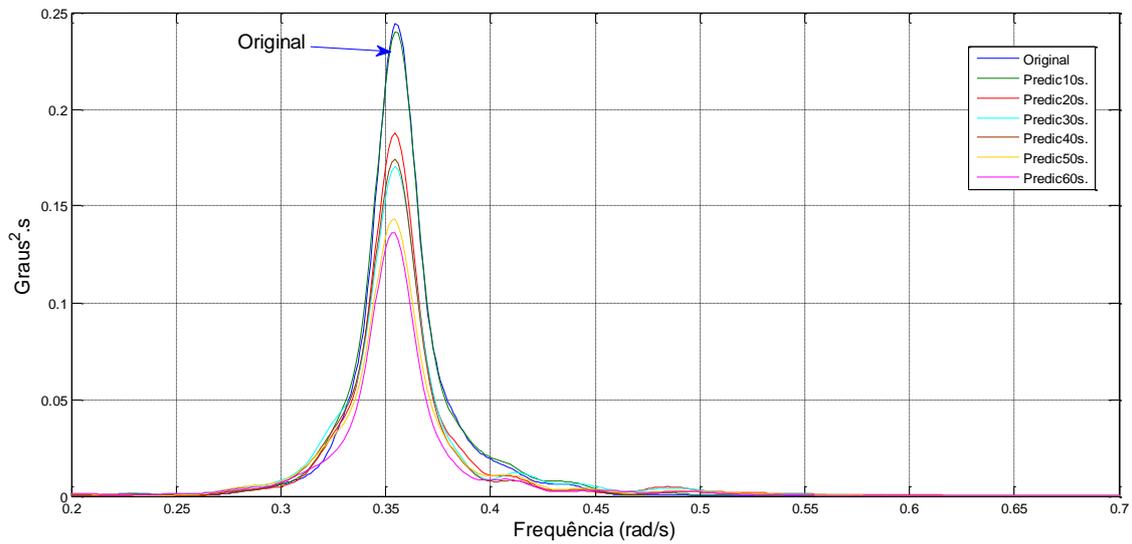


Figura 6.16: SAFEDOR: Transformada de Fourier - *Roll*: Série Temporal 02: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s

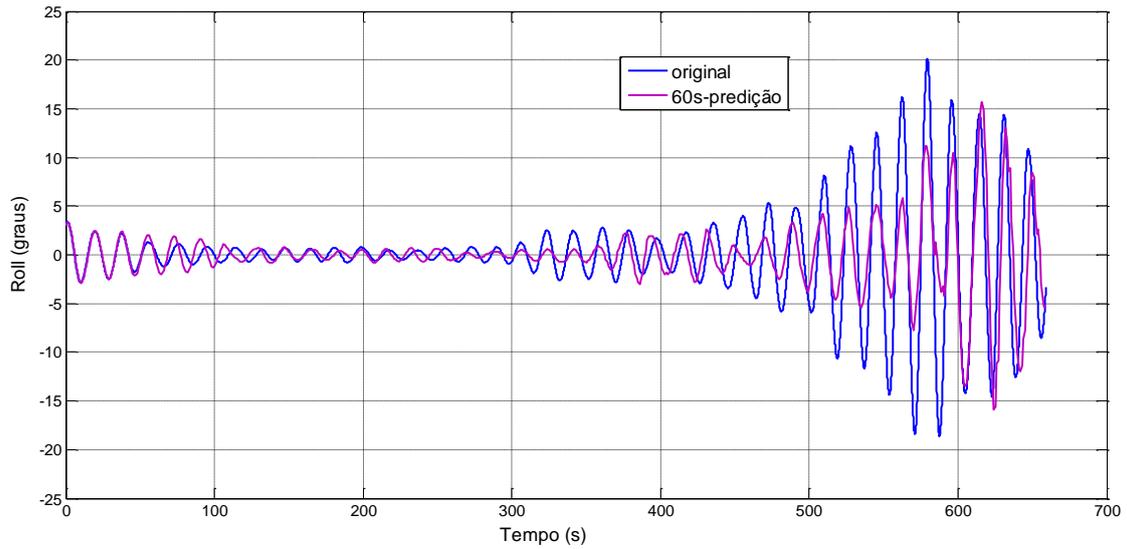


Figura 6.17: SAFEDOR: *Roll*: Série Temporal 03: Janela de Predição 60 s

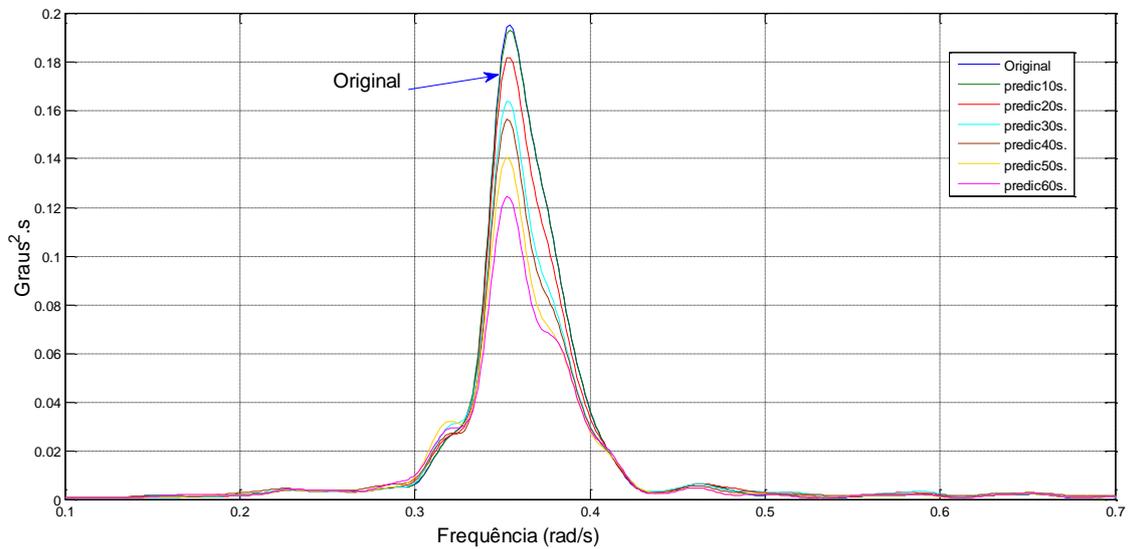


Figura 6.18: SAFEDOR: Transformada de Fourier - *Roll*: Série Temporal 03: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s

Tabela 6.3: Porcentagem do erro: predições para janela de 60 segundos

Série predita	erro (%)
Série 1	4.2954
Série 2	12.4672
Série 3	18.0939

A RNA, uma vez treinada com uma quantidade de séries temporais de *roll* (40 séries) para o espectro II ($H_s = 5.0$ m, $T_p = 10.63$ s, $\gamma = 3.3$, $\text{ksi}=180^\circ$), foi, então, aplicada nas previsões para três séries temporais diferentes às utilizadas no treinamento, considerando-se uma janela de tempo de previsão de até 60 segundos (observação: resultados para previsões correspondentes a janelas de tempo menores estão apresentados no **Anexo C**). As previsões para as séries temporais escolhidas conseguem prever com adequada precisão tanto na região de valores pequenos de *roll* (pequena amplificação de roll - ver **Figura 6.13**) quanto para faixas de valores com amplificação – ver **Figuras 6.15 e 6.17**. A **Tabela 6.3** apresenta o valor percentual dos erros, mostrando resultados considerados aceitáveis. Cabe ressaltar que as previsões feitas para este espectro II também conseguem prever o aparecimento da amplificação de *roll*, que vem a ser o principal objetivo desta tese.

Nas figuras representativas da Transformada de Fourier (**Figuras 6.14, 6.16, 6.18**) para as seis janelas de previsão. Especialmente para as janelas de previsão de 10, 20, 30 s, observa-se boa concordância com curva da Transformada de Fourier da série original. Convém lembrar que um aspecto bastante confiável desta metodologia de previsão é a possibilidade de melhorar a qualidade da previsão, investindo-se na fase de treinamento (aumentando-se o número de camadas escondidas (*deep learning*) e o número de dados da amostra).

6.3.3 Resultados para JONSWAP $H_s = 5.0$ m, $T_p = 8$ s, $\gamma = 3.3$ (incidência 180°)

Para completar o ciclo de análise, o processo de previsão testará o navio **SAFEDOR** agora com um espectro de mar **JONSWAP** com altura significativa (H_s) de 5.00 m, período de pico (T_p) de 8 s, $\gamma = 3.3$ e incidência 180° .

Novamente, da base de dados de 40 séries temporais utilizadas no treinamento da rede, escolhem-se aleatoriamente três séries temporais para fazer a predição.

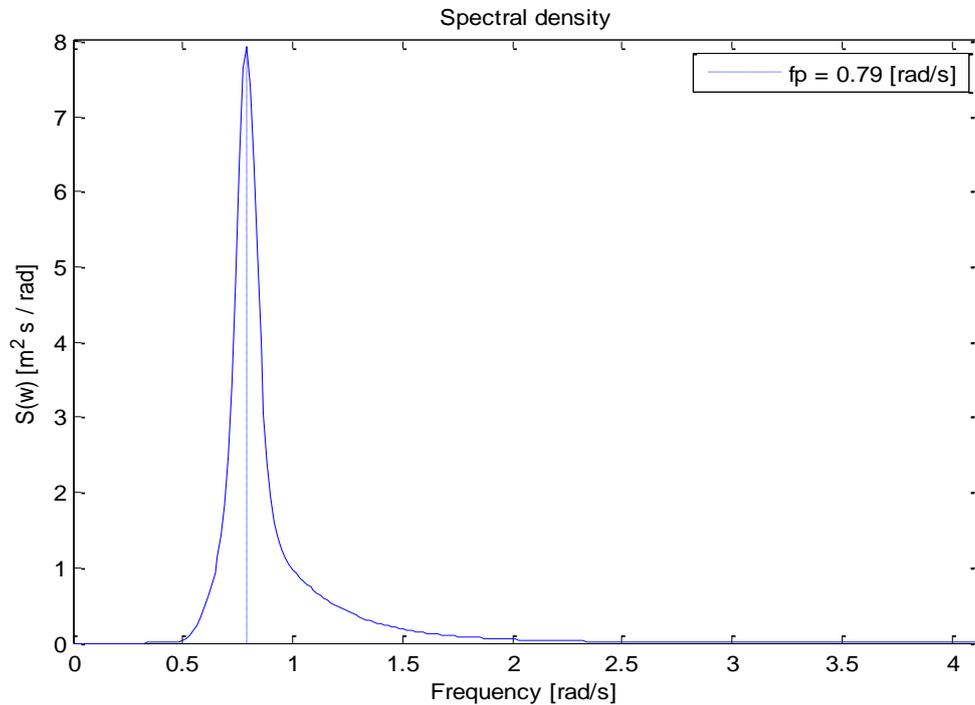


Figura 6.19: Espectro JONSWAP com $H_s=5.0$ m, $T_p=8$ s, $\gamma = 3.3$

(a) Para a primeira série com ondas bem íngremes, A predição para 60 segundos já não consegue acompanhar a série apresentando (**Figura 6.20**), tendo uma percentagem do erro considerável (**Tabela 6.4**).

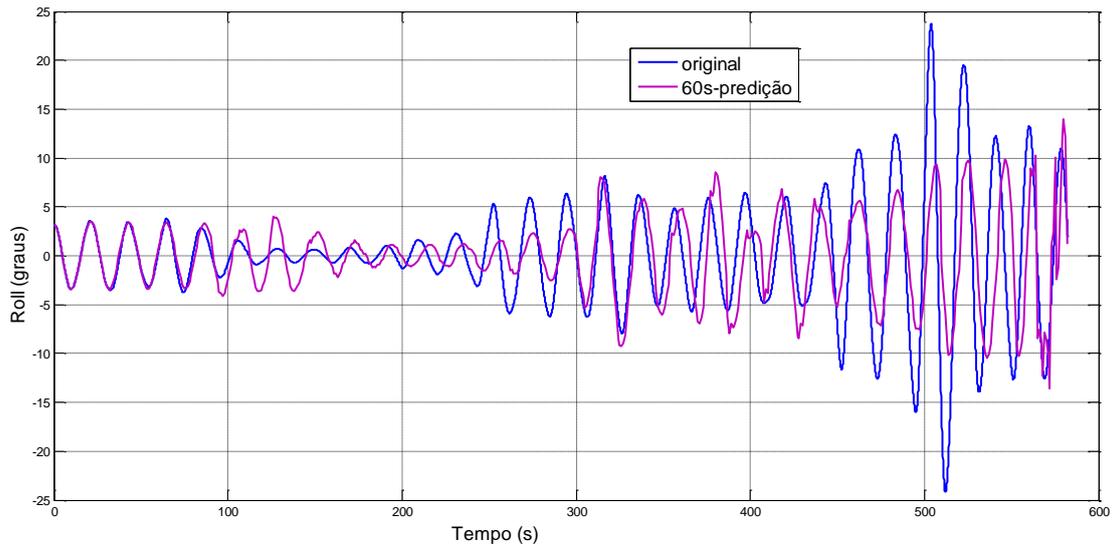


Figura 6.20: SAFEDOR: Roll: Série Temporal 01: Janela de Predição 60 s

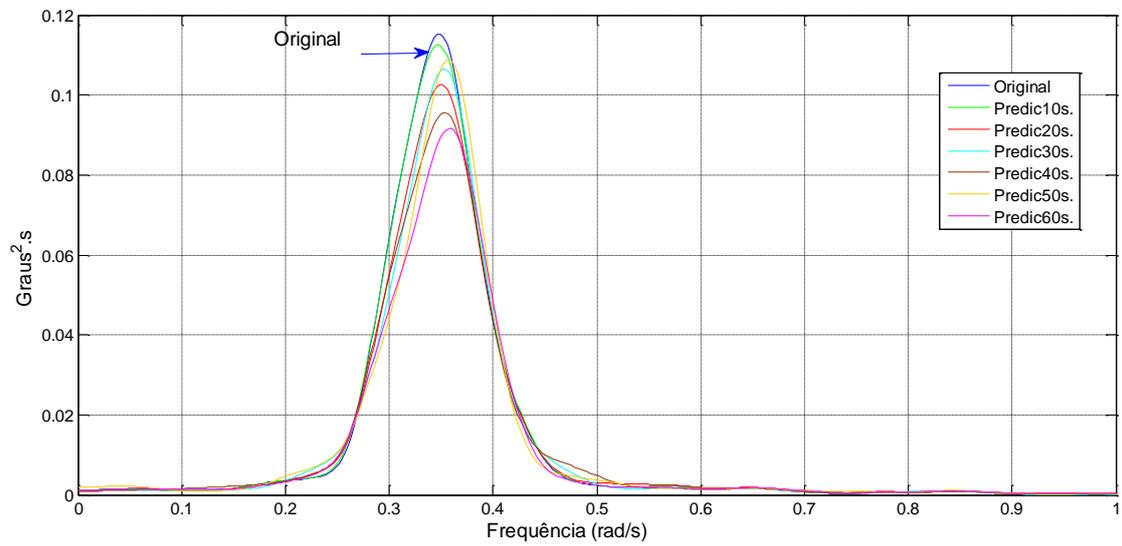


Figura 6.21: SAFEDOR: Transformada de Fourier - Roll: Série Temporal 01: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s

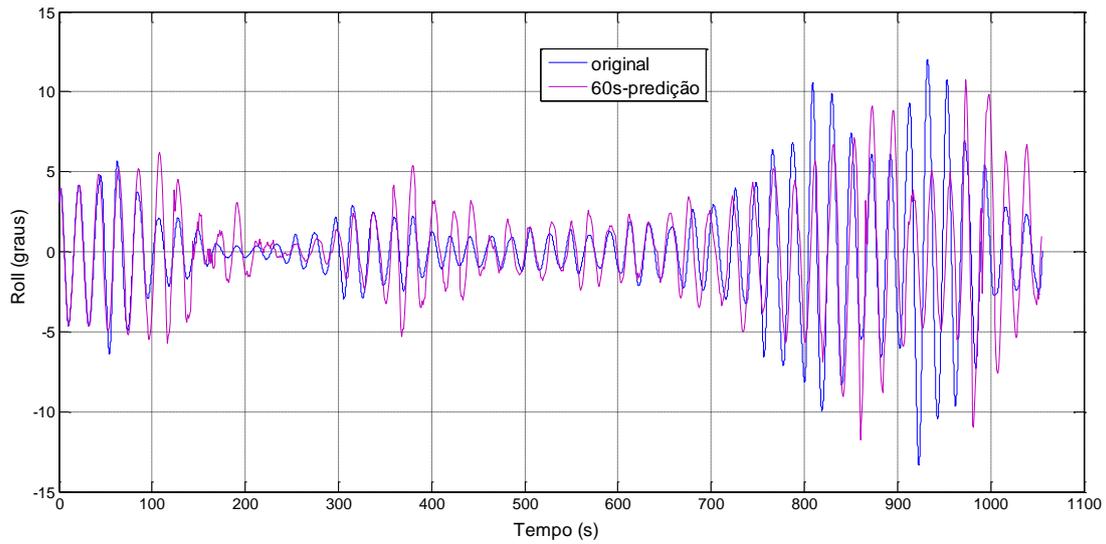


Figura 6.22: SAFEDOR: *Roll*: Série Temporal 02: Janela de Predição 60 s

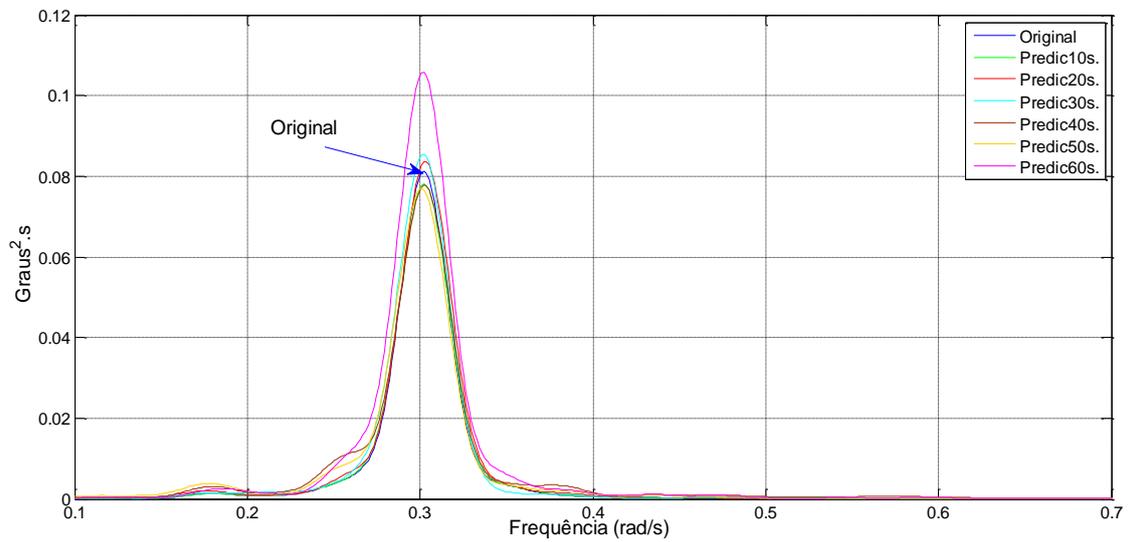


Figura 6.23: SAFEDOR: Transformada de Fourier - *Roll*: Série Temporal 02: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s

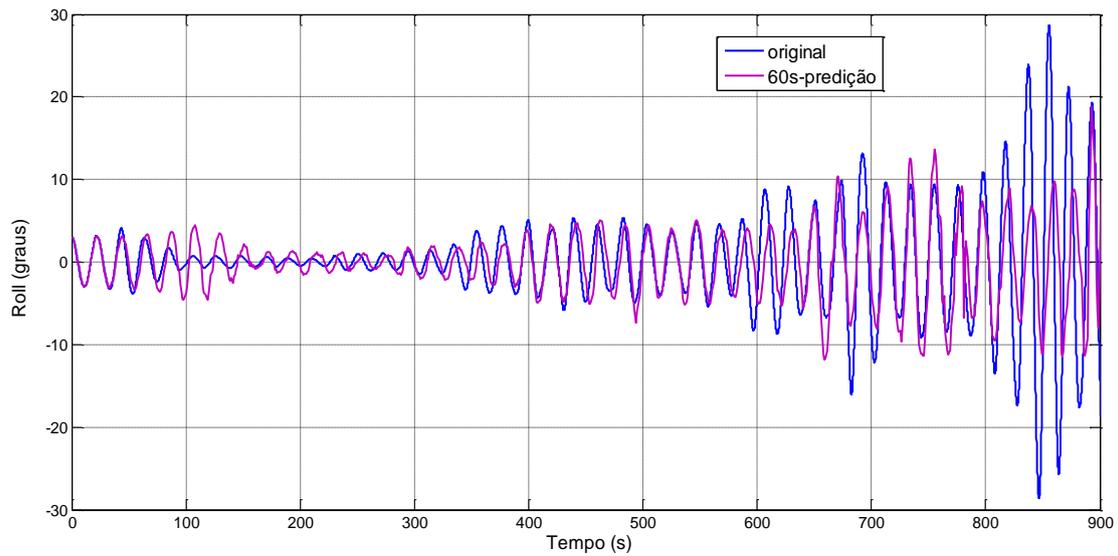


Figura 6.24: SAFEDOR: *Roll*: Série Temporal 03: Janela de Predição 60 s

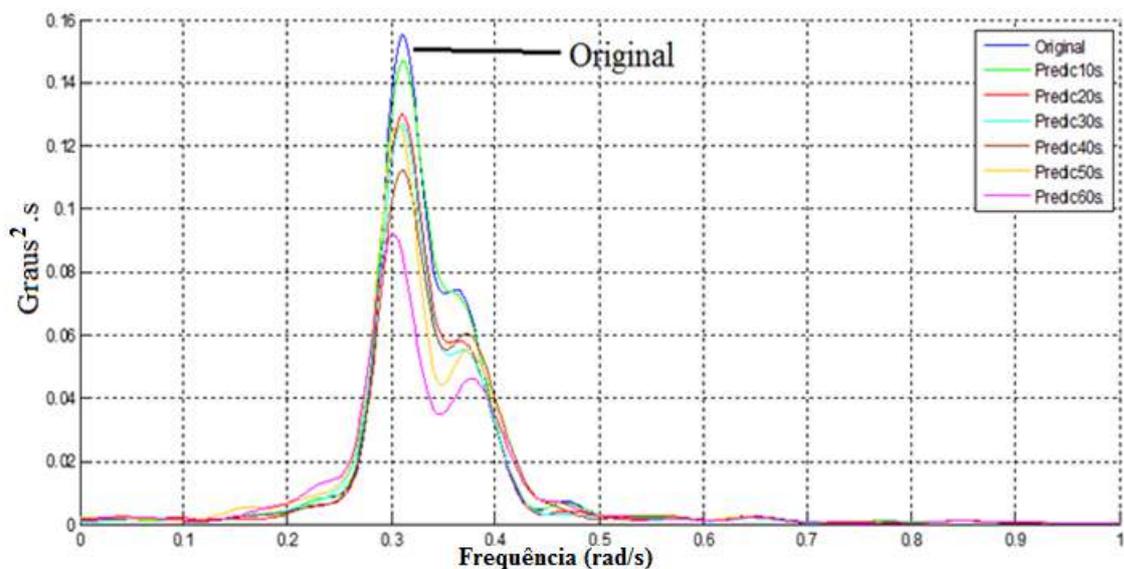


Figura 6.25: SAFEDOR: Transformada de Fourier - *Roll*: Série Temporal 03: Janelas de Tempo de Predição: 10, 20, 30, 40, 50 e 60 s

Na análise dos resultados resumidos nas **Figuras 6.21, 6.23, 6.25** através das curvas da Transformada de Fourier para as seis janelas predições consideradas, para as três séries temporais escolhidas, observa-se uma degradação da qualidade que aumenta com o tempo de predição.

Tabela 6.4: Percentagem do erro: previsões para janela de 60 segundos

Série predita	erro (%)
Série 1	22.9100
Série 2	20.4221
Série 3	24.3321

Por último, as previsões correspondentes ao Espectro III ($H_s = 5.0$ m, $T_p = 8$ s, $\gamma = 3.3$, $k_{si}=180$) apresentam séries temporais com não linearidade ainda mais fortes.

Foram realizadas previsões para três séries temporais de *roll* com janela de até 60 s, seguindo as mesmas orientações anteriores. A RNA conseguiu prever tanto o aparecimento, quanto o desaparecimento da amplificação do movimento de *roll*.

Neste caso, como seria de se esperar, por conta do seu comportamento intensamente não linear, os resultados apresentaram menor precisão (**Tabela 6.4**) em comparação com os espectros anteriores (ver **Figura 6.20, 6.22, 6.24**).

As figuras representativas da Transformada de Fourier (**Figura 6.21, 6.23, 6.25**) repetem a tendência observadas nas análises precedentes apresentando aproximações próximas à Transformada de Fourier da série original.

A análise do conjunto dos resultados apresentados indica que as previsões para os três espectros de onda fornecem adequada previsão da ocorrência da amplificação da resposta de *roll*, em termos práticos, a informação mais importante para o sistema de alerta. Dessa forma, a metodologia apresenta nível adequado de confiabilidade e antecipação necessária para a tomada de decisões na operação de sistema oceânica em mar real.

CAPÍTULO 7

7. CONCLUSÕES E RECOMENDAÇÕES

7.1 Generalidades

Há tempos observam-se embarcações excitadas por ondas em mares de proa, apresentando significativas amplitudes do seu movimento de *roll*. Ou seja, mesmo na ausência da excitação direta das ondas de través, por conta de um efeito ressonante de ordem superior, o movimento de *roll* da embarcação pode se manifestar, algumas vezes, de maneira bastante intensa.

Hoje em dia esse fenômeno, foi identificado como ressonância paramétrica de *roll* em mares longitudinais e passou a ser considerado um problema real para alguns tipos de navios e já conta com um bom nível de compreensão. Sabe-se ainda mais que a eventual ocorrência desse tipo de fenômeno pode levar a consequências catastróficas, incluindo

não só substanciais prejuízos econômicos, mas também a possibilidade de perda de vidas humanas. Nos últimos anos, tem sido observada uma clara tendência para que navios porta-contentores modernos desenvolvam fortes amplificações, gerando dificuldades para a sua operação e a perda de grande número de containers. Em decorrência dessas sucessivas ocorrências, a comunidade técnica marítima indicou a necessidade de se desenvolver sistemas que possam detectar no curto prazo o aparecimento do fenômeno de *roll* paramétrico, antes dele se desenvolver em sua plenitude.

Esse foi, exatamente, o cenário que motivou o planejamento desta pesquisa: investigar a viabilidade do emprego das **RNAs**, com o treinamento adequado, alcançar uma base de previsão a bordo que seja suficientemente rápida e confiável, capaz de antecipar o surgimento do *roll* paramétrico, com intervalo de tempo longo o suficiente para que se possam adotar medidas corretivas e/ou mitigadoras.

Os resultados discutidos nesta tese demonstraram que as RNAs podem ser adotadas como ferramentas adequadas para auxiliar os especialistas nessa tomada de decisões.

Nesse mesmo contexto, as **RNAs** surgem como uma alternativa promissora para realizar a previsão envolvendo outras séries temporais de interesse, oferecendo eficiente alternativa para aplicações reais, em especial para sistemas inteligentes a bordo de outros sistemas oceânicos (exemplos: plataformas utilizadas na indústria de óleo e gás *offshore*, conversores de energia oceânica, fazendas marinhas etc.).

7.2 Conclusões Específicas e Recomendações Gerais

O objetivo principal deste trabalho, é a previsão do comportamento de navios e sistemas oceânicos em mar real, principalmente a previsão da amplificação de roll, foi amplamente discutido e os resultados confirmaram a eficiência uso das RNAs nessas aplicações. Em especial, o estudo da previsão de ocorrência ressonância paramétrica do navio portacorrentor SAFEDOR demonstrou a possibilidade real de se projetar um sistema de detecção de curto prazo baseado em RNAs, no âmbito de um intervalo de tempo suficiente para alertar a tripulação sobre o aparecimento da ressonância paramétrica e, também, decidir por medidas corretivas como a mudança de rumo.

Conforme mostrado nesta investigação, o sistema proposto mostrou-se capaz de conseguir predições confiáveis no caso da ressonância paramétrica de *roll*, com níveis de precisão adequados do comportamento de diferentes sistemas oceânicos em presença de mar real. Isso significa, em linhas gerais, que o sistema baseado em RNAs tem condições de acompanhar, antecipando previsões, após a necessária etapa de treinamento prévio, uma série temporal de interesse que esteja sendo monitorada a bordo. Pelo menos, os seguintes requisitos são indispensáveis para o êxito dessa empreitada:

- a) previsões rápidas, ou seja, tempo de processamento compatível;
- b) resultados suficientemente fidedignos, ou seja, precisos e confiáveis.

A fidedignidade deve refletir-se em pelo menos três aspectos: capacidade de acompanhar possíveis amplificações intensas e sucessivas, como aquelas que ocorrem no processo da dinâmica do *roll* paramétrico do navio; não desenvolver predições erradas que produzam

falsos alarmes; ter capacidade de acompanhar as rápidas reduções sucessivas que podem eventualmente acontecer após as séries de ampliações.

Os resultados principais deste trabalho foram baseados no estudo do navio porta-contentor SAFEDOR, para o qual havia dados experimentais disponíveis, inclusive, em mar irregular. No entanto, um enfoque preliminar buscou garantir a adequação do uso das RNAs para a realização de previsões de séries temporais associadas a registro de mar real no caso linear. Para isso, além da própria elevação de onda oceânica típica, foram analisadas aplicações envolvendo a elevação vertical e a força de excitação atuando num sistema de conversão de energia de ondas (**WEC- *Wave Energy Converter***).

7.2.1 RNAs para a Elevação da Onda de Mar Real

Naturalmente, um sistema de prevenção instalado a bordo deve ser planejado e testado em condições de mar real, ou em outras palavras, mar irregular. No entanto, antes de abordar o problema da previsão das respostas em mar irregular, considerou-se necessário investigar a capacidade de treinamento e previsão da RNA em relação ao registro da própria onda típica do mar real. Este problema, em si, já apresenta complexidades associadas a não linearidades típicas do processo excitado por onda real. Em especial, o registro da elevação da onda apresenta ruídos que incorporam dificuldades à sua adequada previsão:

- Séries temporais geradas a partir de espectros de mar (tipo **JONSWAP**), correspondentes a diferentes alturas significativas (H_s) foram utilizados para treinamento e previsão da elevação da onda em mar irregular. Os resultados obtidos foram satisfatórios a partir do critério de erro adotado nas suas análises;

- A metodologia de predição das séries temporais da elevação de onda, aplicadas para diferentes intervalos de tempo de predição, demonstraram a efetividade da RNA do tipo *feedforward* com múltiplas camadas e algoritmo de retropropagação do erro com o método de otimização de Levenberg-Marquardt para realizar qualificadas predições de registro de ondas de mar real. A RNA, treinada com séries temporais geradas para diferentes valores de alturas significativas ($H_s = 1, 2$ e 4 m) e período pico $T_p = 10$ s, foi aplicada para intervalos de previsão de 10 e 20s.
- Os resultados indicaram uma qualificada precisão, mostrando a sua adequação da metodologia para a predição da elevação da onda real. Essa etapa foi considerada a evidência inicial para o uso da RNA na predição do comportamento de navio em mar real.
- Os ruídos das séries temporais acabaram por impor a uso de filtro do tipo passa-banda (**bpfilt**) para produzir melhora considerável na predição da elevação da onda. O resumo dos valores da percentagem do erro em comparação da predição da mesma série temporal sem filtragem está apresentado na **Tabela 4.2**.

7.2.2 RNAs para WEC (*Wave Energy Converter*)

Para a análise preliminar da previsão de respostas dos sistemas oceânicos excitados pelo mar real, aplicou-se a mesma metodologia no estudo da predição do comportamento de um sistema WEC. Trata-se de um caso reconhecido como linear. Foram realizadas

predições da elevação vertical da boia e da força da excitação da onda (janela de tempo de 30s):

- A RNA do tipo *feedforward* com múltiplas camadas e algoritmo de retropropagação do erro com o método de otimização de Levenberg-Marquardt foi adotada aqui também. A RNA foi treinada com séries temporais calculados para um dado WEC, correspondentes ao espectro de mar (tipo **JONSWAP**), para altura significativa de 2 m, e dois diferentes períodos de pico $T_p = 5.5s$ e $6s$ (janela de predição de 30s).
- As predições, tanto do deslocamento vertical quanto da força de excitação atuante na boia apresentaram excelentes resultados, como confirmam os baixos valores de percentagem do erro apresentados nas **Tabelas 4.5 e 4.6**

7.2.3 RNAs para a Ressonância Paramétrica

O foco principal do trabalho investiu na aplicação da metodologia das RNAs na predição do comportamento do navio em mar real, com níveis de confiabilidade, precisão e janela de tempo suficientes para servir de base de sistema de alerta a bordo. Uma das situações envolvendo maiores riscos de prejuízos e perdas decorre do aparecimento do fenômeno da ressonância paramétrica (*roll* paramétrico). Os resultados discutidos na pertinente análise demonstraram a viabilidade técnico-operacional das RNAs, tanto em termos dos tempos de processamento envolvidos, quanto na confiabilidade e precisão dos seus resultados, mesmo quando aplicados a janelas de tempo de predição alongadas (no caso até 60s):

- Novamente, adotou-se a RNA do tipo *feedforward* com múltiplas camadas, algoritmo de retropropagação do erro e método de otimização de Levenberg-Marquardt. A rede neural artificial foi treinada com as séries temporais do modelo de navio porta contendor SAFEDOR em mar real, correspondentes a três espectros de mar diferentes e intervalos de aprendizado de 10, 20, 30 40, 50, 60s;
- Os resultados obtidos para os três espectros de onda considerados forneceram adequadas previsões, mesmo considerando as pequenas diferenças encontradas na previsão dos picos das amplitudes de *roll*;
- Embora, as previsões realizadas para o espectro mais energético não tenham sido tão precisas quanto aquelas obtidas para dois outros espectros menos energéticos, ainda assim foi possível observar o que pode ser considerado mais importante: a previsão do aparecimento e desaparecimento de *roll* paramétrico;
- O aspecto mais importante da previsão realizada para o navio porta contendor **SAFEDOR** em mar real é, sem dúvida, a possibilidade do reconhecimento antecipado do aparecimento e desaparecimento dos movimentos exagerados associados ao *roll* paramétrico. Este seria o aspecto mais relevante para garantir o efetivo controle das instabilidades de navios em mar real. Dessa forma, pode-se considerar atendida a principal motivação desta tese, identificando-se metodologia adequada a um sistema de monitoramento *online* a ser instalado a bordo. Em resumo, obteve-se uma ferramenta rápida, suficientemente precisa e confiável para ser utilizada na análise do risco da operação do navio;
- A projeção do trabalho é para sua aplicação em navios em alto mar (sistema *online*) pelo qual se quer que a rede, responda em poucos segundos uma vez

treinado. A rede neural apresentada tem poucos segundos (**7 segundos** para um processador Intel i7) de resposta para a rede neural já treinada (predição). Considerando um tempo muito aceitável para a predição da ressonância paramétrica de roll, para seu controle preditivo-corretivo;

- Por fim, as análises permitem considerar a possibilidade de generalização da metodologia proposta, embora tenha sido discutida para o caso específico do navio porta-contentor SAFEDOR;

7.3 Trabalhos Futuros

O trabalho apresentado focalizou, principalmente, a concepção e desenvolvimento de metodologia de predição do *roll* paramétrico do navio, visando a instalação de um sistema de alerta a bordo, para orientar os tripulantes, na detecção do aparecimento de ressonância e impedir o seu desenvolvimento. No entanto, os potenciais aplicações dessa mesma metodologia cobrem um amplo campo de interesses práticos da engenharia naval.

Uma importante característica presente na metodologia das RNAs é a sua capacidade de continuado e permanente processo de treinamento, visando aperfeiçoamento das suas predições. Nesse caso, algumas possíveis alternativas de investigações suplementares devem incluir:

- Ampliar o processo de treinamento para ampliar a variação dos dados de entrada;
- Investigar outras arquiteturas de RNAs capazes de oferecer soluções para janelas de tempo de predição maiores do que 60s. Quanto maior a janela de

tempo de predição, melhores condições para uma eventual tomada e implementação de decisões em navios com sistemas inteligentes *online*. Embora os resultados obtidos já possam ser considerados adequados e, portanto, promissores, a possibilidade de previsões mais alongadas seriam sempre desejáveis;

- O estudo de outras estruturas de RNAs, juntamente, com a análise de outros parâmetros, tais como a incorporação da influência de outros modos de movimentos do navio (exemplos: *heave e pitch*) devem, em princípio, produzir alguma melhora na detecção precoce do fenômeno do *roll* paramétrico.
- A implementação do treinamento e predição das séries temporais considerando a envolvente. Em tese, deve se obter uma melhora no acompanhamento da predição da amplificação do *roll* paramétrico, como também diminuir o tempo de treinamento como o tempo da resposta na fase de predição.
- Embora os dados das séries temporais do movimento de *roll* do navio obtidas numericamente possam ser considerados uma boa base inicial para o desenvolvimento de um sistema de prevenção a bordo, seria desejável, no futuro, fazer-se o treinamento das RNAs com dados experimentais, ou mesmo com dados obtidos a partir da medição em tempo real do movimento de *roll*.
- A efetiva implementação da metodologia proposta em um sistema de bordo, deverá requerer a realização de testes em escala real, como etapa final do desenvolvimento da estratégia de predição, portanto, a aquisição de dados e o processamento dos algoritmos baseados em RNAs em ambiente em tempo real deve ser uma alternativa importante de trabalho futuro.

REFERÊNCIAS BIBLIOGRÁFICAS

ABS, 2004, *Guide for the Assessment of Parametric Roll Resonance in the Design of Container Carriers*. Houston, American Bureau of Shipping.

AHN, Y., KIM, Y., KIM, S., 2019, "Database of model-scale sloshing experiment for LNG tank and application of artificial neural network for sloshing load prediction", *Marine Structures*, Volume 66, Pages 66-82.

ALARCIN, F., GULEZ, K., 2007, "Rudder roll stabilization for fishing vessel using neural network approach.", *Ocean Engineering*, 34(13): 1811-1817.

ARNOLD, L., CHUESHO, I., OCHS, G, 2003, *Stability and Capsizing of Ships in Random Sea-a Survey*, University of Bremen Report Nr. 464, June.

BARBOSA, I. M., 2010, *Estudo das Dispersões Metrológicas em Redes Neurais Artificiais do Tipo Multilayer Perceptron Através da Aplicação em Curvas de Calibração*. Tese D.Sc., Programa Engenharia Elétrica, USP, São Paulo, SP, Brasil.

BELENKY, V. L., WEEMS, K. M., LIN, W., PAULLING, J. R., 2003, "Probabilistic Analysis of Roll Parametric Resonance in Head Seas". In: *Proceedings of the 8th International Conference on Stability of Ships and Ocean Vehicles (STAB'2003)*, Madrid, Spain, pp. 325-340, Sep.

BELENKY, V., YU, H., WEEMS, K., 2006, "Numerical Procedures and Practical Experience of Assessment of Parametric Roll of Container Carriers". In: *Proceedings of the 9th International Conference on Stability of Ships and Ocean Vehicles (STAB'2006)*, vol. 1, Rio de Janeiro, Brazil, pp. 119-130, Sep.

BELENKY, V., WEEMS, K., SPYRO, K. 2015a, "Toward a split-time method for estimation of probability of surf-riding in irregular seas" In: *Proceedings of the 12th International Conference on Stability of Ships and Ocean Vehicles (STAB2015)*. Glasgow, UK.

BELLEÇ, J.-R., NEVES, M. A. S., RODRÍGUEZ, C. A., 2011, "An Investigation on Parametric Rolling Prediction Using Neural Networks", *International Maritime Association of the Mediterranean (IMAM 2011)*, Genoa, Itália.

BISHOP, C. M., 2006. *Pattern Recognition and Machine Learning*, first edition, New York, USA, Springer.

BLOCKI, W., 1980, "Ship Safety in Connection with Parametric Resonance of the Roll", *International Shipbuilding Progress*, v. 27, n. 306, pp. 36-53.

BOX, G. E.; JENKINS, G. M., 1970, *Time Series Analysis: Forecasting and Control*, San Francisco, CA, Holden- Day.

BULIAN, G., and FRANCESCUTTO, A., 2003, "On the Nonlinear Modeling of Parametric Rolling in Regular and Irregular Waves" In: *Proceedings of the 8th*

International Conference on Stability of Ships and Ocean Vehicles (STAB '2003), Madrid, Spain, pp. 507-519, Sep.

BULIAN, G. et al., 2006, "Theoretical, numerical and experimental study on the problem of ergodicity and "practical ergodicity" with an application to parametric roll in longitudinal long crested irregular sea", *Ocean Engineering*, vol. 33, pp. 1007-1043.

CALOBA, L. P., 2002, *Introdução ao Uso de Redes Neurais na Modelagem de Sistemas Dinâmicos e Séries Temporais. Livro de Minicursos do XIV Congresso Brasileiro de Automáta*, Natal, Brasil.

CARDO, A., FRANCESCUTTO, A., NABEROJ, R., 1984, "Nonlinear Rolling Response in a Regular Sea". *Int. Shipbuilding Progress*, Vol. 31, p.204 (Aug.).

CELIS, M. A., 2008, *Análise da Influência da Memória Fluida em Balanço Paramétrico*. Dissertação de Mestrado, COPPE - Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

CYBENKO, G., 1988, *Continuous valued neural networks with two hidden layers are sufficient*, Technical Report, Department of Computer Science, Tufts University.

ELMAN, J. L., 1990, "Finding Structure in time". *Cognitive science*, vol. 14, pp. 179-211.

ESTEFEN S.F., COSTA P.R., FERREIRA R, LOURENCO M.I., MARTINS M, CASTELO X, et al., 2014, *Relatório -7 do projeto de implantação de conversor nearshore para geração de eletricidade pelas ondas do mar - PENO-12754.*

FERREIRA, T. A. E. 2006, *Uma Nova Metodologia Híbrida Inteligente Para a Previsão de Séries Temporais*, TESE D. Sc., UFPE, Recife, Brasil.

FELIPPETTO DE CASTRO, M. C. 2001, *Predição Não-Linear de Séries Temporais Usando redes neurais RBF por decomposição e componentes Principais*, Tese D.Sc., FEEC-UNICAMP, Campinas, SP, Brasil.

FERNANDES de MATOS, N. A., 2005, *Predição de Séries Temporais para Análise Dinâmica de Estruturas Offshore*, Dissertação M. Sc., COPPE-Eng. Civil, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

FRANCE, W. N., LEVADOU, M., TREAKLE, T. W., PAULLING, J. R., MICHEL, R. K., MOORE, C., 2003, "An Investigation of Head-Sea Parametric Rolling and its Influence on Container Lashing Systems", *Marine Technology*, vol. 40, no. 1 (Jan), pp. 1-19.

FROUDE, W., 1863, "Remarks on Mr. Scott Russell's Paper on Rolling", *Trans. Inst. Naval Architects*, n. 4, pp. 232-275.

FUKUSHIMA, K., 1980, "Neocognitron: A Self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position", *Biological Cybernetics*, vol. 36, 196-202.

KANTZ, H. and SCHREIBER, T., 2003, *Nonlinear Time Series Analysis*, , second edition, New York, USA, Cambridge University Press.

KENNEDY, J. M., FORD, J. J., PEREZ, T., VALENTINI, F., 2018, "Detection of Parametric Roll Resonance using Bayesian Discrete-Frequency Model Selection", *IFAC-PapersOnLine*, Volume 51, Issue 29.

GALEAZZI, R., BLANKE, M., and POULSEN, N. K., 2013, "Early Detection of Parametric Roll Resonance on Container Ships," *IEEE Transactions on Control Systems Technology*. Vol. 21, No. 2, pp. 489-503.

HALS, J., BJARTE-LARSSON, T., FALNES, J., 2002, "Optimum Reactive Control and Control by Latching of a Wave-Absorbing Semisubmerged Heaving Sphere", *OMAE2002*, June 23-28, Norway.

HAN, M., XI, J., XU, S., and YIN, F., 2004, "Prediction of chaotic time series based on the recurrent predictor neural network," in *IEEE Transactions on Signal Processing*, vol. 52, no. 12, pp. 3409-3416, Dec.

HAMAMOTO, M., NOMOTO, K., 1982, "Transverse Stability of Ships in a Following Sea", In: *Proceedings of the 2nd International Conference on Stability of Ships and Ocean Vehicles*. Tokyo, Japan, pp. 137- 146.

HAYKIN, S., 2008. *Redes Neurais, Princípios e prática*. 2da Edição, São Paulo, Brasil., Bookman.

HAYKIN, S., 2009, *Neural Networks and Learning Machines*, Third Edition, Ontario, Canada, Pearson.

HIMENO, Y., 1981, *Prediction of Ship Roll Damping - State of Art*, Department of Naval Architect and Marine Engineering. The University of Michigan. Report N. 239, Sept.

HEBB, D. O., 1949, *Organization of Behavior: A Neuropsychological Theory*, New York, Wiley.

HONG, S. Y., YU, H. C., KIM, S., SUNG, H. G., 2009, "Investigation of Parametric Roll of a Container Ship in Irregular Seas by Numerical Simulation". In: *Proceedings of the 10th International Conference on Stability of Ships and Ocean Vehicles (STAB'2009)*, St. Petersburg, Russia, pp. 549-558, Jun.

HOPFIELD, J. J., 1982, "Neural networks and physical systems with emergent collective computational abilities", In *Proceedings of the National Academy of Sciences*, vol. 79, pp. 2554-2558.

HSIEH SHANG-ROU, W. TROESCH ARMIN AND W. SHAW STEVEN, 1994, A nonlinear probabilistic method for predicting vessel capsizing in random beam seas. 446, *Proc. Royal. Society. Lond. A*.

HUA, J., PALMQUIST, M., LINDGREN, G., 2006, "An Analysis of the parametric Roll Events Measured Onboard the PCTC AIDA". In: *Proceedings of the 9th International Conference on Stability of Ships and Ocean Vehicles (STAB2006)*, vol.1, pp. 109-118, Rio de Janeiro, Brazil, Sep.

IMO, 1993, *IMO - International Maritime Organization - Resolución A.749 (18)*.

+ITTC, 2006, *ITTC – Recommended Procedures and Guidelines: Testing and Extrapolation Methods Loads and Responses, Stability – Predicting the Occurrence and Magnitude of Parametric Rolling*, 7.5-02-07-4.3.

FALCÃO, A. 2008. Phase control through load control of oscillating-body wave energy converters with hydraulic PTO system. *Ocean Engineering*. 35:58-66.

FALCÃO A., 2010. Wave energy utilization: A review of the technologies. *Renewable and Sustainable Energy Reviews*. 14. 899-918.

FALNES, J., 1997. *Principle for capture of energy from ocean waves, phase control and optimum oscillation*. Department of Physics, NTNU, N-7034 Trondheim, Norway.

FALNES, J., 2001. Optimum Control of Oscillation of Wave-Energy Converters, International Society of Offshore and Polar Engineers.

JONES, E. B., ROSKILLY, A., WEBSTER, B., and BIRMINGHAM, R. W., 2006, "Adaptive roll stabilization of fishing vessels", *Proceedings of the Institution of Mechanical Engineers, Part M: Journal of Engineering for the Maritime Environment*, 220(1): 13-27.

KERWIN, J. E., 1955, "Notes on Rolling in Longitudinal Waves", *International Shipbuilding Progress*, v. 2, n. 16, pp. 597-614.

KOHOVEN, T., 1972, "Correlation Matrix Memories", *IEEE transactions on Computers*, vol. c-21, No. 4. April.

KUO, C., WELAYA, Y., 1981, "A review of intact ship stability criteria", *Ocean Engineering*. Volume 8, Issue 1, Pages 65-85.

LI, H., GUO, C., and JIN, H., 2005. "Design of Adaptive Inverse Mode Wavelet Neural Network Controller of Fin Stabilizer", *IEEE Transactions on Signal Processing*, Vol. 3, pp. 1745-1748.

LORCA, O. M., 2001, *Ressonância Paramétrica de Navios – Influencia da Velocidade*. Dissertação M.Sc., COPPE – Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

McCULLOCH, W. S., and W. PITTS, 1943. "A logical calculus of the ideas immanent in nervous activity" *Bulletin of Mathematical Biophysics*, vol. 5, pp. 115-133.

MERINO, J. A. M., 2007, *Aplicação da Teoria do Tanque de Estabilização Passivo Tipo U na Diminuição do Jogo Paramétrico*. Dissertação de Mestrado, COPPE - Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

MÍGUEZ, M., PENA, F, CASAS, V., e NEVES, M., 2010, "An Artificial Neural Network Approach for Parametric Rolling Prediction.", *In PRADS Conference*, September, Rio de Janeiro, Brazil.

MÍGUEZ, M. G., LÓPEZ, F. P., DÍAZ, V. C., GALEZZI, R., BLANKE, M., 2011. "Prediction of Parametric Roll Resonance by Multilayer Perceptron Neural Network". *21st International Offshore (Ocean) and Polar Engineering Conference (ISOPE)*, Maui, USA, International Society of Offshore (Ocean) and Polar Engineers.

MÍGUEZ, M. G., 2012, *An Study of Ship Parametric Roll Resonance for the Evaluation of Preventive Strategies*. Thesis PhD., Departamento de Ingeniería Naval y Oceánica, Universidade da Coruña.

MOREIRA, L., GUEDES SOARES, C, 2003, "Dynamic model of manoeuvrability using recursive neural networks", *Ocean Engineering*, v. 30, pp.1669-1697.

NEVES, M. A. S., PÉREZ, N. A., VALERIO, L., 1999, "Stability of Small Fishing Vessels in Longitudinal Waves", *Ocean Engineering*, v. 26, n. 12 (Dec), pp. 1389-1419.

NEVES, M. A. S., PÉREZ, N., LORCA, O., 2003, "Analysis of Roll Motion and Stability of a Fishing Vessel in Head Seas", *Ocean Engineering*, v. 30, (Apr), pp. 921-935.

NEVES, M. A. S, RODRÍGUEZ, C. A., 2006a, "An Investigation on Roll Parametric Resonance in Regular Waves". *Proceedings of the 9th International Conference on Stability of Ships and Ocean Vehicles*, pp. 99-108, Rio de Janeiro, Brazil, 25-29 Sep.

NEVES, M. A. S., RODRÍGUEZ C. A., 2006b, "On Unstable Ship Motions Resulting From Strong Non-Linear Coupling", *Ocean Engineering*, v. 33, pp.1853-1883.

NEVES, M. A. S., RODRÍGUEZ, C. A., 2007, "Influence of Non-Linearities on the Limits of Stability of Ships Rolling in Head Seas". *Ocean Engineering*, vol. 34, no. 11 (Aug), pp. 1618-1630.

NEVES, M. A. S.; VIVANCO, J. E. M. ; RODRÍGUEZ, C. A., 2011, "Nonlinear Dynamics on Parametric Rolling of Ships in Head Seas". In: Neves, M.A.S.; Belenky, V.; de Kat, J.O.; Spyrou, K.; Umeda, N. (Org.). *Contemporary Ideas on Ship Stability and Capsizing in Waves*. Amsterdam: Springer International, 2011, v. 1, p. 449-461.

NEVES, 2016, "Dynamic stability of ships in regular and irregular seas - An overview", *Ocean Engineering*, vol. 120, pp. 362-370.

NUNES DA SILVA, I. et al., 2010, *Redes Neurais Artificiais*, Primeira Edição. São Paulo, Basil, Artliber.

PARKES, A. I., SOBEY, A. J., HUDSON, D. A., 2018, "Physics-based shaft power prediction for large merchant ships using neural networks", *Ocean Engineering*, 166: 92–104.

PAULLING, J. R., ROSENBERG, R. M, 1959, "On Unstable Ship Motions Resulting From Non-Linear Coupling", *Journal of Ship Research*, v. 3, n. 1 (Jun.), pp. 36-46.

PAULLING, J. R., 1960, "Transverse Stability of Tuna Clippers". *Fishing Boats of the World*. Vol. 2. Fishing News Limited, London. pp. 25-39.

PAULLING, J. R., 1961, "The Transverse Stability of a Ship in a Longitudinal Seaway". *Journal of Ship Research*, v. 4, n. 4 (Mar.), pp. 37-49.

PAULLING, J. R., 1972, "Capsizing Experiments with a Models of a Fast Cargo Liner in San Francisco Bay". University of California, Berkeley.

PERCIVAL, D. B., and WALDEN, A. T., 1998, *Spectral Analysis for Physical Applications - Multitaper and Conventional Univariate Techniques*, New York, Cambridge University Press.

PÉREZ, N. A., 1985, *Desenvolvimento de Algumas Técnicas Experimentais em Ondas Regulares*. Dissertação de M.Sc., COPPE - Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

PERNAMBUCO, T. A. M., 1990, *Estabilidade de Navios em Ondas Obliquas*. Dissertação de M.Sc., COPPE/ COPPE - Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

PI, H., and PETERSON, C., 1994, "Finding the Embedding Dimension and Variable Dependencies in Time Series", *Neural Computation*, v. 6, pp. 509-520.

REED, R. D., and RUMELHART, R. J., 1999. *Neural Smoothing: Supervised Learning in Feedforward Artificial Neural Networks*, Cambridge, MA, USA, The MIT Press.

RODRÍGUEZ, C. A., 2004, *Estabilidade Dinâmica do Navio: Um Modelo Não- Linear de Terceira Ordem*. Dissertação de M.Sc., COPPE - Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

RODRÍGUEZ, C. A., 2010, *Sobre a Dinâmica Não Linear do Balanço Paramétrico*. Tese D.Sc., COPPE - Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

RODRÍGUEZ, C. A., NEVES, M. A. S., POLO, J. C. F., 2016, "A time-efficient approach for nonlinear hydrostatic and Froude-Krylov forces for parametric roll assessment in irregular seas", *Ocean Engineering*, Volume 120, Pages 246-255.

GROSSBERG, S., 1972, "Neural expectation: Cerebellar and retinal analogs of cells fired by learnable or unlearned pattern classes" *kybernetik*, vol. 10, pp. 49-57.

RUMELHART, D. E. and McCLELLAND, J. L., 1986, *Parallel distributed processing: Exploration in the microstructure of cognition*, MIT Press, Cambridge, Massachusetts, vol. 1.

RUMELHART, D. E, G. E. HINTON, and R. J. WILLIAMS, 1986, "Learning internal representations by error propagation", in D.E. Rumelhart and J. L. McClelland, eds., vol. 1, Chapter 8, Cambridge, MA: MIT Press.

SHADMAN M, ESTEFEN S.F., RODRÍGUEZ C.A., LOURENCO M.I. 2015. "Preliminary Design of Floating Point Absorber Offshore Rio de Janeiro". *34th Int. Conf.*

Ocean. Offshore Arct. Eng. OMAE2015, May 31-June 5, St. John's, Newfoundland, Canada.

SHADMAN, M., 2017, *Application of the Latching Control on a Wave Energy Converter*. Tese D.Sc., COPPE - Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

SHENG W, ALCORN R, LEWIS A, 2015a. On improving wave energy conversion, part I: Optimal and control technologies, *Renew Energy*, Volume 75, pages 922-934.

SHENG W, ALCORN R, LEWIS A, 2015b. On improving wave energy conversion, part II: Optimal and control technologies, *Renew Energy*, Volume 75, pages 935-944.

SOMAYAJULA, A.S., FALZARANO, J.M. 2014. "Non-linear dynamics of parametric roll of container ship in irregular seas". *OMAE2014-24186*. San Francisco, USA.

SANGUINETTI, C. F. O., 1985, *Estabilidade Dinâmica de Navios Pesqueiros em Ondas Regulares*. Dissertação de M.Sc., COPPE - Eng. Oceânica, UFRJ, Rio de Janeiro, RJ, Brasil.

SAVIT, R., and GREEN, M., 1991, "Time series and dependent variables", *Physica D*, v. 50, pp. 95-116.

SHIN, Y. S., BELENKY, V. L., PAULLING, J. R., WEEMS, K. M., LIN, W. M., 2004, "Criteria for Parametric Roll of Large Containerships in Longitudinal Seas". *Transactions of SNAME*, vol. 112, pp. 14-47.

SKOMEDAL, N., 1982, "Parametric Excitation of Roll Motion and its Influence on Stability", In: *Proceedings of the 2nd International Conference on Stability of Ships and Ocean Vehicles (STAB '82)*, Tokyo, Japan, pp. 113-125.

SVARER, C., 1994, *Neural Networks for Signal Processing.*, PhD thesis, Electric Institute, Technical University Denmark.

TANAKA, et al., 2001, "Estimating the active dimension of the dynamics in a time series based on an information criterion", *Physical D, Nonlinear Phenomena*, 158, 19-31.

TIMOSZCZUK, A. P., 2004, *Reconhecimento Automático do Locutor com Redes Neurais Pulsadas.*, Tese D.Sc., USP, São Paulo, SP, Brasil.

UMEDA, et al., 2015, "Numerical Prediction of Parametric Roll Resonance in Oblique Waves". In: *Proceedings of the 12th International Conference on Stability of Ships and Ocean Vehicles (STAB'2015)*, Glasgow, UK, pp. 331-340, Jun.

VALERIO, L., 1994, *Estabilidade Paramétrica de Navios em Ondas Longitudinais Regulares.* Dissertação M.Sc., COPPE - Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil.

VALERIO, L., 2000, *Sobre a Estabilidade Dinâmica de Navios em Ondas*. Tese de D.Sc., COPPE - Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil.

VIVANCO, J. E.M, 2009, *Análise da Dinâmica Não-Linear no Balanço Paramétrico de uma Embarcação Pesqueira*. Dissertação de M.Sc., COPPE - Eng. Oceânica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, Brasil.

WEIGEND, A. S., and N. A. GERSHENFELD, N. A., 1993, "The Future of Time Series", In: *Time Series Prediction: Forecasting the Future and Understanding the Past*, A. S. Weigend and N. A. Gershenfeld, eds., 1–70, Addison-Wesley.

WIDROW, B., and M. E. HOFF, Jr., 1960, "Adaptive switching circuits" *IRE WESCON Convention Record*, pp. 96-104.

XING, Z., McCUE, L., 2009, "Parameter Identification for two Nonlinear Models of Ship Rolling Using Neural Networks". *Proc. 10th Int. Conf. on Stability of Ships and Ocean Vehicles STAB 2009*, St. Petersburg, Russia.

XING, Z. and L. McCUE, L., 2010. "Modeling Ship Equations of Roll Motion Using Neural Networks." *Naval Engineers Journal* 122(3): pp. 49-60.

YADAV, S., and SHUKLA, S., 2016, "Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification", *Proc. IEEE 6th International Conference on Advanced Computing*. Bhimavaram, India.

YULE, G. U., 1926, "Why do we Sometimes get Nonsense-Correlations between Time-Series? A Study in Sampling and the Nature of Time-Series", *Journal of the Royal Statistical Society*, Vol. 89, No. 1, pp. 1-63.

ZHANG, B. E., and PATUWO, M. Y. H. 1998, "Forecasting with artificial neural networks: The state of the art", *International Journal Of Forecasting*, v. 14, pp. 35-62.

ANEXO A: Redes Neurais Artificiais –

RNAs: Breve Descrição

Este anexo apresenta alguns aspectos teóricos envolvidos nos algoritmos de Redes Neurais Artificiais - RNAs, incluindo o modelo do neurônio artificial e as principais arquiteturas de redes neurais usadas em problemas de identificação e predição de parâmetros. O anexo introduz também, de forma abreviada, a base teórica das rotinas de treinamento da rede neural artificial.

A-1 Redes Neurais Artificiais

Uma rede neural artificial – **RNA** - é um modelo matemático empírico, com memória e desenvolvimento não linear, com base na lógica identificada no funcionamento do cérebro humano. O interesse na compreensão do raciocínio adotado pelo cérebro humano é essencial para se poder simular alguns aspectos chave do seu funcionamento, permitindo que se desenvolvam métodos e algoritmos que dão aos computadores capacidade de realizar adequadamente as funções cotidianas para o cérebro, tais como: reconhecimento de imagens e de voz, a capacidade de generalização de fenômenos **Timoszczuk (2004)**. Portanto, a base lógica de uma rede neural artificial deve ser capaz de simular além da inteligência, desenvolver o aprendizado e a possibilidade de compreensão.

Um modelo de rede neural artificial pode ser descrito como uma unidade de processamento que possui uma ou várias entradas e uma saída acionada por meio de funções de transferência da entrada para a saída, o que é feito por meio de **conexões**, denominadas sinapses. Essas conexões, por sua vez, são ponderadas por pesos,

permitindo obter funções matemáticas altamente complexas, aplicáveis à solução de diversificados e complexos problemas de interesse prático.

A-1.1 Definições

Recentemente, tem-se observado o aumento vertiginoso da atenção sobre estudos das redes neurais artificiais, principalmente, como consequência do grande interesse nas pesquisas sobre inteligência artificial (IA). A capacidade da inteligência artificial de mimetizar funções do funcionamento do cérebro humano tem sido objeto de inúmeras aplicações já em fase avançada de industrialização e comercialização.

O ser humano é dotado de um complexo sistema de circuitos neuronais (neurônios) interconectados entre si (processamento em paralelo), chamado de sinapses. Com essa mesma lógica se persegue o comportamento inteligente em máquinas (processamento em série). Exatamente, neste mesmo contexto, se desenvolvem as estratégias das redes neurais artificiais (RNAs), inspiradas na própria natureza das redes de neurônios e sinapses biológicas.

A-1.2 Neurônio Biológico

Todas as funções e movimentos do organismo vivo estão relacionados ao funcionamento destas pequenas células. Os neurônios estão conectados uns aos outros através de sinapses, e juntos formam uma grande rede, chamada rede neural. As sinapses transmitem estímulos através de diferentes concentrações de Na^+ e K^+ , e o resultado disto pode ser estendido por todo o corpo humano. Esta grande rede proporciona uma fabulosa capacidade de processamento e armazenamento de informação, **Nunes da Silva *et al.*, (2010).**

Tipicamente, os neurônios biológicos são, hoje em dia, de cinco a seis ordens de grandeza mais lentos do que os processadores digitais modernos. Entretanto, o cérebro compensa essa taxa de operação relativamente baixa do neurônio pelo expressivo número total de células nervosas, com conexões sinápticas entre si, **Haykin (2009)**.

Estima-se que haja aproximadamente 10 (dez) bilhões de neurônios no córtex humano e cerca de 60 (sessenta) trilhões de conexões sinápticas entre esses neurônios, **Haykin (2009)**. Uma sinapse é uma conexão simples que pode impor ao neurônio receptor um estímulo que pode excitá-lo ou inibi-lo, mas não pode provocar os dois efeitos ao mesmo tempo.

Os dendritos, como mostrados na **Figura A.1**, formam uma região onde os sinais de entrada são recebidos. O corpo do neurônio, também chamado de *somma*, é responsável por coletar e combinar informações vindas de outros neurônios. Os axônios são as vias através das quais o sinal é transportado até a outra extremidade do neurônio, assemelhando-se a linhas de transmissão elétrica, pois são longos, finos, possuem altas resistência e capacitância elétricas, além de se distribuírem uniformemente ao longo de sua extensão, **Haykin (2009)**. As Redes Neurais Artificiais - RNAs foram desenvolvidas inspiradas, exatamente, neste processo biológico.

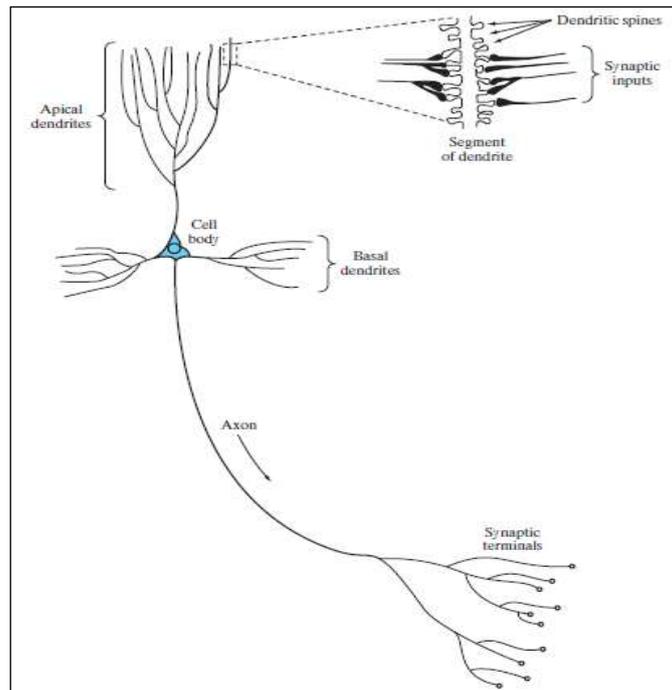


Figura A.1: Modelo de transmissão de impulso em Neurônios Biológicos (Haykin, 2009)

É importante ressaltar que os neurônios que formam Redes Neurais Artificiais podem ser considerados bastante primitivos quando comparados com aqueles encontrados no cérebro humano.

Após essa apresentação de alguns fundamentos biológicos, a seguir apresentam-se os conceitos básicos do neurônio artificial e da Rede Neural Artificial. Uma vez que a capacidade de aprender foi a grande motivadora do desenvolvimento das Redes Neurais Artificiais, segue uma breve comparação das possibilidades potenciais da aplicação dessas redes na resolução de problemas, explorando-se, inclusive, a visão de computabilidade e complexidade em termos das Redes Neurais.

A-1.3 Origens e Evolução das Redes Neurais Artificiais

Já há algumas décadas, são empregados métodos matemáticos para realizar previsões de séries temporais. Até 1920, essa previsão era feita simplesmente extrapolando-se os dados através de simples ajuste global no domínio do tempo. Em 1926, **Yule (Yule, 1926)** propôs o uso de técnica auto-regressiva com o intento de prever o número anual de manchas solares. Nesse caso, a técnica de previsão determinava o valor através da soma ponderada das observações prévias da série. Uma operação puramente linear.

Nos próximos cinquenta anos, tais modelos lineares, acrescidos de ruído, foram objeto de intensa pesquisas. Ao redor de 1980, o começo do uso de computadores de maior porte viabilizou desenvolvimento dos estudos de Redes Neurais Artificiais, e daí, a possibilidade de se estudar séries temporais mais longas, aplicadas a um universo de modelos mais complexos. Dessa forma, com o auxílio das técnicas de Redes Neurais Artificiais e das relações extraídas dos dados, teve-se melhores condições de se entender o próprio processo gerador envolvido.

As RNAs têm a capacidade de aprender padrões subjacentes presentes nos conjuntos de dados disponíveis, apresentando melhor desempenho do que os métodos estatísticos tradicionais, principalmente, quando não se conhece o processo gerador dos dados e/ou quando se trata de um processo não-linear e/ou não-estacionário, como, em geral, são a maioria dos processos encontrados no mundo real. Por isso, representa as RNAs pode ser considerada uma relevante contribuição para os avanços registrados nos estudos das séries temporais.

McCulloch e Pitts, um neurofisiologista e um matemático, respectivamente, em 1943, descreveram o modelo pioneiro de um neurônio artificial, considerado um trabalho referencial para o desenvolvimento das redes neurais artificiais. O próximo grande passo aconteceu em 1949, através de **Hebb**, com a publicação do livro *The Organization of Behaviour*. Nesse livro foi discutida pela primeira vez uma regra de aprendizado para um conjunto de neurônios interligados entre si. As atividades nessa linha de pesquisa se consolidaram com a concepção do perceptron desenvolvida **Rosenblatt em 1958**. O perceptron tem a capacidade de classificar grupos de vetores entre classes linearmente separáveis. Uma aplicação emblemática do perceptron envolveu o reconhecimento de caracteres, adotando-se somente dois valores - verdadeiro e falso. Essa lógica, instalada numa máquina chamada *Mark I perceptron*, causou grande euforia à época, talvez um pouco exagerada, gerando expectativas sobre os futuros robôs inteligentes. A característica mais importante do **perceptron** foi o desenvolvimento de um algoritmo de aprendizagem capaz de adaptar os pesos internos do neurônio de maneira resolver o problema da classificação linear das classes.

Widrow e Hoff, em 1960, desenvolveram um modelo semelhante, mas incorporando uma importante variação do algoritmo de aprendizagem do perceptron, através da aplicação do conceito de erro médio quadrático, com a formulação do elemento linear adaptativo (*Adaline - Adaptive Linear Element*). Utilizando essa teoria, em 1962 Windrow definiu uma das primeiras redes neurais construídas com elementos adaptativos, o *Madaline (Multiple-adaline)*. Durante os anos 60 foram desenvolvidos vários estudos de aplicação do perceptron, demonstrando a enorme versatilidade das RNAs para solucionar diferentes tipos de problema, embora apresente limitações. Um exemplo de limitação do perceptron seria o problema do *Ou exclusivo (XOR)* que prova que mesmo uma função tão simples

de classificação não consegue ser modelada pelo perceptron. Essa crítica aparece no livro “*Perceptrons*” de Minsky e Papert em 1969, onde foi demonstrado matematicamente que o Teorema da Convergência do perceptron, como desenvolvido por Rosenblatt só era aplicável à classe de problemas linearmente separáveis, não sendo, portanto, capaz de resolver problemas tão elementares como o do *Ou exclusivo*. Dessa maneira, ficou matematicamente demonstrado que os modelos de redes neurais baseados no perceptron (na época, redes de apenas um nível), não são capazes de aprender uma função lógica tão simples quanto *Ou exclusivo (XOR)*. A função XOR possui um padrão de valores de entrada e de saída cuja associação não podia ser aprendida pelos modelos de redes baseados em perceptron disponíveis naquela época. O impacto dessa crítica foi tão grande que a comunidade científica, em geral, desacreditou do potencial das Redes Neurais Artificiais, com a exceção de alguns poucos pesquisadores, como foi o caso de **Kohonen (1972)**, **Grossberg (1972)**, **Fukushima (1980)** e **Hopfield (1982)**.

Em 1982 Hopfield utilizou a ideia da minimização da função de energia para analisar o funcionamento de redes recorrentes com conexões sinápticas simétricas, **Haykin (2008)**.

Um grande marco para o recente desenvolvimento das RNAs surge com o algoritmo de retropropagação do erro (***Backpropagation***), no trabalho publicado por Rumelhart, Hinton e Williams, em 1986. A partir daí, foram realizadas séries de trabalhos, dentre os quais destaca-se Broomhead e Low em 1988, que descreveram o uso das funções de base radial (*radial basis functions*).

Pode-se dizer que os trabalhos de Hopfield em 1982 e o livro de Rumelhart e McClelland em 1986, foram os grandes responsáveis pelo ressurgimento do interesse pelas RNAs.

A-2 Modelos de Redes Neurais Artificiais

Os neurônios biológicos são as unidades básicas de processamento do sistema nervoso. De modo análogo, os neurônios artificiais operam como unidades básicas de processamento da Rede Neural Artificial. Assim como no processo biológico, as sinapses são essenciais para o processo de aprendizagem; a sinapse artificial permite que o algoritmo aprenda através da identificação de um conjunto de pesos atribuídos às sinapses para que o comportamento desejado seja perseguido/atingido. O conhecimento, neste contexto, influencia diretamente a forma de processamento da Rede Neural Artificial ou, em outras palavras, seu comportamento de entrada-saída, **Calôba (2002)**.

Por que utilizar as RNAs?

Uma potencial vantagem das RNAs deve-se, em função da sua estrutura lógica, a possibilidade de paralelização do seu processamento. Outro aspecto que coloca as RNAs como uma classe muito especial de sistemas decorre da sua capacidade de generalização. ou seja, a sua capacidade de gerar respostas adequadas, para eventuais entradas que nunca foram apresentadas durante o seu treinamento. Estes dois aspectos fazem com as RNAs sejam capazes de solucionar problemas altamente complexo. Contudo, seria importante observar que, na prática, as Redes Neurais Artificiais não operam milagres, nem solucionam os problemas de maneira autônoma. Sua aplicação deve ser feita sempre de forma criteriosa, decompondo-se o problema em questão em partes que possam ser tratadas eficientemente por uma ou várias RNAs. Deve-se explorar, ao máximo, todas as habilidades de cada uma das redes envolvidas. A utilização das RNAs podem incorporar algumas características muito úteis aos sistemas que as utilizam, a saber:

- Não-linearidade

A não-linearidade é uma propriedade inerente ao neurônio artificial. Essa característica torna-se ainda mais relevante quando o sinal (ou entrada) analisado for gerado por dispositivo não linear, como, a rigor, corre na maioria dos sistemas reais.

- Mapeamento entre a entrada e a saída

Um dos paradigmas de aprendizado mais utilizado nas aplicações de RNAs é o aprendizado supervisionado. Ele promove a modificação dos pesos das conexões da rede, a partir de um conjunto de entradas e suas respectivas saídas. Para cada uma dessas entradas, escolhida aleatoriamente, determina-se a modificação dos pesos de modo a minimizar a diferença entre a resposta atualizada calculada pela rede e a resposta referência/desejada correspondente à respectiva entrada. Desta forma, a rede aprende a partir de exemplos, construindo um mapeamento lógico entre entrada e saída.

- Adaptatividade

As RNAs têm a capacidade natural de adaptar seus parâmetros, em resposta às mudanças no ambiente gerador das entradas, através do seu retreinamento. Contudo, se o ambiente for do tipo não estacionário, a RNA pode ser construída de forma a que essa adaptação dos parâmetros de suas conexões ocorra em tempo real, acompanhado às mudanças no ambiente gerador das entradas. Essa adaptabilidade, no entanto, pode levar a uma perda da robustez da rede, ou seja, a RNA pode passar a responder a estímulos espúrios (ou entradas) aos quais não deveria responder, como por exemplo, ruídos típicos de sensores de medição. Este problema ficou conhecido como Dilema da Estabilidade-Plasticidade, **Haykin (2009)**.

- Tratamento de informação contextual

Dependendo da arquitetura adotada, na fase de treinamento, a saída da rede será afetada pela atividade de todos os neurônios, e a correção dos parâmetros atinge potencialmente todas as conexões. Por exemplo, no caso dos pesos, esse efeito faz com que a informação armazenada na rede seja influenciada por todo o conjunto de dados apresentado, considerando não apenas cada padrão apresentado, mas também a correlação entre os mesmos, produzindo uma forma de informação contextual.

- Tolerância a falhas

Será sempre possível conceber a estrutura da rede, de modo a que a sua saída receba contribuições de todos os neurônios. Portanto, em caso de falha em um dos neurônios, ou em um conjunto de conexões, a saída sofrerá apenas uma possível degradação, mas sem interromper o processo. Em geral, as RNAs não apresentam falhas catastróficas, sendo, portanto, bastante tolerantes a falhas.

A-3.1 Arquiteturas das Redes Neurais

A forma como os neurônios serão definidos é fator importante para o desenvolvimento definição dos algoritmos de aprendizagem utilizados. A RNA se constitui por neurônios (ou elementos processadores), conexões e seus pesos que atuam como ponderadores). Os pesos são os elementos responsáveis pelo armazenamento do conhecimento da rede.

A organização dos neurônios da rede neural está intimamente ligada ao algoritmo de aprendizagem usado para treinamento, funcionando como estruturadores da rede.

A **Figura A.2** apresenta uma ilustração esquemática do neurônio artificial, ou unidade de processamento. Na figura, as sinapses estão representadas por pesos, responsáveis pela

soma ponderada das entradas x_i ; o núcleo da célula está representado por uma função de ativação, usada para comparar as entradas x_i ponderadas pelos pesos sinápticos w_{ij} , com o limiar do núcleo θ_j , e o axônio representado pela saída y_j do neurônio.

Nessa modelação. O núcleo foi expresso por:

$$y_j = F(u_j) = F\left(\sum w_{ij}x_i - \theta_j\right) \quad (\text{A.1})$$

Onde: $F(u_j)$ é a função de ativação do neurônio; são os pesos; x_i ($i = 1, 2, \dots, p$) são as p entradas; θ_j é o limiar (variável que especifica qual será o patamar apropriado para que o resultado produzido pelo combinador linear possa gerar um valor de disparo) de ativação do neurônio, definindo se a saída será disparada; que seria y_j , **Nunes da Silva et al. (2010)**.

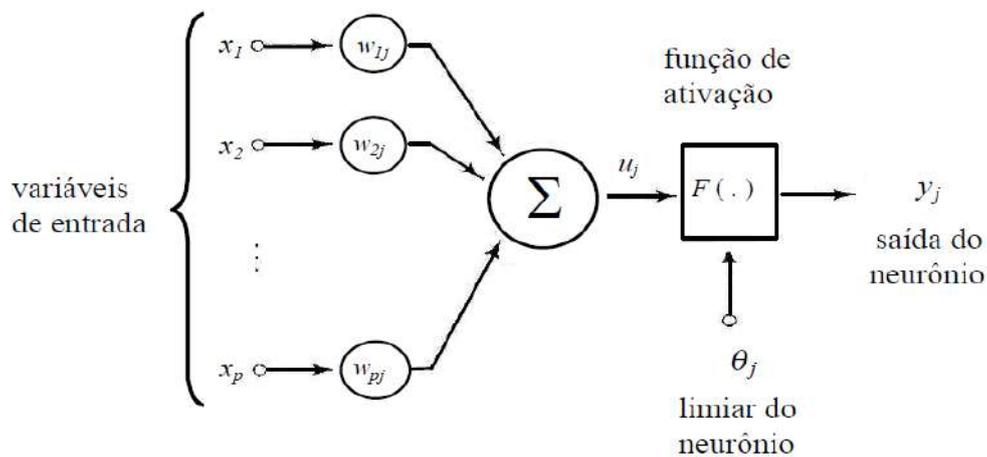


Figura A.2: Modelo básico de neurônio artificial

Segundo o tipo de conexão, as redes neurais podem ser classificadas como redes em camadas (*feedforward*) e redes recorrentes (*feedback*).

A-3.2 Redes Recorrentes

Redes recorrentes são redes neurais com um ou mais laços de realimentação, que podem ser de natureza local ou global. São usadas tanto como conexões no sentido da entrada para saída, e também como laços de realimentação. A utilização como laço de realimentação permite que as redes recorrentes adquiram representações de estado, tornando os dispositivos apropriados para diversas aplicações dinâmicas, tais como: previsão ou modelagem de sistemas não lineares, **Moreira e Guedes Soares (2003)**; equalização adaptativa de canais de comunicação; controle de instalações industriais; diagnósticos de motores automotivos e processamento de sinais temporais, **Haykin (2008)**, entre outras.

A **Figura A.3** mostra a rede neural recorrente de Elman, que se diferencia das demais soluções temporais por conseguir que os dados anteriores a um dado instante de tempo t influenciem o processo no instante presente, devido à realimentação feita na camada escondida, que faz com que os dados da amostra anterior influam na saída, garantido maior influência para os dados mais recentes.. Este tipo de RNA pode apresentar uma ou mais malhas de realimentação, fazendo com que suas conexões permitam que a rede memorize as informações atuais, na camada de contexto, no momento seguinte imediatamente após a sequência investigada.

Na **Figura A.3**, $x(n)$ é o vetor de entradas, formado pelos atrasos, formado pelo elemento atual $x(n)$ e pelos demais elementos de entrada, espaçados do intervalo de tempo τ . Nesse padrão de entrada, o sinal se propaga da entrada para a saída (alimentação à frente).

Ainda na primeira iteração, os neurônios ocultos ativarão os neurônios da camada de contexto que armazenarão a saída dessa primeira iteração a ser utilizada no próximo ciclo.

A recorrência da Rede de Elman ocorre através da unidade de contexto, normalmente, uma estrutura de atraso do tipo z^{-1} , que armazena a saída da primeira camada oculta por um passo de tempo. Dessa forma, a sua arquitetura permite a geração de padrões variáveis no tempo, habilitando a configuração neural para aplicações envolvendo séries temporais.

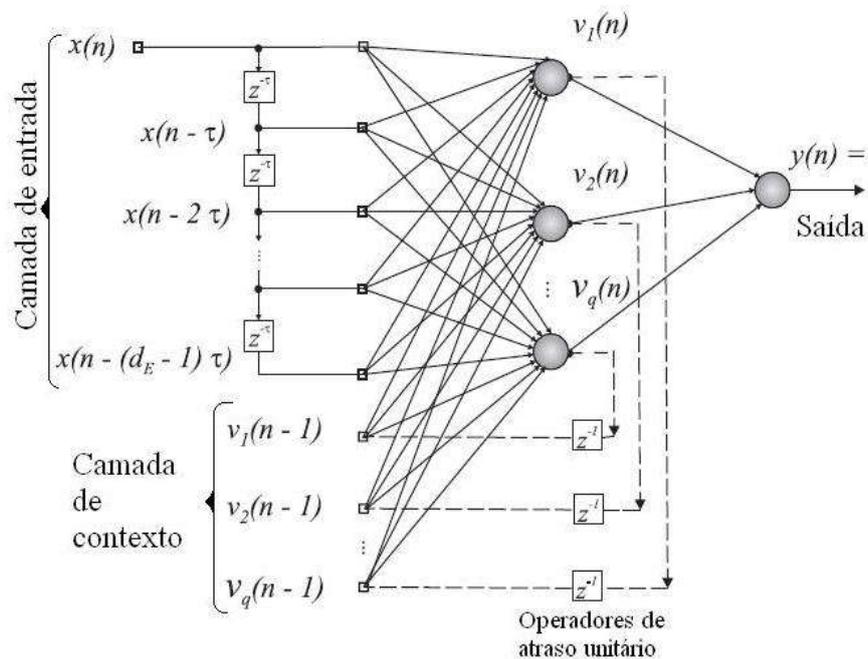


Figura A.3: Rede neural recorrente - RNA de Elman com uma camada oculta

A-3.3 Redes Feedforward

São redes nas quais o processamento se dá sempre em sentido único, da entrada para a saída da rede, sem qualquer realimentação. Adotando-se a sua representação gráfica horizontal, este processamento parte das entradas situadas à esquerda movendo-se para as saídas à direita, e sem qualquer retorno.

A rede neural *feedforward* consiste de uma ou mais camadas de unidades de processamento não-lineares. As conexões entre unidades de camadas adjacentes são definidas por um conjunto de pesos sinápticos. No entanto, para ser considerada *feedforward*, suas saídas devem se conectar somente com as unidades da próxima camada. *Perceptron e Adaline* foram as primeiras redes tipo *feedforward* a aparecerem na literatura [Nunes da Silva *et al.* (2010)]. As redes neurais de múltiplas camadas potencializaram as possibilidades das redes *feedforward*. A **Figura A.4** esquematiza um exemplo de rede neural do tipo *feedforward*.

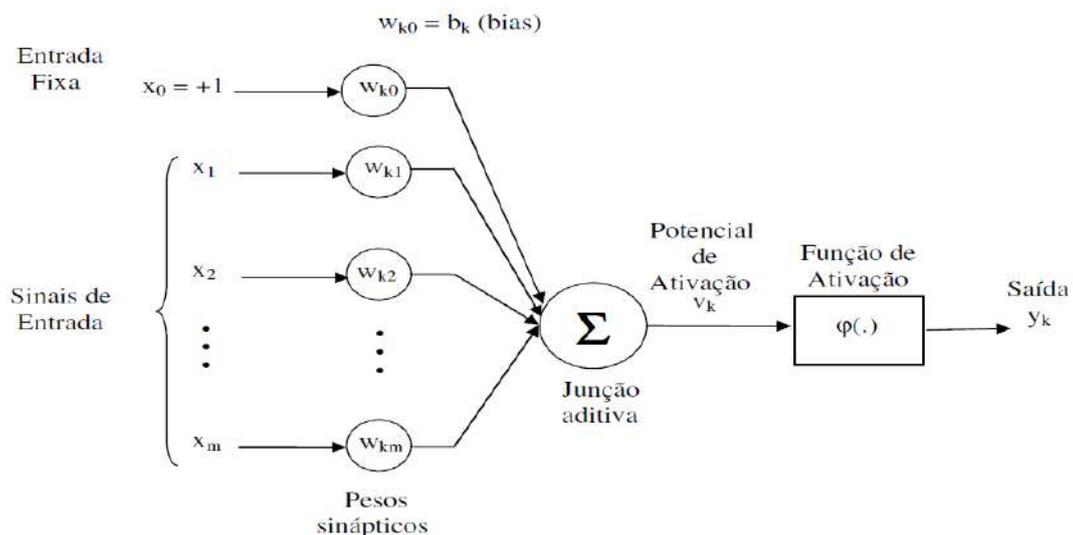


Figura A.4: Rede neural feedforward

A-3.4 Exemplos de Redes Neurais

- *McCulloch e Pitts* [Haykin (2008)]- propuseram o modelo de neurônio representado na **Figura A.5**. Nesse modelo, o neurônio atua como uma unidade de decisão binária ativada quando a soma ponderada de suas entradas i_i , excede um certo limiar θ (*threshold*) e produz saídas correspondentes a zero ou um. O valor θ pode ser interpretado como uma polarização (*bias*). Isso corresponde a uma entrada com valor fixo e sua correspondente

conexão apresentando peso igual à unidade. As expressões para cálculo da saída (o) - equação (3.2) e da função do neurônio (F) estão apresentadas a seguir:

$$o = F\left(\sum_N w_i i_i(t) - \theta\right) \quad (\text{A.2})$$

$$F(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{se } x < 0 \end{cases}$$

Os autores demonstraram que a escolha adequada dos pesos (w_i), permite que um conjunto desses neurônios interligados realize cálculos computacionais envolvendo funções lógicas do tipo E, OU, ou mesmo funções mais complexas [Haykin (2008)].

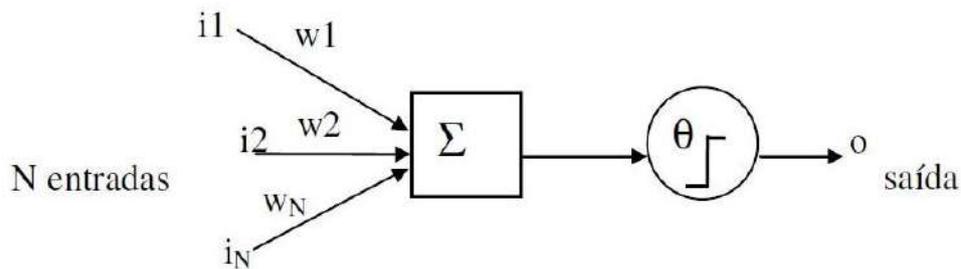


Figura A.5: Neurônio de McCulloch e Pitts (Haykin, 2008)

- **Perceptron** [Haykin (2008)]- modelo de neurônio muito utilizado atualmente como bloco básico para a construção de redes mais complexas. A sua arquitetura é essencialmente a mesma do neurônio McCulloch e Pitts, diferindo apenas em relação ao tipo de algoritmo de aprendizado para ajuste dos pesos, Bishop (2006).

Um modelo de rede neural artificial, em sua forma mais simples (Perceptron, ver **Figura A.6**), pode ser descrito como uma unidade de processamento com uma camada de entrada

(com uma ou várias entradas) e uma saída (com apenas um neurônio, embora, no caso do Perceptron, possa ter vários neurônios na camada de saída, como no caso de vários outros tipos de redes). Esta unidade de processamento é acionada por meio de funções de transferência da entrada para a saída, feito através das conexões/sinapses (*bias*). Essas conexões são ponderadas por pesos, permitindo estudar funções matemáticas altamente complexas, que podem ser aplicadas à solução de diversos problemas de interesse prático.

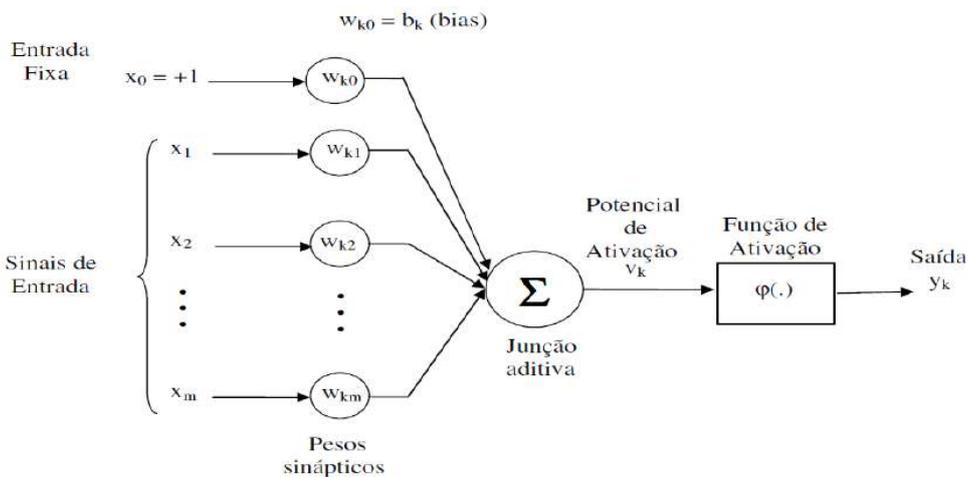


Figura A.6: Rede neural feedforward (perceptron)

No processamento da rede neural perceptron e a obtenção da saída y_k :

x_1, x_2, \dots, x_m - entradas

Limiar de ativação $x_0 = +1$ (valor assumido no *perceptron*)

$w_{k0}, w_{k1}, w_{k2}, \dots, w_{km}$, - pesos sinápticos (parâmetros ajustados no treinamento)

v_k : potencial de ativação

$$v_k = \sum_{i=1}^m w_{ki} \cdot x_i + x_0$$

y_k : saída (potencial de ativação que passa pela função de ativação)

$$y_k = \varphi(v_k)$$

- **Adaline.** -*Adaptive Linear Neuron* [Nunes da Silva *et al.* (2010)] primeira RNA usada em um problema real: representação de filtro adaptativo para eliminar ecos em linhas telefônicas, ver **Figura A.7**.

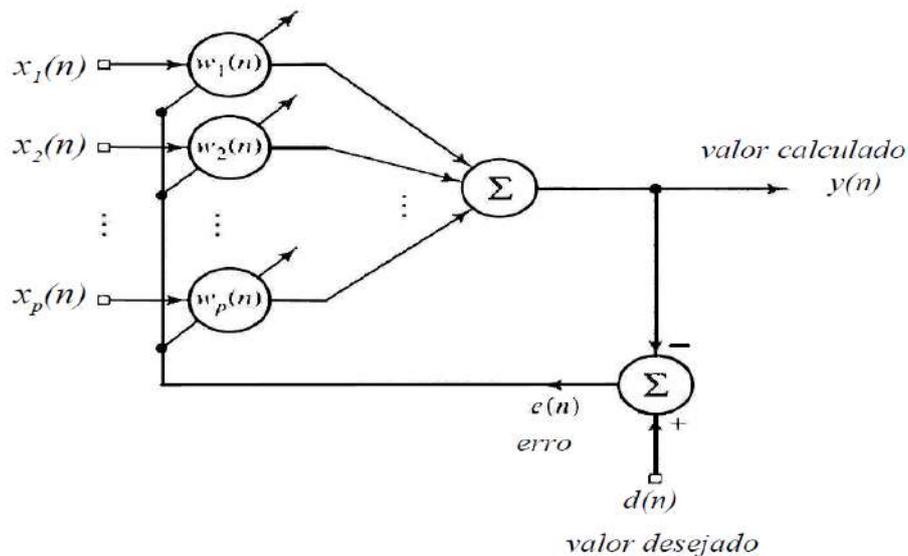


Figura A.7: Treinamento da RNA Adaline

A-3.5 Perceptron de Múltiplas Camadas (PMC)

As redes *PMC* (**Multilayer perceptron, (MLP)**) são formadas por múltiplas camadas de neurônios, utilizando o **perceptron** como unidade de processamento computacional. Rumelhart em 1986 propôs o algoritmo de treinamento conhecido como retropropagação do erro (*backpropagation*), expandindo as possibilidades de aplicação do **perceptron** para o caso de múltiplas camadas (perceptron de múltiplas camadas-PMC). As redes **PMC** destacam-se pela sua capacidade de lidar com problemas fortemente não-lineares, ao contrário das redes perceptron de camada única. O **PMC** tem um grande potencial de aplicação na predição de séries temporais, presentes em muitos e variados problemas de

engenharia, **Felippetto De Castro (2001)**, **Fernandes De Matos (2005)**, COPPE-Eng. Civil.

A **PMC** é uma das redes neurais mais populares, sendo do tipo *feedforward*, não apresenta conexões partindo de nós de uma determinada camada para as camadas anteriores (sem realimentação). Redes **PMC** apresentam poder computacional muito maior do que aqueles das redes sem camadas intermediárias, capazes de lidar apenas com problemas lineares. No caso das redes com camada intermediária pode-se implementar funções com certo grau de complexidade,. Redes com duas camadas intermediárias podem implementar, em princípio, qualquer função matemática, incluindo alto grau de complexidade decorrente de fortes não-linearidades **Cybenko (1988)**.

Define-se uma **PMC (Figura A.8)**, como uma rede com uma única camada de entrada (dados de entrada: (u_{ij}) , i = número da camada, j = número da entrada), uma ou mais camadas intermediárias (ocultas ou escondidas) e uma única camada de saída, Y_i (saída da rede, ver **Figura A.8**).

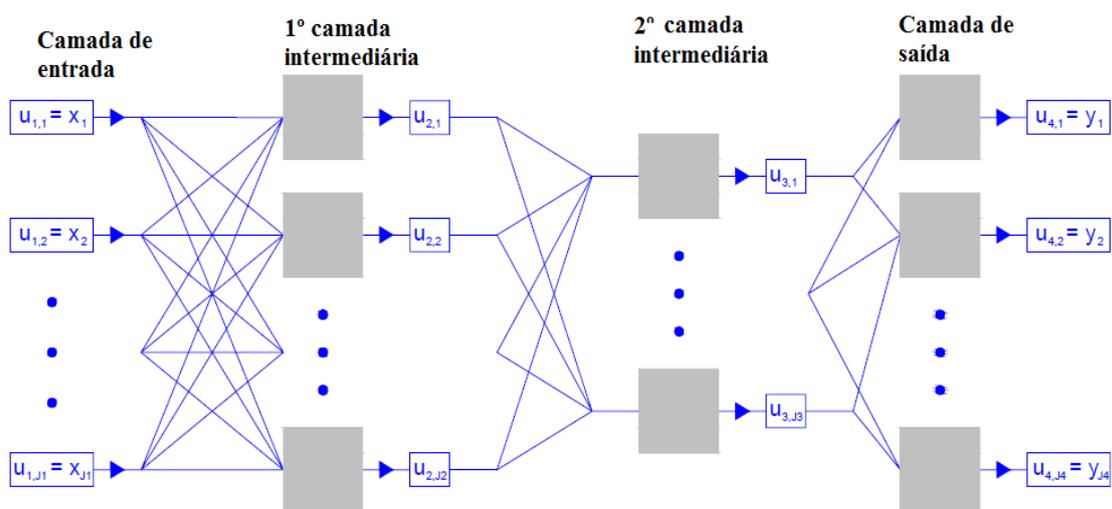


Figura A.8: Arquitetura da rede perceptron de múltiplas camadas (PMC), (**Barbosa, 2010**)

A-3.6 Tipo de Aprendizagem

Uma propriedade importante da rede neural artificial é a sua habilidade de aprender a partir das informações colhidas no ambiente na qual trabalha, e, a partir daí, melhorar progressivamente seu desempenho através do seu processo de aprendizagem. No contexto das redes neurais, aprendizagem é o processo pelo qual os parâmetros livres (pesos sinápticos e limiares) da rede são ajustados através da estimulação exercida pelo ambiente externo. O tipo de aprendizagem está intimamente relacionada à maneira pela qual ocorre a modificação dos parâmetros internos, e se apresenta com a seguinte sequência de eventos:

1. Estimulação da rede neural pelo ambiente externo;
2. Modificações dos pesos sinápticos, em decorrência do estímulo externo;
3. Atualização dos pesos sinápticos e limiares, e geração da nova resposta ao ambiente (saída da rede).

Do ponto de vista do aprendizado, as RNAs se definem como: de treinamento supervisionado ou não supervisionado.

Entende-se por treinamento supervisionado, aquele no qual os pares entrada/saída, representando a excitação e a resposta desejada (*target*) são sucessivamente apresentados à supervisão.

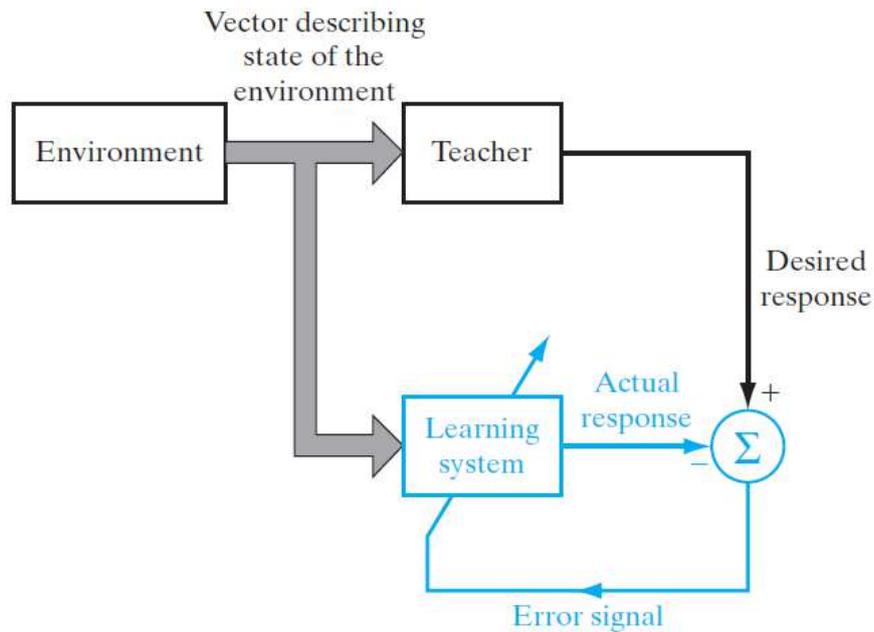


Figura A.9: Diagrama de blocos treinamento supervisionado, a parte da azul constitui um ciclo de realimentação do erro, (Haykin, 2009)

Existem vários algoritmos capazes de realizar o treinamento da rede tipo *feedforward*. Estes algoritmos se dividem em duas categorias: métodos de treinamento determinísticos e métodos de treinamento estocásticos.

Entre os métodos determinísticos incluem-se: método do gradiente, método do gradiente com momentum, método de Quasi-Newton, método de propagação resiliente (*resilient-propagation*) e o método de **Levenberg-Marquardt** (adotado na presente tese).

Entre os métodos estocásticos incluem-se: a filtragem de Kalman, nas versões *full* ou com processamento paralelo e recursivo.

Todos estes métodos possuem em comum o emprego do algoritmo de *backpropagation* (retropropagação do erro) para o cálculo das derivadas parciais das variáveis de saída da rede, em relação aos parâmetros de ajuste ou pesos sinápticos.

A-3.6.1 *Backpropagation* (Retropropagação do Erro)

O algoritmo de *backpropagation* é bastante adotado para o treinamento de redes de múltiplas camadas. Nesse caso, o aprendizado da rede neural ocorre mediante a estimação dos pesos sinápticos, que ocorre pelo fato do erro ser retropropagado durante o treinamento. Considera-se o algoritmo de *backpropagation* como sendo estático e supervisionado. Para cada informação de entrada, a rede gera uma saída correspondente. Este algoritmo é uma generalização da regra delta, proposta por Widrow-Hoff [Haykin (2009)]. Ele se baseia no princípio do aprendizado de correção de erros, no qual o erro se propaga no sentido contrário aos dados processados (nesse caso, da camada de saída para a primeira camada).

Esse tipo de rede permite que se obtenha soluções para funções linearmente não-separáveis e demanda algoritmo de treinamento capaz de automatizar a definição dos pesos. O algoritmo mais utilizado para o treinamento destas redes PMC é uma generalização da Regra Delta, denominada de retropropagação, **Reed and MarkII (1999)**. Durante o treinamento com o algoritmo de retropropagação do erro, a rede opera em uma sequência de dois passos. No primeiro, um padrão é apresentado à camada de entrada da rede. O sinal resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, compara a saída obtida com a saída desejada para esse particular padrão. Calcula-se o eventual erro que será, então, propagado a partir da camada de saída até a camada de entrada; e daí, os pesos das conexões vão sendo retropropagado.

Na regra Delta padrão, implementa-se o gradiente descendente ao quadrado da soma do erro para funções de ativação lineares. Entretanto, como a superfície dos erros pode não ser simples, as redes acabam sujeitas às distorções impostas pelos mínimos locais.

Na regra Delta generalizada, ou retropropagação do erro, adota-se uma função de ativação semi-linear, definida por uma função diferenciável não decrescente.

A Taxa de Aprendizagem é uma constante de proporcionalidade no intervalo $[0,1]$, pois este procedimento de aprendizado requer apenas que a mudança no peso seja proporcional à meta. Entretanto, como o verdadeiro gradiente descendente requer que sejam tomados passos infinitesimais, quanto maior for essa constante, maior será a mudança nos pesos, aumentando a velocidade do aprendizado. Tal situação pode levar a uma oscilação do modelo na superfície do erro. Procura-se, então, utilizar a maior taxa de aprendizado possível que não leve a uma oscilação, resultando em um aprendizado mais rápido. O treinamento das redes PMC com retropropagação do erro pode demandar muitos passos no conjunto de treinamento, resultando em um tempo de treinamento consideravelmente longo. Se for encontrado um mínimo local, o erro para o conjunto de treinamento para de diminuir e estaciona em um valor maior que o aceitável, **Haykin (2009)**.

O algoritmo de retropropagação do erro implementado no toolbox de redes neurais do software **MATLAB** pode utilizar diferentes métodos de otimização, dentre eles podemos citar: o método do gradiente descendente, gradiente descendente com momento, Fletcher-Reeves, Polak-Ribiere, quasi-Newton, **Levenberg-Marquardt (LM)**, etc.

Este algoritmo foi criado como uma generalização do algoritmo Widrow-Hoff e baseia-se no princípio de aprendizado de correção de erros onde o erro é propagado no sentido

contrário em que os dados são processados (da camada de saída para a primeira).

Basicamente, a aprendizagem por retropropagação de erros consiste em duas fases:

1. Fase *forward* ou de propagação e

2. Fase *backward* ou de retropropagação.

- *forward*, onde os dados de entrada são processados e o sinal flui da camada de entrada até a camada de saída, sem que exista realimentação.

- *backward*, onde o resultado da rede é comparado com a solução real do problema apresentado e a diferença entre o valor real e o valor calculado é usado para corrigir os pesos sinápticos, agora na direção contrária (camada de saída para a primeira camada).

O algoritmo *backpropagation* tem como conjunto de treinamento os dados de entrada e sua respectiva saída para o cálculo do erro, a qual é usada para treinar a rede durante a fase em que a rede está aprendendo um novo problema. Composto por um vetor x com n entradas e um vetor de saída exato y_{ek} .

$$Y = \{x_k, y_{ek}\} \quad k=1, \dots, n \quad (\text{A.3})$$

Pode-se definir o erro quadrático médio (**MSE**) sobre a equação (2.3):

$$E_R = \frac{1}{n} \sum_{k=1}^n (y_k - y_{ek})^2 \quad (\text{A.4})$$

Onde y_k é a saída fornecida pela rede e y_{ek} é o valor exato correspondente à saída da rede. Podendo ser expressão em função dos pesos, como se apresenta a seguir:

$$E_R = \frac{1}{n} \sum_{k=1}^n (f(W^T \cdot x) - y_{ek})^2 \quad (\text{A.5})$$

A **equação (A.5)** é da forma de uma função objetiva de um problema de otimização onde se deseja minimizar E_R e cujas variáveis são os pesos W_{ij} . Para resolver esse problema, há vários métodos. Há os que usam o gradiente (mais fácil de calcular, porém de lenta convergência), o Hessiano (altos custos computacionais, mas de convergência mais rápida); e, em particular, o método de Levenberg-Marquardt que usados nesta tese, que usa a matriz jacobiana como aproximação da hessiana na finalidade de balancear custo e eficiência, **Bishop (2006)**. Este último sugere que os pesos sejam ajustados segundo a expressão:

$$W(n+1) = W(n) - [J^T(n)J(n) + \lambda I]^{-1} \cdot J^T(n)e(n) \quad (\text{A.6})$$

Onde: I é a matriz identidade e λ é a constante do método de Levenberg-Marquardt.

A-3.6.1.1 Derivação do Algoritmo Retropropagação do Erro

Para entender o algoritmo de retropropagação do erro é necessário definir diversas derivadas e parâmetros auxiliares para entender como que se gera o processo da atualização dos pesos simpáticos. Usando a topologia de um PMC, apresenta-se um conjunto de variáveis:

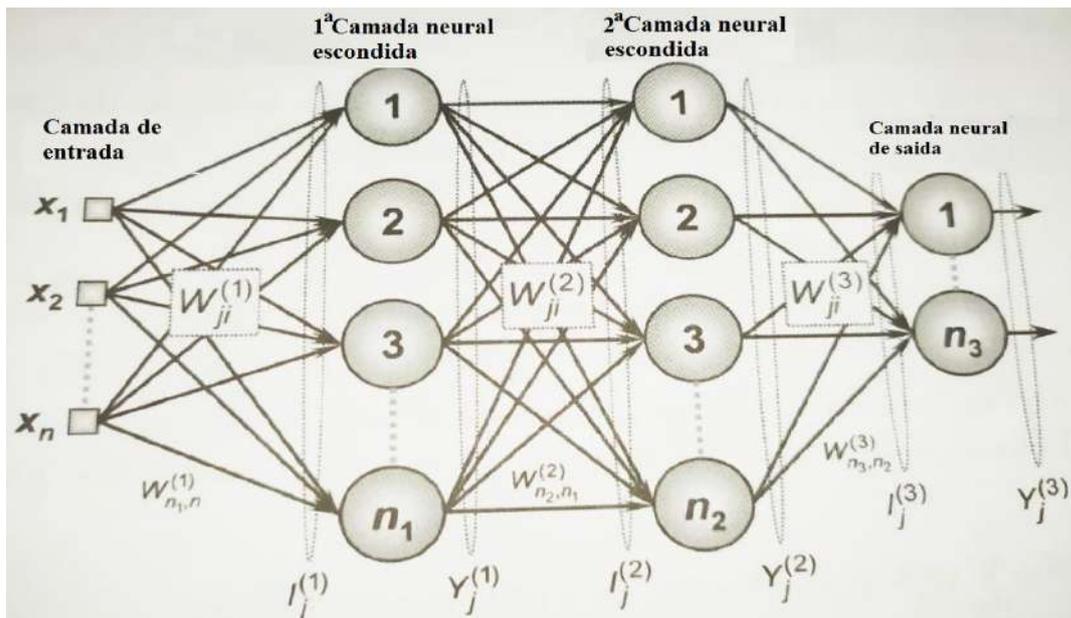


Figura A.10: Notação para derivação do algoritmo de retropropagação do erro, (Nunes da Silva *et al.*, 2010)

A partir da **Figura A.10** assume-se então a seguinte terminologia para os parâmetros constituintes:

- $W_{ji}^{(L)}$ São matrizes de pesos sinápticos, elementos denotam o valor do peso conectado a j -ésimo neurônio da camada (L) ao i -ésimo neurônio da camada (L-1). Para a topologia ilustrada na figura de cima:
 - $W_{ji}^{(3)}$ É o peso sináptico conectado o j -ésimo neurônio da camada de saída ao i -ésimo neurônio da camada 2.
 - $W_{ji}^{(2)}$ É o peso sináptico conectado o j -ésimo neurônio da camada escondida 2 ao i -ésimo neurônio da camada 1.
 - $W_{ji}^{(1)}$ É o peso sináptico conectado o j -ésimo neurônio da camada 1 ao i -ésimo sinal da camada de entrada.
- $L_j^{(L)}$ São vetores cujos elementos denotam a entrada ponderada em relação ao j -ésimo neurônio da camada L.

- $Y_j^{(L)}$ São vetores cujos elementos denotam a saída do j-ésimo neurônio em relação á camada L, os quais são definidos por:

$$Y_j^{(1)} = g(L_j^{(1)})$$

$$Y_j^{(2)} = g(L_j^{(2)})$$

$$Y_j^{(3)} = g(L_j^{(3)})$$

O seguinte para definir a derivação do algoritmo de retropropagação do erro é definir a função representativa do erro de aproximação, onde $E(k)$ é o erro quadrático.

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} (d_j(k) - Y_j^{(3)}(k))^2 \quad (\text{A.7})$$

Onde $Y_j^{(3)}(k)$ é o valor produzido pelo j-ésimo neurônio de saída da rede considerando-se a k-ésima amostra de treinamento, $d_j(k)$ é o valor desejado.

Ajuste dos pesos sinápticos da camada de saída

O processo de adquirir conhecimento da rede neural consiste em ajustar os pesos sinápticos, ao ajustar a matriz de pesos $W_{ji}^{(3)}$ a fim de minimizar o erro gerado entre a saída da rede e o valor desejado. Utilizando a definição de gradiente e explorando a regra da cadeia, das variáveis da **Figura A.10, Nunes da Silva et al. (2010)**:

$$\nabla E^{(3)} = \frac{\partial E}{\partial W_{ji}^{(3)}} = \frac{\partial E}{\partial Y_j^{(3)}} \frac{\partial Y_j^{(3)}}{\partial L_j^{(3)}} \frac{\partial L_j^{(3)}}{\partial W_{ji}^{(3)}} \quad (\text{A.8})$$

Por intermédio das definições anteriores:

$$\frac{\partial L_j^{(3)}}{\partial W_{ji}^{(3)}} = Y_i^{(2)} \quad (\text{A.9})$$

$$\frac{\partial Y_j^{(3)}}{\partial L_j^{(3)}} = g'(L_j^{(3)}) \quad (\text{A.10})$$

$$\frac{\partial E}{\partial Y_j^{(3)}} = -(d_j - Y_j^{(3)}) \quad (\text{A.11})$$

g' Denota a derivada de primeira ordem da função de ativação considerada, substituindo as equações A.9 – A.11 em A.8:

$$\frac{\partial E}{\partial W_{ji}^{(3)}} = -(d_j - Y_j^{(3)}) \cdot g'(L_j^{(3)}) \cdot Y_i^{(2)} \quad (\text{A.12})$$

A Matriz dos pesos sinápticos $W_{ji}^{(3)}$ deve ser efetuada em direção contrária ao gradiente com o fim de minimizar o erro, então:

$$\Delta W_{ji}^{(3)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(3)}} \leftrightarrow \Delta W_{ji}^{(3)} = \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (\text{A.13})$$

$\delta_j^{(3)}$ é definido como gradiente em relação ao j -ésimo neurônio da camada de saída, sendo da forma:

$$\delta_j^{(3)} = (d_j - Y_j^{(3)}) \cdot g'(L_j^{(3)}) \quad (\text{A.14})$$

A expressão A.13 se pode converter num procedimento iterativo da forma seguinte:

$$W_{ji}^{(3)}(t+1) = -W_{ji}^{(3)}(t) + \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (\text{A.15})$$

Sendo η a taxa de aprendizagem do algoritmo de retropropagação do erro, que também pode ser escrito da seguinte forma:

$$W_{ji}^{(3)} \leftarrow W_{ji}^{(3)} + \eta \cdot \delta_j^{(3)} \cdot Y_i^{(2)} \quad (\text{A.16})$$

A expressão **A.16** é a encarregada de fazer o ajuste dos pesos sinápticos dos neurônios da camada de saída, fazendo a consideração o cálculo do erro, entre as respostas produzidas pela rede e os valores desejados. Uma vez feitos os ajustes da camada de saída, agora se faz o mesmo procedimento para ajustar os pesos sinápticos das camadas intermediárias, sempre de direita para esquerda. Uma vez feito o ajuste dos pesos das camadas intermediárias, por último se faz o ajuste dos pesos sinápticos da camada de entrada, com o mesmo procedimento feito nas camadas anteriores.

A-3.5.2 Algoritmo Levenberg-Marquardt

Neste trabalho optou-se por utilizar o algoritmo de **Levenberg-Marquardt** como a técnica de otimização selecionada pelas suas vantagens (custo/benefício), que é uma variação do método de Newton que foi designado para minimizar funções que são a soma dos quadrados de outras funções não-lineares. Este método é muito importante no treinamento de redes neurais e seu índice de desempenho é dado como erro quadrático médio (*mean squared error*, **MSE**).

Em uma RNA de múltiplas camadas, o algoritmo de retropropagação do erro (*backpropagation*) padrão utiliza o método do gradiente decrescente no decorrer do processo de aprendizagem, de forma a minimizar a função erro. Já o algoritmo Levenberg-Marquardt utiliza uma aproximação pelo método de Newton, **Haykin (2009)**; esta aproximação é obtida a partir do método de Gauss-Newton modificado. A atualização dos pesos através do método de Gauss-Newton é feita da seguinte forma:

$$W(n+1) = W(n) - [J^T(n)J(n) + \lambda I]^{-1} J^T(n)e(n) \quad (\text{A.17})$$

Onde:

n	Número da iteração;
W(n+1)	Matriz coluna de pesos sinápticos que serão utilizados na próxima iteração n+1;
W(n)	Matriz coluna de pesos sinápticos na iteração n;
λ	Taxa de aprendizado;
I	Matriz identidade;
E(n)	Matriz coluna de erros na iteração n;
J	Matriz jacobiana dos erros em relação aos pesos sinápticos.

λ é uma constante positiva pequena escolhida para assegurar que $(J^T(n)J(n) + \lambda I)$ seja definida positiva para todo n, **Barbosa (2010)**.

A-4 Predições de Séries Temporais

A predição de séries temporais é o processo de prever valores futuros de uma série temporal a partir de valores passados conhecidos. No trabalho apresentado se quer prever as séries temporais de sistemas flutuantes em mar real, como por exemplo, prever as séries temporais de roll de um navio porta-contentor em condições de mar real, com a intenção de reconhecer o aparecimento da ressonância paramétrica em roll.

A-4.1 Análise de Séries Temporais

Uma série temporal é um histórico de observações feitas sequencialmente ao longo do tempo. Sendo o objetivo principal de poder fazer previsões de valores futuros da série temporal. Um dos métodos para a resolução ao problema de previsão de séries temporais é aplicando o modelo de Box & Jenkins para a geração de padrões de referência, **Box and Jenkins (1970)**. O modelo de Box & Jenkins são bem entendidos, porem são modelos lineares, pelo qual teria suas limitações no estudo dos fenômenos governado por relacionamentos não-lineares.

Em previsão de séries temporais são muitos fatores que influenciam o nível de acuraria, como são: disponibilidade dos dados, precisão atingível, custo de análise, dentre outros. A importância da escolha apropriada das variáveis, para isso, vai-se tentar algumas combinações possíveis a partir de estudos que explicitem quais de essas variáveis apresentam um maior grau de correlação, assim alcançar um melhor desempenho.

A-4.1.1 Modelos Convencionais para Previsão de Séries Temporais

Para realizar um processo de previsão de séries temporais de forma sistemática e científica, é necessário de representar as características da série temporal através de um modelo matemático/computacional, e assim que possa estimar a futuro tais características, e os métodos vão se classificar dependendo a complexidade do problema em análise.

a) Modelos de Box & Jenkins

Propuseram uma família de modelos algébricos (chamados modelos ARIMA, auto-regressivos integrados e de médias móveis) da qual foi escolhida um modelo de melhor desempenho de previsão de uma dada série temporal. A metodologia de Box & Jenkins para a previsão de séries temporais baseia-se no ajuste de modelos tentativos denominados ARIMA. O modelo ARIMA é o estudo algébrico que mostra como uma variável de uma série temporal (Z_t) é relacionada com seus próprios valores passados (Z_{t-1}, \dots, Z_{t-p}). Tal metodologia consiste em propor e ajustar modelos lineares estacionários (ou não-estacionários) a uma série de tempo observada, Box and Jenkins (1970).

b) Modelos Não-Lineares

Na literatura da previsão de séries temporais em sua grande maioria assume que: as séries temporais são estacionárias (ou que podem ser transformados em séries estacionárias), e que são processos lineares que podem ser analisados por modelos lineares. Mas na realidade as séries temporais têm estruturas não-lineares devido à natureza não-linear do meio que a forma. Para isso têm sido propostos muitos métodos não-lineares, entre esses

métodos que tem maior êxito na previsão de séries temporais são a inclusão das redes neurais artificiais, algoritmos genéticos, e outras técnicas de inteligência artificial. Neste trabalho vai-se focar na predição das séries temporais por meio de redes neurais artificiais.

A-4.1.2 Decomposição Clássica de Séries Temporais

Para uma melhor observação das propriedades de uma série temporal $X(t)$ pode ser descomposto da seguinte forma:

$$X(t)=T(t)+S(t)+ CS(t)+E(t) \quad (A.18)$$

Tendência $T(t)$

Podemos pensar em tendência como padrões no nível dos processos, sendo a variação de um período a outro atribuído a uma tendência mais uma variação aleatória.

Sazonalidade $S(t)$

São padrões que se repetem a intervalo regulares, ou que variam ciclicamente no tempo, como em processos periódicos. E o modo de conhecer a sazonalidade da série temporal é pelo conhecimento da fenomenologia da série temporal.

Ciclos Senoidais $CS(t)$

Processos que apresentam um desvio cíclico em torno de uma tendência com uma frequência não muito bem definida. Este tipo de componente cíclico é possível modelar utilizando o comportamento amortecido de uma senoide, **Calôba (2002)**.

Erro $E(t)$

Apresentadas as três primeiras componentes "regulares" de uma série, agora se analisará o erro, componente "irregular" da série temporal, que vem a ser a alteração brusca e não previsível no sistema que gera a série temporal, **Calôba (2002)**. Componente aleatória ou ruído.

A-4.2 Processamento Temporal

O tempo é um elemento importante que faz parte da vida cotidiana e em muitos dos problemas reais são definidos em função dele. Isto faz deste um parâmetro importante em diferentes áreas como no processamento de sinais (na qual estamos interessados). As estruturas computacionais convencionais ainda não são boas o suficiente para lidar com reconhecimento de padrões que mudam com o tempo ou padrões dinâmicos, pois, não são capazes de representá-lo adequadamente. Para isto são necessárias novas estruturas capazes de representar a evolução temporal dos padrões. As redes **PMC** tradicionais não possuem a estrutura adequada para lidar com padrões dinâmicos, portanto, são necessários alguns ajustes em seu treinamento. Uma maneira de adaptar o treinamento é transformar os dados originalmente dinâmicos em dados estáticos através do atraso no tempo.

As arquiteturas dinâmicas devem possuir memória para que os processamentos realizados em momentos anteriores sejam considerados, Elman (1990). Existem basicamente duas maneiras de prover memória a uma RNA, estas são:

1. Introduzir atraso do tempo (técnica de Janela de Tempo, TDNN (*Time Delay Neural Network*)).

2. Por médio de arquiteturas recorrentes como: redes Elman e redes Jordan.

A metodologia utilizada neste trabalho para as predições de séries temporais é através do atraso do tempo utilizando a técnica de Janela de Tempo.

A-4.3 Rede Neural PMC com Atraso no Tempo e Janela de Tempo

As redes neurais **PMC** foram concebidas para executar tarefas de natureza estática, mas não para tratar com problemas temporários de natureza dinâmica. O método atraso no tempo para os dados de entrada foi uma das primeiras adaptações da rede **PMC** treinada com algoritmo de *backpropagation* para o processamento dinâmico. Para essa adaptação é necessário introduzir o atraso no tempo através dos padrões de entrada, mediante a técnica da Janela de tempo.

Esta técnica consiste ao usar redes neurais **PMC** para previsão de séries temporais, e definimos como entrada um conjunto de valores passada ordenados no tempo e como saída o valor posterior a esta sequência (valor único), **Haykin (2009)**. Por tanto, é necessário realizar um processamento na série original, que é feito através do modelo descrito (**equação (A.19)**).

A predição de valores posteriores ao instante do tempo **t**, associados ao comportamento do processo, os quais são computados em função do conhecimento de seus valores temporais anteriores, representados pela seguinte **equação (A.19)**:

$$Z(t) = f(Z(t-1), \dots, Z(t-p)) \quad (\text{A.19})$$

Onde, $Z(t)$ é o valor da série a ser estimada correspondente ao tempo **t**, **p** é o tamanho da janela de tempo. Tomemos como base a série $Z(1), Z(2), Z(3), Z(4), \dots, Z(n)$, (**tabela A.1**), com o tempo variando de 1 a **n**. Durante o treinamento, a ideia é fornecer como entradas

valores sucessivos da série, por exemplo, os valores de $Z(1)$, $Z(2)$ e $Z(3)$, e definir que a saída desejada é o valor $Z(4)$, cujo resultado é explicitado pelo valor $Y(t=4)$ fornecido pela saída da rede neural. Assim no processo de treinamento, a rede tentará ajustar os pesos sinápticos visando minimizar o erro (produzido pela diferença do valor desejado e o valor da saída da rede). Na segunda iteração, os valores das entradas seriam $Z(2)$, $Z(3)$ e $Z(4)$ e a saída desejada $Z(5)$ com o respectivo valor $Y(5)$ da saída da rede, para o cálculo do erro da iteração. E assim sucessivamente se repete o processo de iteração para o restante dos pontos da série (**ver tabela A.1**) até atingir o critério de parada, donde a rede já estará em condição de fazer a predição de outra série diferente a do treino. O número de valores passados usados como inputs é chamado de ordem de linha, atraso ou janela. No exemplo citado, usamos 3 valores para prever o próximo, logo, a janela foi de ordem 3. A arquitetura mostrada na **Figura A.12** é um exemplo de **PMC** que poderia ser aplicado ao exemplo citado.

Tabela A.1: Entradas e saídas desejadas para o treinamento da rede PMC.

Entradas	Saída desejada
$Z(1), Z(2), Z(3)$	$Z(4)$
$Z(2), Z(3), Z(4)$	$Z(5)$
$Z(3), Z(4), Z(5)$	$Z(6)$
$Z(4), Z(5), Z(6)$	$Z(7)$
...	...
$Z(n-3), Z(n-2), Z(n-1)$	$Z(n)$

Ainda sobre a **Figura A.11**, observa-se que o número de unidades de entrada varia de acordo com o tamanho da janela adotado (no exemplo citado o tamanho da janela foi 3). Como acontece em redes **PMC** convencionais, os nodos da camada de entrada não realizam nenhum processamento sobre os padrões de entrada. O processamento é feito

nas camadas intermediárias com funções de transferência não-lineares, tais como a *tangente hiperbólica* e *sigmoide*. Como também se realiza processamento nas unidades da camada de saída (no método citado, existe apenas uma). Na camada de saída é apropriado que façam uso de funções de ativação lineares, pois, elas vão gerar o resultado previsto pela rede e não é interessante que este valor seja limitado entre 0 e 1, como ocorre, por exemplo, quando a função *sigmoide* é usada.

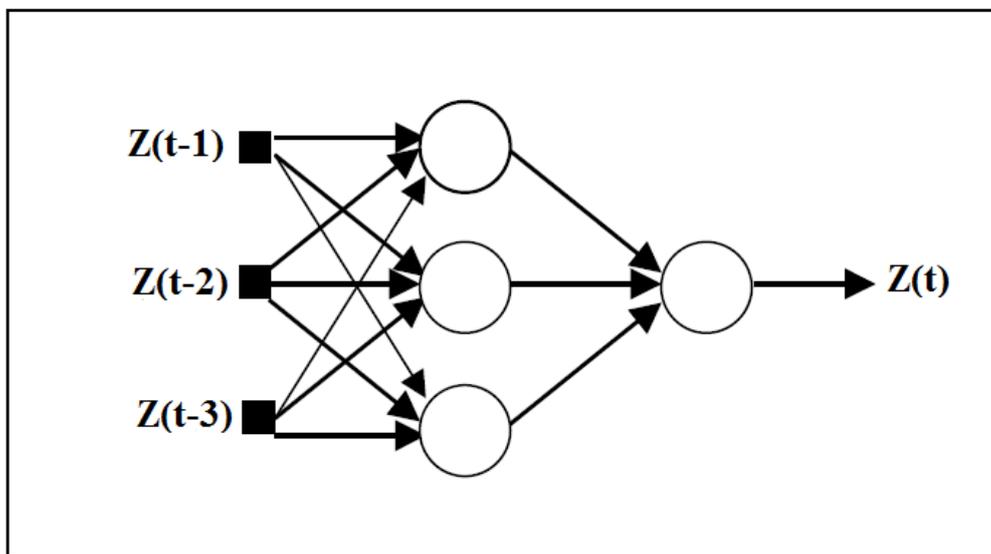


Figura A.11: Rede PMC com janela de tempo com tamanho de 3

Note que o processamento temporal é realizado apenas nos padrões de entrada, logo, é necessário tornar a série estacionária, de modo que suas propriedades estatísticas, como variância e média, variem pouco com o tempo. Séries estacionárias são mais fáceis de prever, uma vez que, suas propriedades estatísticas futuras serão as mesmas do passado.

A-5 Tipos de Função de Ativação

A função de ativação define a saída do neurônio em termos do seu nível de ativação interna. Podem ser identificadas as principais funções de ativação:

A-5.1 Função degrau. - Este tipo de função mostra-se na Figura (A.12):

$$a = \begin{cases} 1 & \text{se } n \geq 0 \\ 0 & \text{se } n < 0 \end{cases}$$

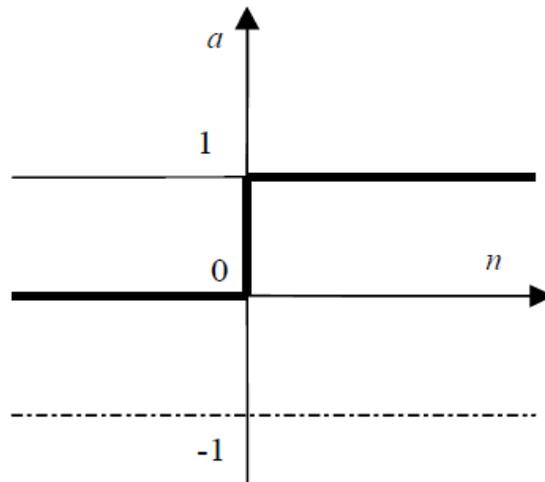


Figura A.12: Função degrau

A-5.2 Função linear por partes. - Para a função linear por partes, mostrada na figura seguinte, **Figura A.13**:

$$a = \begin{cases} -1, & \text{se } n \leq -b \\ n/b, & \text{se } -b < n < b \\ 1, & \text{se } n \geq b \end{cases}$$

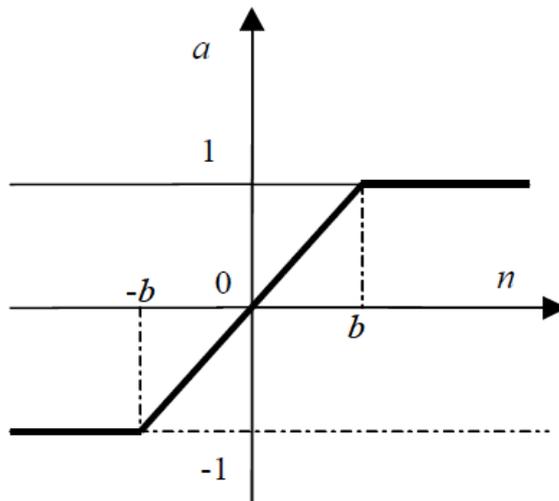


Figura A.13: Função linear por partes

A-5.3 Função sigmoide. - É a função mais utilizada em redes neurais de múltiplas camadas que são treinadas com o algoritmo de retropropagação do erro. Ela é definida como uma função monotônica crescente que apresenta propriedades assintóticas e de suavidade. Um exemplo de função sigmoide é chamado à função logística, **Figura A.14.** Definida por:

$$a(n) = \frac{a}{1 + e^{-an}}$$

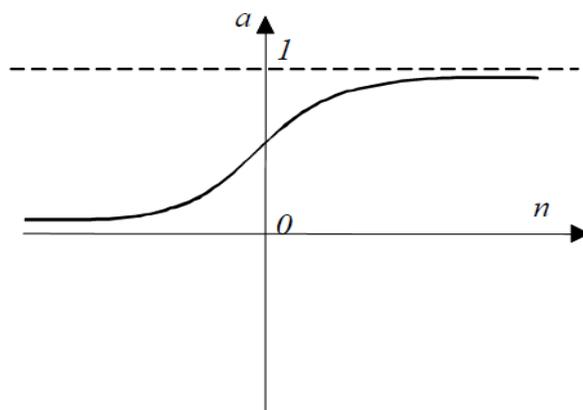


Figura A.14: Função logística

O parâmetro α é o parâmetro de inclinação da função sigmóide. Quando varia, podemos obter funções sigmóides com diferentes inclinações. Em muitas situações é desejável que a função sigmóide varie entre -1 e 1, e neste caso, a função normalmente empregada é a tangente hiperbólica. Dada por:

$$a(n) = \operatorname{tgh}\left(\frac{n}{2}\right) = \frac{1 - e^{-n}}{1 + e^{-n}}$$

A função de transferência usada neste trabalho é a função não linear tangente hiperbólica, Figura A.15 cuja gráfica esta apresentada a seguir:

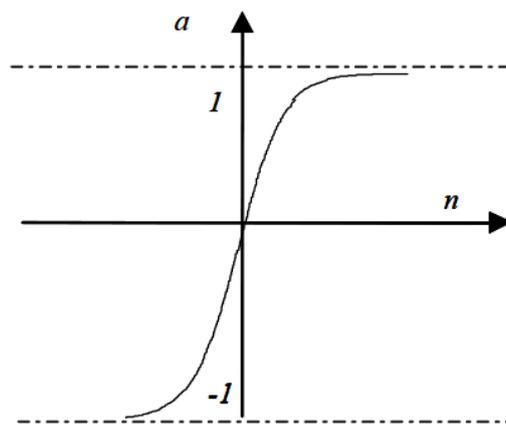


Figura A.15: Função tangente hiperbólica

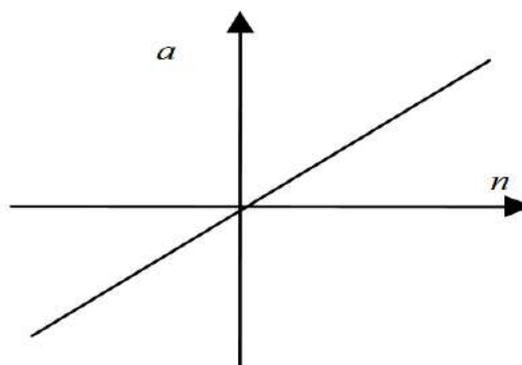


Figura A.16: Função linear

As funções lineares, **Figura A.16**, são geralmente usadas nos neurônios que compõem a última camada de uma rede neural e as funções sigmóides são as mais usadas nos neurônios das camadas intermediárias. Em grande parte dos problemas é necessária a normalização dos dados, já que as funções de ativação são normalmente limitadas superior e inferiormente com -1 e 1.

ANEXO B: Ressonância Paramétrica de Embarcações

B-1. Estabilidade e Perda da Estabilidade do Navio

A importância da análise de estabilidade do navio pelas razões citadas no texto da tese, enfatizaram a consideração do movimento de *roll* para o adequado estudo da estabilidade e impõe que se leve em conta vários fatores relevantes na análise da estabilidade em ondas (não-linearidades relacionadas ao amortecimento e à restauração hidrostática; o efeito da velocidade do navio, das características da onda incidente etc.).

Num dos trabalhos pioneiros realizados nos anos 70, **Paulling (1972)**, a partir de testes num modelo radio-controlado realizados na Baía de São Francisco (USA), foram identificados os modos dinâmicos mais frequentes da perda da estabilidade de navios, todos relacionados ao desempenho do navio em ondas incidindo pela popa da embarcação.

B-1.1 Estabilidade em Ondas Longitudinais

Em ondas longitudinais, tanto em mar de proa ou mar de popa, o perfil da superfície da onda ao longo do casco, juntamente com os movimentos verticais do navio, faz com que a geometria submersa do casco varie com o tempo. Essa variação se traduz na variação também do volume submerso e do braço do momento restaurador. Por conseguinte, a

variação da estabilidade estática transversal também estará variando no tempo. **ABS (2004)**.

Os movimentos verticais e a passagem da onda, ocorrendo simultânea e conjuntamente produzirão a variação das forças exteriores atuantes no casco.

B-1.1.1 Critérios de Estabilidade

Os critérios da estabilidade intacta para os navios, como regulado pelas normas da **IMO** (*International Maritime Organization*), adota recomendações cujas exigências visam garantir a segurança de todos os tipos de navios, procurando minimizar os riscos para pessoal a bordo e ao meio ambiente.

Na atualidade, os critérios de estabilidade são expressos em termos de valores mínimos de parâmetros da curva de restauração estática da embarcação (sem ondas); altura metacêntrica transversal, braço de restauração máximo e o ângulo de inclinação correspondente e a área sob a curva para uma dada faixa de ângulos especificados (tipicamente entre 30 e 40 graus) **IMO (1993)**.

Esses parâmetros decorrem de uma avaliação estritamente estática, não incorporando efeitos associados à dinâmica envolvida na interação da embarcação com as ondas presentes no mar real. Nas últimas décadas tem-se discutido e questionado muito a eficácia dos atuais critérios de estabilidade baseados em parâmetros puramente estáticos.

B-1.1.2 Perda Simples de Estabilidade

Este modo quase-estático ocorre com o navio operando em altas velocidades e com a onda incidindo pela popa. Nesse caso o navio navega acima da onda, fazendo coincidir, aproximadamente, a crista da onda com a região meia nau da embarcação. O braço de restauração hidrostática diminui em decorrência da redução do volume submerso do casco, gerando uma conseqüente perda de P estabilidade transversal. Se esta configuração tiver uma duração de tempo considerável, este modo acarretará uma perda total da estabilidade, e eventualmente, levando ao emborcamento da embarcação.

B-1.1.3 Broaching

Nesse caso, ocorre a perda da estabilidade direcional quando o navio navegando em mar de popa e também em altas velocidades. O fenômeno ocorre quando a velocidade de avanço se aproxima da velocidade de propagação da onda, levando a condição a frequência de encontro a um valor praticamente nulo. Nesse caso, a embarcação “surfa” a onda, provocando a perda da eficiência do leme, daí a perda do seu controle direcional. No *broaching* ocorre uma guinada brusca, posicionando a embarcação de través em relação à onda, podendo provocar o seu emborcamento.

B-1.1.4 Instabilidade Paramétrica

Este tipo de fenômeno está relacionado com a variação periódica do momento de restauração, como resultado da mudança da geométrica submersa, produzida pela posição das ondas com referência ao casco do navio. Este tipo de movimento geralmente se dá quando o navio está em ondas longitudinais ou oblíquas pela popa. Esta variação periódica das características restaurativas dá origem a uma excitação interna do navio em

ondas, sendo mais críticas dependendo da frequência da onda, comprimento e amplitude da onda, apresentando ângulos de roll em aumento progressivo, podendo levar o navio a emborcar.

B-1.2 Ressonância Paramétrica

Navios em condições de mar são excitados diretamente pelas ondas, gerando-se seus diferentes movimentos com seis graus de liberdade (**Figura B.1**). Sendo o movimento de roll uns dos mais críticos e perigosos, podendo apresentar condições ressonantes, quando a combinação de: frequência da onda, velocidade de avanço, e ângulo de incidência da onda, determinam uma **frequência de encontro** e posto em certas sintonias com referência a frequência natural de roll, pode gerar o fenômeno da ressonância. Este fenômeno, para certas características do sistema navio-onda, pode gerar grandes amplitudes do movimento de roll, e mesmo podendo embocar, dependendo do tipo de ressonância que apresente, seja ressonância clássica, ou ressonância paramétrica principal.

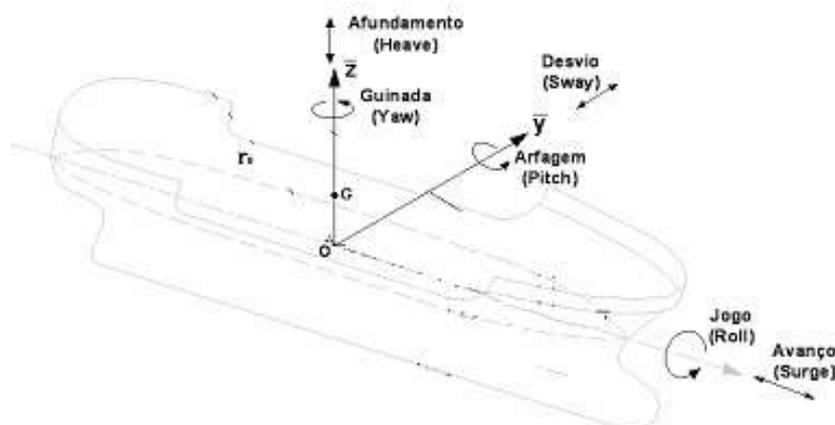


Figura B.1: Sistema de referência com seis graus de liberdade (Merino, 2007)

B-1.2.1 *Roll* ressonante clássico

No caso do *roll* paramétrico clássico é causado quando o navio é excitado diretamente pelas ondas do mar, e o navio que se encontra com certa velocidade de avanço, é atingido pelas ondas do mar com certa frequência e ângulo de incidência, dando-se uma frequência de encontro próxima a frequência natural de *roll*, fazendo que as oscilações em *roll* se amplifiquem, este tipo de *roll* pode ocorrer em ondas de traves ou em ondas oblíquas, já no caso de ondas longitudinais o *roll* clássico não é possível devido simetria do caso, evitando que se de oscilações em *roll*.

B-1.2.2 *Roll* paramétrico principal

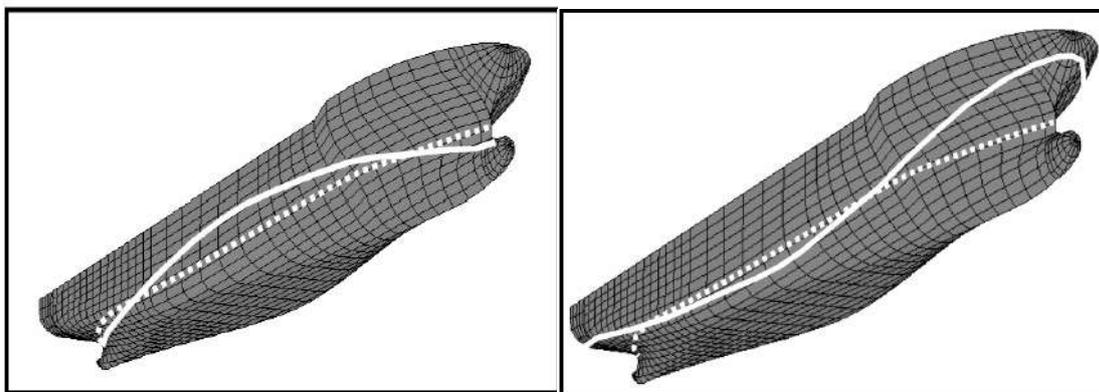
O navio especificamente em ondas longitudinais já seja em mar de proa ou popa, e que está com certa velocidade de avanço, atingem certas frequências de encontro, no qual, o movimento de *roll* pode ser auto excitado (excitação indireta) levando um incremento das oscilações em *roll*. Esta excitação indireta é usualmente conhecida como *roll* paramétrico, o qual é causado pela excitação interna devido às variações de certos parâmetros do sistema em oscilação no decorrer do tempo. Um dos primeiros investigadores a observar a existência deste fenômeno foi **Froude (1863)**.

B-1.2.2.1 Excitação Paramétrica

Este tipo de fenômeno se dá pela excitação indireta da onda longitudinal, sem nenhum tipo de excitação transversal da onda, as variações periódicas de alguns parâmetros internos do sistema (estabilidade transversal do navio) produzem a amplificação do movimento de *roll*.

As condições para surgimento da ressonância paramétrica é que o navio este navegando em ondas longitudinais, a frequência de onda seja o dobro da sua frequência natural de *roll*, e o comprimento de onda seja quase igual ao comprimento do navio. Quando essas condições ocorrem, a alternância periódica das cristas de onda e das cavas na meia nau do navio gera mudanças drásticas na estabilidade transversal do navio, determinando um rápido e súbito aumento das oscilações de *roll*. Para que esse tipo de auto-excitação tenha início é necessário a existência de alguma pequena perturbação externa para iniciar o movimento.

Para um comprimento de onda do mar próximo ao comprimento do navio, quando a crista de onda está situada na meia nau do navio (**Figura B.2.a**), a área do plano de flutuação é mínima e, portanto, os parâmetros de estabilidade (braços de **endireitamento (GZ)** e altura metacêntrica passam por um mínimo). Ao contrário, quando o cavado de onda está na meia nau do navio (**Figura B.2.b**), a área do plano de flutuação e os parâmetros de estabilidade atingem um máximo. Nesta situação, quando esta variação periódica dos parâmetros de estabilidade é ajustada corretamente (a frequência de encontro do navio em onda longitudinal é o dobro da frequência natural do *roll*), o movimento do *roll* começa a aumentar progressivamente.



a) Crista na meia nau

b) cavado na meia nau

Figura B.2 Posição da onda com respeito ao casco do navio (ABS, 2004)

O período de encontro entre o navio e a onda governa o movimento das ondas passando ao longo do navio, assim como os movimentos do navio no plano vertical (*heave* e *pitch*) que, em geral, são movimentos oscilatórios induzidos pela ação direta das ondas. Daí que, os braços de restauração e, conseqüentemente, a estabilidade transversal do navio oscilem com o período de encontro. O *roll* paramétrico ocorre em certas relações entre o período da variação da estabilidade transversal (período de encontro) e o período efetivo do movimento de *roll*, **Rodríguez (2004)**.

Na análise da estabilidade em ondas os múltiplos acoplamentos entre os movimentos de *heave*, *roll* e *pitch* são determinantes na definição das condições sob as quais o movimento em *roll* pode apresentar grandes ângulos ou até mesmo emborcar.

Pelas conseqüências negativas associadas à ocorrência do fenômeno da ressonância paramétrica existirá sempre grande interesse no desenvolvimento de um código computacional fundamentado em RNAs para avaliar a estabilidade de embarcações, em mar irregular, capaz de prever a série temporal em *roll*, código que está propondo nesta tese e que será desenvolvido no **MATLAB**.

Anexo C: Resultados Totais das Previsões da Ressonância Paramétrica

C-1 Resultados para o Navio SAFEDOR

O navio em estudo é um navio porta-contentor **SAFEDOR**. Para esse casco foram geradas séries temporais do seu movimento de *roll*, obtidas numericamente (três graus de liberdade) como proposto por **Rodríguez (2010)**, correspondentes a três espectros de mar diferentes.

C-1.1 Espectro I

Para o navio em estudo, navio **SAFEDOR**, considerou-se o espectro de mar **JONSWAP** com altura significativa (H_s) de 4.8 m, período de pico (T_p) de 10.63 s, $\gamma = 3.3$ e incidência 180° .

A RNA foi definida com 40 neurônios em cada camada escondida e uma base de dados de 40 séries temporais, da qual se escolheu aleatoriamente três séries temporais para fazer a predição.

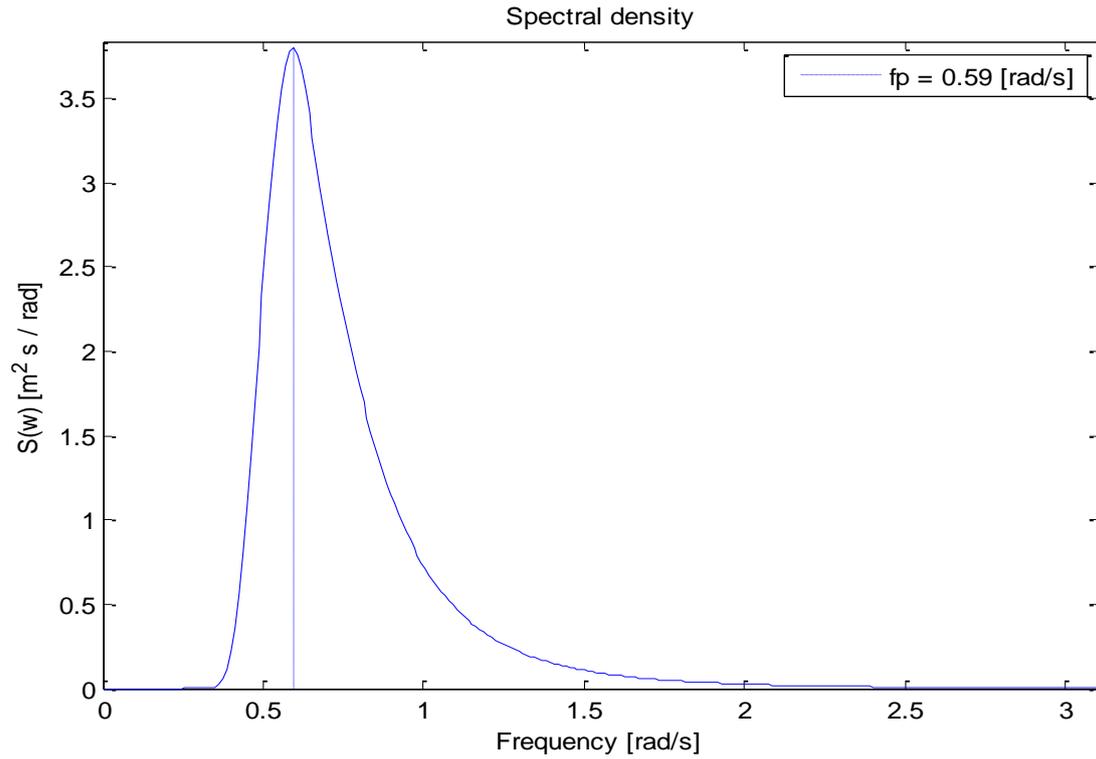


Figura C.1: Espectro JONSWAP com $H_s=4.8$ m, $T_p=10.63$ s, $\gamma = 3.3$

Para este espectro de onda, com 40 dados de entrada, se fez a predição de três séries temporais escolhidas aleatoriamente, para as quais foram adotadas seis diferentes janelas de tempo de predição: 10, 20, 30, 40, 50, 60s.

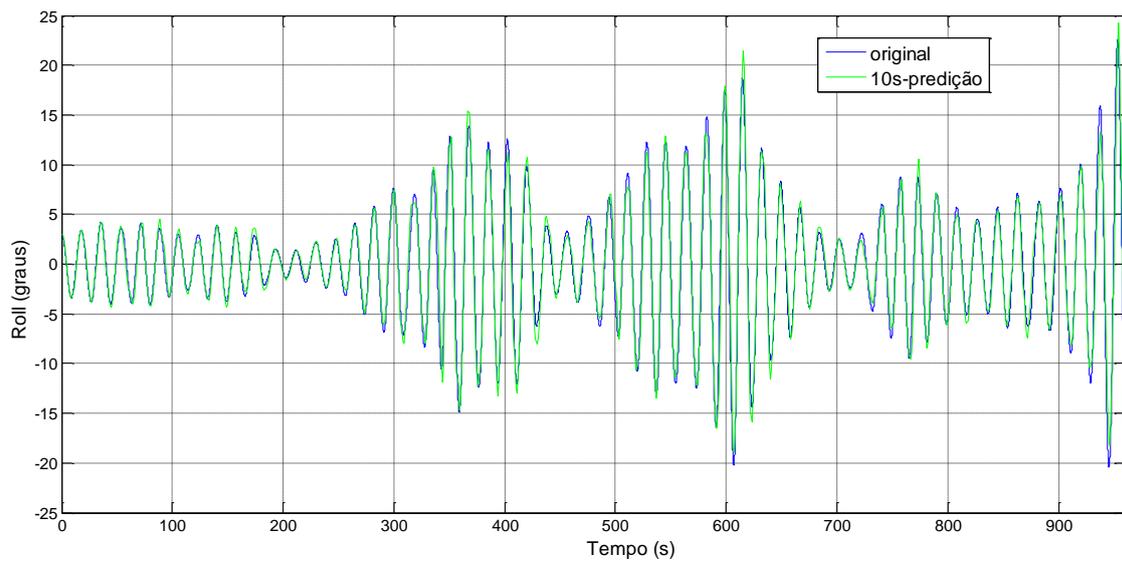


Figura C.2: Série Temporal 1: janela de tempo: 10s

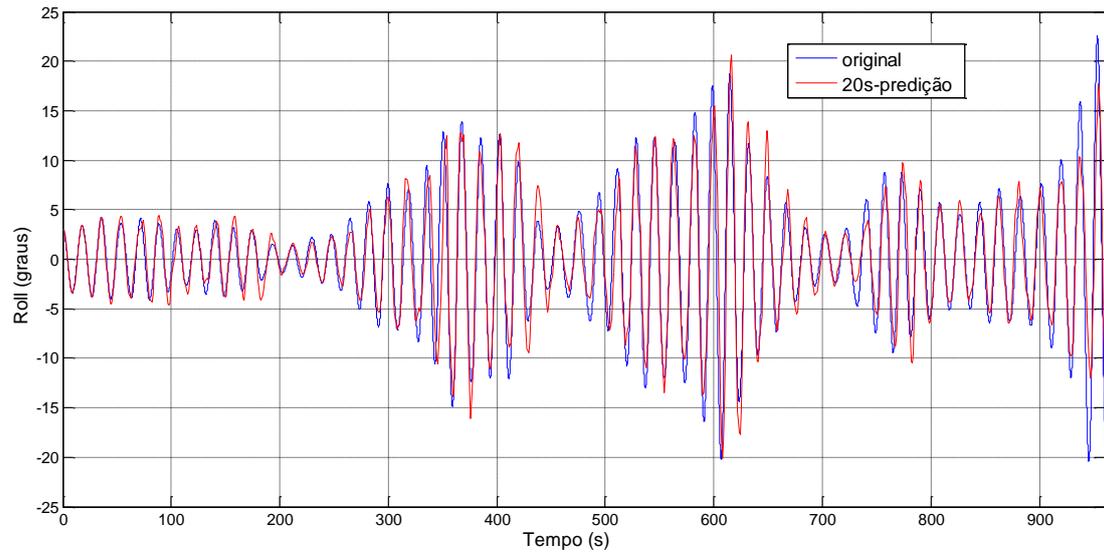


Figura C.3: Série Temporal 1: janela de tempo: 20s

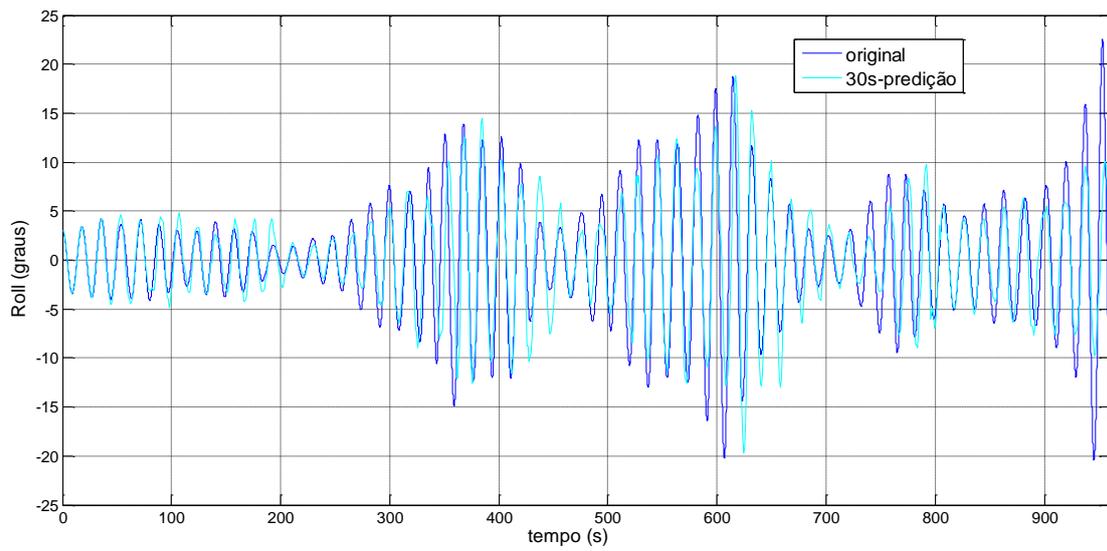


Figura C.4: Série Temporal 1: janela de tempo: 30s

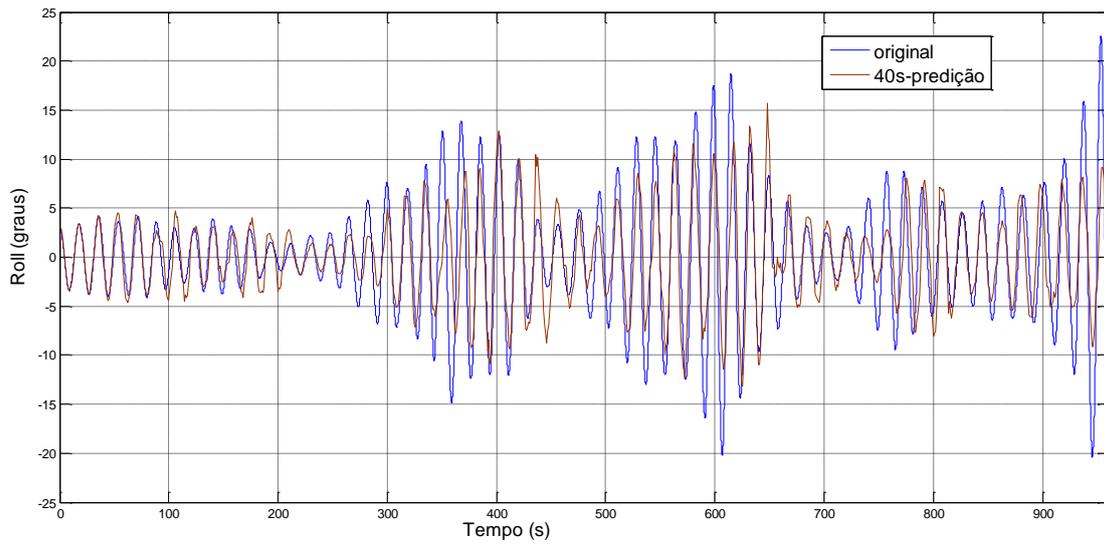


Figura C.5: Série Temporal 1: janela de tempo: 40s

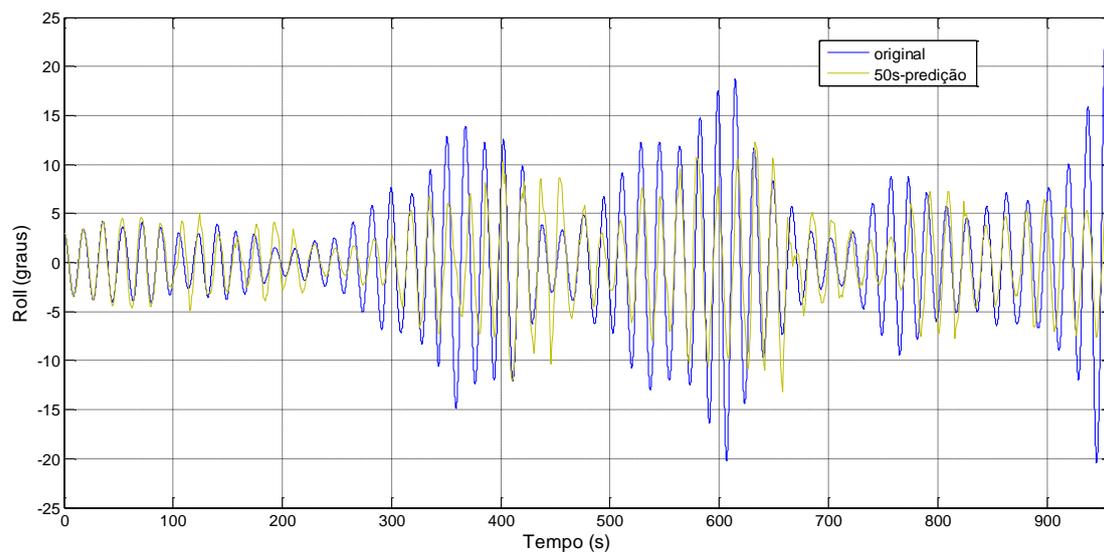


Figura C.6: Série Temporal 1: janela de tempo: 50s

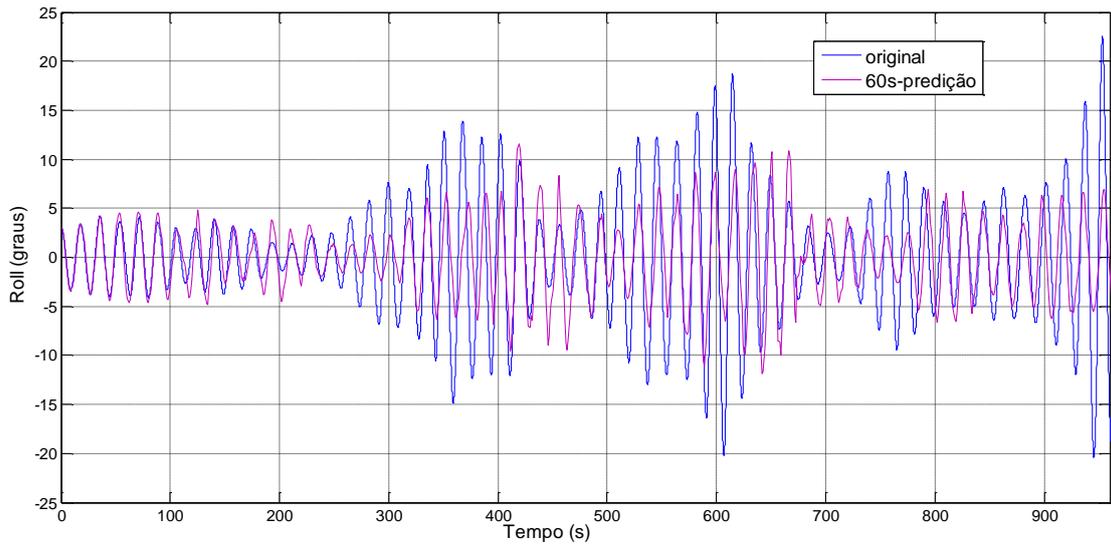


Figura C.7: Série Temporal 1: janela de tempo: 60s

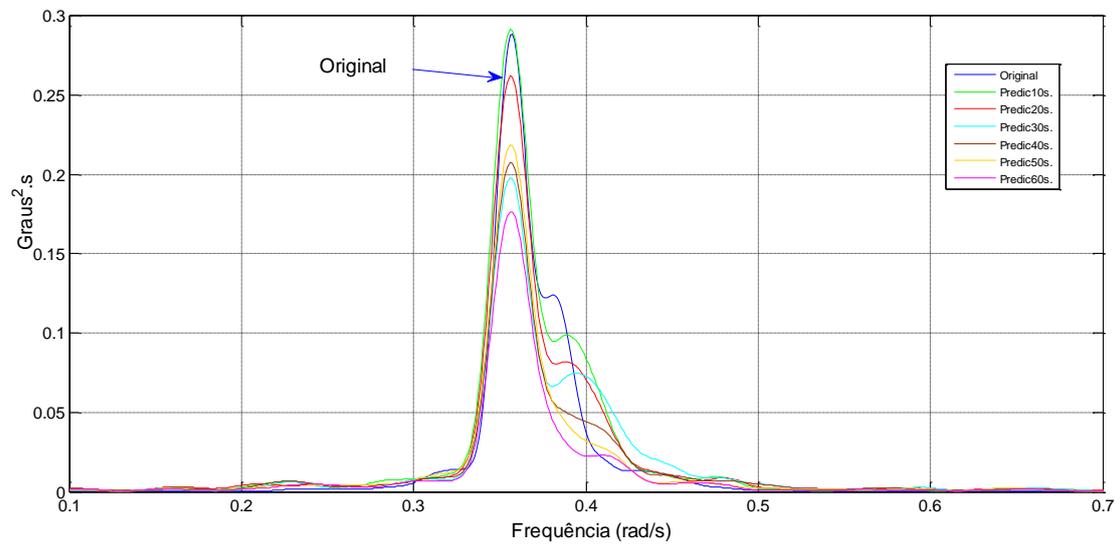


Figura C.8: Serie Temporal1: Transformada de Fourier das predições para as diferentes janelas de tempo de predição

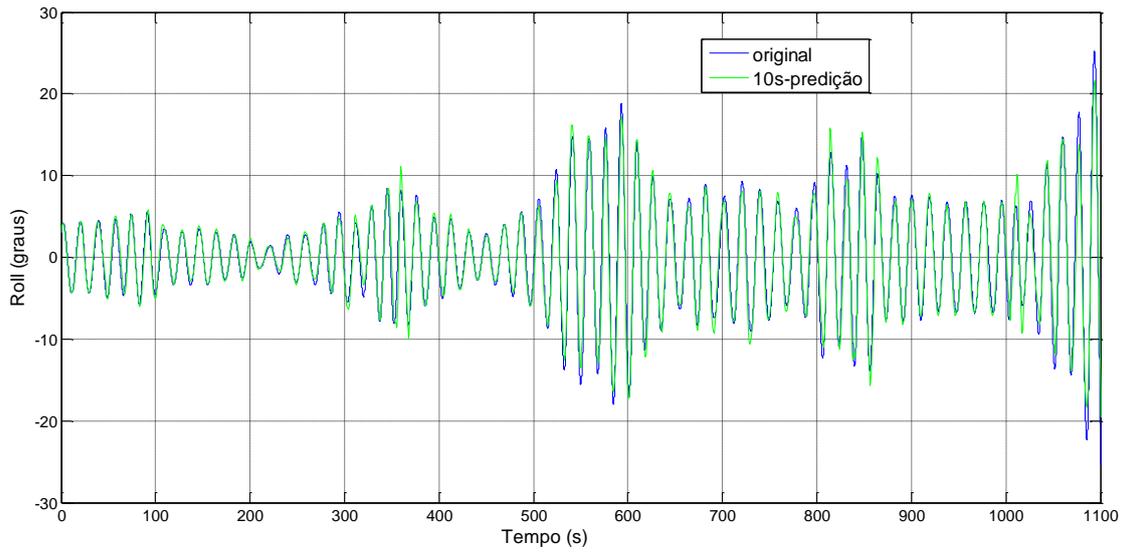


Figura C.9: Série Temporal 2: janela de tempo: 10s

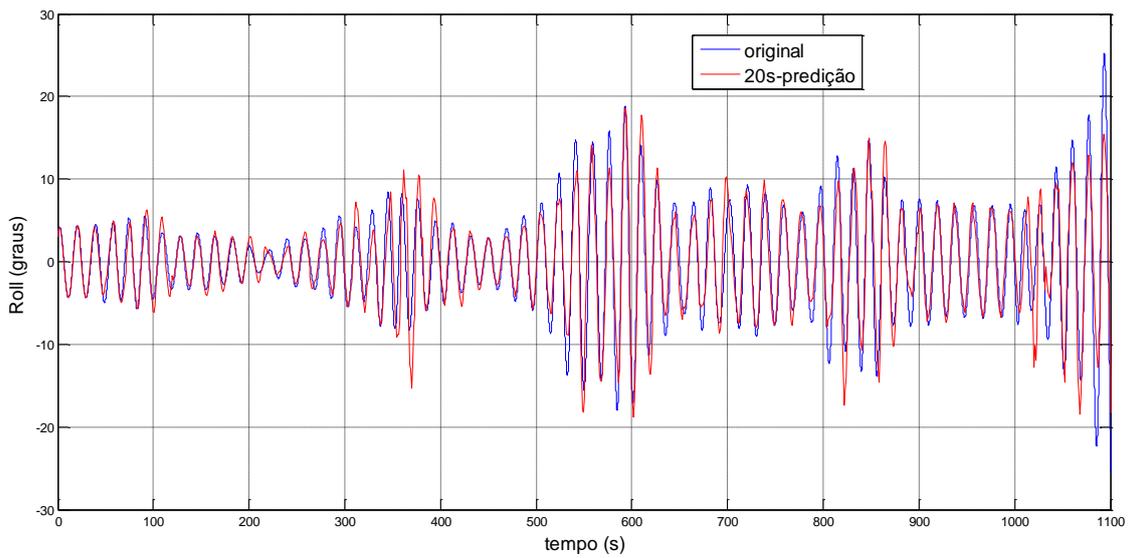


Figura C.10: Série Temporal 2: janela de tempo: 20s

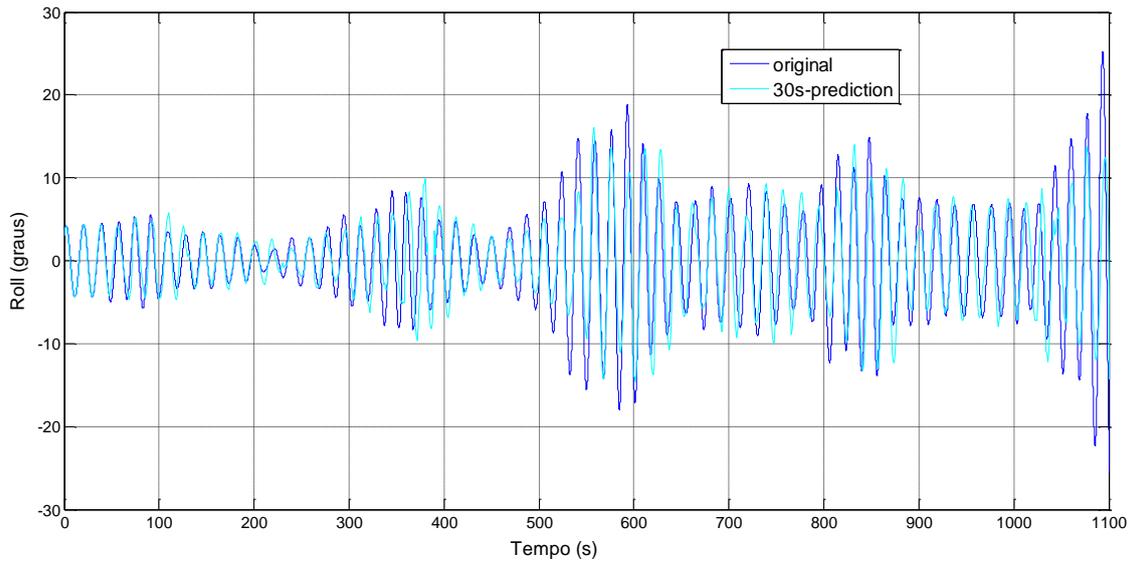


Figura C.11: Série Temporal 2: janela de tempo: 30s

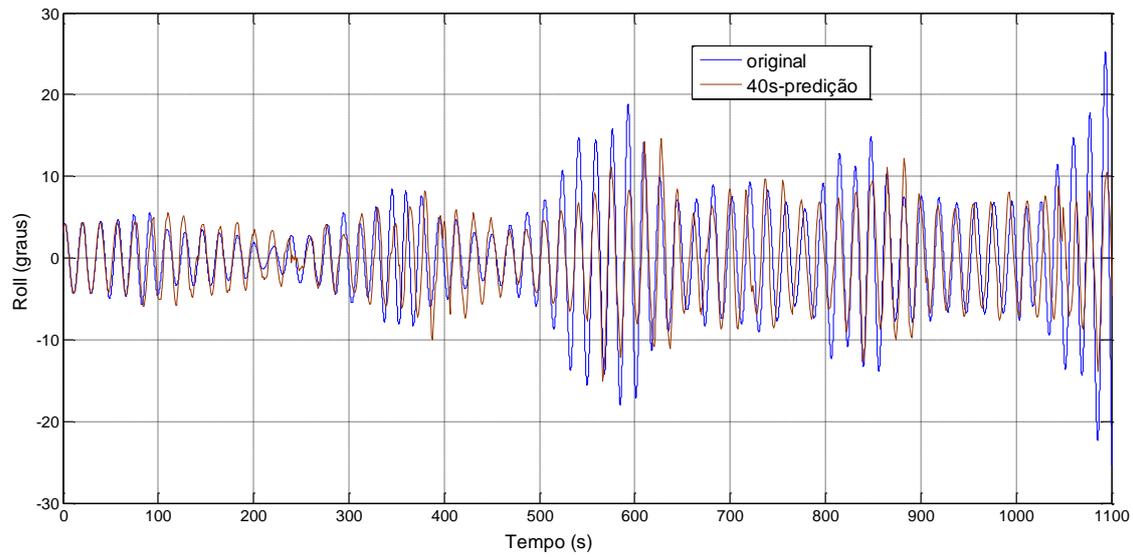


Figura C.12: Série Temporal 2: janela de tempo: 40s

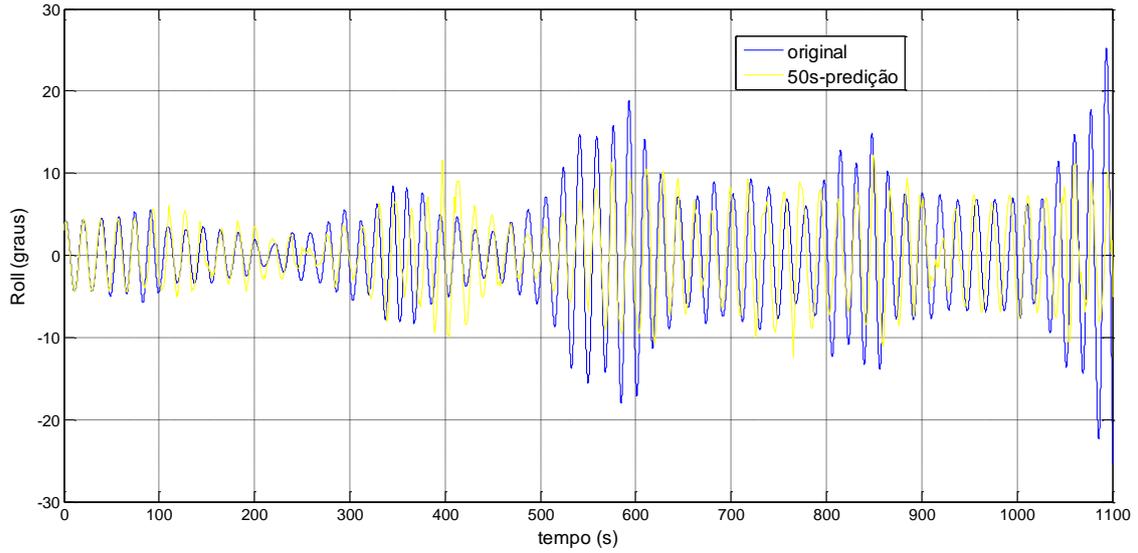


Figura C.13: Série Temporal 2: janela de tempo: 50s

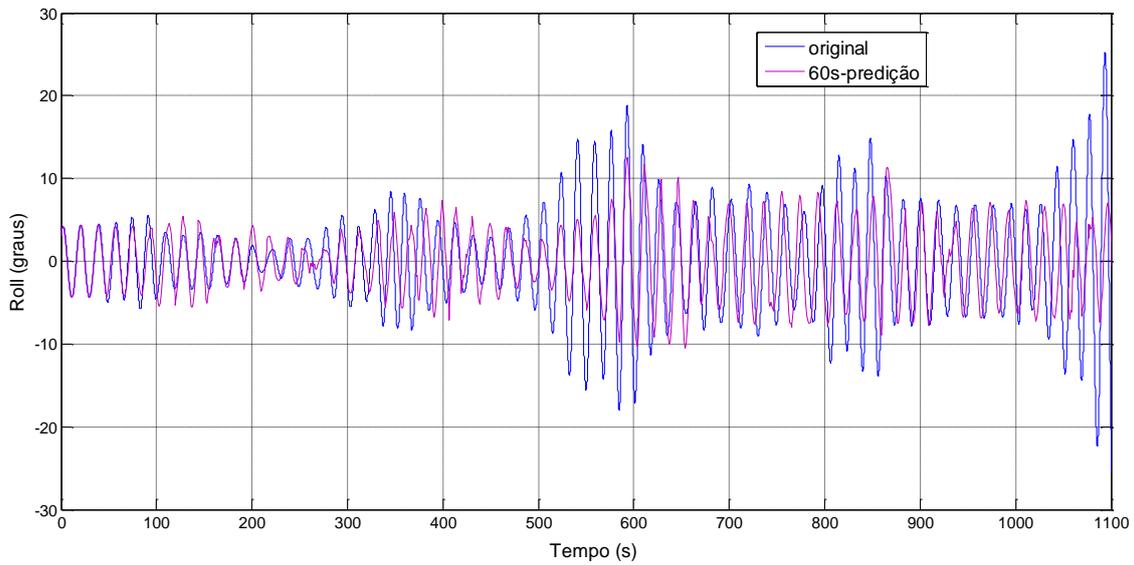


Figura C.14: Série Temporal 2: janela de tempo: 60s

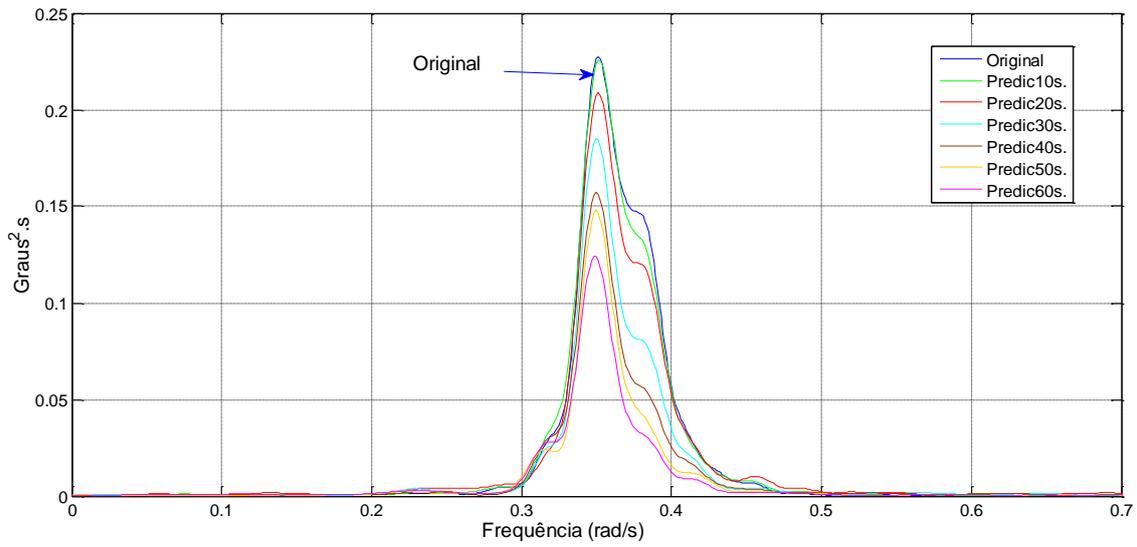


Figura C.15: Serie Temporal 2: Transformada de Fourier das predições para as diferentes janelas de tempo de predição

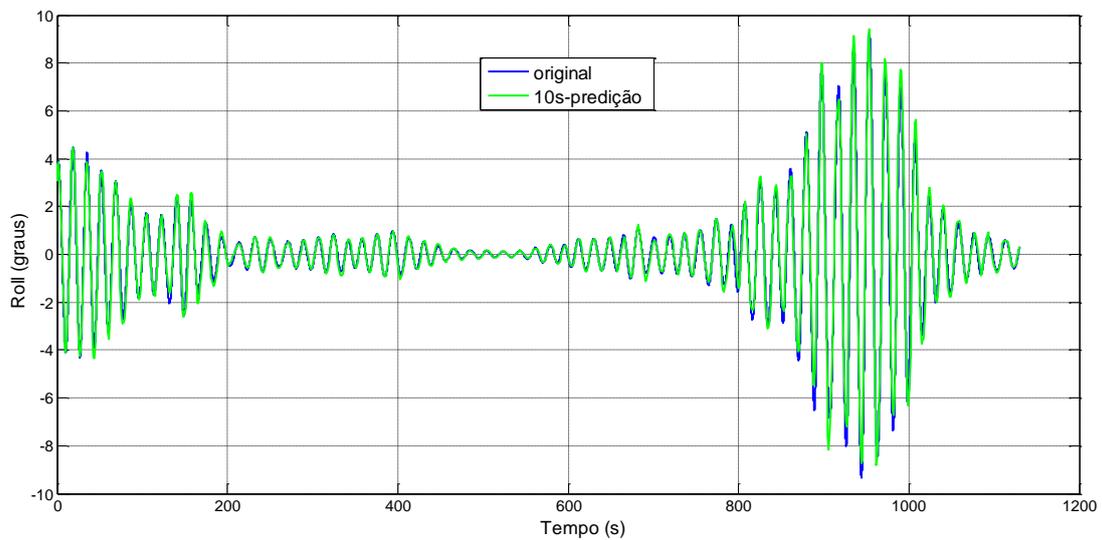


Figura C.16: Série Temporal 3: janela de tempo: 10s

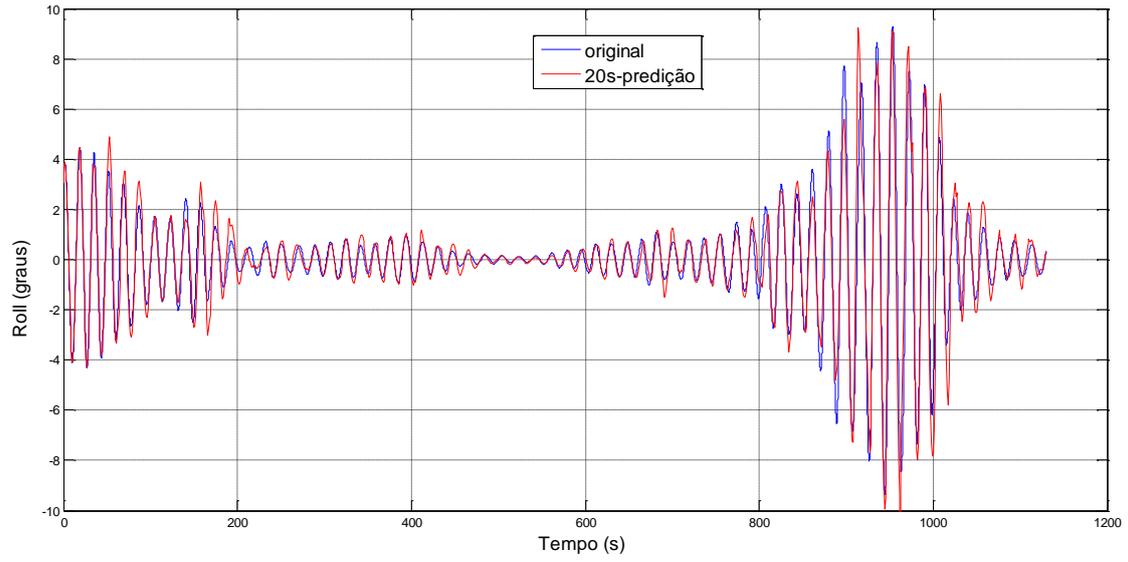


Figura C.17: Série Temporal 3: janela de tempo: 20s

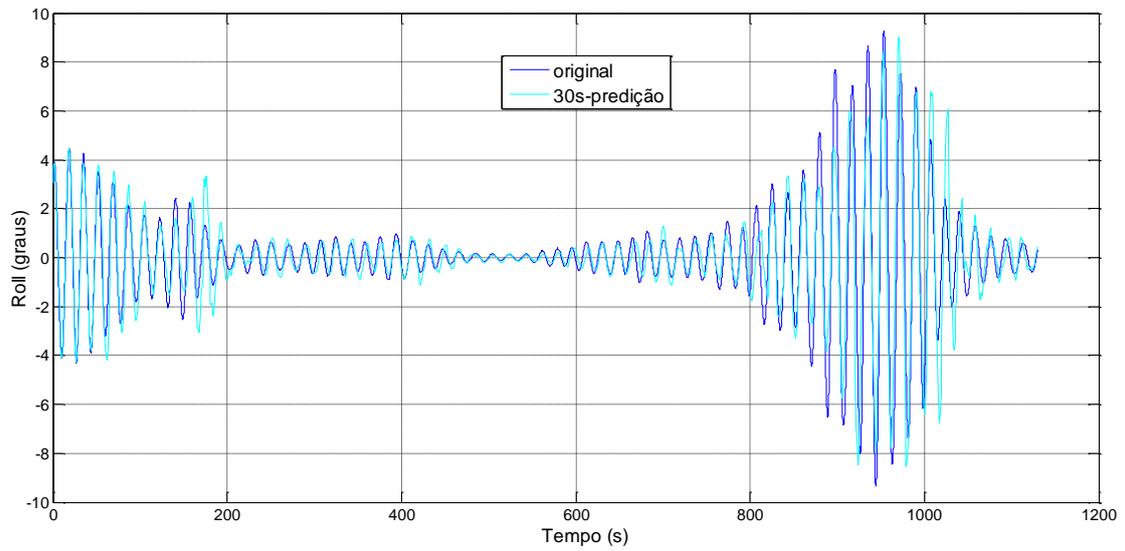


Figura C.18: Série Temporal 3: janela de tempo: 30s

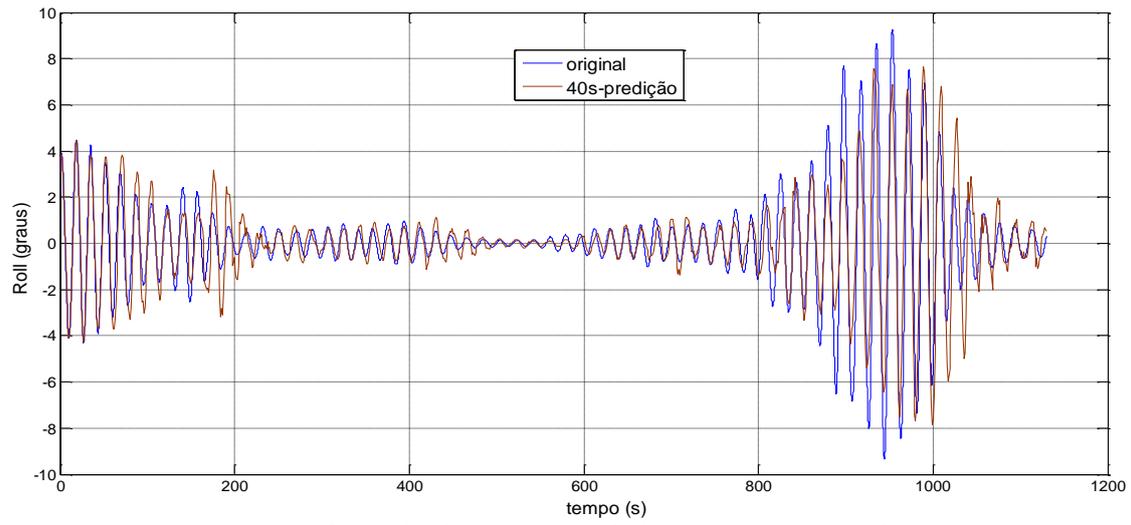


Figura C.19: Série Temporal 3: janela de tempo: 40s

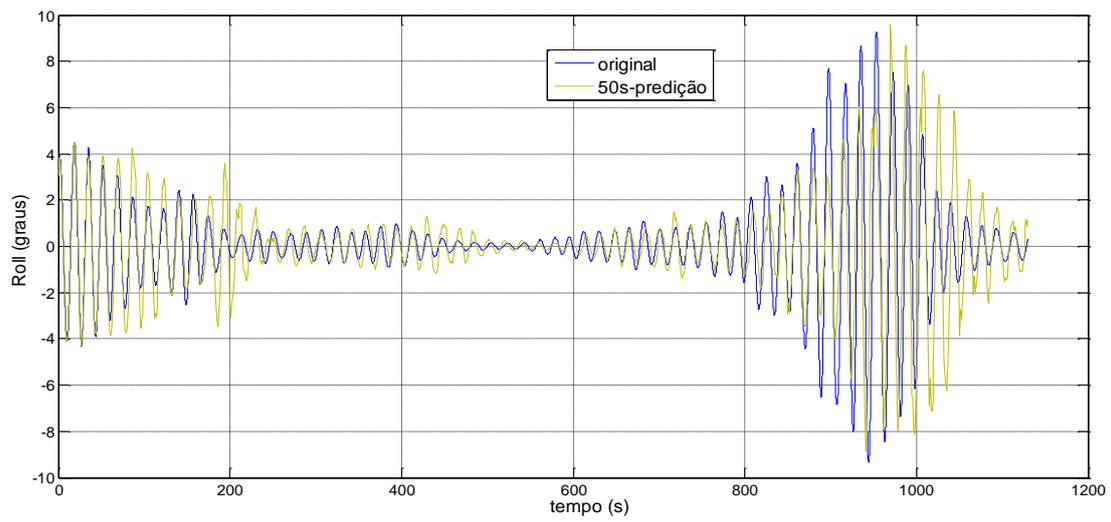


Figura C.20: Série Temporal 3: janela de tempo: 50s

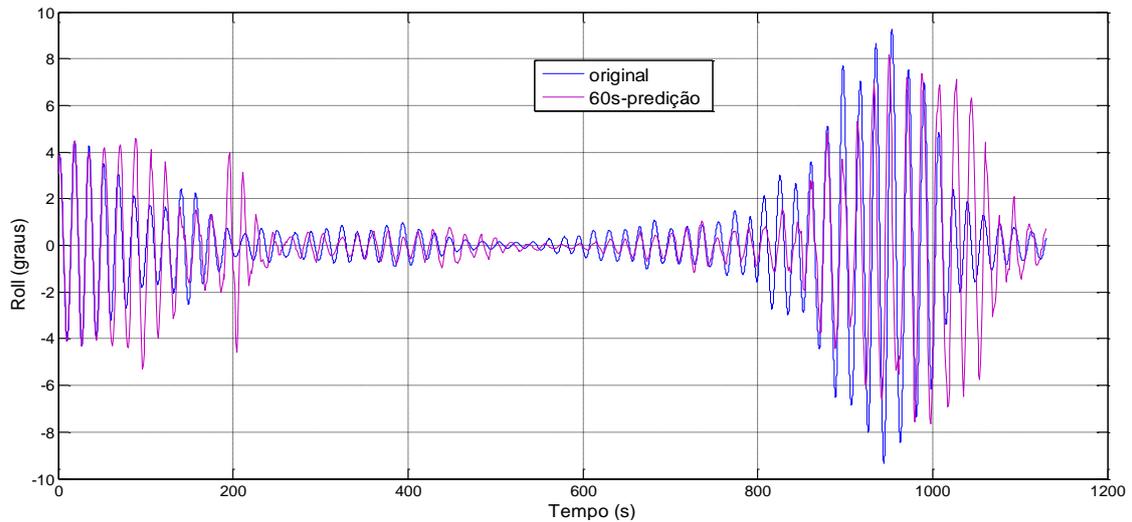


Figura C.21: Série Temporal 3: janela de tempo: 60s

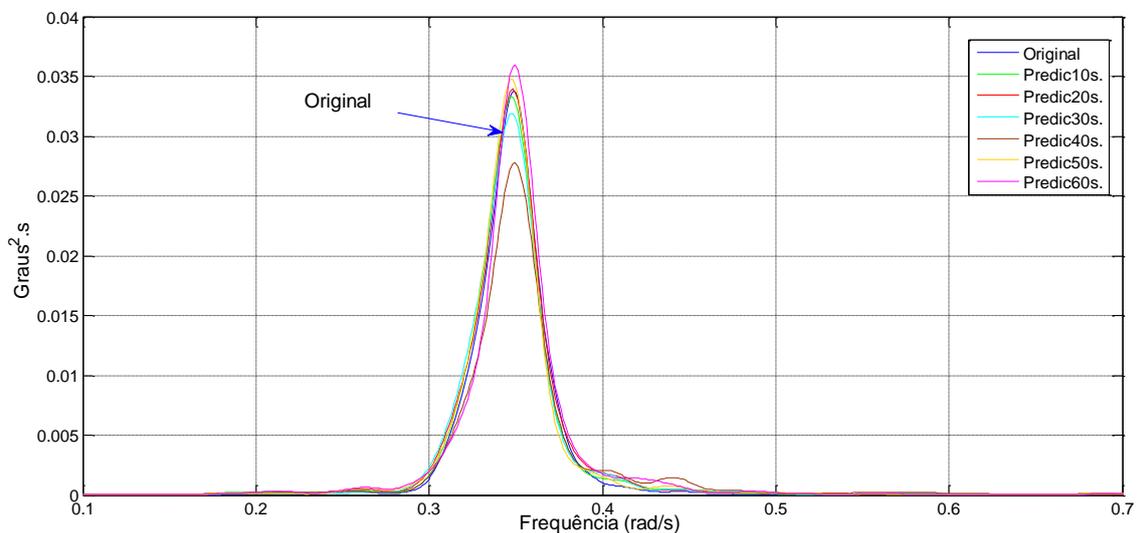


Figura C.22: Serie Temporal 3: Transformada de Fourier das previsões para as diferentes janelas de tempo de previsão

As Transformadas de Fourier das previsões, **Figura C.22**, mostram que as energias das séries preditas são próximas, já que, a energia das séries está concentrada no intervalo de 800 a 1050 segundos, sendo as diferenças neste intervalo pequenas. Para este caso, a previsão de 60 segundos tem valores maiores em comparação à série original, onde se pode observar tanto na série temporal predita como na gráfica das Transformadas de Fourier.

C-1.2 Espectro II

Os resultados da predição do navio **SAFEDOR** com um espectro de mar **JONSWAP** com altura significativa (H_s) de 5.00 m, período de pico (T_p) de 10.63 s, $\gamma = 3.3$ e incidência 180° .

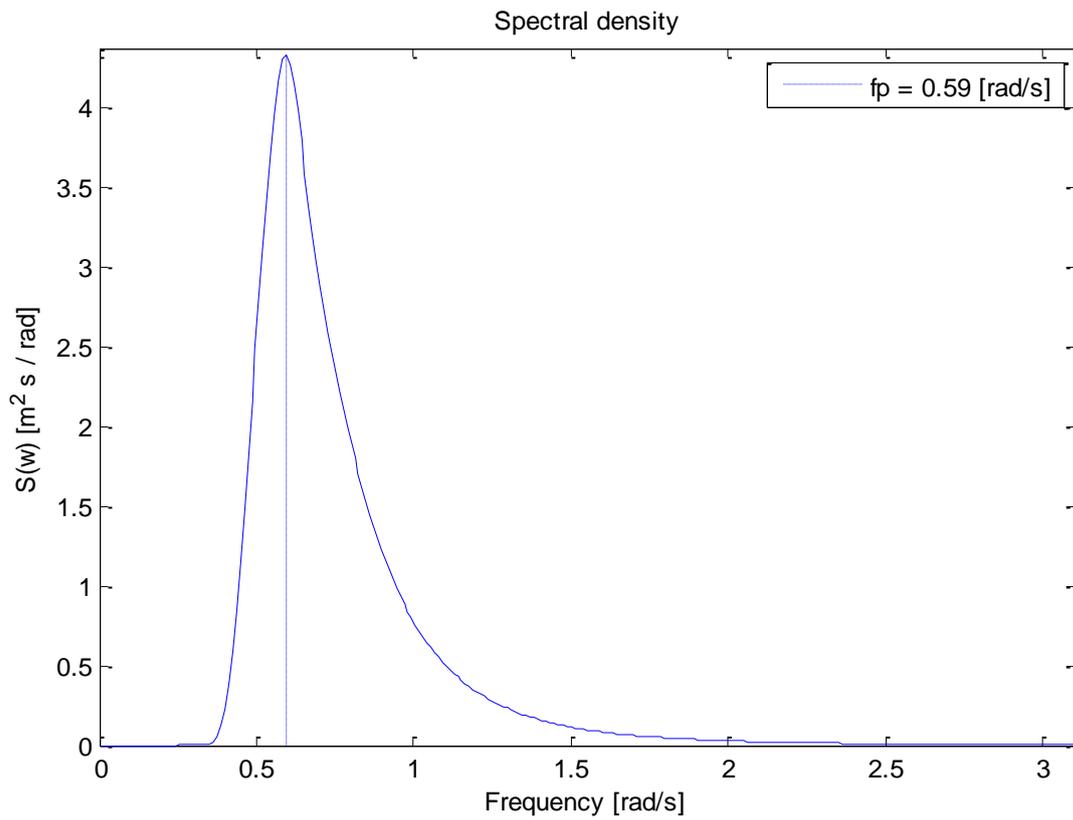


Figura C.23: Espectro II: JONSWAP com $H_s=5.0$ m, $T_p=10.63$ s, $\gamma = 3.3$

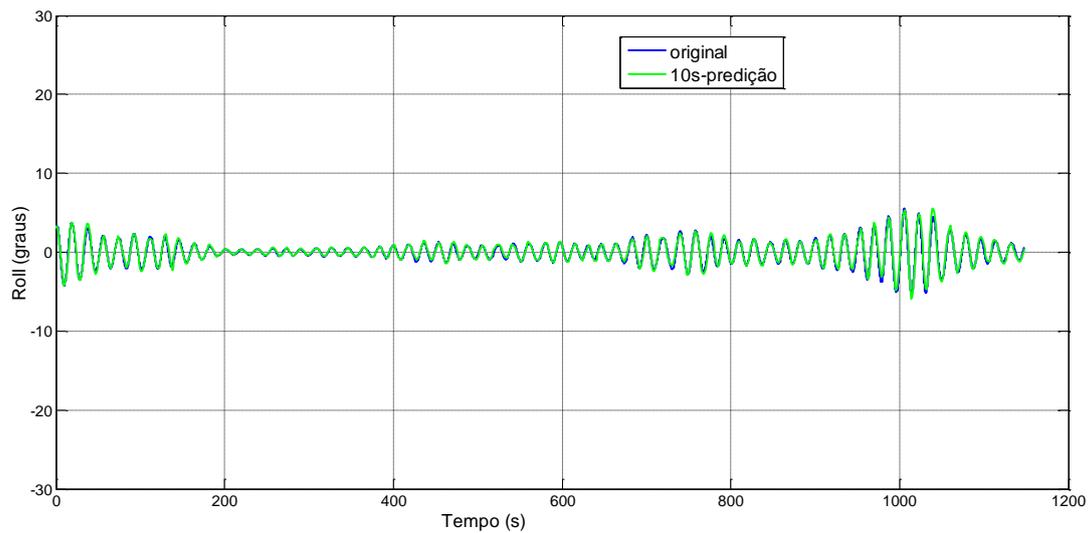


Figura C.24: Série Temporal 1: janela de tempo: 10s

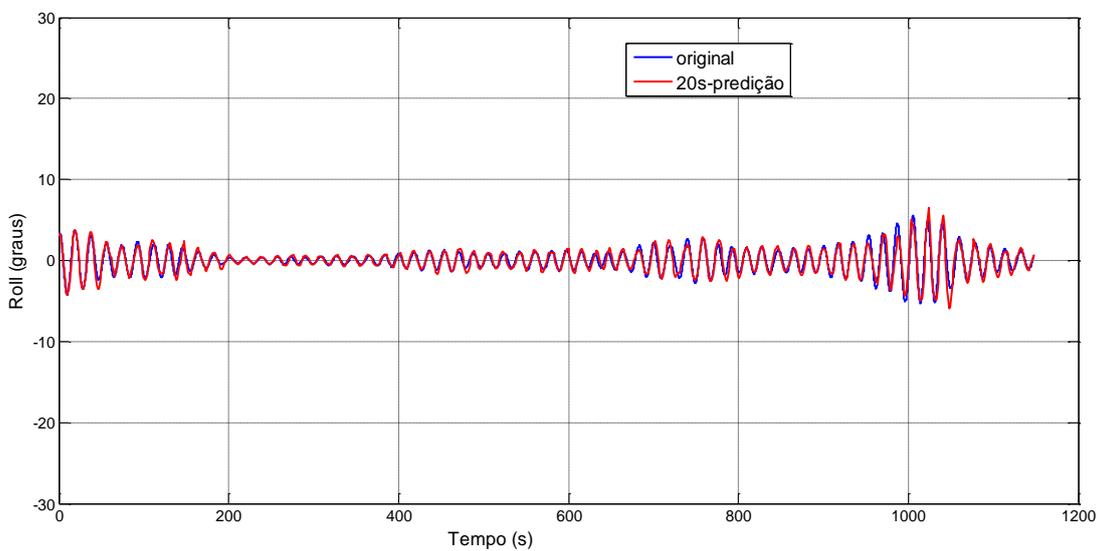


Figura C.25: Série Temporal 1: janela de tempo: 20s

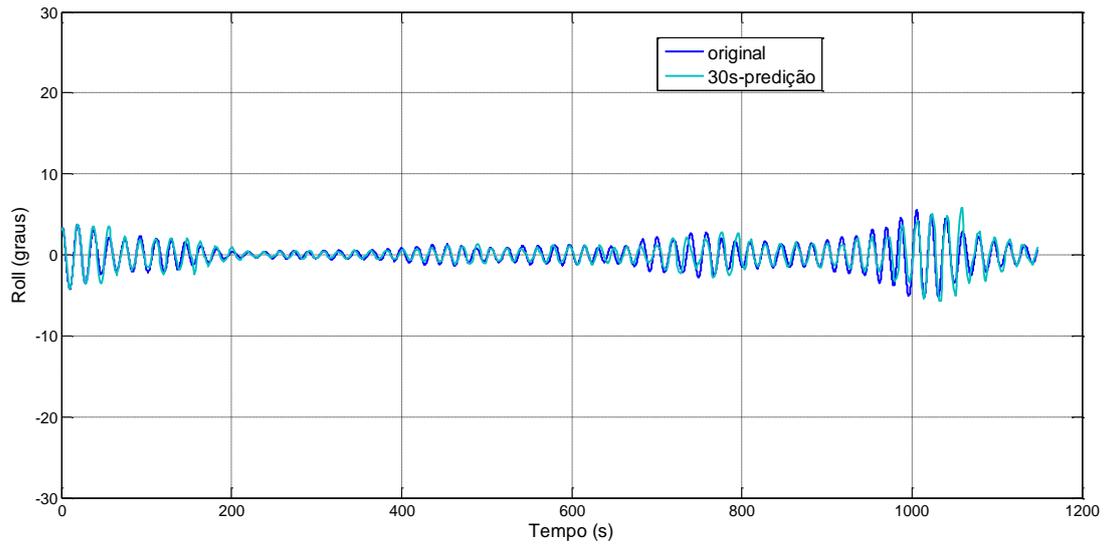


Figura C.26: Série Temporal 1: janela de tempo: 30s

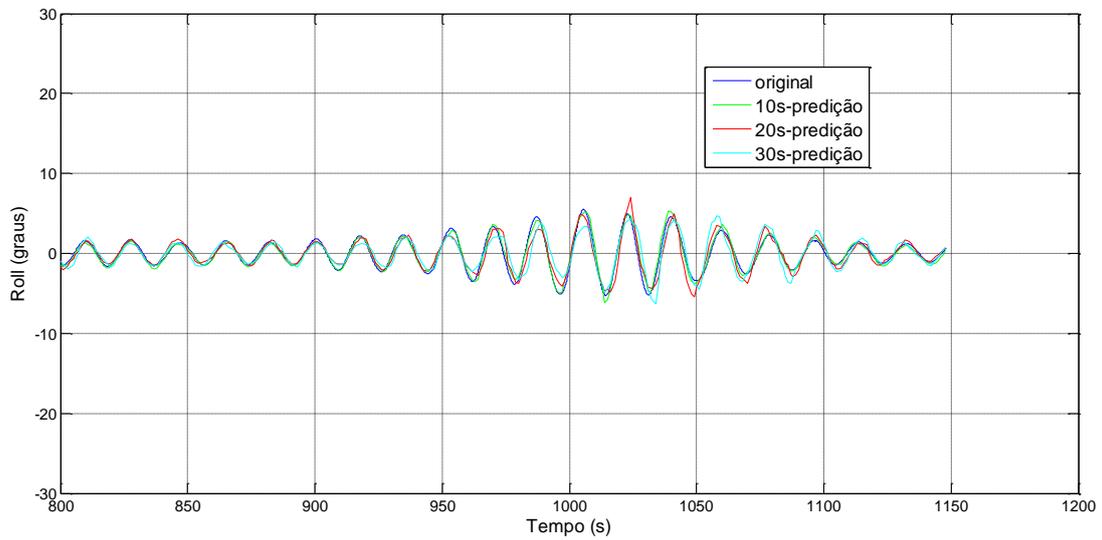


Figura C.26a: Intervalo de 800 a 1200s para três predições de roll

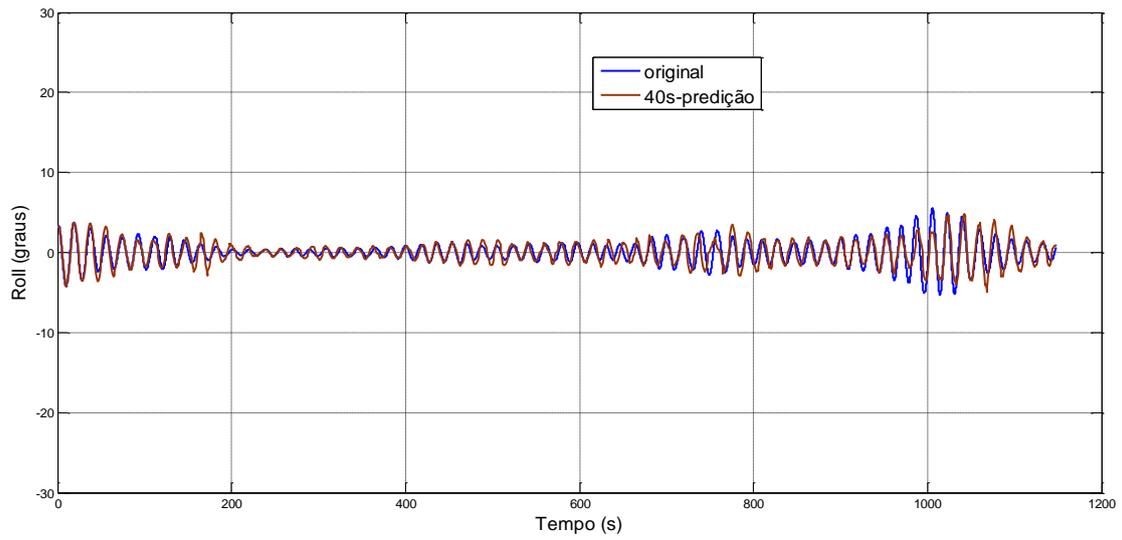


Figura C.27: Série Temporal 1: janela de tempo: 40s

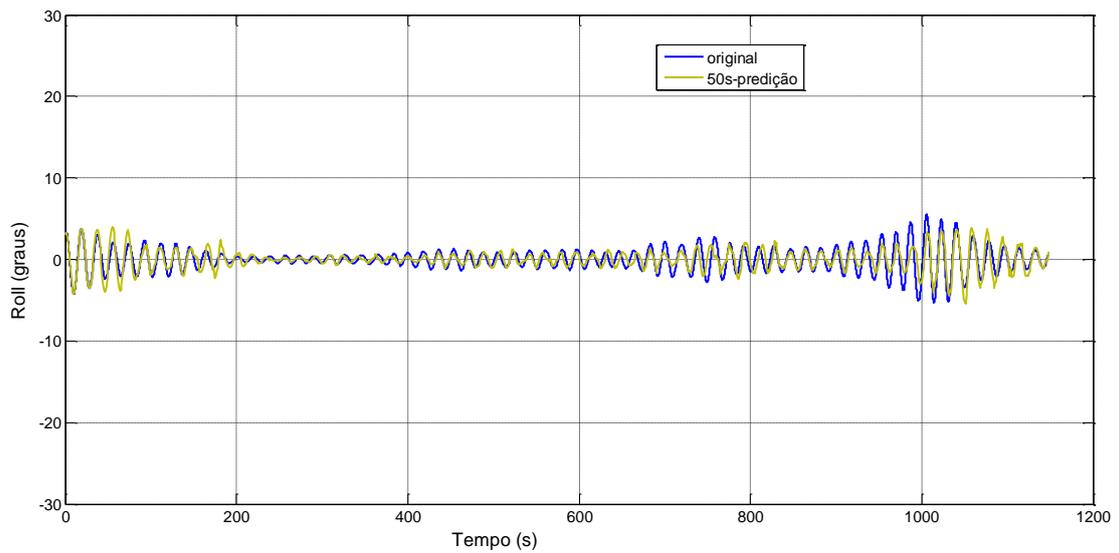


Figura C.28: Série Temporal 1: janela de tempo: 50s

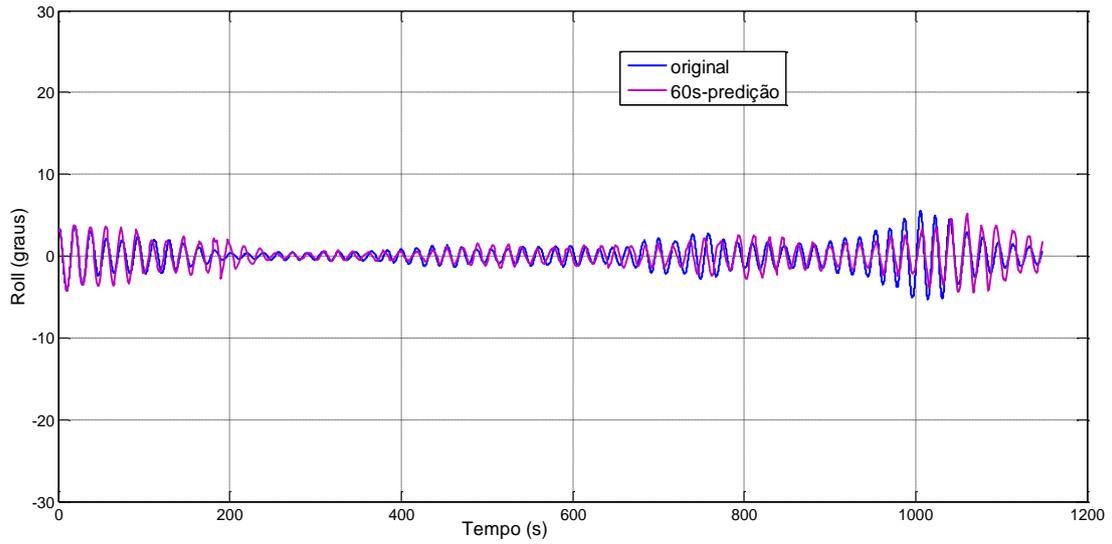


Figura C.29: Série Temporal 1: janela de tempo: 60s

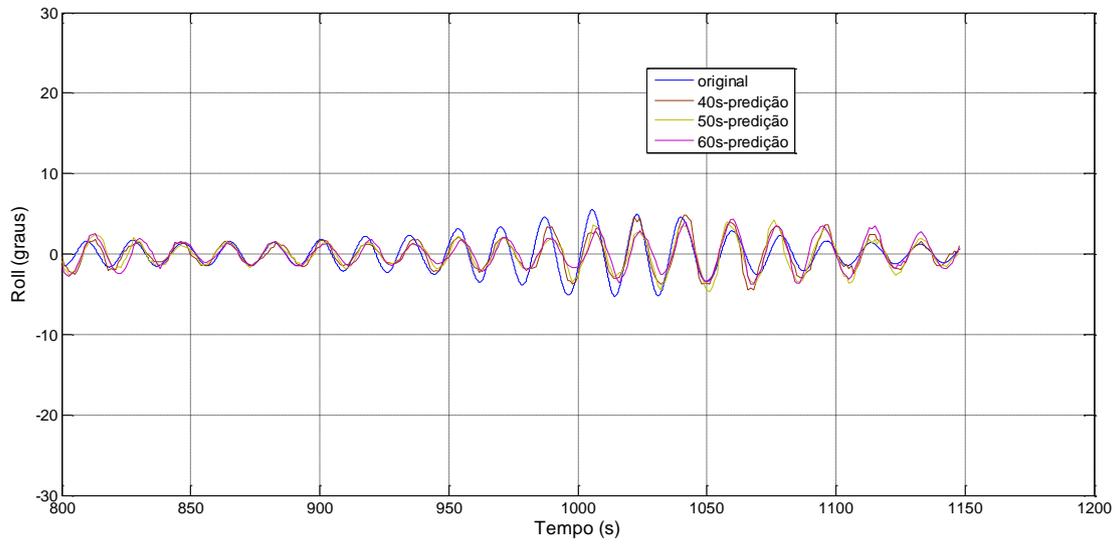


Figura C.29a: Intervalo de 800 a 1200s para três predições de roll

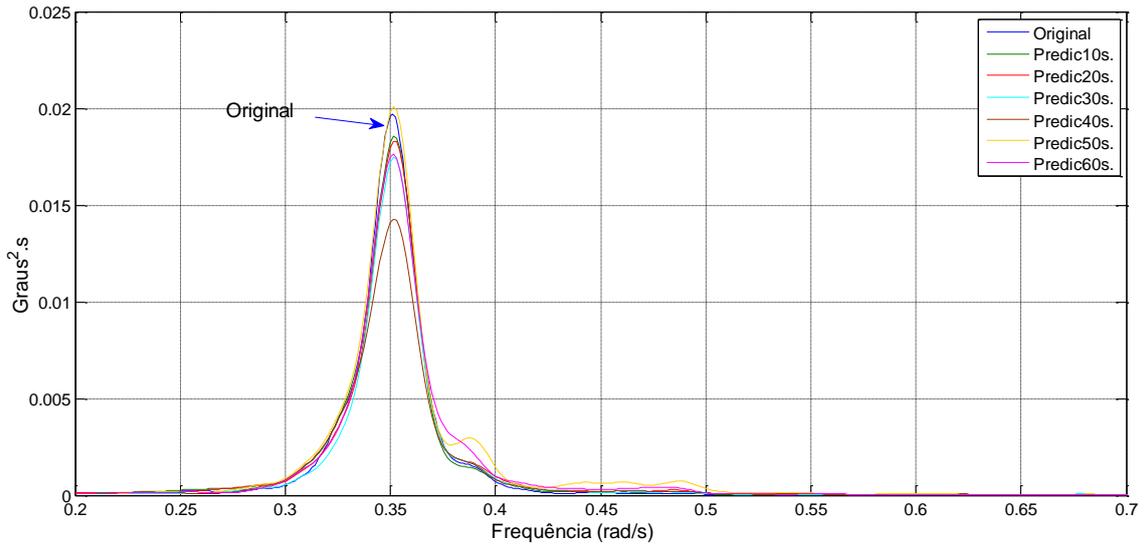


Figura C.30: Serie Temporal 1: Transformada de Fourier das predições para as diferentes janelas de tempo de predição

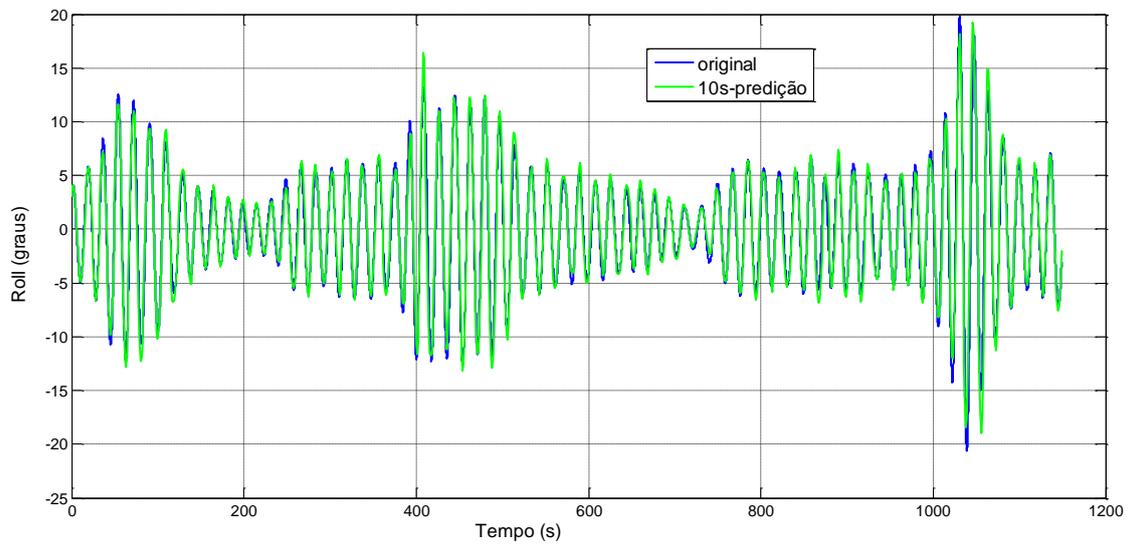


Figura C.31: Série Temporal 2: janela de tempo: 10s

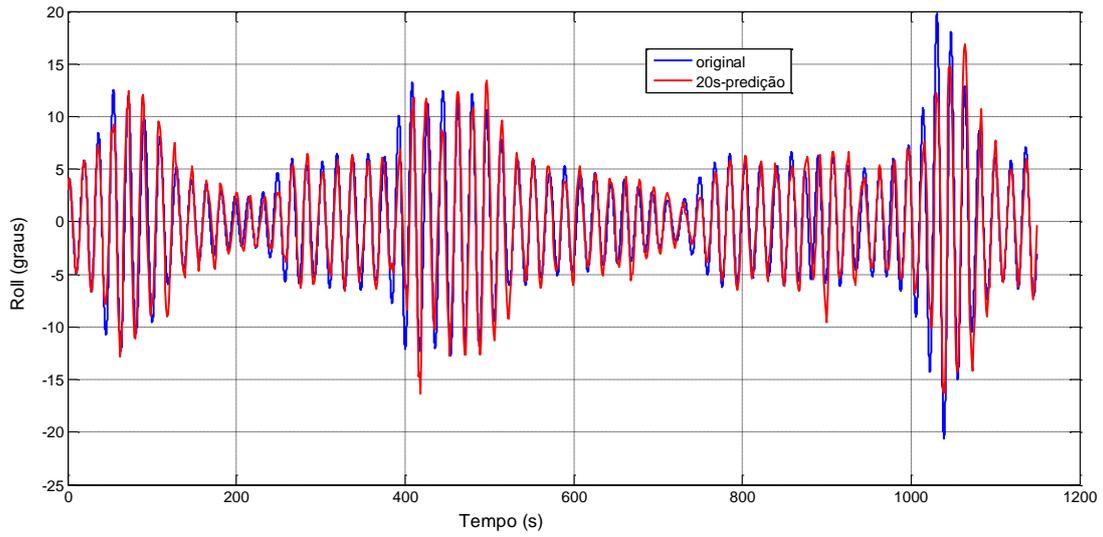


Figura C.32: Série Temporal 2: janela de tempo: 20s

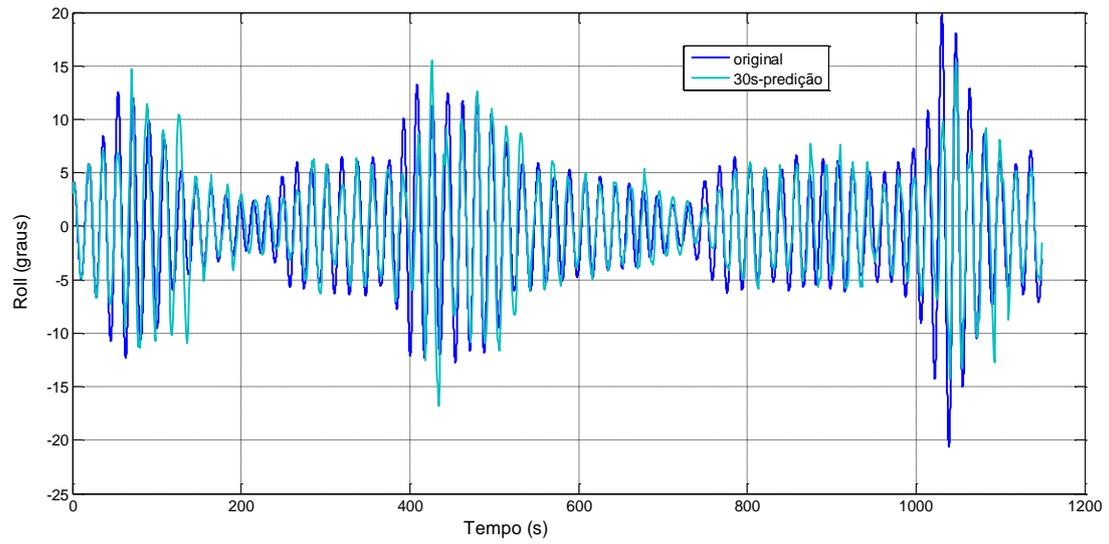


Figura C.33: Série Temporal 2: janela de tempo: 30s

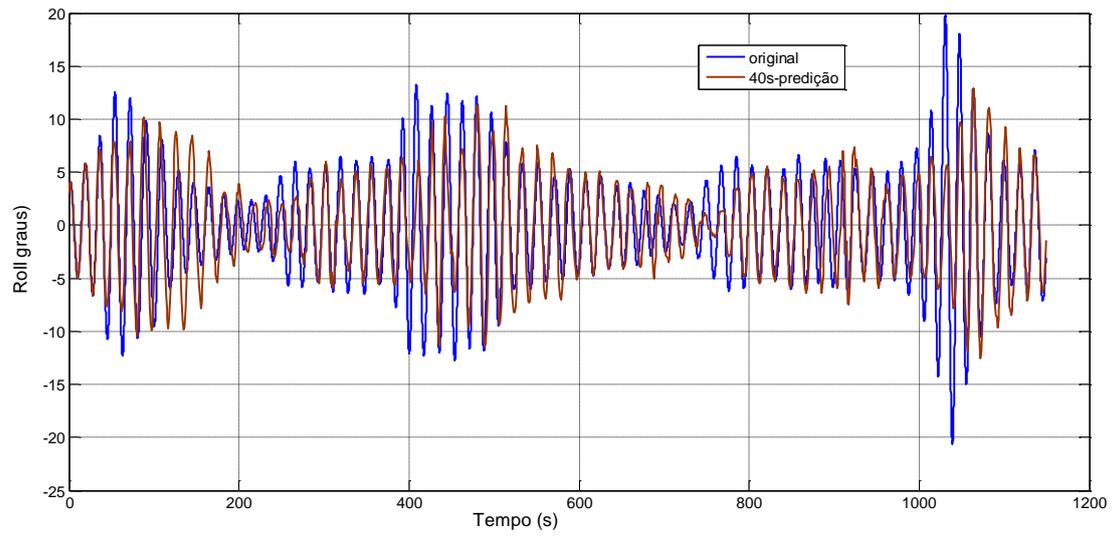


Figura C.34: Série Temporal 2: janela de tempo: 40s

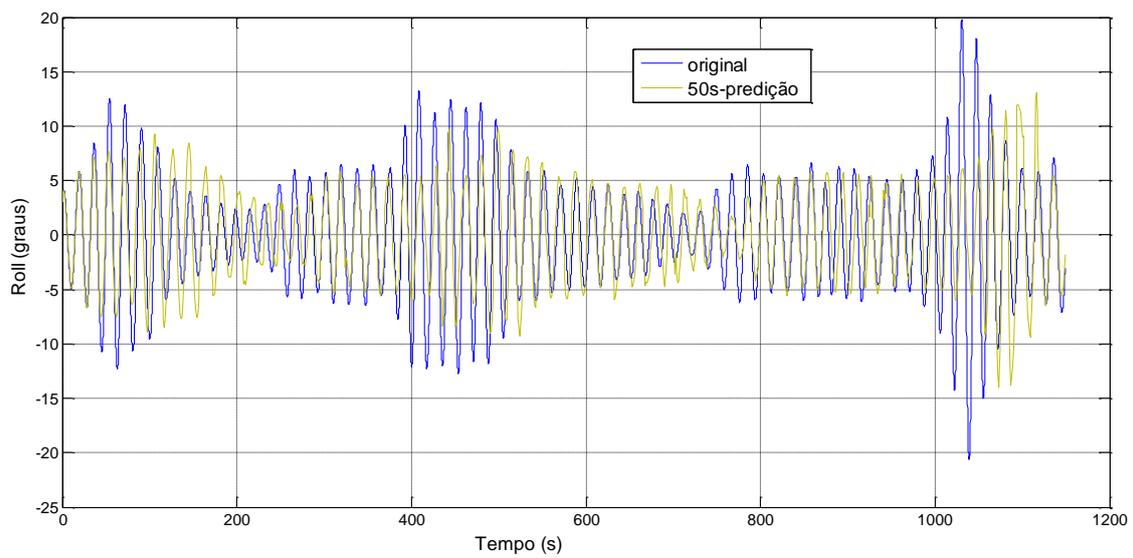


Figura C.35: Série Temporal 2: janela de tempo: 50s

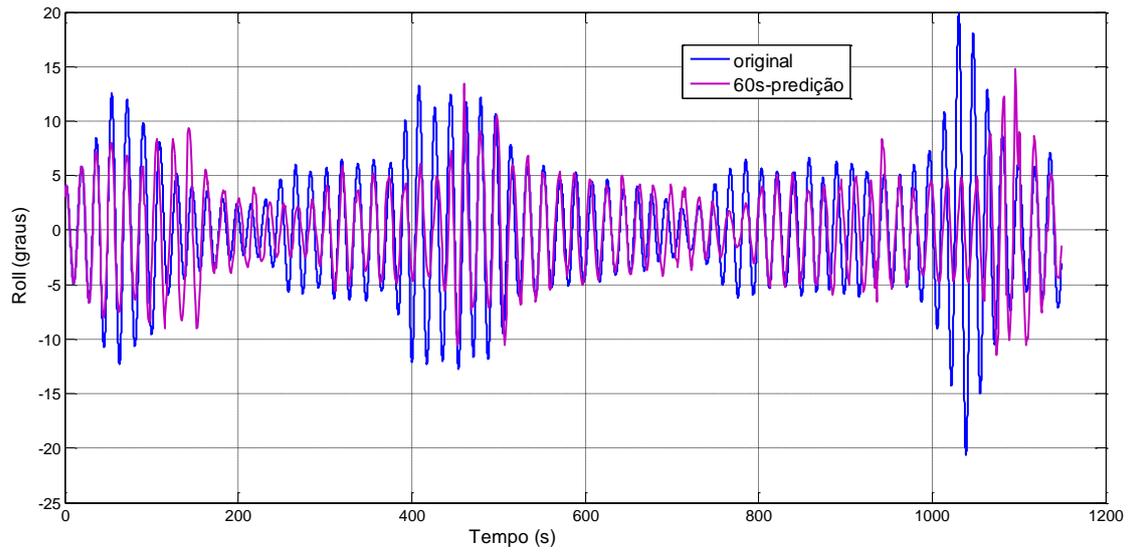


Figura C.36: Série Temporal 2: janela de tempo: 60s

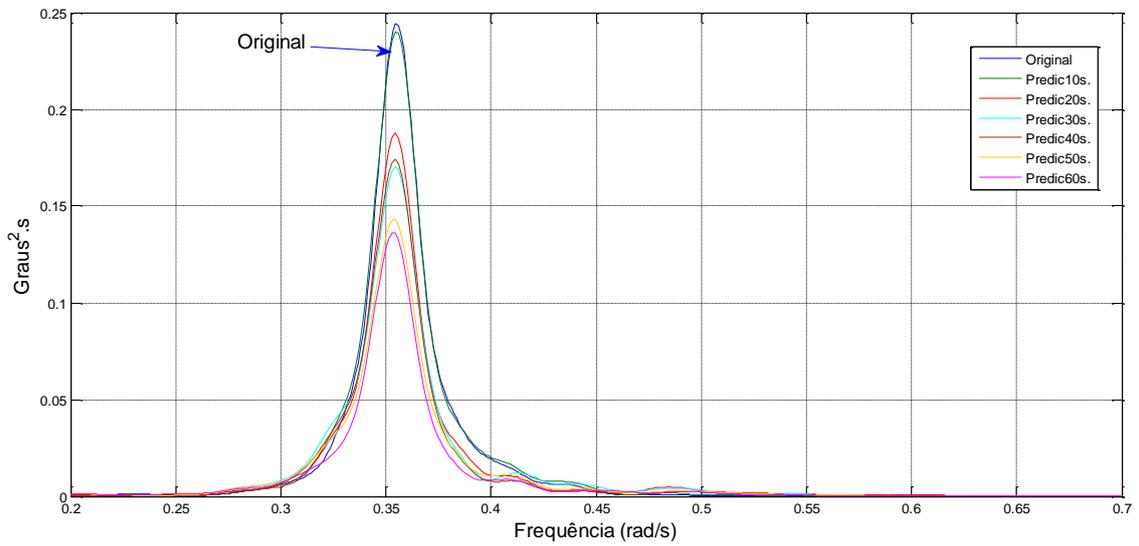


Figura C.37: Serie Temporal 2: Transformada de Fourier das predições para as diferentes janelas de tempo de predição

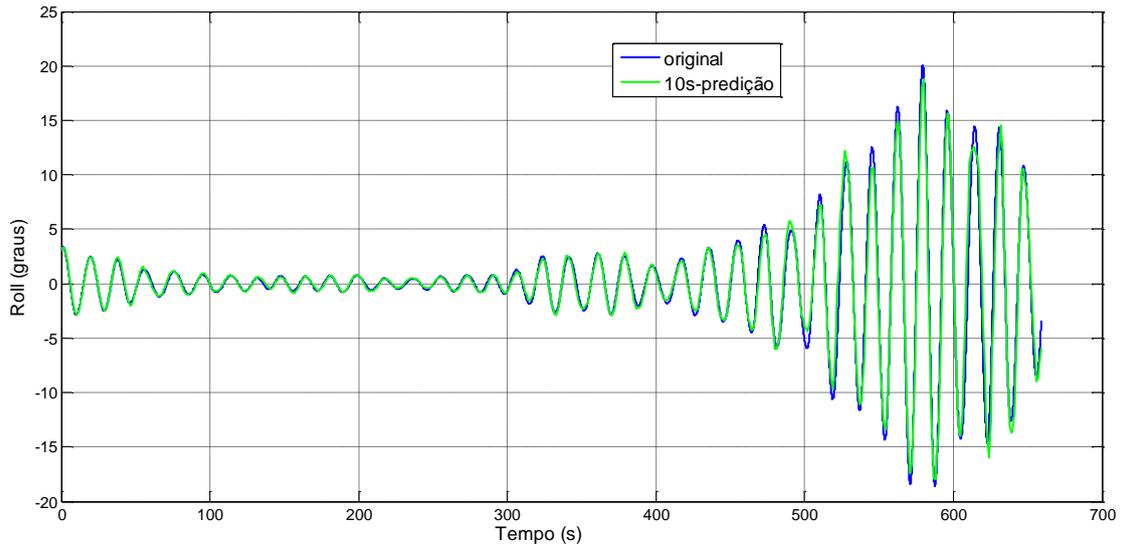


Figura C.39: Série Temporal 3: janela de tempo: 10s

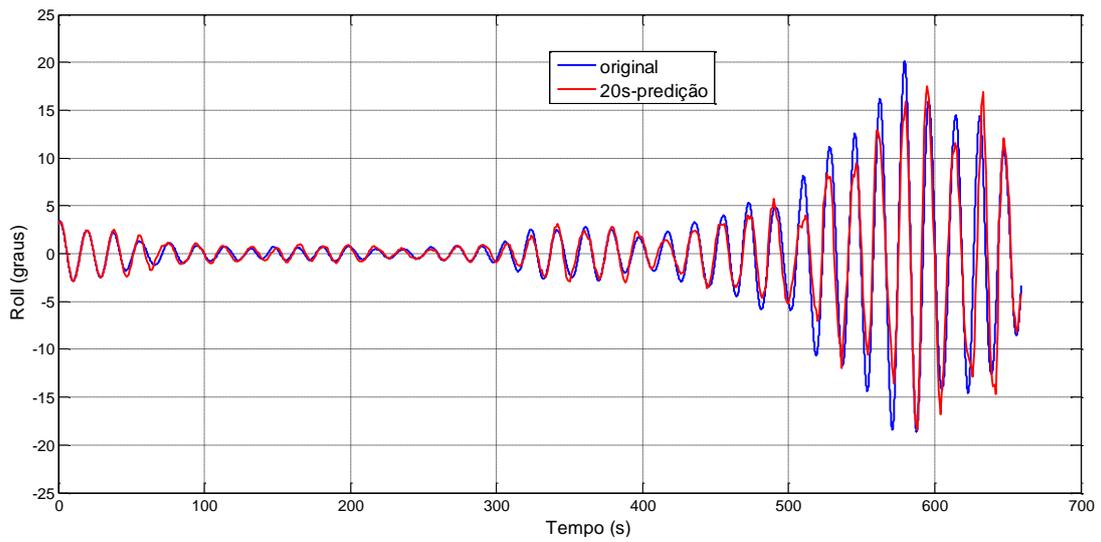


Figura C.40: Série Temporal 3: janela de tempo: 20s

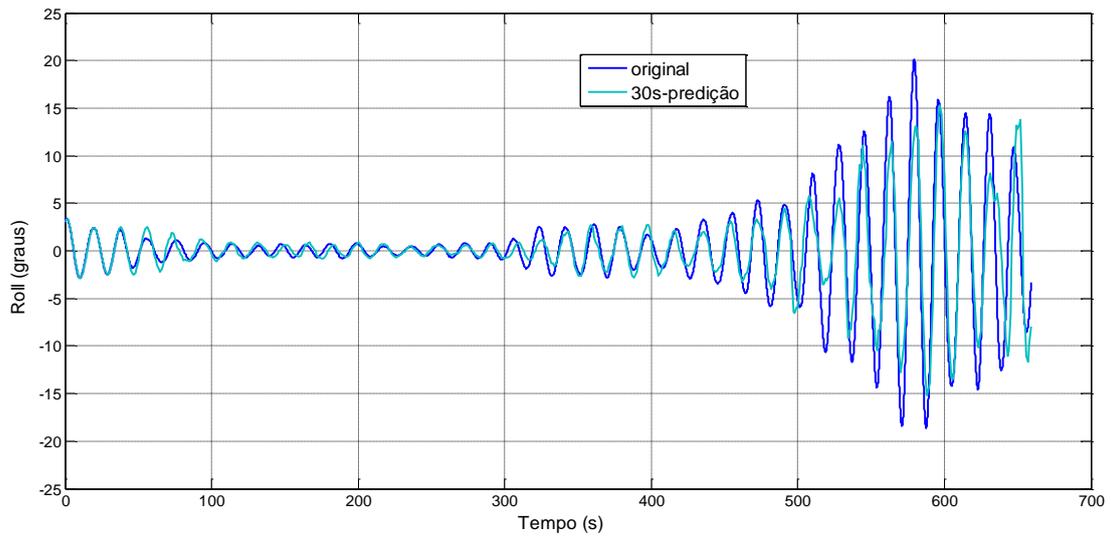


Figura C.41: Série Temporal 3: janela de tempo: 30s

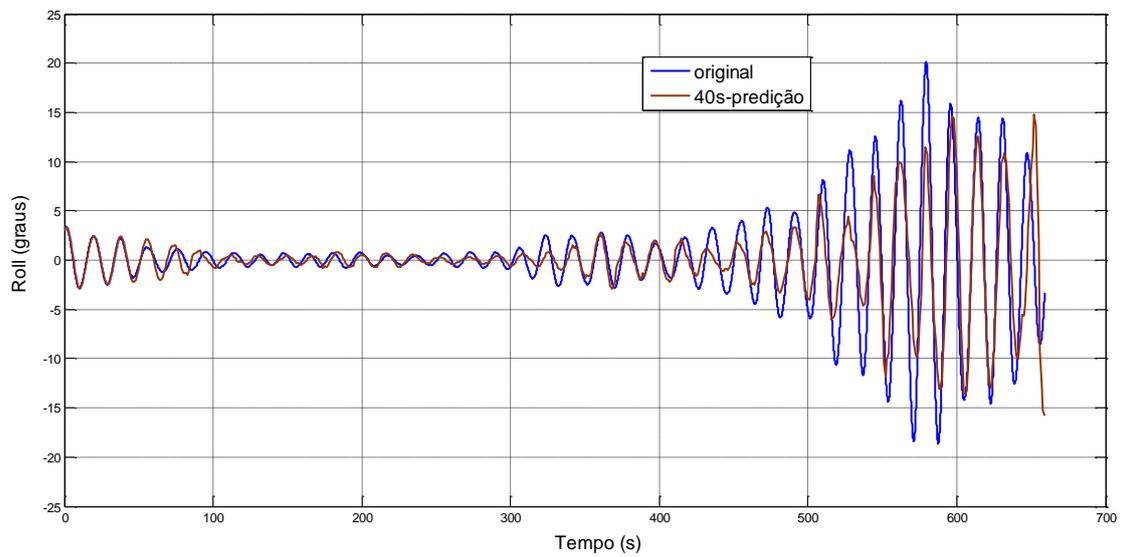


Figura C.42: Série Temporal 3: janela de tempo: 40s

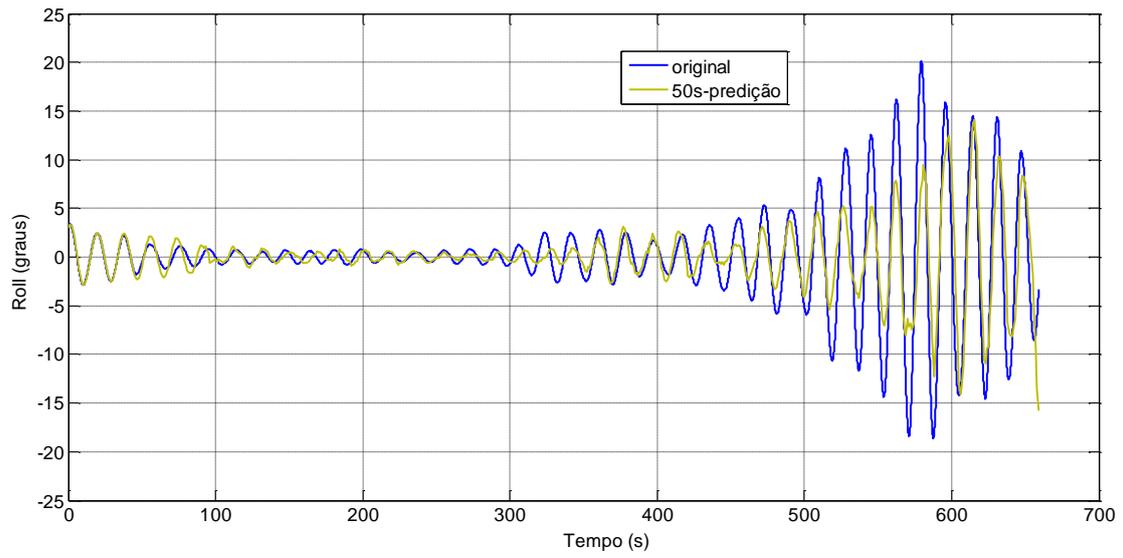


Figura C.43: Série Temporal 3: janela de tempo: 50s

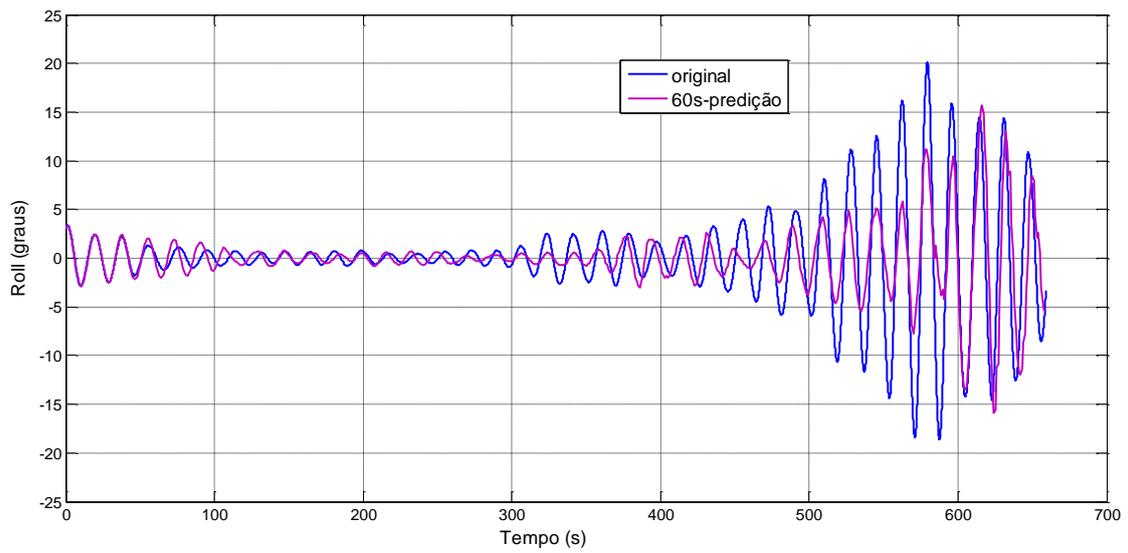


Figura C.44: Série Temporal 3: janela de tempo: 60s

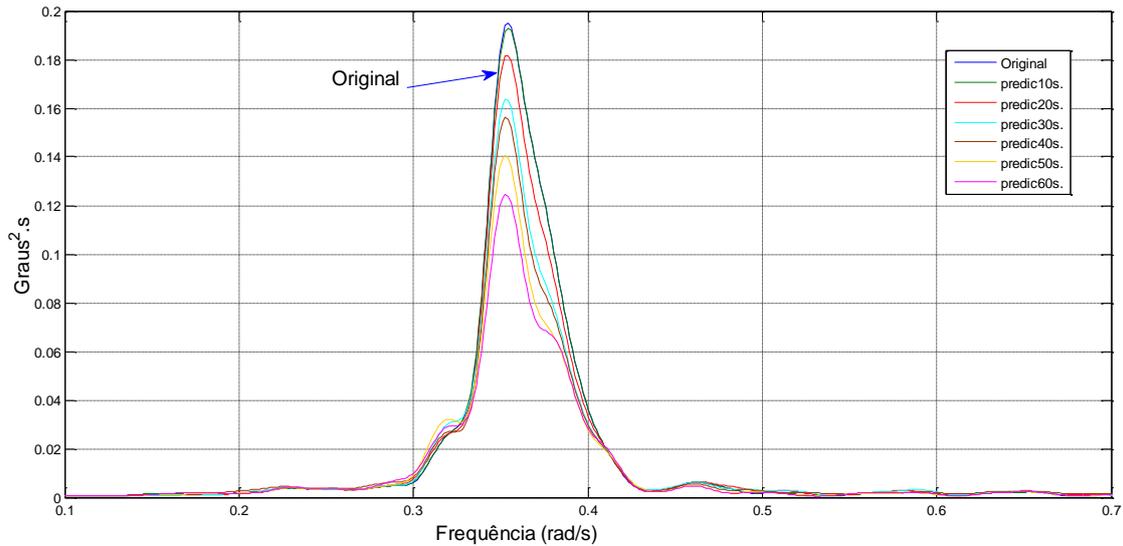


Figura C.45: Serie Temporal 3: Transformada de Fourier das predições para as diferentes janelas de tempo de predição

C-1.3 Espectro III

Treinamento da RNA para espectro maior do que os dois casos anteriores. Para o mesmo navio SAFEDOR testado para espectro de mar JONSWAP com altura significativa (H_s) de 5.00 m, período de pico (T_p) de 8.00 s, $\gamma = 3.3$.

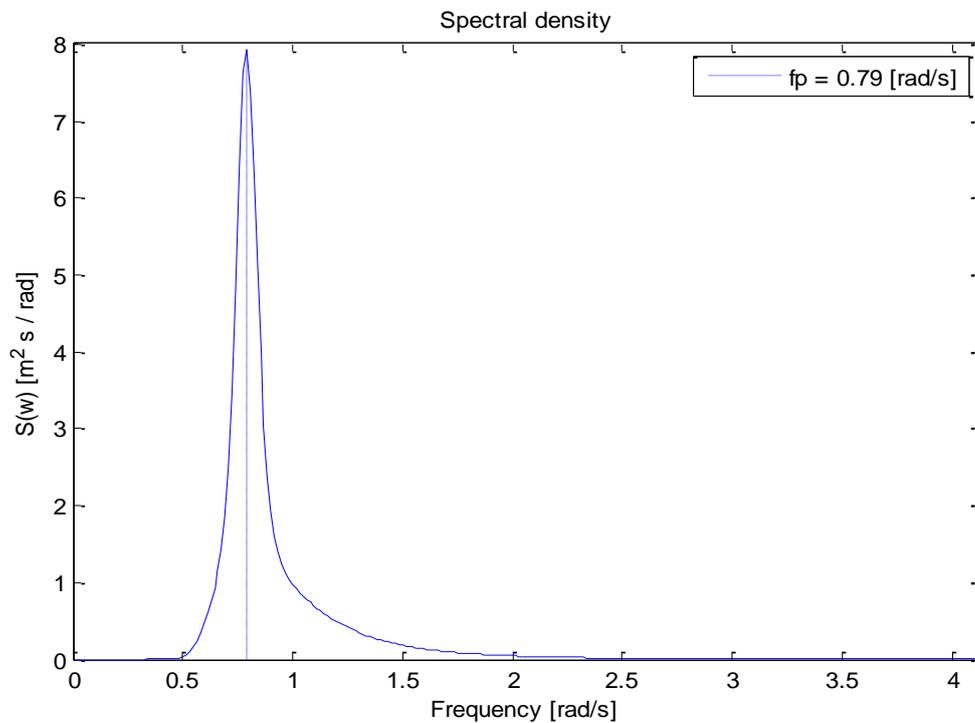


Figura C.46: Espectro JONSWAP com $H_s=5.0$ m, $T_p=8.0$ s, $\gamma = 3.3$

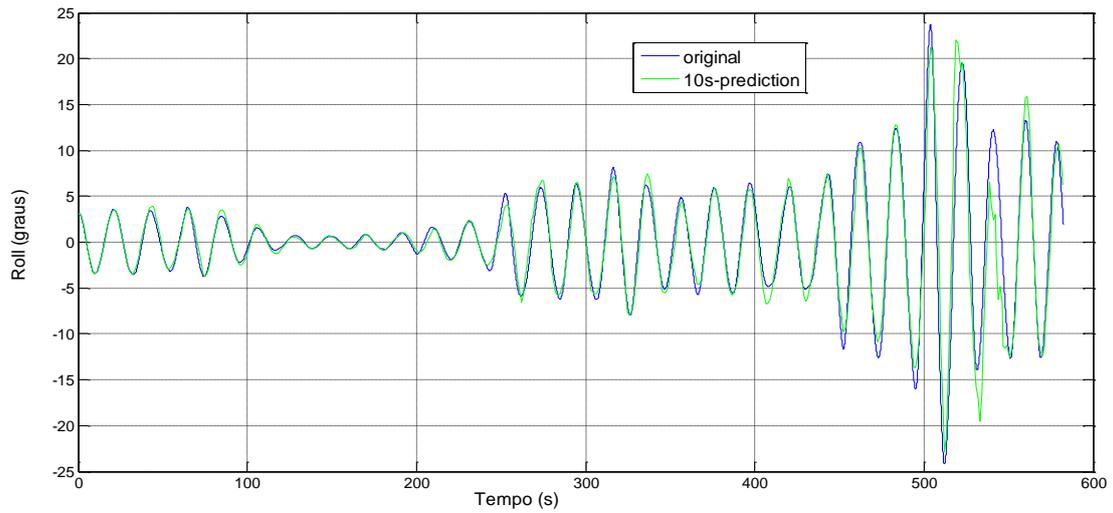


Figura C.47: Série Temporal 1: janela de tempo: 10s

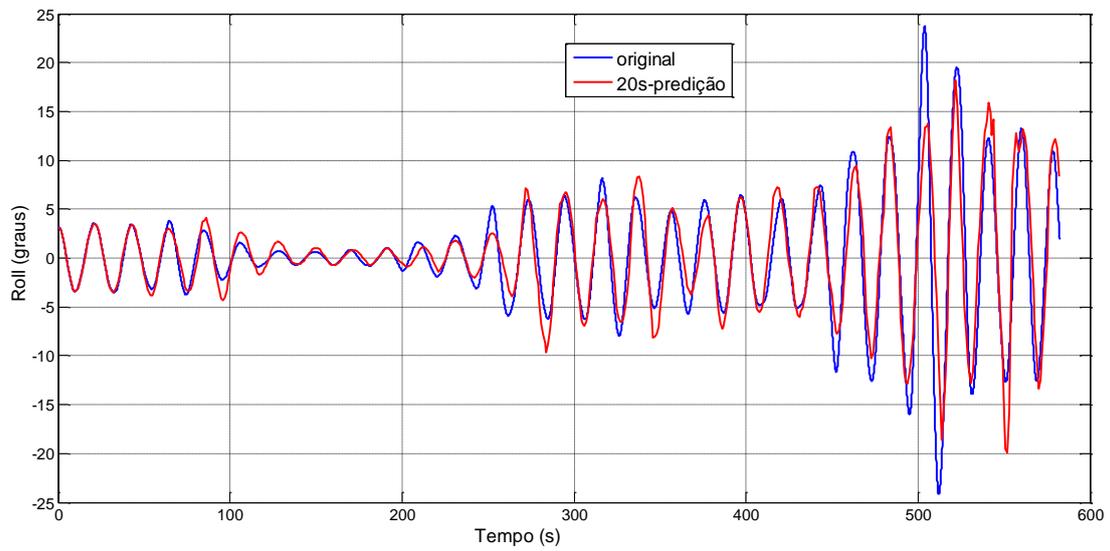


Figura C.48: Série Temporal 1: janela de tempo: 20s

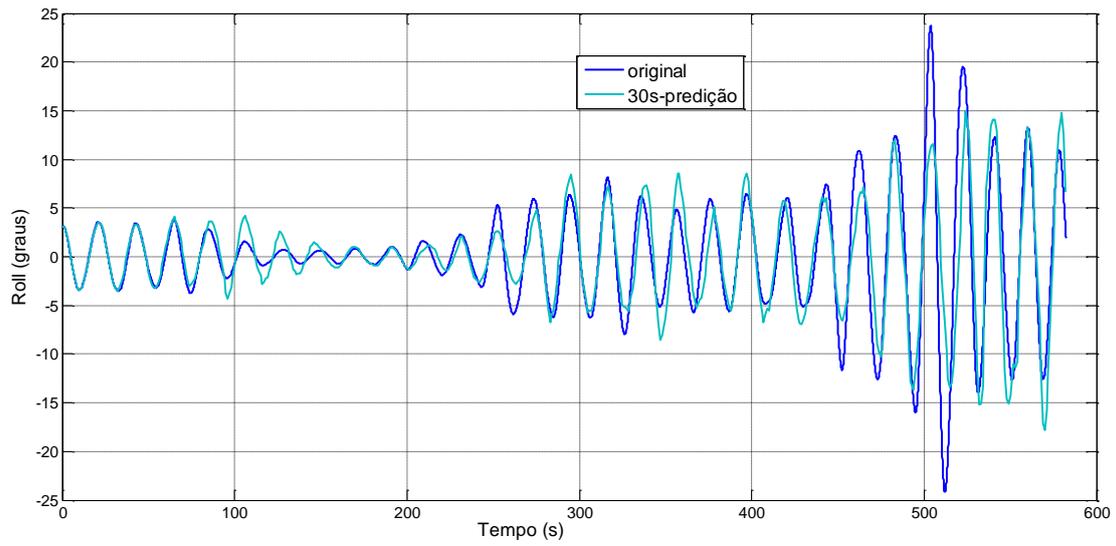


Figura C.49: Série Temporal 1: janela de tempo: 20s

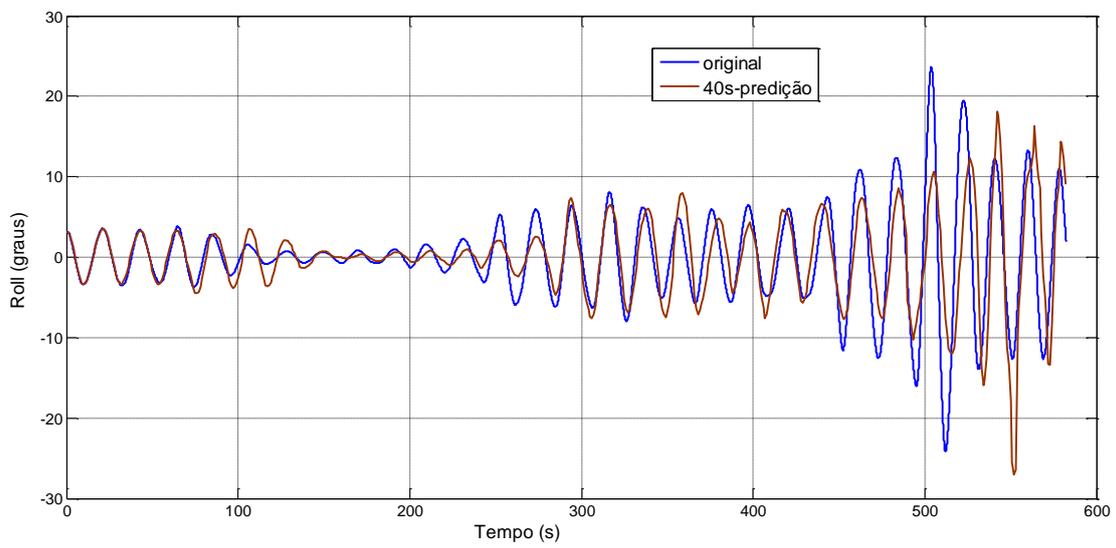


Figura C.50: Série Temporal 1: janela de tempo: 40s

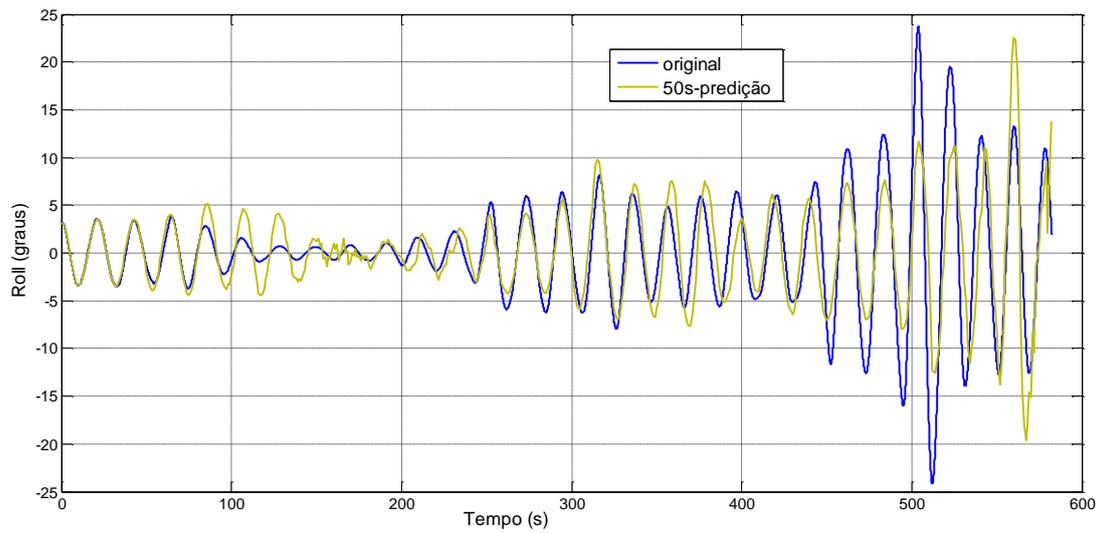


Figura C.51: Série Temporal 1: janela de tempo: 50s

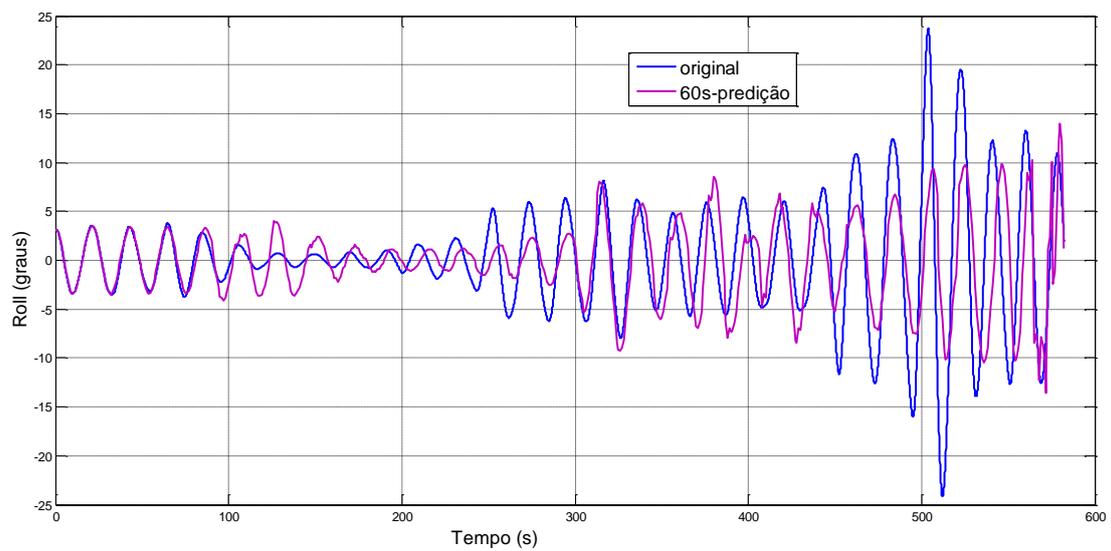


Figura C.52: Série Temporal 1: janela de tempo: 60s

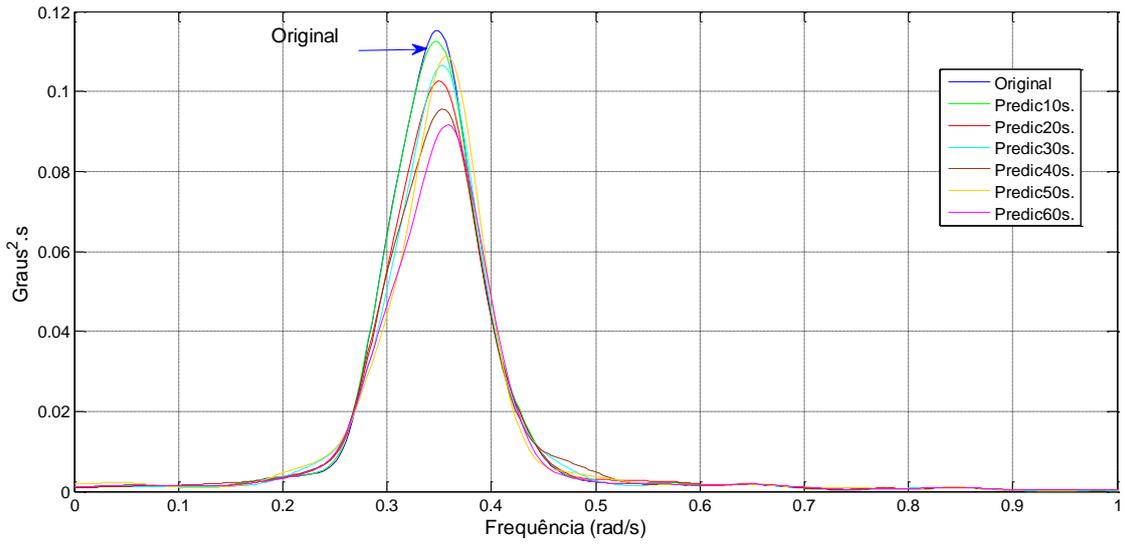


Figura C.53: Serie Temporal 1: Transformada de Fourier das predições para as diferentes janelas de tempo de predição

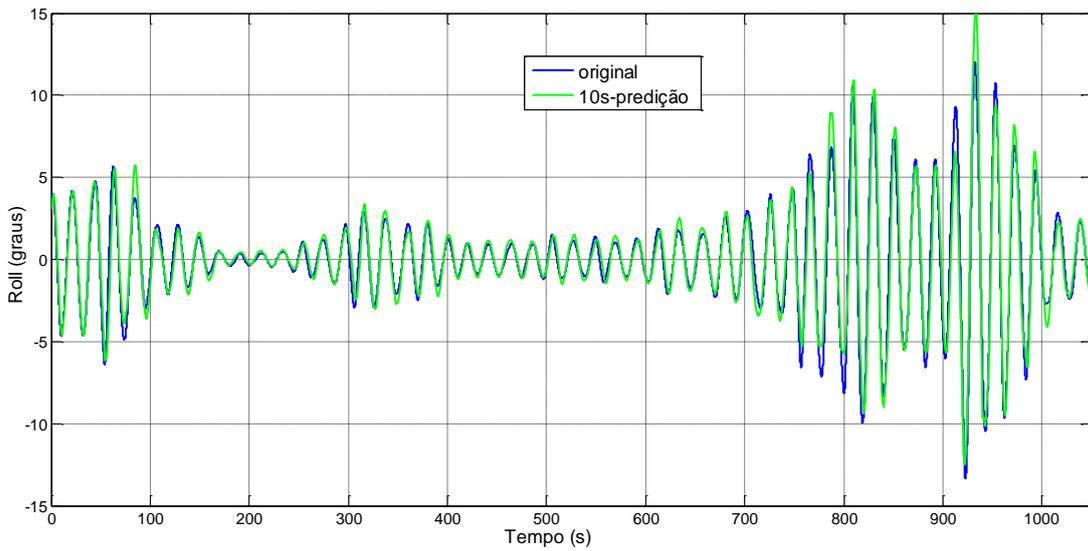


Figura C.54: Série Temporal 2: janela de tempo: 10s

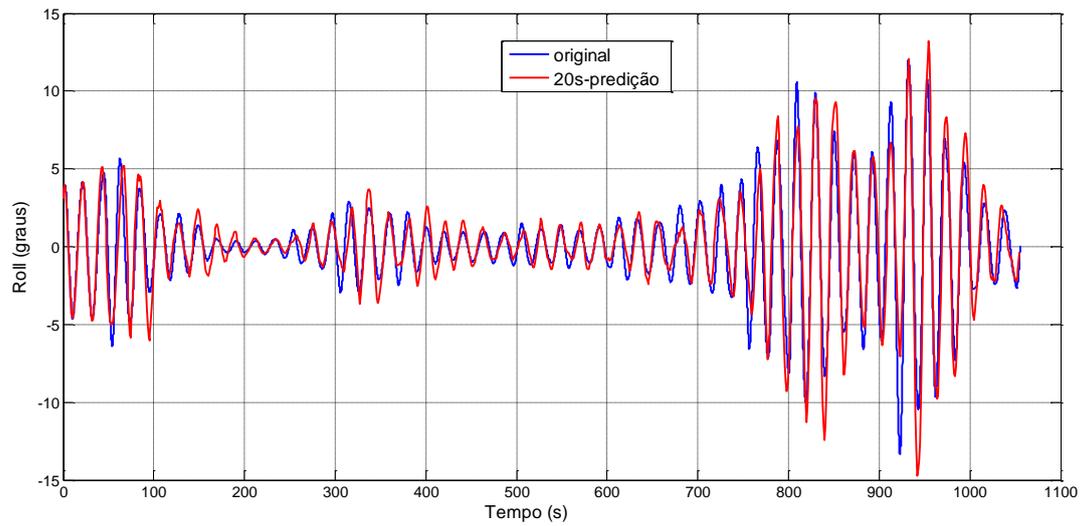


Figura C.55: Série Temporal 2: janela de tempo: 20s

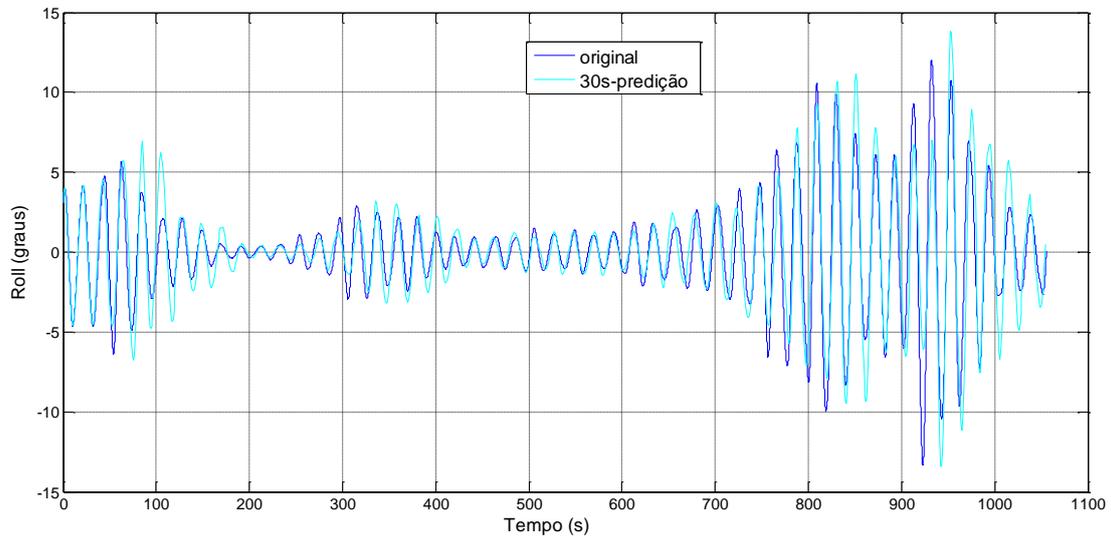


Figura C.56: Série Temporal 2: janela de tempo: 30s

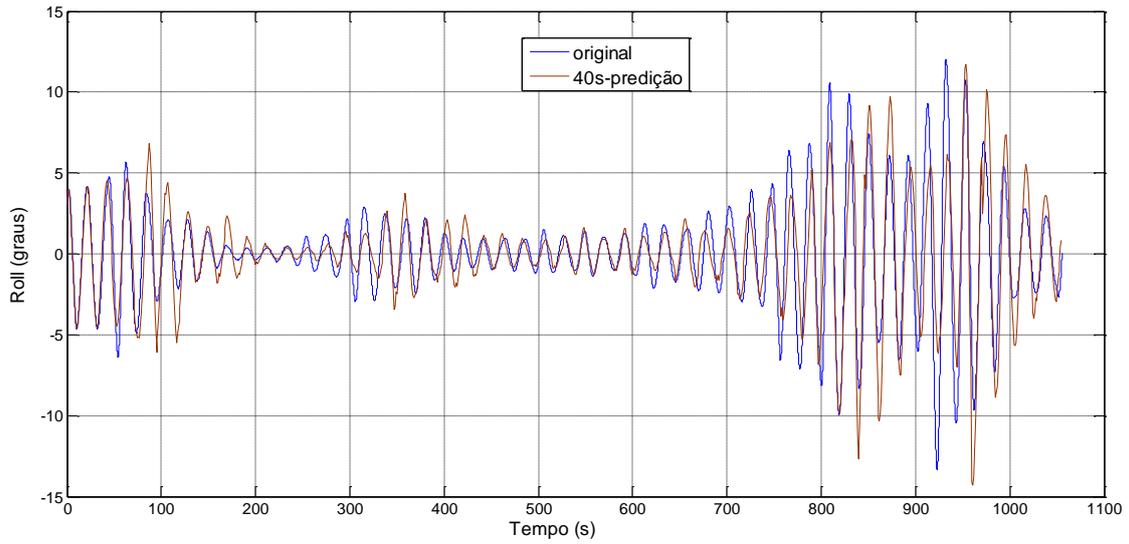


Figura C.57: Série Temporal 2: janela de tempo: 40s

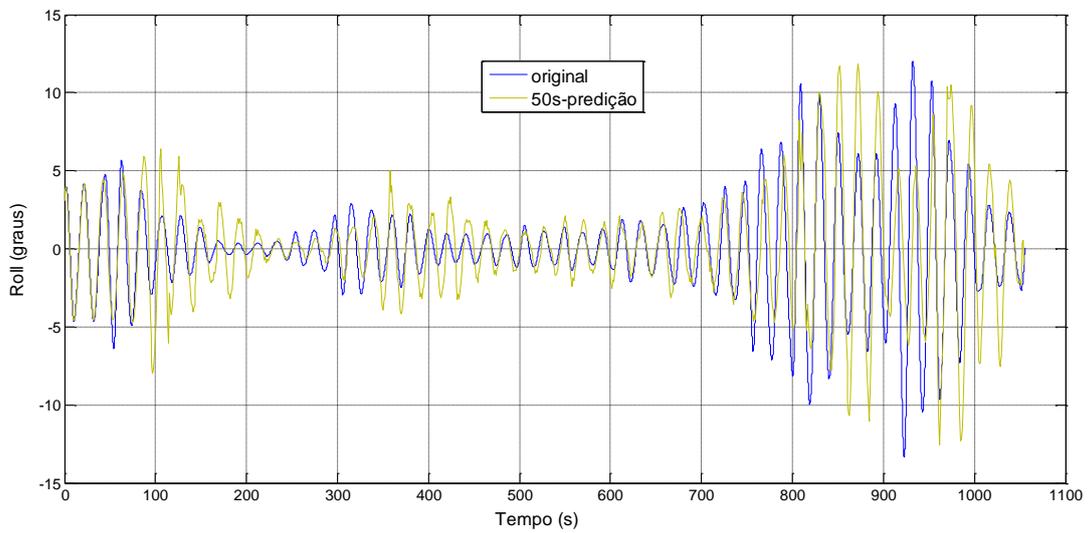


Figura C.58: Série Temporal 2: janela de tempo: 50s

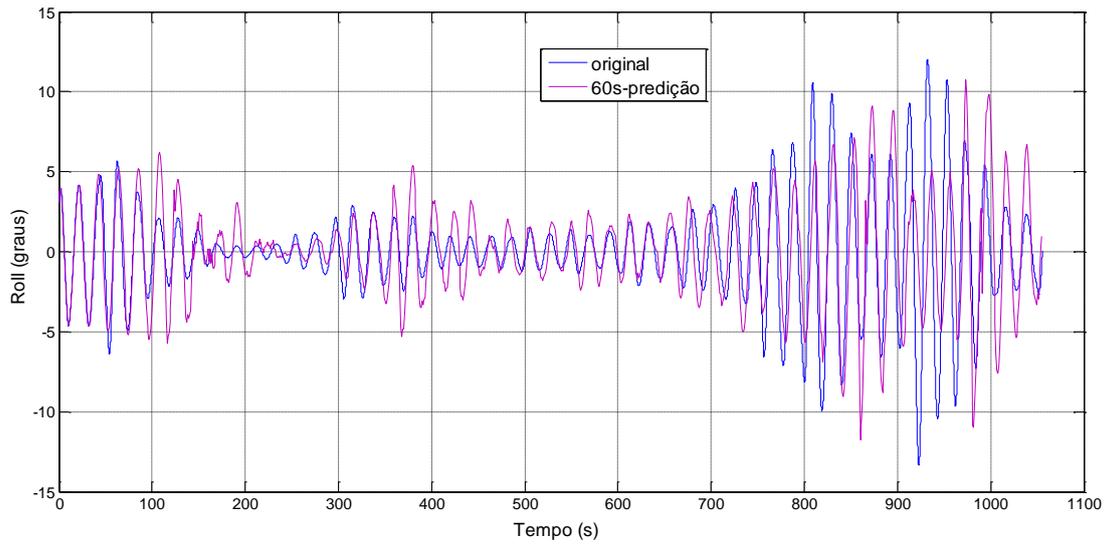


Figura C.59: Série Temporal 2: janela de tempo: 60s

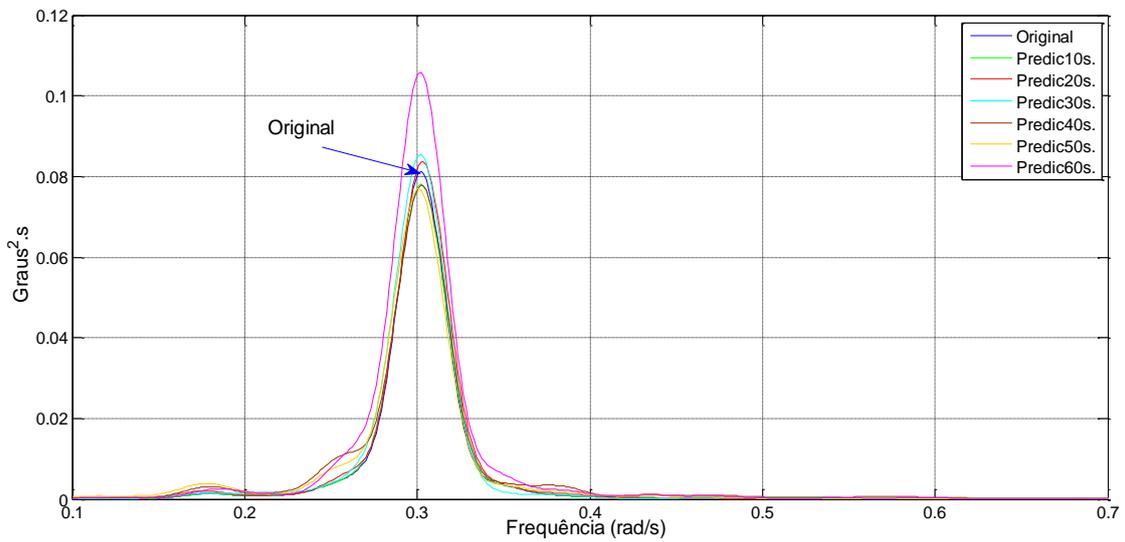


Figura C.60: Serie Temporal 2: Transformada de Fourier das predições para as diferentes janelas de tempo de predição

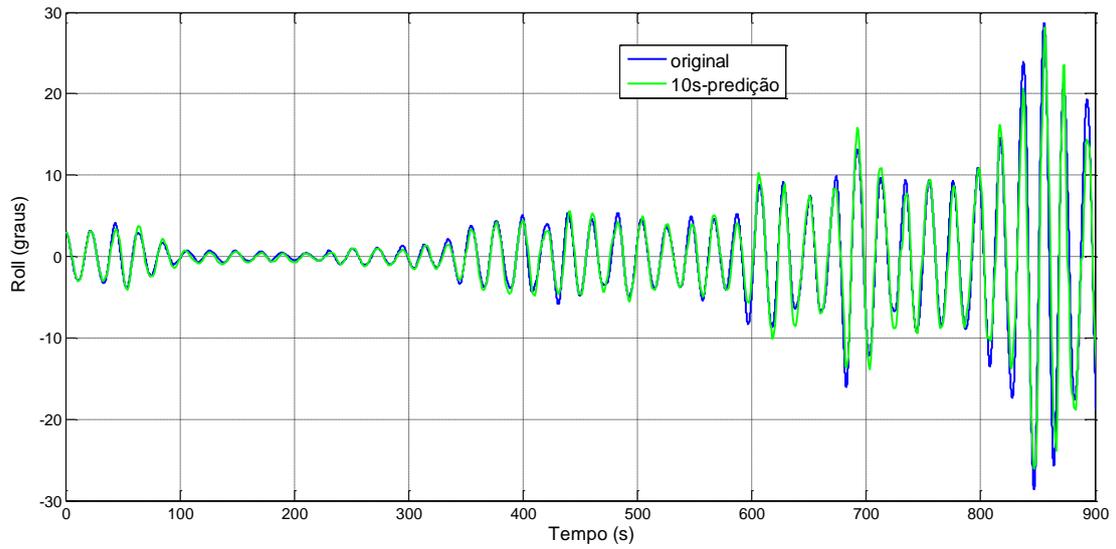


Figura C.61: Série Temporal 3: janela de tempo: 10s

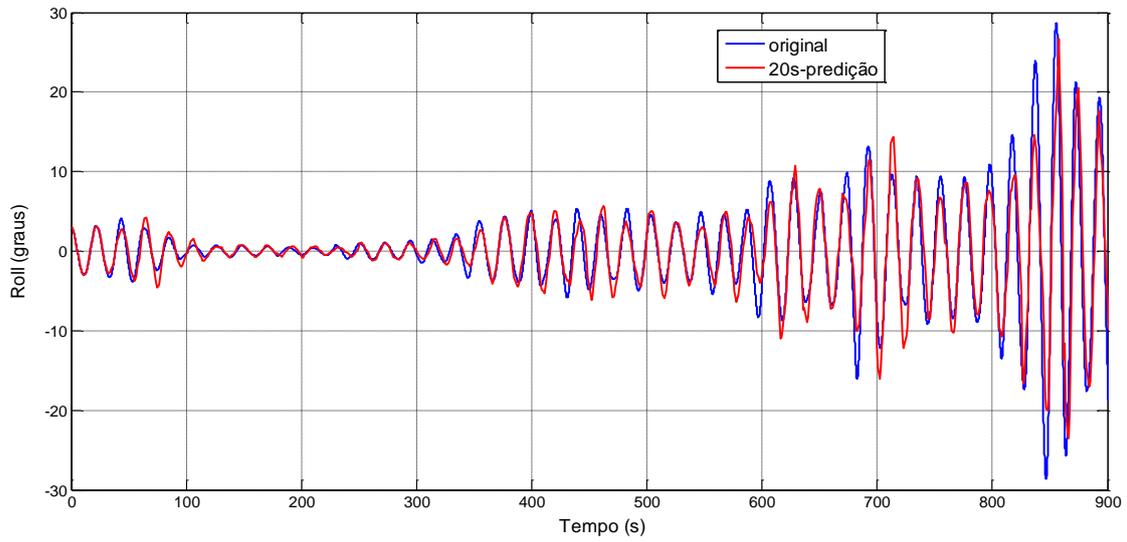


Figura C.62: Série Temporal 3: janela de tempo: 20s

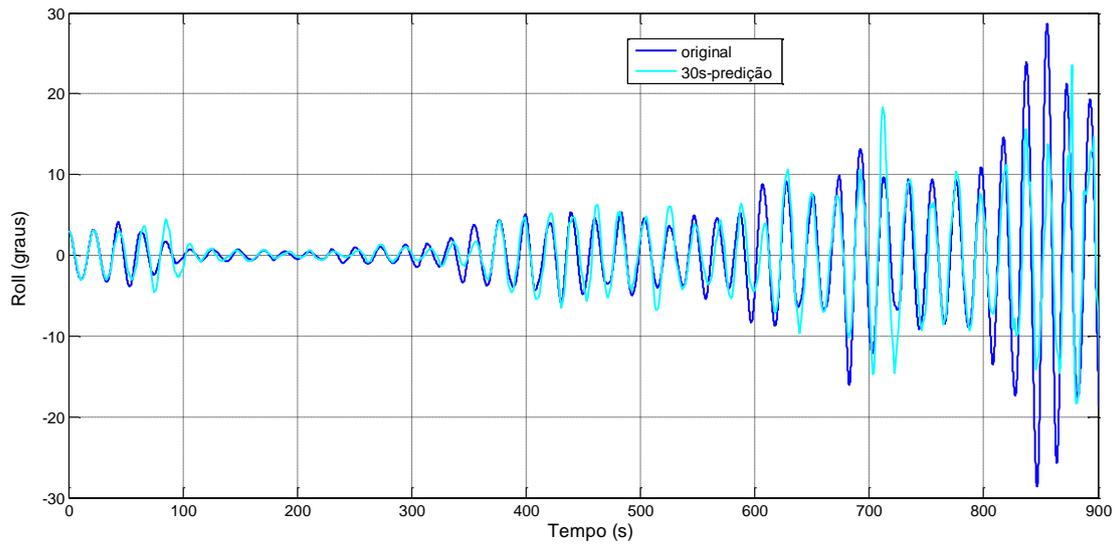


Figura C.63: Série Temporal 3: janela de tempo: 30s

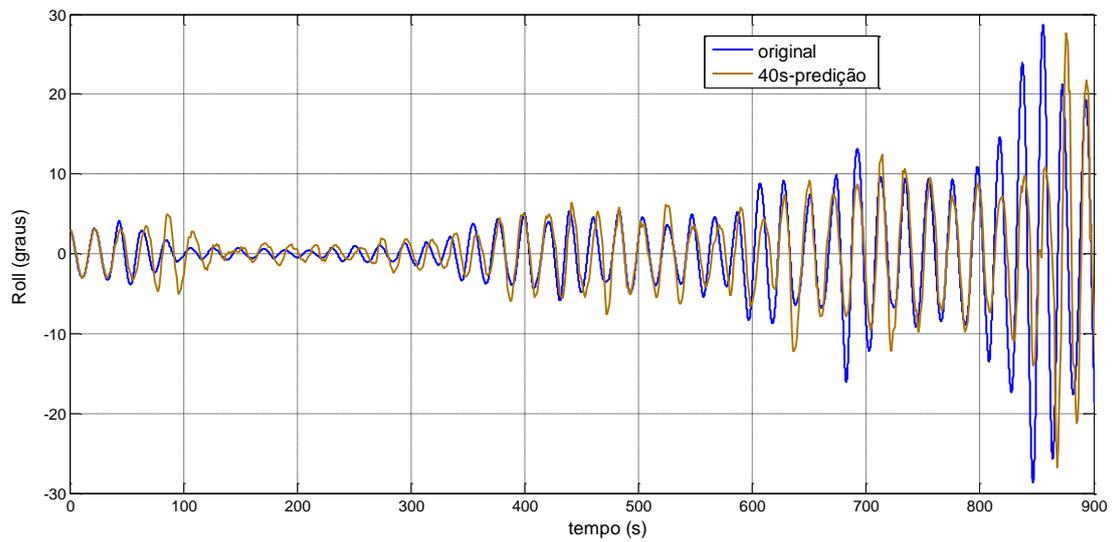


Figura C.64: Série Temporal 3: janela de tempo: 40s

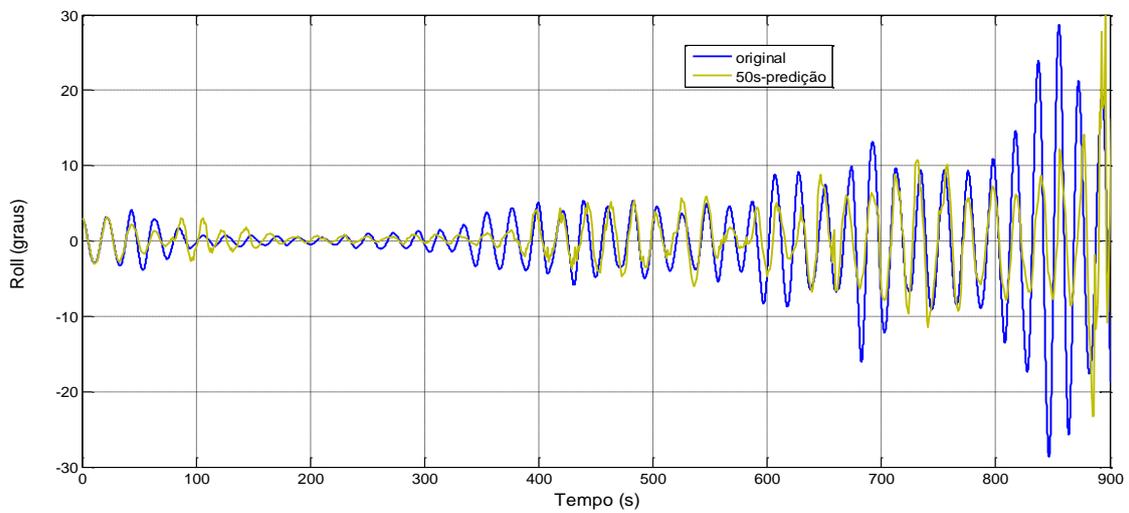


Figura C.65: Série Temporal 3: janela de tempo: 50s

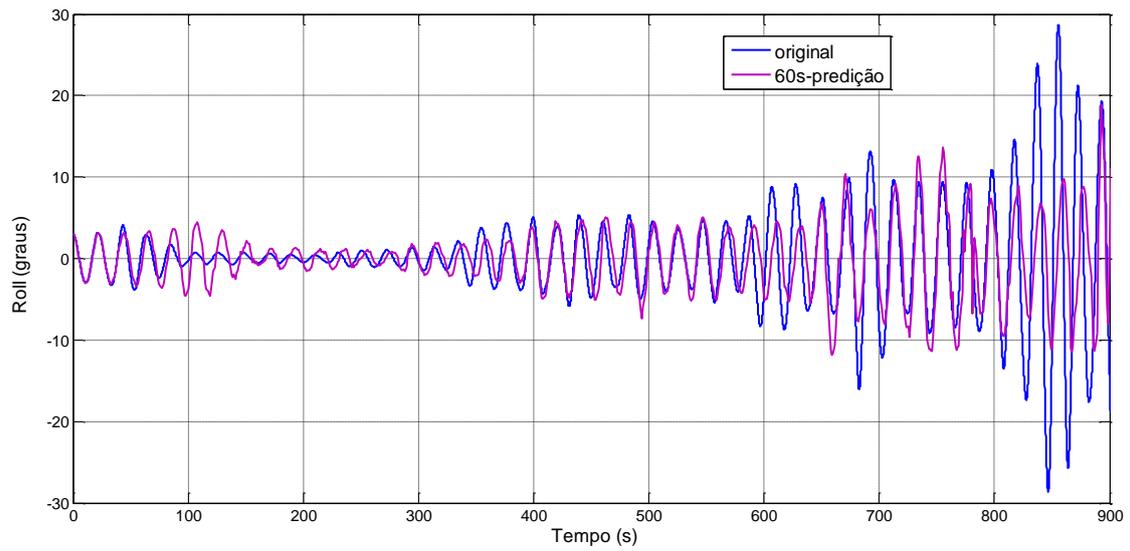


Figura C.66: Série Temporal 3: janela de tempo: 60s

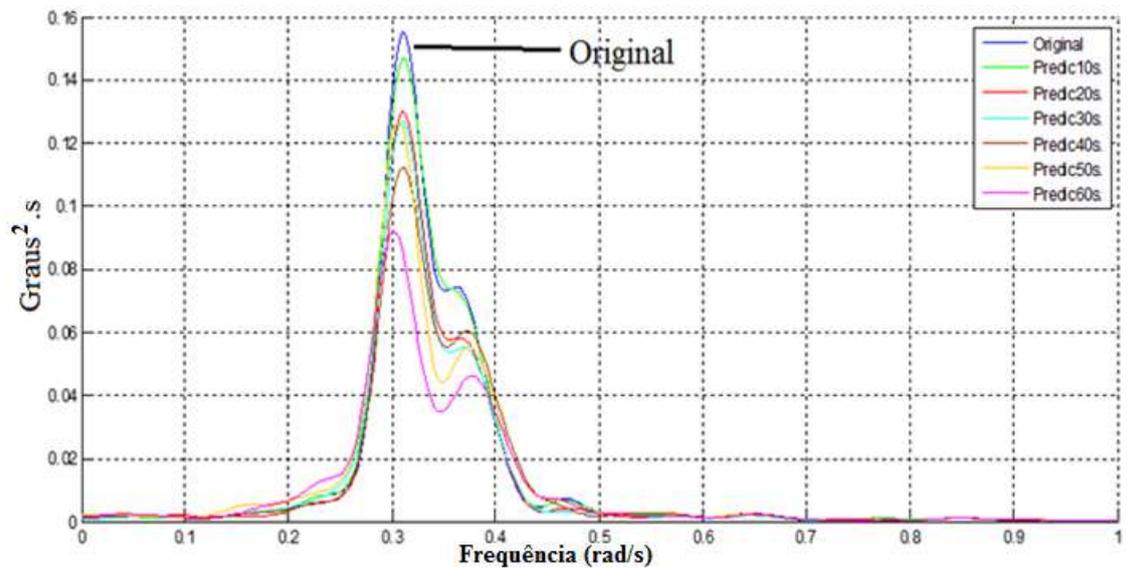


Figura C.67: Série Temporal 3: Transformada de Fourier das predições para as diferentes janelas de tempo de predição