



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Campus de Ilha Solteira

FRANCISCO LLEDO DOS SANTOS

**REDES NEURAIS ARTIFICIAIS ARTMAP-FUZZY
APLICADAS AO ESTUDO DE AGITAÇÃO MARÍTIMA E
ONDAS DE LAGOS**

Ilha Solteira – SP
2013

FRANCISCO LLEDO DOS SANTOS

REDES NEURAIS ARTIFICIAIS ARTMAP-FUZZY
APLICADAS AO ESTUDO DE AGITAÇÃO MARÍTIMA E ONDAS
DE LAGOS

Tese submetida ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira da UNESP, como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica.

Área de Concentração: Automação

Profa. Dra. Anna Diva Plasencia Lotufo
Orientadora
Prof. Dr. Geraldo de Freitas Maciel
Co-orientador

Ilha Solteira – SP
2013

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

S237r Santos, Francisco Lledo Dos.
Redes neurais artificiais ARTMAP-fuzzy aplicadas ao estudo de agitação
marítima e ondas de lagos / Francisco Lledo dos Santos. – Ilha Solteira: [s.n.],
2013
257 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia
de Ilha Solteira. Área de conhecimento: Automação, 2013

Orientador: Anna Diva Plasencia Lotufo
Co-orientador: Geraldo de Freitas Maciel
Inclui bibliografia

1. Redes neurais artificiais. 2. ARTMAP-fuzzy. 3. Agitação marítima. 4.
Galgamento. 5. Ondas em lagos.

unesp

UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

CERTIFICADO DE APROVAÇÃO

TÍTULO: REDES NEURAIS ARTIFICIAIS ARTMAP-FUZZY APLICADAS AO ESTUDO DE AGITAÇÃO MARÍTIMA E ONDAS DE LAGOS

AUTOR: FRANCISCO LLEDO DOS SANTOS

ORIENTADORA: Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

CO-ORIENTADOR: Prof. Dr. GERALDO DE FREITAS MACIEL

Aprovado como parte das exigências para obtenção do Título de DOUTOR EM ENGENHARIA ELÉTRICA, Área: AUTOMAÇÃO, pela Comissão Examinadora:




Profa. Dra. ANNA DIVA PLASENCIA LOTUFO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira




Prof. Dr. MILTON DALL AGLIO SOBRINHO
Departamento de Engenharia Civil / Faculdade de Engenharia de Ilha Solteira



Profa. Dra. MARA LÚCIA MARTINS LOPES
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira



Profa. Dra. MARIA TERESA LEAL GONSALVES VELOSO DOS REIS
Núcleo de Portos e Estruturas Marítimas / Laboratório Nacional de Engenharia Civil - Portugal



Profa. Dra. FERNANDA CASEÑO LIMA TRINDADE
Departamento de Sistemas de Energia Elétrica / Universidade Estadual de Campinas

Data da realização: 12 de dezembro de 2013.

Dedico este trabalho aos meus pais,
minha esposa e minha filha que sempre
me apoiaram e me fizeram acreditar na
realização dos meus sonhos.

AGRADECIMENTOS

Primeiramente, a Deus.

À minha família. Por serem compreensivos durante a realização dessa jornada.

A minha orientadora Prof.^a Anna Diva, pela confiança quando da execução desse trabalho.

À Prof.^a Teresa Reis, que me recebeu junto ao LNEC - Portugal de braços abertos e que, me proporcionou novas e inovadoras experiências junto à minha pesquisa.

Ao Prof. Geraldo Maciel pelo apoio fornecido; apoio esse que percorreu a graduação, o mestrado e finalmente o doutorado.

À Universidade do Estado de Mato Grosso pelo apoio na realização desse projeto.

À UNESP pela oportunidade de me graduar, realizar o mestrado e o doutorado.

Às agências de fomento FAPESP e CAPES pelo apoio incondicional.

Ao Laboratório Nacional de Engenharia Civil (LNEC) – Portugal.

A todos que colaboraram de forma direta e indireta para essa tese de doutoramento.

RESUMO

Os riscos associados a zonas costeiras e portuárias são uma das principais preocupações no planejamento e gestão destas zonas. Exemplos desses riscos são os associados aos fatores: instabilidade de estruturas marítimas de proteção, ocorrência de galgamentos, inundação, erosão costeira e navegação. Não obstante ao citado, tem-se também, o caso dos riscos inerentes ao ambiente dos reservatórios de barragens e de seus usos múltiplos, que fazem parte de segmentos de hidrovias, além de fazer parte de complexos de navegação e rotas comerciais. O exposto justifica a importância crescente do desenvolvimento de metodologias capazes de avaliar o risco neste tipo de situações.

O presente trabalho trata do desenvolvimento e aplicação de uma rede neural artificial, notadamente a rede ARTMAP-Fuzzy, na tentativa de se prever alguns fenômenos de superfície livre e interação onda-estrutura, sejam eles: agitação marítima, comportamento de ondas em lagos de barragem e galgamento.

A rede em questão pertence à família ART (*Adaptive Resonance Theory*), e foi desenvolvida e utilizada na tentativa de se prever tanto a agitação marítima dentro e fora de um porto, quanto para o cálculo do galgamento em um ponto do barramento de contenção e, também na tentativa de se prever o comportamento de ondas geradas por vento em um reservatório formado pela construção de uma usina hidroelétrica.

O porto em estudo foi o de Sines que se situa a sudoeste da Europa, na costa oeste de Portugal, a 58 milhas náuticas a sul de Lisboa. Já, para o caso de ondas em lagos, o mesmo se trata do lago formado pela construção da Usina Hidroelétrica de Ilha Solteira, situado a noroeste do Estado de São Paulo – Brasil.

Para o caso de estudo relativo ao porto de Sines, o treinamento desta rede neural é efetuado com dados de medição de boia-ondógrafo ao largo do porto e ainda, comparados com resultados do modelo numérico de propagação de ondas na zona de entrada do porto (SWAN) e, no interior do porto (DREAMS). Já, para o fenômeno de galgamento, os resultados produzidos pela ferramenta foram comparados com dados obtidos em ensaios em modelo físico bidimensional realizados no Laboratório Nacional de Engenharia Civil (LNEC), para o perfil em estudo. Os resultados da nova ferramenta foram ainda comparados com os provenientes de duas redes neurais do tipo MLP (*multilayer perceptron*).

Para o caso do lago de Ilha Solteira, os resultados fornecidos pela rede foram comparados aos dados obtidos através do uso de um ondógrafo óptico instalado no mesmo. O ondógrafo foi desenvolvido junto ao Laboratório de Hidrologia e Hidrometria – LH² da Faculdade de Engenharia de Ilha Solteira – Unesp.

Posteriormente, avaliou-se o desempenho da rede para diferentes períodos selecionados aleatoriamente. Estes testes tem como finalidade principal, a utilização de uma rede neural artificial ainda não aplicada a esse tipo de fenômeno e também, demonstrar as potencialidades e limitações da rede nestas aplicações.

Finalmente, nesta pesquisa realizada, percebe-se que a aplicação desse tipo de rede neural para o tratamento de agitação marítima, comportamento de ondas geradas por vento e galgamento, parece responder de forma satisfatória a previsão dos mesmos.

Palavras-chave: Redes Neurais Artificiais. ARTMAP-Fuzzy. Agitação Marítima. Galgamento. Ondas em Lagos.

ABSTRACT

The risks associated to coastal and harbor zones are one of the main concerns in planning and managing these zones. Some examples can be mentioned such as: instability of maritime structures, wave overtopping, flooding, coastal erosion and unsafe navigation. Furthermore, there are the risks associated to dam reservoirs and their multiple uses, as for example those reservoirs that are used as waterways, as well as being commercial and navigation routes. These are some of the justifications to develop methodologies capable of evaluating the risk in this kind of situations.

This work is concerned with the development and application of a Fuzzy ARTMAP artificial neural network to forecast some phenomena of free surface and of wave-structure interaction, such as: sea wave conditions, wave behavior in dam lakes and wave overtopping.

The neural network pertains to the ART (Adaptive Resonance Theory) family and is developed and used to forecast the wave conditions outside and inside a port, the wave overtopping at a cross-section of the port protection breakwater, and also the wind waves generated in an hydroelectric dam reservoir.

The studied port is the Sines port, located at south west Europe, west coast of Portugal, 58 nautical miles south of Lisbon. The hydroelectric reservoir is the Ilha Solteira lake, located north west of the State of São Paulo, Brazil.

Considering the Sines port, the neural network training for forecasting wave conditions is performed with data measured by a wave buoy positioned offshore the port, and also with numerical model results of wave propagation at the entrance of the port (SWAN model) and inside the port (DREAMS model). The wave conditions inside the port predicted by the new tool are compared with some field data. The neural network training for forecasting wave overtopping at the breakwater is performed with data obtained from a two-dimensional physical model developed at the National Laboratory for Civil Engineering (LNEC), Portugal. The wave overtopping results of the new tool are compared with those from two existing MLP (multilayer perceptron) neural networks.

The results obtained for the Ilha Solteira lake are compared with data obtained by the use of an optical wave register installed on it. This wave register was developed at Laboratório de Hidrologia e Hidrometria LH² of Faculdade de Engenharia de Ilha Solteira, UNESP.

The performance of the neural network is evaluated for different periods randomly selected. These tests illustrate both the application of an artificial neural network that has never been used to study these kind of phenomena and the advantages and disadvantages of the neural network for these study.

The conclusions show that the neural network predicts in a satisfactory manner the behavior of the analyzed phenomena.

Keywords: Artificial Neural Networks. ARTMAP-Fuzzy. Wave Conditions. Overtopping. Waves in Lakes.

LISTA DE FIGURAS

Figura 1 - Ilustração de situações de risco associadas a zonas costeiras e portuárias. ...	32
Figura 2 - Imagem Ilustrativa da Rede Neural Biológica.....	37
Figura 3 - Modelo de um neurônio.....	38
Figura 4 - Modelo de neurônio artificial.	41
Figura 5 - Modelo de rede neural e seus elementos.	47
Figura 6 – Subsistemas da rede neural ART.	51
Figura 7 - Estrutura topológica da rede ART-1.....	54
Figura 8 - Arquitetura da rede neural ART-1.....	55
Figura 9 - Arquitetura ART Fuzzy.	57
Figura 10 - Arquitetura da rede neural ARTMAP.....	62
Figura 11 - Rede neural ARTMAP-Fuzzy.	64
Figura 12 – Fluxograma da Rede Neural ARTMAP-Fuzzy.....	67
Figura 13 - Tipos de arrebentação de ondas.....	70
Figura 14 - Arrebentação Progressiva.	71
Figura 15 - Arrebentação Mergulhante.	72
Figura 16 - Porto de Sines – Portugal.....	76
Figura 17 - Localização da boia-ondógrafo do Porto de Sines.....	78
Figura 18 - Séries temporais da altura de onda significativa, período médio e direção média na boia-ondógrafo em Sines.	79
Figura 19 - Metodologia para a transferência do regime de agitação marítima do largo (Boia-ondógrafo) para o interior do porto.....	80
Figura 20 - Metodologia para a transferência do regime de agitação marítima do largo (boia-ondógrafo) para o interior do porto com base em matrizes de transferência.	82
Figura 21 - Modelo SWAN. (a) Batimetria; (b) Malhas e pontos onde foram extraídos resultados.....	85
Figura 22 - Modelo DREAMS. Domínio computacional, batimetria e malha de elementos finitos.	90
Figura 23 - Malha de elementos finitos do modelo DREAMS. Localização dos pontos A a G no interior do porto.	91
Figura 24 - Séries temporais dos valores de Hs, Tp e DIR nos pontos D e F obtidos com o modelo DREAMS, para o período de Maio 1988 a Dezembro de 2002.	93

Figura 25 - Localização do equipamento P1 – Infinity_WH.....	94
Figura 26 - Localização do equipamento P1 – LevelTroll e P2 – MiniTroll.	94
Figura 27 - Molhe Oeste do Porto de Sines e posto 2 do terminal de granéis líquidos..	96
Figura 28 - Perfil-tipo do trecho do molhe que protege o posto 2.....	97
Figura 29 – Batedor de Ondas com absorção de reflexão.	98
Figura 30 – Modelo Físico com escala 1:60 executado no LNEC.	99
Figura 31 - Parâmetros de entrada da rede ARTMAP-Fuzzy.	101
Figura 32 - Reservatório de Ilha Solteira.....	104
Figura 33 - Sistema de transmissão de dados em campo.	105
Figura 34 - Sistema de recepção de dados na UNESP/FEIS	106
Figura 35 - Rosas-dos-ventos reinantes mensais, campanha 2008-2009.	108
Figura 36 - Rosas-dos-ventos dominantes mensais, campanha 2008-2009.	109
Figura 37 - Rosas-dos-ventos de todo período de medição da campanha 2008-2009 (a) reinantes e (b) dominantes.....	109
Figura 38 - Mapa de altura de onda para o lago de Ilha Solteira, direção NNE, maior vento médio (5,92 m/s).....	111
Figura 39 - Mapa de altura de onda para o lago de Ilha Solteira, direção NNO, vento máximo 24,62 m/s.	112
Figura 40 - Estação em operação autônoma.	113
Figura 41 - Comparação de Hs entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 1,0$	116
Figura 42 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para $\rho_b = 1,0$	116
Figura 43 - Comparação de Tp entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 1,0$	117
Figura 44 - Correlação de Tp provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para $\rho_b = 1,0$	117
Figura 45 - Comparação de DIR entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b =$ 1,0.	118
Figura 46 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\rho_b = 1,0$	118
Figura 47 - Comparação de Hs entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b =$ 0,995.....	119

Figura 48 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para $\rho_b = 0,995$.	119
Figura 49 – Comparação de Tp entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,995$.	120
Figura 50 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para $\rho_b = 0,995$.	120
Figura 51 – Comparação de DIR entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,995$.	121
Figura 52 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\rho_b = 0,995$.	121
Figura 53 – Comparação de Hs entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,984$.	122
Figura 54 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para $\rho_b = 0,984$.	122
Figura 55 – Comparação de Tp entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,984$.	123
Figura 56 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para $\rho_b = 0,984$.	123
Figura 57 – Comparação de DIR entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,984$.	124
Figura 58 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\rho_b = 0,984$.	124
Figura 59 – Comparação de Hs entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,983$.	125
Figura 60 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para $\rho_b = 0,983$.	126
Figura 61 – Comparação de Tp entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,983$.	126
Figura 62 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para $\rho_b = 0,983$.	127
Figura 63 – Comparação de DIR entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,983$.	127
Figura 64 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\rho_b = 0,983$.	128

Figura 65 - Erro Médio Absoluto Percentual em relação à variação do critério de vigilância de saída para Hs.....	130
Figura 66 - Erro Médio Absoluto Percentual em relação à variação do critério de vigilância de saída para Tp.....	130
Figura 67 - Erro Médio Absoluto Percentual em relação à variação do critério de vigilância de saída para DIR.	131
Figura 68 - Erro Médio Quadrático em relação à variação do critério de vigilância de saída para Hs.	132
Figura 69 - Erro Médio Quadrático em relação à variação do critério de vigilância de saída para Tp.	132
Figura 70 - Erro Médio Quadrático em relação à variação do critério de vigilância de saída para DIR.	133
Figura 71 - Média dos Erros Viés em relação à variação do critério de vigilância de saída para Hs.	134
Figura 72 - Média dos Erros Viés em relação à variação do critério de vigilância de saída para Tp.	134
Figura 73 - Média dos Erros Viés em relação à variação do critério de vigilância de saída para DIR.	135
Figura 74 - Desvio Padrão dos Erros Viés em relação à variação do critério de vigilância de saída para Hs.....	136
Figura 75 - Desvio Padrão dos Erros Viés em relação à variação do critério de vigilância de saída para Tp.....	136
Figura 76 - Desvio Padrão dos Erros Viés em relação à variação do critério de vigilância de saída para DIR.	137
Figura 77 - MAPE em relação à variação do critério de vigilância de saída para Hs, Tp e Dir.....	137
Figura 78 - RMSE em relação à variação do critério de vigilância de saída para Hs, Tp e Dir.....	138
Figura 79 – Média dos Erros Viés em relação à variação do critério de vigilância de saída para Hs, Tp e Dir.....	138
Figura 80 - Desvio Padrão dos Erros Viés em relação à variação do critério de vigilância de saída para Hs, Tp e Dir.	139
Figura 81 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs _{ART} , e do modelo SWAN, Hs _{SWAN} , para $\alpha = 0,1$	141

Figura 82 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, Tp_{ART} , e do modelo SWAN, Tp_{SWAN} , para $\alpha = 0,1$	141
Figura 83 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\alpha = 0,1$	142
Figura 84 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo SWAN, Hs_{SWAN} , para $\alpha = 10$	142
Figura 85 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, Tp_{ART} , e do modelo SWAN, Tp_{SWAN} , para $\alpha = 10$	143
Figura 86 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\alpha = 10$	143
Figura 87 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo SWAN, Hs_{SWAN} , para $\alpha = 100$	144
Figura 88 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, Tp_{ART} , e do modelo SWAN, Tp_{SWAN} , para $\alpha = 100$	144
Figura 89 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\alpha = 100$	145
Figura 90 - Erro Médio Absoluto Percentual em relação à variação do parâmetro de escolha da categoria para Hs.	146
Figura 91 - Erro Médio Absoluto Percentual em relação à variação do parâmetro de escolha da categoria para Tp.	147
Figura 92 - Erro Médio Absoluto Percentual em relação à variação do parâmetro de escolha da categoria para DIR.....	147
Figura 93 - Erro Médio Quadrático em relação à variação do parâmetro de escolha da categoria para Hs.....	148
Figura 94 - Erro Médio Quadrático em relação à variação do parâmetro de escolha da categoria para Tp.....	149
Figura 95 - Erro Médio Quadrático em relação à variação do parâmetro de escolha da categoria para DIR.	149
Figura 96 – Média dos Erros Viés em relação à variação do parâmetro de escolha da categoria para Hs.....	150
Figura 97 - Média dos Erros Viés em relação à variação do parâmetro de escolha da categoria para Tp.....	151
Figura 98 - Média dos Erros Viés em relação à variação do parâmetro de escolha da categoria para DIR.	151

Figura 99 – Desvio Padrão dos Erros Viés em relação à variação do parâmetro de escolha da categoria para Hs.	152
Figura 100 - Desvio Padrão dos Erros Viés em relação à variação do parâmetro de escolha da categoria para Tp.	153
Figura 101 - Desvio Padrão dos Erros Viés em relação à variação do parâmetro de escolha da categoria para DIR.....	153
Figura 102 - Comparação de Hs entre ARTMAP-Fuzzy e SWAN na Costa para $\beta = 0,8$	154
Figura 103 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para $\beta = 0,8$	155
Figura 104 - Comparação de Hs entre ARTMAP-Fuzzy e SWAN na Costa para $\beta = 0,3$	155
Figura 105 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para $\beta = 0,3$	156
Figura 106 – Comparação de Tp entre ARTMAP-Fuzzy e SWAN na Costa para $\beta = 0,3$	156
Figura 107 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para $\beta = 0,3$	157
Figura 108 – Comparação de DIR entre ARTMAP-Fuzzy e SWAN na Costa para $\beta = 0,3$	157
Figura 109 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\beta = 0,3$	158
Figura 110 – Erro Médio Absoluto Percentual em relação à variação da taxa de treinamento para Hs.	159
Figura 111 – Erro Médio Absoluto Percentual em relação à variação da taxa de treinamento para Tp.	160
Figura 112 – Erro Médio Absoluto Percentual em relação à variação da taxa de treinamento para DIR.	160
Figura 113 – Erro Médio Quadrático em relação à variação da taxa de treinamento para Hs.	161
Figura 114 - Erro Médio Quadrático em relação à variação da taxa de treinamento para Tp.	162
Figura 115 - Erro Médio Quadrático em relação à variação da taxa de treinamento para DIR.	162

Figura 116 – Média dos Erros Viés em relação à variação da taxa de treinamento para Hs.	163
Figura 117 - Média dos Erros Viés em relação à variação da taxa de treinamento para Tp.	164
Figura 118 - Média dos Erros Viés em relação à variação da taxa de treinamento para DIR.	164
Figura 119 – Desvio Padrão dos Erros Viés em relação à variação da taxa de treinamento para Hs.	165
Figura 120 - Desvio Padrão dos Erros Viés em relação à variação da taxa de treinamento para Tp.	166
Figura 121 - Desvio Padrão dos Erros Viés em relação à variação da taxa de treinamento para DIR.	166
Figura 122 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para 30% do total de treinamento.....	168
Figura 123 – Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Ano: 2011.....	169
Figura 124 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para o Ano : 2011.....	170
Figura 125 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – Ano: 2011.....	170
Figura 126 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para o Ano : 2011.....	171
Figura 127 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Ano: 2011.....	171
Figura 128 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para o Ano : 2011.	172
Figura 129 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Primavera de 2011 (20/04 a 20/05).	172
Figura 130 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para a Primavera de 2011 (20/04 a 20/05).	173
Figura 131 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – Primavera de 2011 (20/04 a 20/05).	173
Figura 132 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para a Primavera de 2011 (20/04 a 20/05).	174

Figura 133 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Primavera de 2011 (20/04 a 20/05).	174
Figura 134 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para a Primavera de 2011 (20/04 a 20/05)... 175	
Figura 135 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Verão de 2011 (20/07 a 20/08).	175
Figura 136 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo SWAN, Hs_{SWAN} , para o Verão de 2011 (20/07 a 20/08).	176
Figura 137 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – Verão de 2011 (20/07 a 20/08).	176
Figura 138 - Correlação de Tp provenientes da rede ARTMAP-Fuzzy, Tp_{ART} , e do modelo SWAN, Tp_{SWAN} , para o Verão de 2011 (20/07 a 20/08).	177
Figura 139 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Verão de 2011 (20/07 a 20/08).	177
Figura 140 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para o Verão de 2011 (20/07 a 20/08).	178
Figura 141 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Outono de 2011 (20/10 a 20/11).	178
Figura 142 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo SWAN, Hs_{SWAN} , para o Outono de 2011 (20/10 a 20/11).	179
Figura 143 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – Outono de 2011 (20/10 a 20/11).	179
Figura 144 - Correlação de Tp provenientes da rede ARTMAP-Fuzzy, Tp_{ART} , e do modelo SWAN, Tp_{SWAN} , para o Outono de 2011 (20/10 a 20/11).	180
Figura 145 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Outono de 2011 (20/10 a 20/11).	180
Figura 146 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para o Outono de 2011 (20/10 a 20/11).	181
Figura 147 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Inverno de 2011 (20/01 a 20/02).	181
Figura 148 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo SWAN, Hs_{SWAN} , para o Inverno de 2011 (20/01 a 20/02).	182
Figura 149 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – Inverno de 2011 (20/01 a 20/02).	182

Figura 150 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para o Inverno de 2011 (20/01 a 20/02).	183
Figura 151 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Inverno de 2011 (20/01 a 20/02).	183
Figura 152 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para o Inverno de 2011 (20/01 a 20/02).	184
Figura 153 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – 1ª Semana aleatória (10/05/2011 a 16/05/2011).	185
Figura 154 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo SWAN, Hs_{SWAN} , para a 1ª Semana aleatória (10/05/2011 a 16/05/2011).	185
Figura 155 - Comparação ARTMAP-Fuzzy com os dados de T_p do SWAN na Costa – 1ª Semana aleatória (10/05/2011 a 16/05/2011).	186
Figura 156 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para a 1ª Semana aleatória (10/05/2011 a 16/05/2011).	186
Figura 157 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – 1ª Semana aleatória (10/05/2011 a 16/05/2011).	187
Figura 158 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para a 1ª Semana aleatória (10/05/2011 a 16/05/2011).	187
Figura 159 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – 2ª Semana aleatória (10/11/2011 a 16/11/2011).	188
Figura 160 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo SWAN, Hs_{SWAN} , para a 2ª Semana aleatória (10/11/2011 a 16/11/2011).	188
Figura 161 - Comparação ARTMAP-Fuzzy com os dados de T_p do SWAN na Costa – 2ª Semana aleatória (10/11/2011 a 16/11/2011).	189
Figura 162 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para a 2ª Semana aleatória (10/11/2011 a 16/11/2011).	189
Figura 163 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – 2ª Semana aleatória (10/11/2011 a 16/11/2011).	190

Figura 164 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para a 2ª Semana aleatória (10/11/2011 a 16/11/2011).	190
Figura 165 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – 3ª Semana aleatória (10/10/2011 a 16/10/2011).	191
Figura 166 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo SWAN, Hs_{SWAN} , para a 3ª Semana aleatória (10/10/2011 a 16/10/2011).	191
Figura 167 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – 3ª Semana aleatória (10/10/2011 a 16/10/2011).	192
Figura 168 - Correlação de Tp provenientes da rede ARTMAP-Fuzzy, Tp_{ART} , e do modelo SWAN, Tp_{SWAN} , para a 3ª Semana aleatória (10/10/2011 a 16/10/2011).	192
Figura 169 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – 3ª Semana aleatória (10/10/2011 a 16/10/2011).	193
Figura 170 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para a 3ª Semana aleatória (10/10/2011 a 16/10/2011).	193
Figura 171 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – 4ª Semana aleatória (10/08/2011 a 16/08/2011).	194
Figura 172 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo SWAN, Hs_{SWAN} , para a 4ª Semana aleatória (10/08/2011 a 16/08/2011).	194
Figura 173 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – 4ª Semana aleatória (10/08/2011 a 16/08/2011).	195
Figura 174 - Correlação de Tp provenientes da rede ARTMAP-Fuzzy, Tp_{ART} , e do modelo SWAN, Tp_{SWAN} , para a 4ª Semana aleatória (10/08/2011 a 16/08/2011).	195
Figura 175 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – 4ª Semana aleatória (10/08/2011 a 16/08/2011).	196
Figura 176 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para a 4ª Semana aleatória (10/08/2011 a 16/08/2011).	196

Figura 177 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Ano: 2012 (parcial).	197
Figura 178 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para o Ano : 2012 (parcial).	198
Figura 179 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – Ano: 2012 (parcial).	198
Figura 180 - Correlação de Tp provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para o Ano : 2012 (parcial).	199
Figura 181 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Ano: 2012 (parcial).	199
Figura 182 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} para o Ano : 2012 (parcial).	200
Figura 183 - Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto A – Ano: 2009.	204
Figura 184 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo DREAMS, $H_{sDREAMS}$, no Ponto A - Ano: 2009.	204
Figura 185 – Comparação ARTMAP-Fuzzy com os dados de Tp do DREAMS no Ponto A – Ano: 2009.	205
Figura 186 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo DREAMS, $T_{pDREAMS}$, no Ponto A - Ano: 2009.	205
Figura 187 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto A – Ano: 2009.	206
Figura 188 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto A - Ano: 2009.	206
Figura 189 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto B – Ano: 2009.	207
Figura 190 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo DREAMS, $H_{sDREAMS}$, no Ponto B - Ano: 2009.	207
Figura 191 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto B – Ano: 2009.	208
Figura 192 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto B - Ano: 2009.	208
Figura 193 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto C – Ano: 2009.	209

Figura 194 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo DREAMS, $H_{sDREAMS}$, no Ponto C - Ano: 2009.	209
Figura 195 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto C – Ano: 2009.....	210
Figura 196 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto C - Ano: 2009.....	210
Figura 197 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto D – Ano: 2009.....	211
Figura 198 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo DREAMS, $H_{sDREAMS}$, no Ponto D - Ano: 2009.....	211
Figura 199 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto D – Ano: 2009.....	212
Figura 200 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto D - Ano: 2009.....	212
Figura 201 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto E – Ano: 2009.	213
Figura 202 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo DREAMS, $H_{sDREAMS}$, no Ponto E - Ano: 2009.....	213
Figura 203 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto E – Ano: 2009.	214
Figura 204 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto E - Ano: 2009.....	214
Figura 205 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto F – Ano: 2009.....	215
Figura 206 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo DREAMS, $H_{sDREAMS}$, no Ponto F - Ano: 2009.....	215
Figura 207 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto F – Ano: 2009.	216
Figura 208 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto F - Ano: 2009.	216
Figura 209 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto G – Ano: 2009.....	217
Figura 210 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo DREAMS, $H_{sDREAMS}$, no Ponto G - Ano: 2009.....	217

Figura 211 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto G – Ano: 2009.....	218
Figura 212 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto G - Ano: 2009.....	218
Figura 213 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto E – Ano: 2009 (parcial).....	219
Figura 214 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo DREAMS, Hs_{DREAMS} , no Ponto E - Ano: 2009 (parcial).....	220
Figura 215 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto E – Ano: 2009 (parcial).....	220
Figura 216 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto E - Ano: 2009 (parcial).....	221
Figura 217 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto G – Ano: 2009 (parcial).	221
Figura 218 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo DREAMS, Hs_{DREAMS} , no Ponto G - Ano: 2009 (parcial).....	222
Figura 219 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto G – Ano: 2009 (parcial).	222
Figura 220 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto G - Ano: 2009 (parcial).	223
Figura 221 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto G – Ano: 2011 (parcial).	223
Figura 222 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo DREAMS, Hs_{DREAMS} , no Ponto G - Ano: 2011.....	224
Figura 223 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto G – Ano: 2011 (parcial).	224
Figura 224 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto G - Ano: 2011 (parcial).	225
Figura 225 - Comparação ARTMAP-Fuzzy, DREAMS e MiniTroll, para Hs no Ponto E – 26/02/2009.....	228
Figura 226 - Comparação ARTMAP-Fuzzy, DREAMS e LevelTroll, para Hs no Ponto G – 26/02/2009.....	228
Figura 227 - Comparação ARTMAP-Fuzzy, DREAMS e Infinity, para Hs no Ponto G – 25/02/20011.....	229

Figura 228 – Correlação dos galgamentos provenientes da rede ARTMAP-Fuzzy, q_{ART} , e da base de dados do projeto CLASH, q_{CLASH} , para 3.000 testes: a) todos os valores; b) valores para $q_{CLASH} < 0,0005 \text{ m}^3/\text{s}/\text{m}$; c) valores para $q_{CLASH} < 0,00005 \text{ m}^3/\text{s}/\text{m}$	231
Figura 229 - Diferentes geometrias da base de dados CLASH testadas com a rede ARTMAP-Fuzzy.	232
Figura 230 – Correlação dos galgamentos provenientes da rede ARTMAP-Fuzzy, q_{ART} , e da base de dados do projeto CLASH, q_{CLASH} , para os tipos de geometria analisados.	233
Figura 231 - Correlação dos galgamentos provenientes da rede ARTMAP-Fuzzy, q_{ART} , e do modelo reduzido, q_{MF} , para os 12 ensaios analisados.	234
Figura 232 – Correlação dos galgamentos provenientes das ferramentas a) NN_OVERTOPPING2, q_{NN} , e b) OVERTOPPING, q_{OVER} , e do modelo reduzido, q_{MF} , para os 12 ensaios analisados.....	236
Figura 233 - Correlação de H_s provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do ondógrafo óptico, H_{sOND} , para 30% de dados desconhecidos.....	239
Figura 234 - Correlação de H_s provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do ondógrafo óptico, H_{sOND} , para 50% de dados desconhecidos.....	240
Figura 235 - Correlação de H_s provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do ondógrafo óptico, H_{sOND} , para 70% de dados desconhecidos.....	240

LISTA DE TABELAS

Tabela 1- Parâmetros Estatísticos na Boia Sines-1D e no ponto P6.	82
Tabela 2 - Arquivo Sines.....	86
Tabela 3 - Localização geográfica dos 7 pontos de resultados do modelo DREAMS...	92
Tabela 4 – Alturas e Períodos de onda após tratamento dos dados.	95
Tabela 5 - Caudais médios de galgamento por metro linear de estrutura obtidos no modelo físico, q_{MF} , em valores do protótipo.	100
Tabela 6 - Adimensionalização dos parâmetros de entrada e saída da rede ARTMAP-Fuzzy.....	103
Tabela 7 - Velocidades médias mensais do vento para a campanha de 2008-2009.	107
Tabela 8 - Frequências mensais do vento para a campanha de 2008-2009.....	107
Tabela 9 - Ventos dominantes mensais para a campanha de 2008-2009.	107
Tabela 10 – Resumo das médias durante a campanha de 2008-2009.	108
Tabela 11 - Exemplo da base de dados utilizada.....	114
Tabela 12 - Erro Médio Absoluto Percentual em relação à variação do critério de vigilância de saída.....	129
Tabela 13 - Erro Médio Quadrático em relação à variação do critério de vigilância de saída.	131
Tabela 14 - Média dos Erros Viés em relação à variação do critério de vigilância de saída para H_s	133
Tabela 15 - Desvio Padrão dos Erros Viés em relação à variação do critério de vigilância de saída.....	135
Tabela 16 – Variação de T_j em relação à variação de α	145
Tabela 17 - Erro Médio Absoluto Percentual em relação à variação do parâmetro de escolha da categoria.....	146
Tabela 18 - Erro Médio Quadrático em relação à variação do parâmetro de escolha da categoria.....	148
Tabela 19 - Média dos Erros Viés em relação à variação do parâmetro de escolha da categoria.....	150
Tabela 20 - Desvio Padrão dos Erros Viés em relação à variação do parâmetro de escolha da categoria.....	152

Tabela 21 - Erro Médio Absoluto Percentual em relação à variação da taxa de treinamento.	159
Tabela 22 - Erro Médio Quadrático em relação à variação da taxa de treinamento.....	161
Tabela 23 - Média dos Erros Viés em relação à variação da taxa de treinamento.	163
Tabela 24 - Desvio Padrão dos Erros Viés em relação à variação da taxa de treinamento.	165
Tabela 25 – Erros calculados para Hs.	200
Tabela 26 - Erros calculados para Tp.	201
Tabela 27 - Erros calculados para DIR.....	201
Tabela 28 – Erros calculados para Hs.	225
Tabela 29 - Erros calculados para Tp.	226
Tabela 30 - Erros calculados para DIR.....	226
Tabela 31 - Comparação dos galgamentos provenientes da rede ARTMAP-Fuzzy, q_{ART} , e do modelo reduzido, q_{MF} , para os 12 ensaios analisados.....	233
Tabela 32 – Mapeamento dos erros dos caudais médios de galgamento obtidos através da rede ARTMAP-Fuzzy para os 12 ensaios analisados.....	234
Tabela 33 - Comparação dos galgamentos provenientes das ferramentas NN_OVERTOPPING2, q_{NN} , OVERTOPPING, q_{OVER} , e ARTMAP-Fuzzy, q_{ART} , com os medidos no modelo reduzido, q_{MF} , para os 12 ensaios analisados.....	236
Tabela 34 – Mapeamento dos erros dos caudais médios de galgamento obtidos através das ferramentas NN_OVERTOPPING2, OVERTOPPING e ARTMAP-Fuzzy para as melhores representações da estrutura.	237

LISTA DE SÍMBOLOS

X_p	entradas no modelo de neurônio artificial
$W_{k,p}$	pesos no modelo de neurônio artificial
ϕ	função de ativação
Y_k	saída no modelo de neurônio artificial
F_0	camada que representa o vetor de entradas
F_1	camada de comparação
F_2	camada de reconhecimento
w_i	pesos de conexão do tipo <i>feedforward</i>
w_j	pesos de conexão do tipo <i>feedback</i>
ρ	parâmetro de vigilância
M	número de vetores de entrada na camada F_1
N	dimensão dos vetores na camada F_2 formam as categorias
β	taxa de treinamento
α	parâmetro de escolha
x	vetor de entrada
F_{1b}	parte superior da camada de comparação
F_{1a}	parte inferior da camada de comparação
a_{ij}	memória na conexão da <i>i-ésima</i> unidade de F_1 para F_2
d_{ij}	memória na conexão da <i>i-ésima</i> unidade de F_2 para F_{1b}
a	dados de entrada
$\bar{a}$	vetor normalizado
$\bar{a}_c$	vetor complementar de entrada normalizada
I	novo vetor de entrada normalizado
y_j	vetor de atividade F_2
T_j	função de escolha da categoria
J	categoria ativa (escolhida) para o módulo ART_a
K	categoria ativa (escolhida) para o módulo ART_b
w^a	vetor peso na ART_a
w^{ab}	vetor peso no módulo inter-ART
w^b	vetor peso na ART_b
ε	incremento na vigilância do módulo ART_a

H_s	altura significativa de onda
H_{m0}	altura de ondas no momento de ordem zero
$H_{1/3}$	altura de onda calculada pela média dos terços superiores
H	altura de onda
L	comprimento de onda
S	declividade da onda
T	período da onda
T_m	período médio
T_p	período de pico
S_{0m}	declividade média
S_{0p}	declividade de pico
L_0	comprimento de onda ao largo
h	profundidade da água
$T_{1/3}$	periodo médio calculado pelo média dos terços superiores
$T_{m-1,0}$	período médio calculado pelo momento espectral
ξ	número de Iribarren
S	declividade da onda
S_0	declividade da onda ao largo
ξ_0	número de Iribarren ao largo
ξ_{0m}	número de Iribarren médio
ξ_{0p}	número de Iribarren de pico
S_{0m}	declividade média
S_{0p}	declividade de pico
DIR	direção média da onda
C	velocidade de fase ou celeridade da onda
C_g	velocidade de grupo
Φ	potencial de velocidade, função das coordenadas (x,y)
η	elevação da superfície livre
ω	frequência angular ou frequência absoluta
g	aceleração da gravidade
q_{MF}	caudais médios de galgamento por metro linear do modelo físico
q_{ART}	caudais médios de galgamento por metro linear da rede ARTMAP_Fuzzy

q_{NN}	caudais médios de galgamento por metro linear da NNOVERTOPING_2
q_{OVER}	caudais médios de galgamento por metro linear da OVERTOPPING
β_t	ângulo entre a direção de propagação da agitação e a normal à estrutura
h_t	profundidade da banquetta de fundo da estrutura
B_t	largura da banquetta de fundo da estrutura
$\cot \alpha_d$	1º declive da estrutura
$\cot \alpha_u$	2º declive da estrutura
B	largura da berma
h_b	profundidade de água na berma
$\tan \alpha_B$	inclinação da berma
R_c	o bordo livre do coroamento
A_c	distância entre o meio da berma de coroamento e o nível da água
G_c	largura de coroamento
γ_f	rugosidade e permeabilidade da estrutura
H_{SART}	altura significativa obtida pela ARTMAP-Fuzzy
H_{SOND}	altura significativa obtida pelo ondógrafo óptico
FAM	fuzzy artmap

SUMÁRIO

1 INTRODUÇÃO	31
1.1 Definição do Problema	31
1.2 Principais Referências.....	33
1.3 Objetivo do Trabalho	35
1.4 Organização da Tese	36
2 REDES NEURAIS ARTIFICIAIS.....	37
2.1 Neurônio Biológico e Artificial	37
2.2 Histórico de Desenvolvimento das RNAs	39
2.3 Funcionamento das RNAs	43
2.4 Treinamento e Arquitetura das RNAs	46
3 TEORIA DA RESSONÂNCIA ADAPTIVA	49
3.1 Introdução	49
3.2 Principais Características e Fundamentos	50
3.3 Estrutura da Rede Neural ART	51
3.4 Parâmetros da Rede ART.....	53
3.5 Redes Neurais ART-1, ART-2 e ART-Fuzzy	54
3.5.1 Rede Neural ART-1.....	54
3.5.2 Rede Neural ART-2.....	56
3.5.3 Rede Neural ART-Fuzzy	56
3.5.4 Lógica Fuzzy	57
3.5.5 Algoritmo da ART-Fuzzy.....	59
3.6 Rede Neural ARTMAP	62
3.7 Rede Neural ARTMAP-Fuzzy.....	63
3.7.1 Funcionamento da Rede ARTMAP-Fuzzy	65
4 ONDAS MARÍTIMAS E EM LAGOS.....	68
4.1 Introdução	68
4.2 Definição dos Parâmetros Chave para Ondas Marítimas	68

4.2.1 Altura de Onda	68
4.2.2 Período de Onda	69
4.2.3 Arrebentação das Ondas	69
4.3 Galgamentos (<i>Overtopping</i>).....	72
4.4 Definição dos Parâmetros Chave para Ondas em Lagos.....	73
4.4.1 Ventos.....	73
4.4.2 Pista de Ventos	74
4.4.3 Altura de Onda	74
5 DESCRIÇÃO DOS CASOS DE ESTUDO.....	76
5.1 Descrição da Área de Estudo: Porto de Sines	76
5.1.1 Descrição Geral	76
5.1.2 Caracterização das Condições ao Largo (Offshore)	77
5.1.3 Metodologia de Transferência do Regime de Agitação	79
5.1.4 Caracterização das Condições em Frente ao Porto.....	82
5.1.4.1 <i>Modelo numérico SWAN</i>	83
5.1.4.2 <i>Aplicação do SWAN - Domínio de Cálculo, Batimetria e Malhas Computacionais</i>	84
5.1.5 Caracterização das Condições dentro do Porto	86
5.1.5.1 <i>Modelo Numérico DREAMS</i>	86
5.1.5.2 <i>Aplicação do DREAMS - Domínio de Cálculo, Batimetria e Malha Computacional</i>	90
5.1.5.3 <i>Regime de Agitação no Interior do Porto de Sines</i>	92
5.1.5.4 <i>Campanha de Medição no Interior do Porto</i>	93
5.2 Caracterização das Condições de Galgamento no Mole Oeste.....	96
5.2.1 Perfil Analisado	96
5.2.2 Modelagem Física	97
5.2.3 Modelagem com Redes Neurais	100
5.3 Descrição da Área de Estudo: Lago de Ilha Solteira.....	103
5.3.1 Dados de Ondas	110
6 RESULTADOS E DISCUSSÃO	115
6.1 Análise de Sensibilidade dos Parâmetros da Rede fora do Porto	115
6.1.1 Variação da Vigilância na Saída (ρ_b).....	115

6.1.2 Variação do parâmetro de escolha (α)	140
6.1.3 Variação da Taxa de Treinamento (β)	154
6.1.4 Variação dos Parâmetros de Vigilância da Entrada (ρ_a) e de Entrada/Saída (ρ_{ab})	167
6.2 Diagnóstico da ARTMAP-Fuzzy para Agitação Marítima fora do Porto (comparação com o modelo numérico SWAN).....	167
6.3 Previsão da ARTMAP-Fuzzy para Agitação Marítima fora do Porto.....	168
6.4 Previsão da ARTMAP-Fuzzy para Agitação Marítima dentro do Porto	203
6.5 Aplicação da Rede ARTMAP-Fuzzy ao Estudo do Galgamento no Porto de Sines	229
6.6 Diagnóstico da ARTMAP-Fuzzy para o Estudo do Galgamento no Porto de Sines	230
6.7 Previsão da ARTMAP-Fuzzy para o Cálculo de Galgamento (Comparação com os Resultados do Modelo Reduzido)	233
6.8 Previsão da ARTMAP-Fuzzy para o Cálculo de Galgamento (Comparação com Outras Ferramentas Neurais)	235
6.9 Previsão da ARTMAP-Fuzzy para Comportamento de Ondas no Lago de Ilha Solteira.....	238
7 CONCLUSÃO E PERSPECTIVAS FUTURAS.....	242
8 PUBLICAÇÕES RESULTANTES	245
REFERÊNCIAS BIBLIOGRÁFICAS	246

1 INTRODUÇÃO

1.1 Definição do Problema

As inundações são fenômenos naturais que parecem existir desde antes do surgimento do homem no planeta Terra. Ao deixar de ser nômade, o homem preferencialmente ocupou as áreas próximas a cursos d'água, pois ali ele poderia ter acesso fácil a outros locais através de embarcações, água para o seu consumo e mesmo onde dispor seus dejetos. Esta preferência humana ainda prevalece nos dias de hoje e a grande maioria das cidades está próxima a cursos d'água, suscetíveis a inundações (DORNELLES, 2007).

Essa ocupação do homem, seja ela em mananciais de água doce ou litorais marítimos, aliado a tentativa de amenizar os efeitos naturais, faz com que estruturas sejam projetadas a fim de garantir qualidade de vida e segurança às populações vizinhas.

Dentre as atividades para proteção contra inundações, existem as medidas estruturais e as não estruturais. As medidas estruturais são caracterizadas por intervenções físicas que modificam o escoamento, confinam o fluxo ou amortecem o impacto das ondas.

Segundo Dornelles (2007), proteções estruturais, tais como diques, pôlderes, represas, moles, espigões e quebra-mares, sempre são projetadas para um determinado tempo de recorrência dos eventos de inundação, sendo que, para situações além do projetado, os prejuízos são amplificados, pois nas zonas “protegidas” a ocupação é intensificada pela falsa segurança de que a inundação nunca chegará àquela região.

Mas, o que se verifica antes dos projetos dessas estruturas, perpassa os conceitos de engenharia, tendo suas origens na construção de modelos matemáticos que possam antecipar a ocorrência de ondas de cheia, agitação marítima ou marés não só por experiências, mas como previsões de eventos que seriam capazes de ultrapassar essas barreiras. Para isso, modelos numéricos de previsão têm sido muito utilizados no campo da engenharia há muitas décadas.

As consequências de situações indesejadas podem ser graves quando existe manifesta falta de segurança, nomeadamente no que se refere a perdas de vidas, bens materiais e a consequências para o meio ambiente (Figura 1).

Atendendo à natureza das zonas costeiras e portuárias, e das áreas de grandes reservatórios de barragens, o cumprimento do acima proposto se traduz na necessidade de caracterização da agitação nestes locais. Para isso, realiza-se a integração de dados de condições de ondas, medidos na proximidade do local em estudo ou obtidos com modelos de previsão da agitação, com resultados de modelos numéricos, de modelos físicos ou de formulações empíricas, de forma a simular um conjunto de cenários capaz de conter condições menos favoráveis à segurança dessas zonas. Há necessidade ainda de metodologias de previsão e monitoramento de ondas para: fins de segurança à navegação, proteção de margens e eventuais áreas de abrigo, em se tratando de segurança de reservatórios.

Figura 1 - Ilustração de situações de risco associadas a zonas costeiras e portuárias.



Fonte: Arquivo Fotográfico do LNEC.

No que diz respeito a medições em campo da agitação das ondas, embora sejam a metodologia mais confiável, na maioria dos locais são escassas, pontuais ou mesmo inexistentes. No caso da modelagem numérica, a utilização de modelos de propagação e deformação das condições de ondas permite a simulação de cenários reais. Estes modelos são muito exigentes do ponto de vista computacional e têm as suas próprias limitações, essencialmente relacionadas com o fato de dificilmente conseguirem simular

todos os fenômenos físicos envolvidos no complexo processo de geração, propagação e dissipação de agitação marítima e ondas em lagos. Cita-se como exemplo desses fenômenos: refração, empolamento (devido à variação do fundo e presença de correntes), difração, rebentação (por influência do fundo e por “excesso” de declividade – *whitecapping*), interação onda-correntes, dissipação de energia devido ao atrito de fundo, etc. Com relação a fenômenos de interação onda-estrutura, pode-se destacar: reflexão, transmissão através de obstáculos, dissipação, etc.

A modelagem física permite analisar estes fenômenos, mas é dispendiosa, morosa, exige infraestruturas e equipamento muito específico e requer uma elevada experiência de quem realiza os ensaios e analisa os seus resultados.

Assim sendo, quando a capacidade de utilização desses modelos, quer sejam numéricos ou físicos, se torna complicada, muito dispendiosa do ponto de vista computacional ou financeiro, ou com o aparecimento de muitas variáveis complexas, as técnicas de utilização de Redes Neurais Artificiais (RNAs) têm sido empregadas com grande satisfação dentro da literatura.

Assim, é proposto nessa pesquisa, a utilização de Redes Neurais Artificiais tipo ARTMAP, com técnicas da Lógica Fuzzy, para tentar absorver a complexidade de modelos de previsão de ondas, sejam eles em ambientes confinados (lagos) ou abertos (mar).

1.2 Principais Referências

Nas últimas décadas, técnicas baseadas em redes neurais artificiais têm-se mostrado muito úteis na prática da Engenharia (LONDHE; DEO, 2004), mas apresentam ainda limitações relacionadas essencialmente com a falta de capacidade de generalização. Outro fator de relevante importância é a utilização, em sua grande maioria, somente de redes do tipo MLP (*Multilayer Perceptron*), as quais, recentemente, são apresentadas com diversas topologias (VERHAEGHE, 2005).

Em se tratando da utilização vários tipos de redes neurais, aplicadas a estudos em zonas costeiras, tem-se como referências trabalhos no campo internacional que são de suma importância e podem ser citados:

- “*Analysis of the stability of rubble mound breakwaters*” (MASE et al., 1995);

- “*Prediction of wave forces on vertical structures*” (VAN GENT e VAN DEN BOOGAARD, 1998);
- “*Prediction of wave run-up and overtopping*” (MEDINA, 1999 e MEDINA *et al.*, 2002);
- “*Prediction of wave transmission*” (PANIZZO *et al.*, 2003);
- “*Tidal level forecasting*” (TSAI *et al.*, 1999);
- “*Prediction of the occurrence of impact wave force*” (MASE *et al.*, 1999);
- “*Analysis of wave directional spreading*” (DEO *et al.*, 2002);
- “*Prediction of storm-built beach profile parameters*” (TSAI *et al.*, 2000);
- “*Prediction of scour depths at culvert outlets*” (LIRIANO e DAY, 2001);
- “*Prediction of wind induced water levels*” (WESTRA *et al.*, 2002);
- “*Prediction of the breaker depth and breaking height of breaking waves*” (DEO e YAGDALE, 2003);

Já, no campo de estudos de casos nacionais, alguns trabalhos utilizando redes neurais podem ser citados no que tange a estudos de engenharia costeira, variações climáticas, previsões no campo de recursos hídricos, variações de séries temporais, etc.

- “Uso de Redes Neurais Artificiais e Teoria dos Conjuntos Aproximativos no Estudo de Padrões Climáticos Sazonais” (ANOCHI, 2009);
- “Predição da Variação Extrema do Nível do Mar Relacionada a Tempestades Severas Utilizando Redes Neurais Artificiais” (OLIVEIRA, 2009);
- “Análise do desempenho de Redes Neurais Artificiais no preenchimento de falhas em séries de precipitação diária” (ALMEIDA, 2012);
- “Inferência Bayesiana no Desenvolvimento de Previsores Neurais de Vazão Diária utilizando Informações de Precipitação” (LEOCÁDIO, 2012);
- “Previsão de Vazões Médias Mensais usando Redes Neurais Nebulosas” (BALLINI, 2003);
- “Redes Neurais Artificiais na Previsão de Séries Temporais” (ABELÉM, 1994),
- “Estimativa de padrões espaço-temporais utilizando redes neurais artificiais e Física Solar” (ANDRADE *et al.*, 2001);
- “Predição Não-Linear de Séries Temporais Usando Redes Neurais RBF por Decomposição de Componentes Principais” (CASTRO, 2001);
- “Previsão de vazões mensais utilizando redes neurais multicamadas com algoritmo *backpropagation*” (KADOWAKI e ANDRADE, 1997);

- “Análise de Modelos de Redes Neurais Aplicados ao Processo Chuva-Deflúvio no Semi-Arido” (FERREIRA *et al.*, 2003);
- “Previsão de Níveis Fluviais com Redes Neurais: aplicação para Rosário do Sul – RS. Porto Alegre” (PEDROLLO, 2005);
- “Modelagem chuva-vazão mensal utilizando redes neurais” (MACHADO, 2005).

Observa-se que ainda é muito escassa (quase inexistente) a presença de trabalhos de redes neurais artificiais da família ART, notadamente ARTMAP-Fuzzy seja no campo de engenharia costeira ou no estudo de ondas em lagos. Isso se reflete como uma das justificativas da utilização dessa família de redes para tentativa, por exemplo, de uma possível melhora do ganho computacional ou refinamento dos resultados. Outro fator de interesse está no fato da rede em questão ser auto-organizável, o que facilita a configuração da mesma, no que se refere à composição dos neurônios.

1.3 Objetivo do Trabalho

A previsão de agitação marítima, ondas de cheia, galgamentos, têm sido enfocadas, pela literatura, utilizando vários modelos matemáticos. Atualmente, encontram-se na mesma inúmeras técnicas que vem mostrando resultados bastante satisfatórios, as quais são baseadas em modelagem matemática. Contudo, ainda há um grande espaço para a pesquisa no uso de redes neurais, principalmente quando os modelos empregados se tornam muito complexos, com grande quantidade de variáveis ou com elevado custo computacional.

O objetivo principal deste trabalho é aplicar a rede ARTMAP-Fuzzy, sendo ela pertencente à família de redes neurais ART (*Adaptive Resonance Theory*), à previsão de agitação marítima e galgamento na costa portuguesa e do comportamento de ondas no lago de Ilha Solteira.

1.4 Organização da Tese

O trabalho está dividido em oito capítulos, sendo organizado da seguinte forma: introdução, redes neurais artificiais, teoria da ressonância adaptiva, ondas marítimas e

em lagos, descrição dos casos de estudo, resultados e discussão, conclusão e perspectivas futuras, publicações resultantes e referenciais teóricos.

O capítulo 1 refere-se à definição do problema estudado, assim como um apanhado sobre as principais referências encontradas na literatura e a organização desse trabalho.

No capítulo 2 é feita uma abordagem geral sobre redes neurais artificiais contendo em seu escopo o histórico, funcionamento, treinamento e aprendizagem das mesmas.

O capítulo 3 enfoca a teoria da ressonância adaptiva contendo os principais tipos de redes da família ART assim como um a rede utilizada nessa pesquisa (ARTMAP-Fuzzy).

Já, o capítulo 4, trás consigo uma introdução e definição dos parâmetros em relação à teoria de agitação marítima e ondas em lagos.

O capítulo 5 descreve as áreas de estudo, métodos de cálculo e modelos utilizados, isso no Porto de Sines – Portugal e no reservatório formado pela barragem de Ilha Solteira – São Paulo – Brasil.

No capítulo 6 são apresentados os resultados e discussões quando da aplicação da rede ARTMAP-Fuzzy, para previsão de agitação marítima e galgamentos, Porto de Sines e; comportamento de ondas no Lago de Ilha Solteira, respectivamente.


O capítulo 7 apresenta as principais conclusões dessa pesquisa, assim como as perspectivas futuras. O capítulo 8 apresenta as comunicações científicas resultantes desse trabalho e, encerra-se com a apresentação das referências bibliográficas utilizadas.

2 REDES NEURAIS ARTIFICIAIS

2.1 Neurônio Biológico e Artificial

O capítulo a seguir é uma adaptação de alguns autores no que tange a inspiração biológica. O mesmo se faz necessário para que se tenha uma ideia dos princípios de correlação básicos entre as redes neurais artificiais e o funcionamento das redes neurais biológicas (Figura 2). Essa revisão simplista sobre o assunto tem como princípio o fornecimento de uma noção básica para fins de utilização dessas ferramentas em trabalhos posteriores no campo de aplicação da engenharia civil, notadamente na área de hidráulica marítima ou hidráulica de superfície livre.

Figura 2 - Imagem Ilustrativa da Rede Neural Biológica.



Fonte: Adaptado de Dennis Kunkel (www.DennisKunkel.com).


Segundo Haykin (2001), no cérebro existe um fluxo de informações codificadas (neurotransmissão) da sinapse em direção ao axônio, através do qual a informação é transmitida para outros neurônios (Figura 3). Um neurônio recebe informações das sinapses de muitos outros neurônios, e cada neurônio pode receber informações de

outros neurônios. Estima-se que o cérebro humano possua cerca de 10^{12} neurônios no córtex, conectados num sistema altamente complexo de 10^{14} a 10^{15} conexões ou sinapses.

Segundo Kartalopoulos (1996), o neurônio possui um corpo celular chamado soma constituído de núcleo e pericárdio, que dá suporte metabólico a toda célula. Os dendritos são ramificações nervosas (arborizações terminais) que emergem do pericárdio e do final do axônio e conduzem sinais elétricos das extremidades para o corpo celular, sendo, na maioria das vezes, responsáveis pela comunicação entre os neurônios através das sinapses. O axônio é uma ramificação maior (fibra nervosa) e única que aparece no soma.

Para Kovács (2002), o neurônio biológico é o dispositivo computacional elementar do sistema nervoso. O mesmo possui múltiplas entradas e uma saída. As entradas ocorrem por meio de conexões sinápticas, que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por estes axônios são pulsos elétricos conhecidos por potenciais de ação. Estes constituem a informação que o neurônio irá processar para produzir como saída um impulso nervoso no seu axônio. A Figura 3 ilustra o modelo de um neurônio humano.

Figura 3 - Modelo de um neurônio.



Fonte: Adaptado de Packter (2005).

Segundo Corrêa (2004), o comportamento de um neurônio irá depender do estado em que o mesmo se encontra e do grau de estimulação que ele recebe. Estes estímulos são provenientes de outros neurônios e chegam como um sinal eletroquímico através dos axônios, que se encaminham até a outra extremidade do neurônio e se ramificam para estabelecer comunicação com os outros neurônios.

Segundo Kovács (2002) uma vez que essas moléculas do neurotransmissor são liberadas de uma célula como resultado do disparo de um potencial de ação, elas se ligam a receptores específicos na superfície da célula pós-sináptica. A partir disso os neuroreguladores insinuam uma função reguladora que modula as características operacionais dos neurônios receptores, isto em suas respostas aos neurotransmissores.

Lorenzi (2009) mostra que as conexões entre os neurônios não foram predeterminadas, mas foi algo que evoluiu para competir com as circunstâncias impostas pelo ambiente.

Segundo Lorenzi (2009), o cérebro executa tarefas como reconhecimento de padrões e processamento visual em tempos muito mais rápidos do que qualquer computador. Entretanto, o cérebro humano pode ser influenciado pela emoção e não é muito eficiente quando se depara com algum problema que envolve um grande número de variáveis. Além disso, treinar o cérebro humano de forma a que ele execute suas habilidades requer um grande tempo de treinamento.

Como é de conhecimento geral o treinamento do cérebro inicia-se no nascimento e se faz continuamente ao longo da vida. O cérebro pode ser visto como um sistema paralelo de processamento de alta capacidade, capaz de lidar com informações extremamente complexas, de forma não linear. Assim, por mais adiantado que a tentativa de transferência para máquinas do procedimento comportamental do cérebro esteja, há de se ressaltar o quão longe ainda isso está (LORENZI, 2009).

2.2 Histórico de Desenvolvimento das RNAs

Segundo Ganascia (1997), durante a década de 40, biólogos, físicos e especialistas em eletrônica decidiram fabricar um modelo do sistema nervoso. Esperava-se, desta forma, compreender os fenômenos cognitivos, através de uma simulação do material biológico no qual tomavam forma.

Segundo Haykin (2001), a era moderna das redes neurais começou com o trabalho pioneiro de McCulloch e Pitts (1943). McCulloch foi um psiquiatra e neuroanatomista que passou cerca de 20 anos refletindo sobre a apresentação de um evento no sistema nervoso. Pitts foi um prodígio matemático que se associou a McCulloch em 1942. O trabalho intitulava-se “*A logical calculus of the ideas immanent in nervous activity*”.

Segundo Lorenzi (2009), o estudo envolvia a análise do comportamento de um neurônio biológico. Seu objetivo era criar um modelo matemático que simulasse o comportamento de um neurônio. Este trabalho estabeleceu muitos dos teoremas fundamentais que embasaram os futuros estudos sobre as Redes Neurais Artificiais (RNAs).


Com o intuito de simular a capacidade humana de aprendizagem, através de estruturas semelhantes à rede neural biológica, surgiram as RNAs. Estas, por sua vez, são uma forma de programação não algorítmica, baseada em processamento distribuído paralelo de suas unidades, os neurônios artificiais (HAYKIN, 2001). Sendo possível modelar computacionalmente as conexões neurais, surge a idéia de que também será possível fazer emergir comportamentos inteligentes em máquinas (SIMEÓN, 2008).

Ainda em Lorenzi (2009), a tese fundamental defendida por McCulloch e Pitts era de que todo fenômeno psicológico pode ser analisado e compreendido em termos da atividade em uma rede de dispositivos lógicos de dois estados. Essa ideia parece ocupar um espaço pequeno devido a sua simplicidade, mas o que acarretou a posteriori deslumbrou-se em alguns pontos de extremo interesse:

a) atividade do neurônio é do tipo tudo ou nada (0 ou 1); ou seja, o neurônio estará no estado ativado se a sua saída ultrapassar um valor limite. Caso contrário, ficará no estado de repouso. Entende-se por estado ativado transmitir a saída a outros neurônios da rede (MUELLER, 2000);

b) a atividade de qualquer sinapse inibitória previne a excitação do neurônio naquele instante. Esta afirmação teve grande importância na construção do neurônio formal a partir do conceito de pesos, ou seja, cada entrada do neurônio terá um valor associado. Caso este seja positivo, tenderá a excitar a célula. Caso ele seja negativo, tenderá a inibir a mesma (MUELLER, 2000).

Figura 4 - Modelo de neurônio artificial.



Fonte: Adaptada de Simeón (2008).

A Figura 4 representa um modelo de neurônio artificial. As entradas, correspondentes aos dendritos dos neurônios biológicos, estão representadas pelas variáveis x_p . As ligações sinápticas entre os axônios dos outros neurônios e os dendritos deste são representadas pelos pesos $w_{k,p}$. A função de ativação ϕ processa o somatório das entradas ponderadas pelos seus respectivos pesos, para produzir a saída final do neurônio y_k . O valor desta saída é enviado aos demais neurônios. Os pesos dos neurônios artificiais após o processo de aprendizagem armazenam o conhecimento adquirido pela rede (HAYKIN, 2001 e KOVÁCS, 2002).

A partir do modelo de um neurônio artificial podem ser construídas as RNAs, que são neurônios artificiais interconectados simulando a estrutura neural biológica. Diversas topologias foram propostas para diferentes tipos de aplicação. Uma construção bastante popular no domínio de reconhecimento de padrões é a rede multicamada, (MLP) utilizando o algoritmo de aprendizado *backpropagation*.

Embora este modelo atenda razoavelmente as capacidades citadas em relação às unidades constituintes do cérebro, ele apresenta problemas quanto aos requisitos da memória como faculdade mental: o aprendizado incremental e as duas classificações, de curto e longo termo (SIMEÓN, 2008). Uma vez treinada, se apresentado um exemplo novo, sozinho, à rede, informações anteriores podem ser perdidas no processo. Ou seja, para um novo acontecimento, talvez haja a necessidade de se treinar novamente a rede, o que tornaria o processo dispendioso do ponto de vista computacional.

Voltando a história evolutiva das redes, Kovács (2002) ilustrou que a essência da proposta de McCulloch e Pitts consistia na noção de que a inteligência pode ser considerada, essencialmente, como um série de cálculos de predicados, atividade que pode ser implementada por meio de funções booleanas. O sistema nervoso é composto por uma rede de neurônios que, com as devidas simplificações, tem justamente a capacidade de implementar esta função.

De acordo com Sanad e Saka (2001), uma RNA é uma ferramenta computacional que tenta simular a arquitetura e o modo de operar do cérebro humano e seu sistema nervoso, sendo constituída de uma série de elementos de processamento que estão conectados entre si, formando uma rede.

Lorenzi (2009) reforça que os “pesos sinápticos” representam a força de cada conexão entre os elementos processadores e são determinados através de um exercício de treinamento da rede realizado a partir da análise de uma grande série de valores de entrada e saída conhecidos.

O modelo inicial de Rede Neural Artificial (RNA) proposto por Rosenblatt e Wightman, denominado *Perceptron*, consistia em uma rede linear de neurônios, que são organizados em uma única camada, sendo que o vetor de entrada alimenta simultaneamente todos os neurônios (SANTOS, 2001b). As limitações do conceito de *Perceptron* foram evidenciadas por Minsky. Os mesmos demonstraram que os *Perceptrons* não eram adequados para resolver problemas de classificação simples. Estas dificuldades restringiram o avanço das pesquisas na área durante algum tempo. Todavia, com o advento dos microprocessadores, pequenos e baratos, se tornou praticável a implementação de máquinas de conexão compostas de milhares de microprocessadores. Esta mudança, aliada ao desenvolvimento de estratégias para solução de alguns problemas teóricos importantes, deu novo impulso às pesquisas.

Já, divulgado em uma literatura bem ampla, é sabido que, durante os anos 60 prosseguiram os desenvolvimentos de conceitos relativos às RNAs, com o aprimoramento do modelo original de *Perceptron* e o surgimento de variantes de estruturação das redes; como o *Adaline* (*ADaptive LInear Element*) que difere do neurônio de McCulloch e Pitts na proposta da regra de aprendizagem: Regra Delta. Ambos os modelos utilizavam as mesmas ideias genéricas, porém se diferenciavam em termos da lógica de aprendizado (LORENZI, 2009).

A década de 70 foi marcada por um excessivo entusiasmo, derivado de previsões sobre a iminência do desenvolvimento de máquinas tão poderosas como o cérebro

humano. Estas previsões, pouco confiáveis para a época, acabaram por afetar a credibilidade dos vários estudos da área, inclusive aqueles relacionados às RNAs (TATIBANA e KAETSU, 2005).

Nos anos 80 as RNAs, através de refinamentos nas técnicas de ajuste das ligações sinápticas, provocaram uma retomada de interesse pelas abordagens conexionistas. Porém para que se pudesse obter resultados eficazes, o modelo informático começou a se distanciar da analogia biológica (GANASCIA, 1997). Rumelhart, Hinton e Williams propuseram, em 1986, o algoritmo *backpropagation*, o qual fez com que as RNAs tomassem a forma como é reconhecida nos dias atuais (PINHEIRO, 2005).

2.3 Funcionamento das RNAs

No tocante ao funcionamento das RNAs, o capítulo seguinte traz uma revisão dos princípios básicos das mesmas. Como apresentado, a tentativa de se ter um software, rodando em um computador, que emule certas condições que ocorrem em um cérebro humano, é algo fascinante.

Segundo Lorenzi (2009), as RNAs se caracterizam justamente por ser um método de solucionar problemas através da construção de um sistema artificial que tenta reproduzir o comportamento do cérebro humano, gerando um simulacro de raciocínio.

Conforme Haykin (2001), o objetivo da IA consiste em desenvolver paradigmas ou algoritmos que permitam às máquinas realizar tarefas cognitivas nas quais os humanos atualmente são melhores. Para este fim, um sistema de IA deverá ser estruturado para cumprir três funções fundamentais: representar o conhecimento, operar com o conhecimento armazenado (raciocínio) e ampliar este conhecimento com a experiência (aprendizagem).

Ainda em Lorenzi (2009), o funcionamento das RNAs se baseia no estabelecimento de relações entre estímulos de entrada e de saída de um sistema, e apresentam a vantagem de que, para este fim, não é necessário estabelecer um modelo matemático prévio que defina a forma destas relações. As mesmas tendem a buscar essa correlação ao longo do processo. Fato esse, de grande interesse, principalmente quando não se conhece o modelo matemático em questão.

Engel (2002) descreve as RNAs como processadores paralelos distribuídos de grande capacidade, constituído de unidades de processamento simples, que se encontram interligados por pesos que possuem pesos adaptados. Estes parâmetros ajustáveis foram denominados de pesos sinápticos, em analogia às sinapses biológicas, e permitem controlar a intensidade das conexões entre os neurônios que formam as redes. De acordo com Tsai *et al.* (2001), o funcionamento da rede é largamente determinado pelo valor destas conexões entre os seus elementos. Os pesos sinápticos armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede.

Fabri (1999) define as RNAs como sistemas paralelos distribuídos, compostos de neurônios (unidades de processamento simples) que computam determinadas funções matemáticas. Esses nodos são dispostos em uma ou mais camadas e interligados por um grande número de conexões (associadas a pesos na maioria dos modelos). Esses nodos são denominados neurônios artificiais. Os mesmos são a unidade fundamental de processamento da informação para a operação de uma RNA, recebendo uma ou mais entradas e as transformando em saídas.

Tomando como base toda referência apresentada previamente, pode-se então, partir para uma análise um tanto quanto simplista do modelo de funcionamento do neurônio fundamental.

Segundo Haykin (2001) os coeficientes de correlação entre os neurônios constituem os pesos sinápticos. Eles recebem uma série de dados de entrada ou estímulo, cada qual sendo ativado com certo peso sináptico. Estes estímulos são combinados através de uma função aditiva que pode ser influenciada por uma tendência (ou *bias*) introduzida no sistema. O resultado é filtrado por uma função de ativação que gera um sinal de saída com certa intensidade, que servirá de estímulo para o próximo neurônio.

Esta função de ativação também é conhecida como função restritiva, pelo fato de restringir o intervalo permissível de amplitude do sinal de saída a um valor finito, (HAYKIN, 2001).

Os sinais apresentados na entrada da rede se propagam pelas camadas da rede gerando, na camada de saída, os sinais de saída da rede.

As funções de ativação realizam o processamento dos sinais recebidos por cada neurônio individualmente e o transformam em um estado de ativação neural. A razão para o uso de funções de ativação diferentes da função identidade reside na necessidade

de se limitar os valores de saída da rede, bem como no interesse em estabelecer um limiar de ativação para que um neurônio propague seu sinal adiante. O uso de diferentes tipos de funções de ativação, portanto, consiste na delimitação da amplitude do sinal de saída do neurônio. (HAYKIN, 2001).

Segundo Altran *et al.* (2005), para o caso de problemas que a saída possuam dependência não linear da entrada, as funções de ativação de um neurônio artificial devem ser funções diferenciáveis e não-lineares. Esta não linearidade se torna importante para que a função de ativação forneça à RNA uma saída similar à de um neurônio, que normalmente não é linearmente dependente de suas entradas. As funções sigmóides são utilizadas na maioria das aplicações de RNAs, por serem funções complexas e diferenciáveis (MUELLER, 1996).

Segundo Engel (2002), a arquitetura das redes dota-as de uma propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. As RNAs podem adquirir, armazenar e utilizar conhecimento extraído através da utilização de algum tipo de algoritmo de aprendizagem. O conhecimento fica armazenado na forma de estados estáveis ou mapeamentos de pesos sinápticos que são incorporados na rede de processadores simples.

Haykin (2001) considera que uma RNA extrai seu poder computacional de sua estrutura maciça e de sua habilidade de aprender (fazer generalizações), ou seja, de produzir saídas para combinações de estímulos não empregadas durante o treinamento (causando uma extensão do conhecimento). Estas duas capacidades permitem às RNAs solucionar problemas complexos, que podem ser intratáveis por técnicas tradicionais de análise.

Lorenzi (2009) mostra que, para se iniciar o processo, as redes precisam ser treinadas. Isto é feito expondo-as a uma série elevada de dados de entrada e de saída conhecidos, que lhes permitem estimar coeficientes de correlação (pesos) para cada camada.

Para Haykin (2001), na propagação, um vetor de entrada é aplicado aos nós sensoriais da rede e seu efeito se propaga através da rede, produzindo um conjunto de saídas como resposta. Os pesos sinápticos são ajustados de acordo com uma regra de correção de erro. O ajuste dos pesos faz com que a resposta real da rede tenda para mais perto da resposta desejada.

A principal característica de uma RNA é a generalização dos conhecimentos de forma a fazer com que a rede seja capaz de dar respostas “corretas”, mesmo quando as

entradas não fizeram parte do seu conjunto de treinamento. A generalização pode ser considerada como um método de aproximação de funções a partir de amostras conhecidas (SANTOS, 2001a).

Partindo-se do princípio que a RNA foi bem treinada e, após o seu treinamento, recebe sinais desconhecidos, porém semelhantes aos que foram utilizados anteriormente, a resposta da RNA será semelhante (LORENZI, 2009). Desta forma pode-se mapear sinais novos recebidos, desde que a RNA tenha uma base de dados significativa para poder diferenciar as várias situações a que pode estar exposta.

A programação de uma RNA consistirá da determinação de: 1) um conjunto de exemplos de treinamento; 2) da forma da função de ativação dos neurônios artificiais (linear, não linear, hiperbólica, sigmoide, etc.); 3) da topologia ou arquitetura da rede (número de neurônios, número de camadas, etc.) e 4) do tipo de algoritmo de treinamento (*backpropagation*, tipo de aprendizado, etc.) (CORRÊA, 2004). A partir da definição destes parâmetros poder-se-á passar para as etapas de criação do modelo da RNA para realizar-se uma representação não linear dos problemas que se desejam resolver. Este é um diferencial significativo deste tipo de programação em relação aos programas computacionais tradicionais.


2.4 Treinamento e Arquitetura das RNAs

Uma das características mais importantes de uma rede neural artificial é a capacidade de aprender, adaptando-se às condições do meio. Isto é feito através de um processo iterativo de ajuste de seus pesos, chamado de aprendizado (PORTILHO, 2006).

Quando a rede aprende uma solução para uma classe generalizada de problemas dizemos que ela aprendeu a tratar destes. Para que uma rede neural possa fazer isto é necessário fornecer a ela um conjunto de valores possíveis de entradas e, no caso de redes com aprendizado supervisionado, as saídas corretas para as soluções propostas.

Aplica-se então um algoritmo que irá ajustar os pesos das arestas internas (Figura 5) da rede, para generalizar aquela classe de problema. Estes algoritmos diferenciam-se entre si principalmente pelo modo como os pesos são ajustados.

Figura 5 - Modelo de rede neural e seus elementos.



Fonte: Portilho (2006).

Todo o conhecimento de uma rede está nas sinapses, ou seja, nos pesos das arestas (Figura 5). Para que a rede não seja configurada de maneira errônea o processo de aprendizado deve ser feito de forma “rigorosa”.

Dentre os principais procedimentos para aprendizado, podemos citar:

- a) *Treinamento Supervisionado* ou **Aprendizado supervisionado**: aquele no qual um “professor” provê valores de saída para cada padrão de entrada da rede. Pode-se citar como um exemplo o reconhecimento de padrões, os quais devem ser fornecidos por um operador (professor).

Consiste no ajuste de pesos de uma rede neural para fornecer saídas desejadas, considerando-se o conjunto de padrões de entrada. O treinamento supervisionado necessita de um vetor de entrada e vetor alvo representando a saída desejada. Juntos eles são chamados de par treinado. Segundo Fabri (1999), este é o método de treinamento mais comum empregado para as RNAs.

O objetivo do aprendizado consiste em ajustar os parâmetros da rede, objetivando encontrar a ligação mais adequada entre pares de estímulos de entrada e saída conhecidos.

Para cada padrão de entrada submetido, será comparada a resposta desejada e a calculada pela RNA, sendo ajustados os pesos das conexões, de forma a minimizar o erro. A desvantagem principal deste tipo de aprendizado é que se necessita conhecer os valores de resposta para cada padrão apresentado à RNA (BALESTRASSI, 2000).

- b) *Treinamento Não-supervisionado* ou **Aprendizado não-supervisionado**: no qual não há um "professor", e a rede deve encontrar regularidades nos dados de treinamento por si mesma.

Consiste no ajuste de pesos de uma rede neural, levando-se em conta somente o conjunto de padrões de entrada. É, portanto, um procedimento de treinamento auto-organizável.

No aprendizado não supervisionado a RNA é desprovida de uma saída desejada para ser utilizada no melhoramento de seu comportamento e o conjunto de treinamento consiste de somente entradas. A rede tenta, nesse caso, descobrir aspectos comuns entre as entradas separando os padrões entre si (BALESTRASSI, 2000). De acordo com Von Zuben (2003), cada amostra do conjunto de treinamento descreve uma lista de atributos que caracterizam um evento ou objeto. A necessidade de expressões numéricas dos atributos não representa uma restrição importante. A informação que se deseja extrair pode ser de diversas naturezas. Sabe-se que pontos próximos no espaço de atributos correspondem a amostras com forte semelhança nos atributos e que pontos que estão uniformemente distribuídos neste espaço correspondem a amostras que apresentam o mesmo nível de correlação de atributos entre si.

Uma vez que a rede se ajuste para as regularidades estatísticas dos dados de entrada ela desenvolve a habilidade de formar representações internas para codificar as características da entrada, criando novas classes (HAYKIN, 2001).

Cabe uma ressalva em relação ao tipo de rede aplicada nessa pesquisa (a ser visto *a posteriori*), a mesma, apesar de ser composta por redes auto organizáveis (ART) não supervisionada, tem em sua estrutura a apresentação de respostas desejadas, ou seja, apresenta em sua estrutura o treinamento supervisionado (rede ARTMAP-Fuzzy).

3 TEORIA DA RESSONÂNCIA ADAPTIVA

3.1 Introdução

A inspiração inicial para o desenvolvimento da teoria da ressonância adaptiva (*Adaptive Resonance Theory – ART*), proposta por Grossberg (1976a, 1976b), levava em consideração observações de alguns fenômenos biológicos, tais como: visão, fala e entre outros. Segundo Silva *et al.* (2010), esta teoria está baseada em três princípios biológicos: i) normalização de sinais: capacidade dos sistemas biológicos em se adaptar a ambientes que se alteram a todo o momento; ii) intensificação de contraste: potencialidade de identificar detalhes sutis a partir de sucessivas observações realizadas sobre o ambiente; iii) memória de curto prazo: possibilidade de armazenar momentaneamente as informações sensoriais advindas do mecanismo de intensificação de contraste, antes que possam ser decodificadas visando à tomada de decisões.

Os modelos neurais ART englobam uma grande variedade de redes neurais artificiais baseadas na neurofisiologia, e são definidas, em relação ao seu algoritmo de treinamento, em termos de equações diferenciais detalhadas e consideradas como modelos plausíveis dos neurônios biológicos.

Segundo Malange (2010), esse tipo de rede neural foi proposta inicialmente por Stephen Grossberg, nos anos 70, que desenvolveu na Teoria da Ressonância Adaptativa (GROSSBERG, 1976a), um número de hipóteses sobre os princípios que governam os sistemas neurais biológicos. Foi uma resposta para as questões sobre o dilema “estabilidade x plasticidade”, mostrando como um sistema treinado pode permanecer adaptativo a cada nova informação e ainda permanecer estável em resposta a informações irrelevantes, preservando seu conhecimento já adquirido e ao mesmo tempo sendo flexível o suficiente para armazenar novas informações.

Ainda em Malange (2010) esse dilema é resolvido com um mecanismo de vigilância que administra a inclusão de novas entradas em cada grupo. Uma regra de similaridade, que define onde agrupar um padrão é determinado por um grau de semelhança entre um padrão previamente armazenado.

3.2 Principais Características e Fundamentos

A rede ART é um sistema que auto organiza padrões de entrada em categorias de reconhecimento, mantendo um equilíbrio entre as propriedades de plasticidade e de estabilidade (MALANGE, 2010).

A propriedade da plasticidade define a habilidade da rede em criar novas categorias de reconhecimento, quando padrões estranhos estimulam a rede ART, ou seja, consiste na flexibilidade de poder incorporar mudanças ocorridas no ambiente.

A propriedade da estabilidade é responsável pela capacidade de agrupar padrões similares na mesma categoria de reconhecimento. A estabilidade está associada à permanência do sistema estável, desta forma sem variações, tendo como resposta as informações já aprendidas e essa característica é mantida através do processo de adaptação de pesos (CARPENTER e GROSSBERG, 1987).

Conforme Malange (2010), a rede ART é um sistema de aprendizagem competitivo não-supervisionado que auto organiza categorias em resposta a sequências arbitrárias de padrões de entrada, em tempo real, para reconhecimento de padrões. Tem como característica importante a combinação de padrões, onde o padrão de entrada atual é comparado com uma representação de categoria selecionada.

Ainda em Malange (2010), as redes neurais da família ART apresentam algumas dificuldades operacionais: razoável sensibilidade aos parâmetros da rede (parâmetro de vigilância, parâmetro de escolha e taxa de treinamento) e a precisão das análises. Os efeitos da sensibilidade dos parâmetros têm sido resolvidos, ou atenuados, através do emprego de novas concepções de treinamento e de arquitetura das redes neurais ART (CARPENTER *et al.*, 1991a). Igualmente, várias propostas têm sido apresentadas na literatura especializada visando sanar o problema da imprecisão. Grande parte da imprecisão decorre em consequência, principalmente, do mecanismo de escolha de categorias e do teste de vigilância que necessita de aperfeiçoamento.

No que se refere à pesquisa em questão, há de se ver futuramente que uma análise de sensibilidade prévia da variação desses parâmetros da rede, pode implicar em um ganho extremamente expressivo. Cabe salientar também, que essa análise, realizada no escopo desse trabalho, não aparece com frequência na literatura pesquisada, principalmente no que se refere à aplicação estudada.


3.3 Estrutura da Rede Neural ART

A arquitetura da rede ART consiste em dois subsistemas: o subsistema de atenção e o subsistema de orientação que atuam em um mecanismo de *reset*. A união desses dois subsistemas faz com que se implemente a verificação de similaridade entre o padrão apresentado e um padrão já representado por algum neurônio já treinado, e habilita ou não o treinamento ou retreinamento do neurônio (CARPENTER *et al.*, 1991a).

Os subsistemas de atenção possuem três camadas de neurônios, sendo elas: F_0 representa a camada de nós, F_1 representa a camada de comparação e F_2 representa a camada de representação (ANTUNES, 2013).

Os padrões de atividade desenvolvidos sobre os nós nas duas camadas, F_1 e F_2 , no estado de ressonância são chamado de memórias de curto prazo (*short-term memory* - *STM*). A aprendizagem ocorre durante o período de ressonância (DJUKANOVIC *et al.*, 1995; GEORGIOPOULOS *et al.*, 1996). Esse procedimento pode ser visualizado na Figura 6.

Figura 6 – Subsistemas da rede neural ART.



Fonte: Adaptado de Antunes (2013).

Novamente, o subsistema de atenção consiste de dois campos de neurônios: F_1 , que processa os dados de entrada e F_2 , que agrupa os padrões de treinamento em categorias de reconhecimento, e cada campo pode ser constituído por várias camadas de neurônios. Tais campos são conectados com pesos de conexão do tipo *feedforward* (w_i) e *feedback* (w_j) que são responsáveis pelo armazenamento das informações através de

um processo que envolve a escolha da categoria, critério de equalização e treinamento. O subsistema de orientação é controlado por um parâmetro de vigilância (ρ), que determina se um padrão de entrada pode ser incluído em uma das categorias existentes. Os neurônios da camada F_2 , camada que representa as categorias de reconhecimento, podem ser de dois tipos: comprometidos e descomprometidos. Os nós comprometidos são aqueles que armazenam as informações dos padrões já apresentados à rede, representando categorias reais, e os nós descomprometidos são os nós vazios que representam a memória em branco da rede (CARPENTER *et al.*, 1991a).

Segundo ANTUNES (2012) a rede ART é constituída em quatro fases, sendo elas:

- Reconhecimento: cada neurônio do campo F_1 , sendo a camada de entrada, recebe sinais de baixo para cima do vetor de entrada e de cima para baixo do campo F_2 , sendo a camada de saída, que representa a categoria ativa. O neurônio do campo F_2 , com maior valor de ativação, é selecionado como provável categoria para armazenar o novo padrão. O neurônio selecionado envia ao campo F_1 seu protótipo;
- Comparação: é efetuado um mecanismo de reajuste, sua função é testar a similaridade entre o vetor de entrada e o vetor de comparação, que é o vetor resultante da atividade calculada no campo F_1 mediante o vetor protótipo dado pelo campo F_2 após a fase de reconhecimento. A comparação é feita através do padrão de vigilância (ρ), ele determina se um padrão de entrada pode ser incluído em uma das categorias existentes. Se o valor da comparação for maior do que ρ , então o padrão de entrada é incluído na categoria ativa, caso contrário, a rede entra em fase de busca;
- Busca: durante esta fase, a rede procura um novo neurônio do campo F_2 para representar o vetor de entrada atual. O neurônio da camada de saída rejeitado na fase de comparação anterior é desabilitado nesta seleção. O vetor de entrada é reapresentado e a rede entra novamente na fase de comparação, que termina com o teste no mecanismo de reajuste para determinar a similaridade entre o novo protótipo escolhido e o vetor de entrada atual. Este processo é repetido, desabilitando neurônios da camada de saída, até encontrar um neurônio de saída que melhor se

assemelhe ao vetor de entrada corrente, dentro dos limites do parâmetro de vigilância ρ . Se nenhum neurônio de saída for encontrado, o vetor de entrada é então considerado como uma classe desconhecida, sendo alocado um neurônio de saída que não esteja associado ainda a nenhuma categoria para representá-lo;

- Treinamento: o algoritmo de aprendizado da rede ART é não-supervisionado e pode ser ativado a qualquer momento, permitindo que a rede aprenda novos padrões continuamente.

A rede neural ART possui dois tipos de treinamento: aprendizado rápido e aprendizado lento. No aprendizado rápido, os pesos de conexão são ajustados para seus valores ótimos em poucos ciclos, geralmente em apenas um ciclo de treinamento. No aprendizado lento, os pesos são ajustados lentamente em vários ciclos de treinamento, possibilitando um ajuste melhor dos pesos da rede aos padrões de treinamento (GROSSBERG, 1976a). No entanto, o tempo computacional está diretamente ligado à escolha do modo de aprendizado: para o caso de um β baixo (próximo à zero) a rede gastará muito tempo pra se estabilizar, o que pode não ser interessante dependendo do tipo de problema estudado.

3.4 Parâmetros da Rede ART

A seguir, é apresentada uma síntese dos principais parâmetros utilizados no algoritmo de treinamento em uma rede ART (CARPENTER e GROSSBERG, 1987b):

- M : número de unidade de entrada (camadas F_0 e F_1);
- N : número de unidades de *cluster* ou categorias (camada F_2);
- β : taxa de treinamento, sendo que $0 \leq \beta \leq 1$; seu valor indica a taxa de treinamento, isto é, um valor baixo para β indica um treinamento lento, enquanto que $\beta = 1$ leva a um treinamento rápido;
- α : parâmetro de escolha da categoria, sendo que $\alpha > 0$; seu valor indica o grau que os novos padrões pertencentes a cada *cluster* terão na atualização de seus pesos no próximo ciclo de treinamento;
- ρ : parâmetro de vigilância, sendo $0 \leq \rho \leq 1$; este parâmetro determina quantos *clusters* serão formados, em uma razão direta ao valor adotado, o

que significa que este parâmetro define o grau de variação admitido entre os próprios componentes de cada *cluster*.


3.5 Redes Neurais ART-1, ART-2 e ART-Fuzzy

3.5.1 Rede Neural ART-1

Na estrutura da rede ART-1 desenvolvida por Carpenter e Grossberg (1987a), os vetores de entrada são valores binários, desta forma seu treinamento é não supervisionado, tendo como base o treinamento competitivo. As categorias se identificam autonomamente e se necessário são criadas novas categorias. Esse tipo de rede utiliza os operadores lógicos binários AND/OR (CARPENTER e GROSSBERG, 1987).

Segundo Antunes (2013), esta rede se destaca pela sua característica de classificação de padrões, podendo ser também um sistema de classificação de vetores. Na Figura 7 é apresentada a estrutura da rede ART-1, descrevendo assim seu funcionamento posteriormente.

Figura 7 - Estrutura topológica da rede ART-1.



Fonte: Silva *et al.* (2010).


Para apresentação de qualquer vetor de entrada x , a rede ART tem como função primordial classificar a mesma em uma das classes representativas de um determinado

problema, sendo utilizado para tanto uma medida de similaridade deste vetor em relação aos outros vetores que já compõem as referidas classes (SILVA *et al.*, 2010).

A rede neural ART-1 pode ser descrita de uma forma simplificada, dividindo-a em três grupos de neurônios: a entrada F_1 (um campo de processamento), camada F_2 (unidade de agrupamento) e um *reset* o qual desempenha a função de controlar o grau de similaridade dos padrões no mesmo agrupamento (CARPENTER e GROSSBERG, 1987b).

A camada F_1 consiste de duas partes: o registro de entrada e a interface. A interface, parte superior da camada de entrada chamada de F_{1b} , combina os sinais do registro de entrada e da camada F_2 para efetuar a análise de similaridade entre o sinal de entrada com o vetor de peso do neurônio que foi selecionado como um candidato para o aprendizado. Pode-se chamar de registro de entrada da camada F_1 como F_{1a} (MALANGE, 2010). Isso pode ser visualizado em síntese na Figura 8.

Figura 8 - Arquitetura da rede neural ART-1.



Fonte: Malange (2010).

Para controlar a similaridade dos padrões colocados no mesmo agrupamento, há dois grupos de conexões (cada um com os seus próprios pesos) entre cada neurônio da interface do campo de entrada e cada neurônio da camada de ressonância. A camada F_{1b} está conectada à camada F_2 pelos pesos *bottom-up*. O peso *bottom-up* na conexão da i -ésima unidade da camada F_1 para a j -ésima unidade da camada F_2 é designada a_{ij} . A camada F_2 é conectada à camada F_{1b} pelos pesos *top-down*; o peso *top-down* na

conexão da i -ésima unidade da camada F_2 para a j -ésima unidade da camada F_{1b} é designada d_{ij} (CARPENTER e GROSSBERG, 1987b).

A camada F_2 é uma camada competitiva: sendo que a unidade de agrupamento contendo a maior entrada de rede se torna a candidata para aprender o padrão de entrada. As ativações de todas as unidades F_2 são estabelecidas em zero. Nesta fase, as unidades de interface combinam a informação da entrada e das unidades da camada F_2 (CARPENTER e GROSSBERG, 1987b).

3.5.2 Rede Neural ART-2

A rede neural ART-2 possui algumas características da ART-1, trabalha padrões com entradas binárias ou analógicas (contínuas) e treinamento não-supervisionado (CARPENTER e GROSSBERG, 1987b). Sua arquitetura é similar a ART-1, sendo a camada F_1 da rede constituída em duas partes: uma parte é designada à leitura dos vetores de entrada F_{1a} e outra é designada à interface entre estes vetores e a própria rede F_{1b} (ANTUNES, 2013).

Esta rede combina sinais recebidos, tanto da leitura dos vetores, quanto da camada F_2 , com a finalidade de fazer a comparação da similaridade entre o sinal de entrada com o vetor de pesos do neurônio selecionado como candidato ao aprendizado. Estes nós podem ser considerados nós auxiliares que pré-processam as entradas, através de uma combinação de operações de normalização dos dados (para se evitar proliferação das categorias). Isso torna o modelo ART-2 adequado ao processamento e classificação de dados analógicos (MALANGE, 2010).


3.5.3 Rede Neural ART-Fuzzy

A rede neural ART-Fuzzy pode aprender categorias estáveis (capacidade de reconhecimento através de auto-organização em resposta a padrões de entradas analógicos ou binários), tendo treinamento não-supervisionado (GRANGER *et al.*, 1997; GEORGIOPOULOS *et al.*, 1996; LUBKIN e CAUWENBERGHS, 2002; CARPENTER *et al.*, 1991b).

ART-Fuzzy possui também algumas características da ART-1, no entanto, o diferencial desta rede é a inclusão da teoria dos conjuntos *fuzzy* (nebulosos), visto a *posteriori* (MCNEIL e THRO, 1994; TERANO *et al.*, 1991). A estrutura geral da ART-

Fuzzy é constituída basicamente pela mesma quando da ART-1. Sua arquitetura é composta por três camadas (Figura 9): F_0 a camada de entrada, F_1 a camada de comparação e F_2 a camada de reconhecimento, que armazena as categorias, chamadas de *clusters* (CARPENTER *et al.*, 1992).

Figura 9 - Arquitetura ART Fuzzy.



Fonte: Moreno (2010).

Na camada de entrada F_0 ocorre o pré-processamento do neurônio, os valores do vetor de entrada são apresentados à rede após serem normalizados quando necessário, para evitar a proliferação de categorias. Desta forma são trabalhados com números binários ou entre 0 e 1. Na camada de comparação F_1 são recebidas as entradas de F_0 e as categorias de F_2 e se aplica o teste de vigilância da categoria escolhida para se verificar se houve ressonância (critério de vigilância aceito) ou *reset* e escolha de uma nova categoria. Esta camada possui $2N$ nós (neurônios). Na camada de reconhecimento F_2 são armazenadas as categorias. Nessa camada são encontrados os pesos a serem atualizados e é onde são armazenados os resultados (CARPENTER *et al.*, 1992).

3.5.4 Lógica Fuzzy

A razão humana é capaz de extrair de um amplo conjunto de informações apenas o que é relevante na solução do problema, com um mínimo grau de precisão. Para tratar de problemas que o ser humano pode resolver, é preciso uma abordagem que não utilize a precisão, o rigor e o formalismo matemático, e sim uma abordagem tolerante às falhas e verdades parciais (ZADEH, 1965).

A Lógica Nebulosa (ou Lógica Fuzzy), baseada nos Conjuntos Nebulosos (ZADEH, 1965), permite este tratamento baseado em valores qualitativos e não quantitativos, utilizando variáveis linguísticas e não numéricas, para representar o problema e as regras utilizadas para resolvê-lo. Ainda que utilize estas etiquetas de linguagem, esta abordagem permite tratar de maneira categórica algumas questões imprecisas ou mal definidas.

As soluções que se utilizam de Computação Nebulosa tipicamente são modeladas através de conhecimento especialista sobre o problema, e este conhecimento é representado e passado através de regras linguísticas, do tipo: “SE x é A ENTÃO y é B ”, onde “ x é A ” é o antecedente e “ y é B ” é o consequente. Quando o antecedente ou o consequente são asseverações linguísticas, então esta regra é dita linguística ou nebulosa (SIMEÓN, 2008).

A lógica *fuzzy* pode ser encarada como teoria das possibilidades, com esta lógica podem ser criadas várias técnicas para a solução de problemas, possuindo assim diversas aplicações, das quais podemos destacar: tomada de decisões, desta forma são apresentadas informações imprecisas. Já na lógica clássica, onde assumem dois valores lógicos ‘verdadeiro’ ou ‘falso’. Os valores lógicos *fuzzy* são assumidos entre 0 e 1, ou seja, são valores encontrados no intervalo 0 e 1, chamados de grau de pertinência.

Um determinado conjunto *fuzzy* é definido por uma função denominada função de pertinência. A função de pertinência é definida em um conjunto *fuzzy*, A de um conjunto universal U , sendo atribuído um grau de pertinência, $\mu_A(x)$, entre 0 e 1 para cada elemento x de U . Esse é denominado o grau com o qual x pertence a A (ZADEH, 1965):

Na Teoria de Conjuntos Clássica, tem-se:

- considere S um conjunto não-vazio, denominado conjunto universo, que consiste de todos os possíveis elementos de interesse de contexto particular. Cada elemento de interesse é chamado de membro ou elemento de S . A união de uma quantidade (finita ou infinita) de elementos de S é definida como um subconjunto de S , denotado por A . Um determinado elemento x de S pode pertencer ou não a um subconjunto A de S .

Já, na Teoria de Conjuntos Fuzzy, um determinado elemento pode pertencer a um conjunto parcialmente. O grau de pertinência é quem será responsável por isso.

Uma das habilidades da lógica *fuzzy* é a geração de resultados baseados na informação imprecisa, vaga, incompleta. Porém podem ser aplicadas a diversas áreas de

conhecimento, das quais podemos destacar: reconhecimento de padrão, inteligência artificial e entre outros.

Redes Neurais e Lógica Fuzzy são técnicas desenvolvidas a partir do funcionamento do cérebro humano, pois o mesmo consegue solucionar problemas ou situações as quais envolvem imprecisões.

3.5.5 Algoritmo da ART-Fuzzy

A importância deste item está no fato de que a rede utilizada nessa pesquisa (ARTMAP-Fuzzy) é composta por dois módulos ART-Fuzzy, como será visto a frente. O algoritmo, descrito através de passos, é uma adaptação do encontrado na literatura, notadamente em Malange (2010).

O algoritmo resumido da rede neural ART nebulosa consiste, basicamente, nos passos apresentados (CARPENTER *et al.*, 1991b; CARPENTER e GROSSEBERG, 1991c; CARPENTER *et al.*, 1992).

Antes de se apresentar o algoritmo da rede ART-Fuzzy, faz-se importante relembrar os parâmetros utilizados no processamento da rede, a saber:

1. Parâmetro de Escolha: $\alpha > 0$;
2. Taxa de Treinamento: $\beta \in [0,1]$;
3. Parâmetro de Vigilância: $\rho \in [0,1]$;

i) Primeiro Passo: Dados de entrada

Os dados de entradas são denotados pelo vetor $a = [a_1 \ a_2 \ \dots a_M]$ M-Dimensional. Este vetor é normalizado com o intuito de evitar a proliferação de muitas categorias. Assim:

$$\bar{a} = \frac{a}{|a|} \quad (1)$$

$\bar{a}$ = vetor normalizado

$$|a| = \sum a_i$$

ii) Segundo Passo: Codificação do vetor de entrada

A codificação de complemento é realizada para preservar a amplitude da informação:

$$\bar{a}_c = 1 - \bar{a}_i \quad (2)$$

onde: $\bar{a}_c$ é o vetor complementar de entrada normalizada, porém o novo vetor de entrada será um vetor $2M$ -dimensional, sendo expressado pela fórmula:

$$I = [\bar{a} \ \bar{a}_c] \quad (3)$$

ou por

$$I = [\bar{a} \ \bar{a} \dots \bar{a}_M \ \bar{a}_{1c} \ \bar{a}_{2c} \dots \bar{a}_{Mc}] \quad (4)$$

Desta forma, todos os vetores de entrada após a normalização e codificação terão o mesmo tamanho M .

$$|I| = \sum_i^M \bar{a}_i + \sum_i^M \bar{a}_{ic} = \sum_i^M \bar{a}_i + \sum_i^M (1 - \bar{a}_i) = \sum_i^M \bar{a}_i + M - \sum_i^M \bar{a}_i = M \quad (5)$$

iii) Terceiro passo: Vetor de atividade

O vetor de atividade F_2 é simbolizado por $y_j = [y_1 \ y_2 \dots y_n]$, sendo N o número de categorias criadas em F_2 , assim temos:

$$y_j = \begin{cases} 1, \text{ se o nó } j \text{ de } F_2 \text{ é ativo} \\ 0, \text{ caso contrário} \end{cases}$$

iv) Quarto passo: Iniciação dos pesos

Inicialmente todos os pesos possuem valores igual a 1, ou seja, desta forma indica que não possui nenhuma categoria ativa:

$$\omega_{ij}(0) = \omega_{j2}(0) = \dots = \omega_{j2M}(0) = 1$$

v) Quinto passo: Escolha da categoria

Dado o vetor de entrada I em F_1 para cada nó j em F_2 , a função de escolha T_j é determinada por:

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (6)$$

$\wedge$ = operador AND nebuloso, definido por:

$$(I \wedge w)_i = \min (I_i, w_i)$$

A categoria é escolhida como sendo o nó j ativo, ou seja:

$$J = \arg \max T_j$$

$$j = 1, \dots, N$$

Em se obtendo o mesmo valor para T_j , será escolhida aquela que possuir menor índice.

vi) Sexto passo: Ressonância ou *reset*

A ressonância ocorre se o critério de vigilância for satisfeito:

$$\frac{|I \wedge w_j|}{|I|} \geq \rho \quad (7)$$

Caso o critério definido pela equação (7) não seja satisfeito, ocorre o *reset*. No *reset*, o nó J de F_2 é excluído do processo de busca, ou seja, $T_J = 0$. Então, é escolhida uma nova categoria para o processo de ressonância. Este procedimento será realizado até que a rede encontre uma categoria que satisfaça o critério de vigilância.

vii) Sétimo passo: Atualização dos pesos – Treinamento

Após o vetor de entrada I ter completado o estado de ressonância, segue o processo de treinamento, no qual ocorre a modificação do vetor peso dado por:

$$w_J^{\text{novo}} = \beta (I \wedge w_J^{\text{velho}}) + (1 - \beta) w_J^{\text{velho}} \quad (8)$$

J = categoria ativa;

w_J^{novo} = vetor peso atualizado;

w_J^{velho} = vetor peso referente à atualização anterior;


Se $\beta = 1$, tem-se o treinamento rápido;

3.6 Rede Neural ARTMAP

A rede apresentada a seguir pode ser descrita como um sistema com aprendizado supervisionado capaz de auto-organizar o reconhecimento estável de categorias em respostas aos padrões de entrada arbitrários. É composta por dois módulos ART e foi a primeira arquitetura baseada na teoria da ressonância adaptativa apropriada para a tarefa de classificação, apresentando treinamento supervisionado (CARPENTER *et al.*, 1991b).

Esse tipo de rede é composta por duas sub-redes, ART_a, que recebe e processa um determinado padrão de entrada apresentado, e ART_b, que constitui a resposta desejada para o padrão apresentado à rede, que são interligadas por um módulo de memória associativa, denominado Inter-ART, que realiza o mapeamento conforme Figura 10 (LIM e HARRISON, 1997).

Figura 10 - Arquitetura da rede neural ARTMAP.



Fonte: Ferreira (2003).

Segundo Antunes (2012) as matrizes de pesos devem ser iniciadas com valores iguais a 1, sendo assim, todas as atividades encontram-se inativas. Estas atividades são ativadas à medida que ocorre ressonância entre os padrões de entrada e de saída. O

módulo Inter-ART é responsável pela verificação da existência de ligação entre a entrada (ART_a) e a saída (ART_b).

O módulo ART_a aprende a classificar os padrões de entrada apresentados na camada F_0^a , enquanto o módulo ART_b , com parâmetro de vigilância ρ_b , desenvolve categorias referentes aos padrões de saída desejados expostos na camada F_0^b . Os módulos F_2^b e F_{ab} são conectados por um vínculo associativo cujos pesos são ajustados através do treinamento. Nos módulos F_2^b e F_{ab} , cada nó de F_2^b é conectado com seu nó correspondente em F_{ab} (LIM e HARRISON, 1997).

Ainda no módulo Inter-ART são efetuadas as adaptações de pesos entre uma categoria ativa J do ART_a e uma categoria ativa K do ART_b de forma que, a conexão correspondente entre as categorias ativas do módulo ART_a e ART_b , ou seja, a conexão entre $F_2^a \rightarrow F_{ab}$, terá o valor 1, e todas as conexões restantes referente ao mesmo nó do ART_a possuirão o valor 0 (KARTALOPOULOS, 1996; LIM & HARRISON, 1997).

Ainda em Antunes (2013) a rede possui um processamento que autorregula a maximização, gerencia e minimiza os erros, processo esse denominado, *match tracking*. Este processo é utilizado para a correção de um prognóstico considerado errado, onde no módulo ART_a o parâmetro de vigilância ρ_a será incrementado o mínimo possível para corrigir o erro no módulo ART_b .

Desta forma será ativada uma nova busca, onde será escolhida uma nova categoria no ART_a , sendo esse prognóstico combinado novamente com a categoria atual do ART_b . Este processo continua até a rede encontrar uma categoria no ART_a que prediz a categoria correta da entrada atual ou crie uma nova categoria em F_2^a e a sua conexão correspondente com o módulo F_{ab} . Após poucas apresentações do conjunto de treinamento, a rede auto-estabilizará e obterá a saída esperada para cada entrada sem necessariamente efetuar todo o processo de busca (LIM e HARRISON, 1997).


3.7 Rede Neural ARTMAP-Fuzzy

Após toda revisão bibliográfica vista anteriormente, cabe agora, a apresentação da rede utilizada nessa pesquisa. Como a de se notar, a mesma contém em sua estrutura uma composição das principais técnicas apresentadas. Sendo assim, pode-se tratar da rede como se segue.

A rede neural ARTMAP-Fuzzy (Figura 11) compreende a rede ARTMAP, no entanto, com a presença agora da teoria dos conjuntos Fuzzy. Seus dados de entrada e saída ainda podem ser analógicos ou binários. A diferença básica entre as redes neurais ARTMAP-Fuzzy e ARTMAP são os operadores nebulosos “ $\wedge$ ”, no lugar do operador de interseção “ $\cap$ ”. A mesma possui treinamento supervisionado, sendo um sistema de aprendizado auto-organizável (CARPENTER *et al.*, 1992; RAVEENDRAN *et al.*, 2000).

Destina-se à aproximação de funções não lineares multidimensionais para classificar vetores de entrada cujos elementos assumem valores nebulosos, entre 0 e 1, indicando o nível de presença de cada característica (MALANGE, 2010)

Figura 11 - Rede neural ARTMAP-Fuzzy.



Fonte: Lopes (2005).

Esta rede (Figura 11) é constituída por dois módulos, ART_a nebuloso e ART_b nebuloso, que possuem a mesma estrutura da rede neural ART-Fuzzy, exceto que na ART_a nebulosa inclui um campo de mapeamento controlando o treinamento de um mapa associativo de categorias de reconhecimento da ART_a para categorias de reconhecimento da ART_b . Como já visto anteriormente, esse campo de mapeamento controla a regra “match tracking” (casamento), que aumenta o parâmetro de vigilância da rede ART_a por uma quantia mínima necessária para corrigir um erro preditivo (MARCHIORI *et al.*, 2006).

Esse módulo Inter-ART é responsável pela verificação se há casamento da entrada ART_a e da saída ART_b . As matrizes pesos associadas aos módulos ART_a (w^a) e ART_b (w^b), assim, semelhantes ao módulo Inter-ART (w^{ab}), são iniciadas com

valores iguais a 1, ou seja, todas as atividades encontram-se inativas. Estas atividades são ativadas à medida que ocorre ressonância entre os padrões de entrada e de saída, ou seja, toda vez que os pares de entrada (a, b), associados aos módulos ART_a e ART_b, são confirmados (as entradas **a** e **b** referem-se às categorias J e K ativas, respectivamente), de acordo com o teste do *match tracking*:

$$|x^{ab}|_i = \frac{|y^{aJ} \wedge w_j^{ab}|}{|yJ|} \quad (9)$$

se: $|x^{ab}|_i \geq \rho_{ab}$, o par de treinamento deve ser confirmado nas matrizes de pesos com índices J e K.

$|x^{ab}|_i < \rho_{ab}$ deve se buscar outro índice J (com relação ao vetores de entrada **a**), até que o critério seja satisfeito.

Os pesos w^a , w^b e w^{ab} serão adaptados através da equação:

$$w_K^b \text{ novo} = \beta (I \wedge w_K^b \text{ velho}) + (1 - \beta) w_K^b \text{ velho}$$

$$w_{JK}^{ab} \text{ novo} = 1 \quad (10)$$

3.7.1 Funcionamento da Rede ARTMAP-Fuzzy

Ainda que já bem exemplificado em itens anteriores, acredita-se ser de bom tom, uma apresentação, mesmo que simplista, do funcionamento da rede ARTMAP-Fuzzy (Figura 12) que, segundo Malange (2010), consiste basicamente em oito passos, a saber:

i) Primeiro Passo: Normalização dos vetores de entrada ART_a e saída ART_b, se necessário pois, inicialmente, todos os valores dos neurônios devem ser normalizados se não estiverem entre 0 e 1;

ii) Segundo Passo: Codificação complementar dos vetores dos módulos ART_a e ART_b. Um novo padrão de entrada deve sofrer uma codificação complementar preliminar para se preservar a amplitude da informação;

iii) Terceiro Passo: Inicialização dos pesos e parâmetros dos módulos ART_a, ART_b e Inter-ART. Deve-se iniciar os pesos ($w_a = w_b = w_{ab} = 1$, ou seja, todas as categorias desativadas inicialmente), taxas de treinamento β (entre 0 e 1), parâmetro de

escolha ($\alpha > 0$), parâmetro de vigilância (ρ_a , ρ_b e ρ_{ab} entre 0 e 1) e ε (incremento na vigilância do módulo ART_a);

iv) Quarto Passo: Escolha da categoria para os módulos ART_a e ART_b . Se mais de um neurônio está ativo, é escolhido aquele com o maior índice de ordenação (maior valor);


v) Quinto Passo: Teste de vigilância dos módulos ART_a e ART_b . A ressonância ocorre se é satisfeito o critério de vigilância. Caso contrário, se o mesmo falhar para a categoria escolhida, ocorre o *reset* e um novo índice é escolhido (retornar-se ao quarto passo). O processo de busca se repete até que o índice escolhido satisfaça o teste de vigilância;

vi) Sexto Passo: Teste de Ressonância (*Match tracking*) entre os módulos ART_a e ART_b . Verificação se houve “casamento” da entrada com a saída. Caso o mesmo não ocorra, deve-se procurar outro índice que satisfaça o teste;

vii) Sétimo Passo: Adaptação dos pesos. Os vetores peso da camada F_2 dos módulos ART_a , ART_b e Inter-ART são atualizados com os novos pesos;

viii) Oitavo Passo: Repetir os passos 4 a 7 para todos os pares a serem treinados.

Figura 12 – Fluxograma da Rede Neural ARTMAP-Fuzzy.



Fonte: Moreno (2010).

4 ONDAS MARÍTIMAS E EM LAGOS

4.1 Introdução

O capítulo seguinte trata-se de uma revisão dos parâmetros de ondas marítimas de grande interesse para a execução dessa pesquisa. É organizado da seguinte maneira: primeiro, faz-se uma descrição dos parâmetros chave utilizados; segundo, refere-se brevemente ao fenômeno do galgamento de estruturas marítimas.

Já, no que se refere a ondas em lagos, é apresentada uma adaptação dos trabalhos já realizados pela equipe do projeto ONDISA do HM2 de Ilha solteira. Isso se fez necessário para dar uma continuação aos trabalhos já realizados, apresentar um conhecimento já adquirido pela equipe, no que tange a ventos e ondas em lagos de barragens. Isso posto, *a posteriori*, far-se-á a aplicação de redes neurais aos resultados já contemplados pela equipe de ondas.

4.2 Definição dos Parâmetros Chave para Ondas Marítimas

4.2.1 Altura de Onda

A altura de onda comumente utilizada em fórmulas de hidráulica de ondas é a altura significativa H_s , retirada por análise das ondas no momento de ordem zero (H_{m0}) ou, por análise no tempo, média do terço superior das ondas, $H_{1/3}$. Em águas profundas, ambas as definições produzem quase o mesmo valor, mas situações em águas rasas podem levar a diferenças de 10-15% (PULLEN *et al.*, 2007).

Para caracterizar cada onda recorre-se frequentemente à declividade da onda (S), que relaciona a altura da onda (H) com o comprimento de onda (L).

$$S = \frac{H}{L} \quad (11)$$

Na definição da declividade, e no caso de agitação irregular, utiliza-se a altura de onda significativa local, calculada com o momento de ordem zero do espectro ($H_{m0} = 4\sqrt{m_0}$), mencionado anteriormente. Por sua vez, o comprimento de onda (L) pode ser referente ao período médio (T_m) ou ao de pico (T_p), possibilitando a obtenção da declividade média, S_{0m} , e de pico, S_{0p} , respectivamente. O comprimento de onda ao

largo (L_0) que, no âmbito da teoria linear da onda é calculado pela equação (12), relaciona-se com o comprimento de onda no pé da estrutura (L), à profundidade h , pela relação de dispersão sob a forma apresentada na equação (13) (MARIZ, 2012).

$$L_0 = \frac{g}{2\pi} T^2 \quad (12)$$

$$L = L_0 \tanh\left(\frac{2\pi}{L} h\right) = \frac{g}{2\pi} T^2 \tanh\left(\frac{2\pi}{L} h\right) \quad (13)$$

em que g é a aceleração gravitacional.

4.2.2 Período de Onda

Períodos de onda diferentes podem ser definidos para um espectro de ondas ou registro de ondas. Os períodos de ondas convencionais são: o período de pico T_p (o período correspondente à maior energia do espectro), a média do período T_m (calculado a partir do espectro ou do registro das ondas) e $T_{1/3}$ período significativo (a média do período do terço superior das ondas). A relação T_p / T_m geralmente situa-se entre 1,1 e 1,25, e T_p e $T_{1/3}$ são quase idênticos (PULLEN *et al.*, 2007).

O período de onda geralmente utilizado tanto para o espraçamento das ondas num talude quanto para fórmulas de galgamento aconselhado pelo EurOtop (PULLEN *et al.*, 2007) é o período espectral $T_{m-1,0}$ ($= m_{-1}/m_0$).

Ainda segundo o EurOtop (PULLEN *et al.*, 2007), no caso de um espectro unimodal há uma relação fixa entre o período espectral $T_{m-1,0}$ e o período de pico. Um fator de conversão ($T_p = 1,1 T_{m-1,0}$) é fornecido para o caso em que o período de pico é conhecido ou determinado, mas não se tem o período espectral; ou vice-versa.

4.2.3 Arrebentação das Ondas


Dependendo da inclinação do talude da estrutura ou praia e da declividade da onda, o tipo de rebentação sobre a estrutura tomará diferentes formas, que podem ser caracterizadas através do parâmetro de arrebentação ou Número de Iribarren (ξ), que se define pela expressão.

$$\xi = \frac{\tan \alpha}{\sqrt{S}} \quad (14)$$

O Número de Iribarren pode tomar várias formas de acordo com a declividade utilizada. No caso de se usar a declividade da onda ao largo (S_0), obtida pela expressão (11) com a altura e comprimento de onda ao largo (H_0 e L_0 , respectivamente), obtém-se o Número de Iribarren ao largo, ξ_0 . De forma análoga pode ser obtido o Número de Iribarren médio, ξ_{0m} , e de pico, ξ_{0p} , respectivamente, calculados com S_{0m} e S_{0p} .

Na Figura 13 segue um esquema explicitando os tipos de arrebentação em termos de período espectral $T_{m-1,0}$.

Figura 13 - Tipos de arrebentação de ondas.



Fonte: Adaptado de Pullen *et al.* (2007)

Outra classificação sugerida, em termos de ξ_0 ao largo pode ser aplicada (USACE, 2006):

a) Arrebentação progressiva (“*spilling*”) – a crista deforma-se e desestabiliza-se, criando uma leve espuma sobre o talude (Figura 14); ocorre mais frequentemente em taludes mais suaves; em termos de declividade ao largo ($\xi_0 < 0,5$).

b) Arrebentação mergulhante (“*plunging*”) – a crista da onda cria uma curvatura e cai sobre o talude (Figura 15) originando grandes salpicos ($0,5 < \xi_0 < 3$).

c) Arrebentação colapsante (“*collapsing*”) – a crista não rebenta inteiramente, não origina grandes salpicos, mas cria-se uma espuma que se estende pelo talude; este

tipo pode surgir pela sobreposição dos dois tipos de rebentação anteriormente descritos ($3 < \xi_0 < 0,5$).

d) Rebentação de fundo (“*surging*”) – no caso da onda apresentar pouca declividade, esta espraia-se sobre o talude sem rebentar; são caracterizadas por terem uma forte reflexão ($\xi_0 > 3,5$).

Figura 14 - Arrebentação Progressiva.



Fonte: Pullen *et al.* (2007).

Figura 15 - Arrebentação Mergulhante.



Fonte: Pullen *et al.* (2007).

4.3 Galgamentos (*Overtopping*)

O fenômeno do galgamento ocorre quando um dado nível de agitação marítima em combinação com determinados níveis do mar originam a passagem de água sobre o coroamento da estrutura. Dependendo do volume de água galgado, a estabilidade da estrutura galgada pode ser posta em risco (CIRIA/CUR/CETMEF, 2007).

O galgamento pode ser classificado em três formas, dependendo do modo como é feita a passagem da água sobre o coroamento da estrutura (BESLEY, 1999).

A primeira forma é designada por “*green water*” e representa o galgamento que ocorre com veia líquida contínua sobre a superfície do coroamento da estrutura. Verifica-se quando o nível de espraçamento (“*run-up*”) é suficientemente elevado para que a passagem de água se dê tal como foi descrito.

A segunda forma de galgamento é denominada por “*splash*” (salpicos), ocorre durante a fase de arrebentação das ondas sobre a estrutura produzindo volumes de água, que em algumas circunstâncias podem ser significativos, sob a forma de gotículas. A passagem pode ainda ser potenciada por vento incidente junto da estrutura.

A terceira forma designa-se por “*spray*” e é considerada a menos importante das três, uma vez que corresponde à passagem de “borrifos” gerados pela ação do vento na crista da onda junto da estrutura. O “*spray*” não contribui com volumes significativos de galgamento.

4.4 Definição dos Parâmetros Chave para Ondas em Lagos

4.4.1 Ventos

Segundo Moraes (2009), o vento pode ser considerado como o ar em movimento. Resulta do deslocamento de massas de ar, derivado dos efeitos das diferenças de pressão atmosférica entre duas regiões distintas e é influenciado por efeitos locais como a orografia e a rugosidade do solo.

Essas diferenças de pressão têm uma origem térmica estando diretamente relacionadas com a radiação solar e os processos de aquecimento das massas de ar. Formam-se a partir de influências naturais, como continentalidade, maritimidade, latitude, altitude.

A camada de ar que envolve a Terra é conhecida como atmosfera (atmos = ar; esfera = esfera terrestre). A atmosfera pode ser dividida em cinco camadas: a troposfera, a estratosfera, a mesosfera, a ionosfera e a exosfera, excedendo os 400 km de altitude.

Entende-se por vento reinante aquele que possui uma maior probabilidade de ocorrer em uma determinada direção. O vento dominante seria aquele que tem um maior potencial energético em termos de ωu^2 , onde ω é a frequência e u é a velocidade do vento.

De acordo com U.S. Army Corps of Engineers (2001), cinco correções devem ser realizadas na velocidade do vento, a saber: elevação, efeitos de localização, estabilidade (devido à diferença de temperatura), velocidade média no tempo e coeficiente de arraste.

4.4.2 Pista de Ventos

Quando a onda é gerada pela ação do vento, a altura da onda fica condicionada a três fatores relacionados ao vento: a velocidade, a duração e a pista sobre a qual ele sopra.

A pista de vento é a área de geração de ondas definida como sendo a região na qual a velocidade e direção do vento podem ser consideradas aproximadamente constantes. Segundo o U. S. Army Coastal Engineering Research Center (1973), esta velocidade é considerada constante quando as variações não excedem 2,5 m/s, partindo da velocidade média.

Na aplicação dos métodos de estimativa da altura destas ondas, uma importante etapa consiste na determinação do comprimento da pista de vento, também conhecida como *fetch*.

Na grande maioria dos métodos empregados, o comprimento desta pista entra como uma variável importante no processo de estimativa da altura da onda. Portanto, uma boa estimativa da altura da onda tem início com uma eficiente determinação do comprimento da pista de vento.

O efeito da largura da pista de vento pode ser desprezado em áreas de geração que possuem a largura tão grande, ou superiores ao comprimento. Esta situação é comumente identificada em áreas oceânicas.

Já em águas interiores, as pistas são limitadas pelas margens que contornam tais corpos d'água. Pistas de vento de grande comprimento, se comparado à largura, são frequentemente encontradas, e a influência do entorno não pode ser desprezada. Estes casos de área de geração afetada pela margem resultam em altura de onda significativamente menor se comparada à mesma condição de geração em corpos de água sem limitação marginal.

Para o cálculo do comprimento da pista efetiva, esta passa a ser a média das projeções dos segmentos no eixo principal ponderada pelos cossenos dos ângulos.

4.4.3 Altura de Onda

Conforme Moraes (2009), para gerar uma onda é preciso que exista uma fonte de energia que, ao ser transmitida à água, produza um movimento oscilatório das partículas

do líquido sem que haja um transporte importante de massa. As ondas aqui estudadas se desenvolvem por transferência de energia entre o vento e a superfície do corpo d'água.

O local que recebe os efeitos iniciais do vento é chamado de área de geração. Dentro desta área, as ondas apresentam uma forma desorganizada. Pela contínua ação do vento, as ondas vão se modificando, até que, ao sair desta área, assumem gradualmente uma forma mais regular e simétrica, organizando-se em “trens de onda”, e passa a ser chamada de ondulação. Quando a velocidade do vento persiste o bastante e tem área suficiente para atuar, atinge-se um limite em que a transferência de energia do ar para a água iguala a taxa de dissipação de energia por arrebentação das ondas.

Quanto aos estudos de estimativa das ondas anteriormente realizadas, especificamente nos lagos de Ilha Solteira, são consideradas as análises feitas por Lima (2005) e Kaiser (1995).

Lima (2005) estimou a altura das ondas no lago de Ilha Solteira através do método JONSWAP baseado em informações de vento obtidas pela CESP entre 1977 e 1990.

5 DESCRIÇÃO DOS CASOS DE ESTUDO

5.1 Descrição da Área de Estudo: Porto de Sines

5.1.1 Descrição Geral

O porto de Sines situa-se à sudoeste da Europa, na costa oeste de Portugal, a 58 milhas náuticas a sul de Lisboa, no cruzamento das principais rotas marítimas internacionais – Leste-Oeste e Norte-Sul (Figura 16).

Figura 16 - Porto de Sines – Portugal.



Fonte: Acervo do LNEC.

Sendo um porto moderno (1978), com excelente acesso marítimo, sem restrições, é um dos principais *gateways* econômicos e comerciais da Península Ibérica, o que o configura como um porto de grande importância estratégica e geográfica de Portugal e Espanha.

O porto é abrigado por dois moles principais, o Oeste e o Este (Figura 16), que protegem um conjunto de terminais (o Terminal XXI, Terminal de Gás Natural Liquefeito, Terminal Petrolero, Terminal Petroquímico e Terminal Multiusos), o porto de recreio, o porto de pesca e a praia. Devido a seus modernos terminais especializados, o porto é capaz de lidar com os diferentes tipos de cargas, elevando o volume de carga manipulada do setor portuário português (principalmente em cargas em massa, líquidas e sólidas) e oferecendo características naturais únicas para receber qualquer tipo de navios.


O porto de Sines apresenta um elevado potencial de crescimento, a fim de tornar-se um porto de referência a nível Ibérico, Europeu e mundial. Na verdade, o porto representa uma zona de apoio industrial e logístico, com mais de 2.000 ha, é já uma plataforma utilizada por todo mundo, capaz de receber os principais intervenientes dos setores portuário, marítimo, industrial e logístico.

Neste momento, o complexo do Porto de Sines é composto por várias infraestruturas marítimas para abrigo e acostagem, tornando-o num dos poucos portos europeus de águas profundas que permite a acostagem de navios de grande porte. Os elevados valores anuais de movimentação de mercadorias transformaram o porto de Sines no primeiro porto nacional em tonelagem anual movimentada.

5.1.2 Caracterização das Condições ao Largo (*Offshore*)

Para caracterizar as condições de onda *offshore* do Porto de Sines, existem dados da boia-ondógrafo direcional "Sines 1-D" do Instituto Hidrográfico, Portugal. A boia está localizada *offshore* do Porto ($37^{\circ}55' \text{ N}$ e $08^{\circ}55' \text{ W}$) a uma cota batimétrica -93 m (ZH) (Figura 17). Em condições normais, os parâmetros de onda, como a altura de onda significativa (H_s), o período de onda média (T_m) e a direção da onda (DIR), são produzidos a cada 1 hora, com base em medições de onda na boia de 20 minutos de duração. O conjunto de dados utilizados perfaz um total de 51.247 registos obtidos entre maio de 1988 e dezembro de 2002 e janeiro de 2005 e junho de 2012. Não foram utilizados para essa caracterização os dados referentes ao período compreendido entre dezembro de 2002 a janeiro de 2005.


Figura 17 - Localização da boia-ondógrafo do Porto de Sines.



Fonte: Google Earth 5.0TM.

Consequentemente, procedeu-se ao cálculo do regime geral observado, correspondente a todos os valores do período em estudo. A seguir, é apresentado um exemplo da obtenção de séries temporais da boia-ondógrafo para o período de maio de 1988 a dezembro de 2002 (Figura 18).

Figura 18 - Séries temporais da altura de onda significativa, período médio e direção média na boia-ondógrafo em Sines.



Fonte: Neves *et al* (2010).

5.1.3 Metodologia de Transferência do Regime de Agitação


O item seguinte é uma adaptação de Neves *et al* (2010) e, sua apresentação reflete o trabalho executado em conjunto com o pesquisador.

Para a caracterização das condições de abrigo dentro do porto (a ser utilizada a posteriori nessa pesquisa) e dada a extensão da área de estudo, houve que resolver alguns problemas associados às limitações dos modelos numéricos utilizados na propagação de ondas, nomeadamente os relacionados com os respectivos domínios de aplicabilidade e tempos de cálculo. Como tal, foi adotada a metodologia de Neves *et al.* (2010) representada na Figura 19.

Dados os diferentes domínios de aplicabilidade de cada modelo de propagação de ondas, para a zona marítima do porto de Sines houve a necessidade de acoplar dois

modelos numéricos – o modelo SWAN (BOOIJ *et al.*, 1999) e o modelo DREAMS (FORTES, 1993) . Assim, enquanto que o modelo SWAN permite a propagação das ondas desde águas profundas até junto à entrada do porto, mas não pode ser utilizado em zonas confinadas, o modelo DREAMS permite a simulação da agitação marítima na zona interior do porto, mas dado o esforço computacional envolvido, não pode ser aplicado a grandes áreas de cálculo. Daí a necessidade de recorrer a dois modelos numéricos de propagação de ondas.

Figura 19 - Metodologia para a transferência do regime de agitação marítima do largo (Boia-ondógrafo) para o interior do porto.



Fonte: Neves *et al.* (2010).

Por outro lado, o tempo de cálculo necessário para executar esses modelos é também um fator limitativo. Com efeito, para estabelecer um regime de agitação marítima, o ideal seria correr os modelos SWAN e DREAMS para todas as condições de agitação do registro total da boia. Porém, o tempo de cálculo associado a cada simulação com ambos os modelos SWAN e DREAMS é de cerca de 45 minutos o que para a totalidade dos registos na boia, corresponderia a vários meses de cálculo. Isso faz

com que seja de grande interesse a busca por novas ferramentas que tendam a diminuir o custo computacional, um dos objetivos dessa pesquisa.

A forma de ultrapassar este problema, foi a de implementar uma metodologia, conforme Santos *et al.* (2008), Palha (2007), consistindo em transferir a agitação marítima do largo para junto à costa, recorrendo, para a zona em estudo, à(s) matriz(es) de transferência da agitação marítima. Estas matrizes relacionam a agitação marítima ao largo (admite-se que são os registos da boia) e a agitação num ponto, neste caso no interior do porto de Sines.

Nesta metodologia, simula-se *a priori* um vasto leque de condições de agitação marítima (H_s , T_m , DIR) que representam apropriadamente todas as possibilidades de ocorrência dessa agitação ao largo, mas que é em número significativamente inferior ao número de registos de agitação marítima. Com esses resultados, constrói-se uma matriz de valores que permite interpolar eficazmente quaisquer outros casos não simulados. Uma vez conhecida a matriz de transferência para a zona em estudo, para cada trio de parâmetros de agitação marítima ao largo (H_s , T_m , DIR) obtido num dado instante, procede-se à interpolação desse trio utilizando a matriz de transferência e obtêm-se as características da agitação marítima no(s) ponto(s) em estudo. Desta forma, são transferidos os registos da boia para os pontos no interior do porto, obtendo-se o regime de agitação marítima em cada ponto. O programa REGIMES (PINHEIRO *et al.*, 2004) permite efectuar essa transferência de modo automático.


Para estabelecer a matriz de transferência, com base nos registos da boia, é necessário definir gamas com os respectivos intervalos de alturas de onda significativas, período médio e direcção de onda que abrangem todas as ocorrências que se verificam nos registos da boia. Uma vez definido esse conjunto de trios (H_s , T_m , DIR) igualmente espaçados, que constituem as condições iniciais de onda, do modelo de propagação de onda, efectuem-se os cálculos numéricos. Com os resultados numéricos, é definida a matriz de transferência pretendida.

Este método, além de reduzir drasticamente o tempo de cálculo, permitindo simulações posteriores quase instantâneas, tem ainda a vantagem de tornar o processo de automatização muito mais simples.

No caso do presente estudo, como é necessário recorrer a dois modelos de propagação de ondas, haverá que efectuar duas matrizes de transferência (Figura 20), uma relativa à propagação feita pelo SWAN e outra relativa à propagação feita pelo DREAMS. Assim, a agitação ao largo (na boia-ondógrafo) é transferida para um ponto

designado por P6 (Figura 20), ainda no exterior do porto, utilizando a matriz de transferência do SWAN, e deste ponto é transferida para pontos no interior do porto, utilizando a matriz de transferência DREAMS.

Figura 20 - Metodologia para a transferência do regime de agitação marítima do largo (boia-ondógrafo) para o interior do porto com base em matrizes de transferência.



Fonte: Neves *et al.* (2010).

5.1.4 Caracterização das Condições em Frente ao Porto

Para prever as características de onda em frente ao Porto, o modelo de propagação de onda SWAN é forçado pelos dados da boia. Os resultados (HS, TZ, DIR) perto da costa, e em particular no ponto P6 (Figura 19) localizado a uma cota batimétrica -40 m (ZH), foram obtidos a partir de maio 1988 a dezembro de 2012. A Tabela 1 apresenta uma visão geral dos dados da boia e os resultados correspondentes do SWAN no ponto P6.

Tabela 1- Parâmetros Estatísticos na Boia Sines-1D e no ponto P6.

Local	Parâmetros Estatísticos	Máximo	Média	Mínimo	Desvio Padrão	Gama mais Frequente
Boia	Hs (m)	7,35	1,60	0,27	0,90	[1,0 - 2,0] (48,05%)
	Tp (s)	1,00	8,80	4,20	2,33	[6,0 - 7,0] (17,78%)
	DIR (°)	358,00	299,00	5,00	18,61	[300 - 310] (32,68%)
Ponto P6	Hs (m)	11,09	1,54	0,07	0,93	[1,0 - 2,0] (48,26%)
	Tp (s)	18,9	8,9	4,2	2,3	[9,0 - 10,0] (22,27%)
	DIR (°)	352	303	72	25	[310 - 320] (32,34%)

5.1.4.1 Modelo numérico SWAN

O modelo SWAN - acrônimo de *Simulating WAVes Nearshore* - é um modelo numérico para geração, propagação e dissipação da agitação marítima, baseado na equação para a conservação da ação de onda (BOOIJ *et al.*, 1999). Trata-se de um modelo de domínio público (*freeware*), que possui como uma das maiores vantagens a manutenção da estrutura da base de dados e de resultados, o que permite a fácil atualização de versões mais robustas e completas do modelo sempre que necessário.

Este modelo propaga a agitação marítima desde o largo até próximo da costa considerando os processos físicos de refração, difração e empolamento devido a variações do fundo e presença de correntes, crescimento de onda por ação do vento, rebentação por influência do fundo e por “excesso” de declividade (*whitecapping*), dissipação de energia devido ao atrito de fundo, bloqueio e reflexão por correntes opostas e transmissão através de obstáculos.

O campo de ondas na zona é caracterizado pelo espectro bidimensional de densidade da ação da agitação marítima. Com esta representação, é possível a aplicação do modelo em áreas onde o crescimento da agitação marítima pela ação do vento seja notável. A propagação da agitação nos modos estacionário ou não-estacionário, nos espaços geográfico e espectral, é realizada utilizando esquemas numéricos implícitos. A zona em estudo pode ser descrita com coordenadas cartesianas ou esféricas, utilizando uma malha regular.

Os dados necessários para a execução do SWAN são: a malha batimétrica da zona a modelar, as condições de agitação na fronteira de entrada do domínio de cálculo ou alternativamente o campo de ventos para o forçamento da geração de ondas e os fenômenos físicos a ter em conta. Pode ainda ser definido o campo de correntes.

Para o cálculo da evolução do campo de ondas no tempo e no espaço, o modelo SWAN utiliza a formulação de balanço espectral da ação de onda, dada pela equação (15):

$$\frac{\partial N}{\partial t} + \frac{\partial(c_x N)}{\partial x} + \frac{\partial(c_y N)}{\partial y} + \frac{\partial(c_\sigma N)}{\partial \sigma} + \frac{\partial(c_\theta N)}{\partial \theta} = \frac{S}{\sigma} \quad (15)$$

onde a densidade espectral da ação da onda é definida como $N = N(\sigma, \theta) = E(\sigma, \theta) / \sigma$, em que σ é a frequência relativa; c_x e c_y são as velocidades

de propagação no espaço, e c_σ e c_θ são as velocidades de propagação no espectro. O termo S representa as fontes ou sumidouros associados aos processos relativos ao crescimento, decaimento e redistribuição da energia da onda, dados pela equação (16).

$$S(\sigma, \theta) = S_{in}(\sigma, \theta) + S_{ds}(\sigma, \theta) + S_{nl}(\sigma, \theta) \quad (16)$$

em que, $S_{in}(\sigma, \theta)$ representa a aquisição de energia devido à ação do vento, $S_{ds}(\sigma, \theta)$ a dissipação por rebentação parcial, por atrito no fundo e por rebentação induzida pelo fundo e $S_{nl}(\sigma, \theta)$ a transferência de energia entre componentes espectrais por interações ressonantes a quatro e três ondas.

O modelo SWAN apresenta como resultados, em qualquer ponto do domínio, a altura significativa da onda (H_s), os períodos médio (T_m) e de pico (T_p), a direção média (θ_m ou DIR) e de pico (θ), o comprimento de onda (L), e a dispersão direcional.


Como qualquer modelo, este possui limitações na correta representação de um estado de agitação, que são devidas, quer à formulação teórica em que o modelo se baseia, quer ao esquema numérico utilizado. Relativamente à formulação teórica, a principal limitação está relacionada com a calibração dos parâmetros envolvidos na descrição dos diferentes fenómenos físicos.

A calibração efetuada para o modelo SWAN utilizou dados da campanha JONSWAP, que foi realizada no Mar do Norte, Hasselmann *et al.* (1973). Devido a este fato, por exemplo, os parâmetros utilizados no espectro de ondas ou na dissipação de energia por atrito de fundo estão calibrados para o Mar do Norte. Tais parâmetros poderão não estar corretos para áreas com diferentes características de clima de ondas (ondas associadas ao estado de mar vaga e ondulação) ou diferentes características do fundo marinho.

5.1.4.2 Aplicação do SWAN - Domínio de Cálculo, Batimetria e Malhas Computacionais

A Figura 21 (a) mostra o domínio de cálculo e a batimetria utilizados para efetuar os cálculos com o modelo SWAN.

Figura 21 - Modelo SWAN. (a) Batimetria; (b) Malhas e pontos onde foram extraídos resultados.



Fonte: Neves *et al.* (2010).

Esta batimetria foi construída a partir de dados de batimetria do Instituto Hidrográfico, nomeadamente das cartas:

- Carta n. PT324204 - Cabo da Roca ao Cabo de Sines, de Dezembro 2005;
- Carta n. PT324205 - Cabo de Sines a Lagos, de Dezembro de 2005;
- Carta n. PT426408 - Aproximações ao Porto de Sines, de Março de 1995.

No modelo SWAN foram definidas 2 malhas computacionais, Figura 21 (b), em que a malha principal tem uma resolução de 80 m e uma dimensão de 8 km por 8 km, cobrindo todo o domínio de cálculo. Foi definida uma malha encaixada na malha principal com resolução de 40 m e uma dimensão de 5 km por 5 km.

Os cálculos a realizar com o modelo SWAN foram efetuados para uma gama de alturas significativas (H_s) com uma discretização de 1 m e que vai de 1 a 9 m, com períodos de pico (T_p , admitindo $T_p = 1,27 \times T_m$) de 4 a 20 s, com intervalos de 1 s, e com as direcções ($^\circ$) definidas por intervalos de 10° para uma gama que abrange as direcções de 180° a 360° . O número total de cálculos realizados através da matriz acima definida é de 2907. Desta forma, delimitaram-se, com base nos dados da boia ondógrafo, os cálculos a realizar com o sentido de, dadas as limitações no tempo de cálculo, e com intervalos de discretização relativamente pequenos, abranger o máximo de situações de condições de agitação possíveis de ocorrer na entrada do Porto de Sines.

Para cada trio de valores (H_s , T_p , DIR), a agitação incidente na fronteira do domínio de cálculo do SWAN (isto é, ao largo) foi definida através de um espectro bidimensional, caracterizado por um espectro em frequência JONSWAP, com um fator de pico $\gamma=3,3$, e uma função de dispersão direccional cosseno de potência 20. No

cálculo do espectro da agitação ao longo do domínio impôs-se uma discretização em frequência com 23 intervalos de 0,04 a 1 Hz, e uma discretização em direcção de 2°, de 0° a 360°.

Os cálculos foram efectuados em regime estacionário e consideraram-se os fenómenos de difração, atrito de fundo e o efeito da interacção entre tríades de ondas (*triad wave-wave interactions*). Não se consideraram os fenómenos, quer devido a ventos, devido à pequena extensão do domínio, quer devidos às correntes, por falta de informação existente.

Foram definidos 11 pontos de estudo para obter resultados do modelo SWAN, dos quais 5 estão localizados na fronteira Oeste da malha do modelo DREAMS, 5 localizados na fronteira Sul e 1 é um ponto de vértice da malha DREAMS (ponto P6).

A Tabela 2 apresenta um exemplo do formato do arquivo “.xlsx” para o ponto P6, utilizado nessa pesquisa.

Tabela 2 - Arquivo Sines.

Local	Hora	Dia	Mês	Ano	Data-hora	HL	TL	TetL	Hs	Tm	Tetm
SINES1D	16	26	5	1988	26/05/1988 16:43	1,55	11,1	319	1,0522	8,3709	289,6307
SINES1D	18	26	5	1988	26/05/1988 18:00	1,46	10,5	318	0,9876	7,8307	289,4082
SINES1D	21	26	5	1988	26/05/1988 21:00	1,44	10,5	312	1,0269	7,8326	286,6075
SINES1D	00	27	5	1988	27/05/1988 00:00	1,83	12,5	322	0	0	0
SINES1D	03	27	5	1988	27/05/1988 03:00	1,7	12,5	320	1,183	9,6582	289,4883
SINES1D	06	27	5	1988	27/05/1988 06:00	1,66	11,8	318	1,1534	9,0026	288,8832
SINES1D	09	27	5	1988	27/05/1988 09:00	1,39	11,8	322	0	0	0
SINES1D	12	27	5	1988	27/05/1988 12:00	1,45	11,8	317	1,0174	8,9935	288,4786
SINES1D	15	27	5	1988	27/05/1988 15:00	1,3	11,8	315	0,9286	8,9884	287,6014
SINES1D	18	27	5	1988	27/05/1988 18:00	1,44	11,1	314	1,022	8,3675	287,3349
SINES1D	21	27	5	1988	27/05/1988 21:00	1,65	10,5	306	1,2357	7,842	283,7325
SINES1D	00	28	5	1988	28/05/1988 00:00	1,4	10	314	0,9712	7,3841	287,733
SINES1D	03	28	5	1988	28/05/1988 03:00	1,46	10,5	312	1,041	7,8332	286,5998
SINES1D	06	28	5	1988	28/05/1988 06:00	1,24	10	310	0,8912	7,382	285,9209
SINES1D	09	28	5	1988	28/05/1988 09:00	1,13	10,5	314	0,7933	7,8222	287,6603
SINES1D	12	28	5	1988	28/05/1988 12:00	0,95	10,5	313	0,6734	7,8191	287,2441
SINES1D	15	28	5	1988	28/05/1988 15:00	0,88	9,1	314	0,6125	6,6419	288,1132
SINES1D	18	28	5	1988	28/05/1988 18:00	0,87	9,1	311	0,6217	6,6458	286,7086

Fonte: LNEC.

5.1.5 Caracterização das Condições dentro do Porto

5.1.5.1 Modelo Numérico DREAMS

A propagação das ondas é condicionada por diversos fenómenos físicos como, por exemplo, os associados às variações topográficas, à existência de obstáculos, à presença de correntes longitudinais ou transversais à costa, à dissipação de energia por

atrito de fundo ou por percolação no fundo, à reflexão das ondas no fundo ou na costa, à ocorrência de rebentação de ondas e às interações entre ondas e/ou ondas-correntes. Em consequência destes fenômenos, verifica-se a modificação da velocidade e da direcção de propagação da onda (refracção) e uma redistribuição da energia ao longo das cristas (difracção), à medida que as ondas se aproximam da costa. A diminuição da profundidade é geradora de um aumento da instabilidade da onda que culmina na rebentação, fenómeno que provoca a dissipação de energia da onda.

À medida que as ondas se propagam em zonas de profundidades cada vez menores, os efeitos associados à topografia do fundo, às interacções onda-onda ou onda-corrente, às transferências de energia entre componentes de onda, à geração de componentes de baixa frequência por grupos de ondas curtas, tornam-se cada vez mais importantes. Estes fenômenos traduzem-se numa progressiva assimetria do perfil da onda (um maior declive na zona frontal da onda do que na sua traseira), no alongamento das cristas e achatamento das cavas, ou na alteração da velocidade de fase, altura e direcção da onda.

A resolução da complexidade e diversidade dos fenômenos relacionados com a deformação de ondas desde águas profundas até águas pouco profundas, obrigaria à resolução das equações de Navier-Stokes para a conservação da massa e da quantidade de movimento de um escoamento incompressível e viscoso, mas tal só é possível presentemente para regiões muito limitadas, conforme Fortes (2002). A solução passa então por admitir certas hipóteses simplificativas, de modo a que a aproximação permita obter a solução de um dado problema com uma determinada precisão.

Um exemplo deste tipo de aproximações é a equação de declive suave, de Berkhoff (1972), que descreve os efeitos combinados da refração e difracção de ondas monocromáticas propagando-se em fundos de inclinação suave. Trata-se assim de uma equação especialmente indicada para a propagação e deformação de ondas em zonas abrigadas, como é o caso dos portos.

A equação elíptica de declive suave, equação (17), é obtida da integração vertical das equações de continuidade e de quantidade de movimento para escoamentos irrotacionais e gravíticos de fluidos ideais (fluido homogêneo, incompressível e não-viscoso), considerando a teoria das ondas de pequena amplitude, e admitindo que o fundo é de declive suave. Assim, é possível obter a seguinte expressão da equação linear de *mild-slope*, ou de declive suave, independente do tempo:

$$\nabla \cdot (CC_g \nabla \phi) + k^2 CC_g \phi = 0 \quad (17)$$

sendo ϕ o potencial de velocidade independente da coordenada vertical z e da variável tempo, t , que se relaciona com Φ através de:

$$\Phi(x, y, z, t) = \phi(x, y) \cdot \frac{\cosh k(h+z)}{\cosh kh} e^{-i\omega t} \quad (18)$$

C é a velocidade de fase ou celeridade de fase da onda:

$$C = \frac{\omega}{k} = \sqrt{\frac{g}{k} \tanh(kh)} \quad (19)$$

C_g é a velocidade de grupo:

$$C_g = \frac{d\omega}{dk} = \frac{1}{2} C \left[1 + \frac{2kh}{\sinh(2kh)} \right] \quad (20)$$

ω é a frequência angular obtida através da relação de dispersão para ondas de pequena amplitude (teoria linear):

$$\omega^2 = gk \tanh kh \quad (21)$$

Esta equação também pode ser expressa em termos da elevação da superfície livre, η , em que se relaciona com ϕ através de:

$$\eta = \text{Re} \left[\frac{i\omega}{g} \left(\phi(x, y) \cdot \frac{\cosh k(h+z)}{\cosh kh} \right) e^{-i\omega t} \right]_{z=0} \quad (22)$$

A introdução de η dado pela equação (22) na equação (17) conduz a:

$$\nabla \cdot (CC_g \nabla \eta) + k^2 CC_g \eta = 0 \quad (23)$$

Uma das importantes consequências da teoria linear é a possibilidade de descrever fenômenos complexos pela sobreposição de efeitos mais simples.

O modelo DREAMS, conforme Fortes (1993, 2002), resolve a equação de declive suave utilizando o método dos elementos finitos. As condições de fronteira implementadas no modelo DREAMS são: a condição de radiação que permite a saída das ondas geradas no domínio; condição de geração e radiação combinadas que simula a entrada e saída de ondas numa fronteira do domínio, por exemplo, nas fronteiras abertas; e condição de reflexão (total ou parcial) que simula fronteiras como praias, falésias, moles ou obras acostáveis.

O modelo DREAMS requer como dados de entrada as características da agitação incidente (período, direcção da onda e nível de maré), bem como da malha de elementos finitos com que foi discretizado o domínio em estudo e da fronteira desse domínio. Note-se que, tratando-se de um modelo linear, os cálculos são efectuados para um único valor de altura de onda igual a 1m. Os resultados do modelo DREAMS são os índices de agitação (H/H_0), relação entre a altura de onda no ponto do domínio de cálculo, H , e a altura de onda à entrada do domínio de cálculo, H_0 , ou coeficientes de amplificação (em estudos de ressonância portuária), direcções de propagação da onda, e ainda o campo de velocidades horizontais na superfície livre e as linhas representativas das cristas das ondas (linhas de igual fase).

A metodologia seguida para aplicação do modelo DREAMS passa por: a) definir o domínio de cálculo do caso em estudo; b) gerar uma malha irregular de elementos finitos, onde haja no mínimo 8 pontos de cálculo (8 pontos por onde passa a malha) por comprimento de onda a aplicar no modelo; a malha tem que estar de acordo com a batimetria do local; c) construir os ficheiros de dados de entrada no modelo, como é o caso das condições de agitação incidente que serão impostas e os coeficientes de reflexão a impor nos vários trechos que compõem a fronteira do modelo; e d) executar o modelo e analisar os resultados.

O modelo DREAMS é uma ferramenta de modelagem numérica de propagação e dissipação de ondas em zonas portuárias e abrigadas, com resultados bastante satisfatórios em todas as aplicações. Uma vantagem do modelo é também o facto de as malhas de elementos finitos serem completamente independentes da direcção de onda, ou seja, a qualidade dos resultados não vem afectada pela posição da malha relativamente à direcção de onda.

Como limitações do modelo salientam-se (i) O facto do modelo não considerar os efeitos da dissipação de energia por rebentação e atrito de fundo, os efeitos das correntes na propagação das ondas ou os galgamentos sobre estruturas portuárias; (ii) O modelo é linear pelo que não tem em conta efeitos não-lineares, como por exemplo, a interação de ondas e correntes, a interação de ondas devido à topografia do fundo, a transferência de energia entre componentes de onda e a geração de componentes de baixa frequência induzidas por grupos de ondas curtas; (iii) O modelo efetua a propagação de ondas regulares e unidireccionais, não tendo por isso em conta, os efeitos da dispersão em frequência e em direcção, presentes na agitação real; (iv) A aplicação do modelo está condicionada a fundos de declive suave, ou seja, até $1/3$; (v) Na


propagação de ondas marítimas de curto período, a aplicação do modelo está limitada a zonas relativamente pequenas, devido ao elevado esforço computacional exigido pelo modelo.

5.1.5.2 Aplicação do DREAMS - Domínio de Cálculo, Batimetria e Malha Computacional

O modelo DREAMS efetua a propagação da agitação marítima desde a entrada no Porto de Sines até ao seu interior, onde os fenômenos de refração, difração e reflexão são importantes. O domínio computacional e a batimetria considerados são apresentados na Figura 22.

O domínio computacional foi discretizado por uma malha de elementos finitos e é constituída por 300139 elementos e 151669 nós, admitindo-se um número mínimo de nós por comprimento de onda igual a 8, Figura 22. A malha de elementos finitos para o modelo DREAMS foi gerada através do módulo de geração de malhas que contém o programa para construção de malhas não estruturadas, GMALHA, (PINHEIRO *et al.*,2006).

Figura 22 - Modelo DREAMS. Domínio computacional, batimetria e malha de elementos finitos.



Fonte: Neves *et al.* (2010).

As fronteiras (Oeste e Sul, Figura 22) são fronteiras de entrada onde se impõe os valores de agitação incidente. Neste caso, os valores a impor resultarão dos valores calculados pelo modelo SWAN, no ponto P6.


Nas restantes fronteiras do domínio de cálculo, correspondentes aos diferentes trechos que delimitam o porto, procedeu-se ao cálculo dos respectivos coeficientes de

reflexão. A fronteira do modelo foi dividida em vários trechos, onde, do nó inicial ao nó final de cada trecho foi atribuído um coeficiente de reflexão que caracteriza as propriedades reflectivas desse trecho.

Para a construção da matriz de transferência do modelo DREAMS foram analisados os resultados do modelo SWAN no ponto exterior ao domínio, Ponto P6. Os cálculos foram efectuados para períodos de onda (T) entre 5 a 20 s com 1 s de intervalo, e para as direcções de onda (DIR) entre os 180° e 360° com 20° de intervalo, resultando num número total de combinações (T , DIR) de 160. Desta forma, é possível abranger todos os períodos e direcções da agitação marítima passíveis de penetrar no porto de Sines.

No interior do porto, foram definidos 7 pontos de análise (A, B, C, D, E, F e G) (Figura 23) dos resultados do modelo DREAMS, Tabela 3. Esta disposição espacial dos pontos no interior do porto permite conhecer o regime de agitação marítima desde a entrada do porto até ao pequeno porto de pesca na zona mais abrigada do porto, passando pelos regimes de agitação junto aos moles principais e no centro do Porto de Sines.

Figura 23 - Malha de elementos finitos do modelo DREAMS. Localização dos pontos A a G no interior do porto.



Fonte: Neves *et al* (2010).

Tabela 3 - Localização geográfica dos 7 pontos de resultados do modelo DREAMS.

Pontos	A	B	C	D	E	F	G
Coordenadas Militares	(133576, 107320)	(133650, 109010)	(136059, 108109)	(135285, 109560)	(135576, 109721)	(135036, 109773)	(135021, 108955)
Coordenadas Geográficas	(-08°53'14,615"; 37° 55' 43,017")	(-08° 53' 12,146"; 37° 56' 37,844")	(-08° 51' 33,208"; 37° 56' 09,245")	(-08° 52' 05,370"; 37° 56' 56,104")	(-08° 51' 53,504"; 37° 57' 01,400")	(-08° 52' 15,636"; 37° 57' 02,948")	(-08° 52' 15,985"; 37° 56' 36,416")
Coordenadas definidas de acordo com o sistema de coordenadas Hayford-Gauss Militar, Datum Lisboa							

Fonte: Neves *et al.* (2010).


5.1.5.3 Regime de Agitação no Interior do Porto de Sines

Como referido, foi primeiramente construída a matriz de transferência com base nos cálculos do SWAN. Com o programa REGIMES, foram transferidos os dados de agitação marítima na boia-ondógrafo para o ponto P6. Seguidamente, construiu-se a matriz de transferência com base nos cálculos do DREAMS e, utilizando, mais uma vez, o programa REGIMES, realizaram-se as interpolações necessárias para transferir os resultados obtidos no ponto P6 para os pontos no interior do porto, definindo em cada um deles os regimes de agitação e os valores extremos de Hs.

A título de exemplificação, serão apenas apresentados os gráficos das séries temporais correspondentes ao ponto P6 (SWAN) e aos pontos D e F.

Na Figura 24 são apresentadas as séries temporais dos valores de altura, período e direção de onda nos pontos D e F. Note-se que para o ponto P6, de resultados do modelo SWAN e para os pontos A, B, C, D, E, F e G, de resultados do modelo DREAMS, foram excluídos do regime geral os valores que se encontravam fora da gama definida nas matrizes de transferência do modelo SWAN e do modelo DREAMS, e também os valores de altura significativa igual a zero.

Figura 24 - Séries temporais dos valores de H_s , T_p e DIR nos pontos D e F obtidos com o modelo DREAMS, para o período de Maio 1988 a Dezembro de 2002.




Fonte: Neves *et al.* (2010).

5.1.5.4 Campanha de Medição no Interior do Porto

A campanha de medição no interior do Porto de Sines foi realizada no âmbito do Projecto GUIOMAR - Interface Geo(gráfica) para Modelação Costeira e Marinha, financiado pela Fundação para a Ciência e Tecnologia (contrato PTDC/AMB/67450/2006). Teve como principal objetivo a medição da agitação marítima no porto de Sines com vista à determinação de parâmetros de onda representativos, utilizando para isso um sensor de pressão autónomo, da marca “ALEC ELECTRONICS Infinity_WH”, adiante designado por Infinity_WH. Também foram realizadas outras duas campanhas utilizando para isso dois outros sensores de pressão, sendo eles denominados LevelTroll e MiniTroll. Nas Figura 25 e Figura 26 são apresentados os locais aproximados da realização dessas medições em campo.

Figura 25 - Localização do equipamento P1 – Infinity_WH.



Fonte: Neves *et al.* (2010).

Figura 26 - Localização do equipamento P1 – LevelTroll e P2 – MiniTroll.



Fonte: Neves *et al.* (2010).

A campanha de campo foi realizada em duas datas como se segue: nos dias 25 de fevereiro de 2011 (Infinity_WH), e 26 de fevereiro de 2009 (LevelTroll e MiniTroll).

Para os registros obtidos, o tratamento consistiu:

- na remoção da componente de maré [$Tide(m)$], com base no cálculo expedito de uma média móvel de 40 pontos das elevações da superfície livre obtidas pelos equipamentos [$Depth(m)$].
- na divisão do registo corrigido total [$elevation(m)$] em troços individuais, de 30 minutos de duração, para posterior análise isolada dos diferentes estados de mar, considerados estacionários.
- na análise temporal desses registos com os programas REGISTROS (FORTES e CAPITÃO, 2009) e ANOIAGI. Obtiveram-se, para cada registo, os valores de H_{max} (altura máxima do registo), H_s (altura significativa), H_m (altura média), T_s (período significativo) e T_m (período médio).
- na análise espectral desses registos com o módulo 7 do programa SAM (CAPITÃO, 2002). Extraíram-se os valores da altura significativa, H_{m0} , T_m , e T_p .

Após o tratamento desses dados, fora extraída a seguinte Tabela 4.

Tabela 4 – Alturas e Períodos de onda após tratamento dos dados.

LevelTroll			
Análise temporal		Análise espectral	
H_s	T_s	H_{m0}	T_p
0,362	11,728	0,353	10,537
0,249	11,549	0,260	10,800
MiniTroll			
Análise discreta		Análise espectral	
H_s	T_s	H_{m0}	T_p
0,217	13,256	0,223	12,529
Infinity			
Análise discreta		Análise espectral	
H_s	T_s	H_s	T_p
0,441	*28,074	0,408	13,123

* Dado superestimado.

Fonte: LNEC

Esses resultados serão utilizados quando da tentativa de se comparar com as alturas significativas previstas pela rede ARTMAP-Fuzzy e pelo modelo DREAMS. Os resultados dessa comparação serão apresentados em seu respectivo capítulo.

5.2 Caracterização das Condições de Galgamento no Mole Oeste

5.2.1 Perfil Analisado

Como visto anteriormente, o Porto de Sines está localizado na costa Oeste de Portugal continental e é protegido por dois moles: Oeste e Este (Figura 27). O molhe Oeste é o molhe principal e serve de abrigo aos postos de acostagem de águas profundas para navios petroleiros e aos quatro terminais principais do porto.

Figura 27 - Molhe Oeste do Porto de Sines e posto 2 do terminal de granéis líquidos.




Fonte: Santos *et al.* (2013).

O perfil-tipo do trecho do molhe que protege o posto 2 do terminal de granéis líquidos do porto consiste num quebramar de taludes, com cubos Antifer de 900 kN colocados, em duas camadas, de forma regular acima do zero hidrográfico (ZH) e de forma irregular abaixo do ZH (Figura 28). Devido à realização de vários trabalhos de reabilitação, o talude da estrutura não é uniforme, com quatro troços inclinados ao longo

da zona ativa do manto. O coroamento é composto por uma berma de 20 m de largura à cota +18,0 m (ZH), encostada a uma superestrutura de betão com deflector de onda, com o coroamento à cota +19,0 m (ZH) (REIS *et al.*, 2011).

Figura 28 - Perfil-tipo do trecho do molhe que protege o posto 2.




Fonte: Bravo (2013).

5.2.2 Modelagem Física

Para este perfil, foram realizados no LNEC ensaios em modelo físico bidimensional de estabilidade e galgamento num canal de ondas irregulares, tendo sido utilizada a escala geométrica de 1:60 (LNEC, 2008) (

Figura 29 e Figura 30). Os ensaios contemplaram dois níveis de maré, 0,0 m (ZH) e +4,0 m (ZH), e foram realizados para diferentes condições de agitação incidente irregular, com uma configuração espectral empírica de JONSWAP, períodos de pico do espectro, T_p , entre 10 s e 20 s e alturas de onda significativa, H_s , entre 4 m e 14 m, aproximadamente, valores estes referidos em protótipo.

Figura 29 – Batedor de Ondas com absorção de reflexão.



Fonte: LNEC.

Figura 30 – Modelo Físico com escala 1:60 executado no LNEC.



Fonte: LNEC.

A Tabela 5 apresenta os valores dos caudais médios de galgamento por metro linear de estrutura medidos no modelo físico, q_{MF} , para doze ensaios realizados nos estudos de reabilitação do molhe. As características da agitação, T_p e H_s , representam valores medidos em frente da estrutura, à profundidade -45,0 m (ZH) (valor do protótipo).

Tabela 5 - Caudais médios de galgamento por metro linear de estrutura obtidos no modelo físico, q_{MF} , em valores do protótipo.

Ensaio	Nível de Maré (m ZH)	Tp (s)	Hs (m)	q_{MF} ($10^{-3} \text{ m}^3/\text{s/m}$)
1	0,0	10	6	0,0
2		14	9	0,0
3		18	11,5	1,8
4		16	12	0,3
5		20	13	13,5
6		20	14	35,3
7	4,0	10	6	0,0
8		14	9	0,6
9		18	11,5	44,2
10		16	12	33,3
11		20	13	138,6
12		20	14	246,8

Fonte: LNEC.


5.2.3 Modelagem com Redes Neurais

Para o cálculo do galgamento de estruturas marítimas foram desenvolvidas na última década, no âmbito do projeto de investigação Europeu CLASH (*Crest Level Assessment of coastal Structures by full scale monitoring, neural network prediction and Hazard analysis on permissible wave overtopping*) e contemporaneamente ao projeto, duas ferramentas que se baseiam no desenvolvimento e análise de sistemas de redes neurais artificiais, do tipo *multi-layer feed-forward*, que usam no processo de treino o algoritmo matemático de *error-backpropagation* combinado com um algoritmo *quasi-Newton* ou *Levenberg-Marquardt*: NN_OVERTOPPING2 (COEVELD *et al.*, 2005) e OVERTOPPING (VERHAEGHE, 2005). Estas redes têm como base uma extensa coletânea de, aproximadamente, 10.500 testes de galgamentos, que resultaram de ensaios em modelo físico reduzido e de medições em protótipo, que constam da base de dados CLASH (VAN DER MEER *et al.*, 2009) e que foram distribuídos pelas fases de treino e de teste das redes neurais através de um procedimento de amostragem *bootstrapping*. Estas ferramentas têm-se mostrado muito úteis na prática da Engenharia, mas apresentam ainda limitações, relacionadas essencialmente com a falta de capacidade de generalização a casos desconhecidos das redes.

A base de dados de galgamentos CLASH (VAN DER MEER *et al.*, 2009), com cerca de 10.500 dados, foi utilizada na sua totalidade para treino da nova rede neural ARTMAP-Fuzzy desenvolvida no âmbito dessa pesquisa. Apresenta informação de testes em modelo físico efetuados em vários laboratórios internacionais contendo, para cada teste, informação relativa ao comportamento de vários parâmetros hidráulicos (por exemplo: características das ondas incidentes e medições dos caudais de galgamento), assim como informação relativa às estruturas marítimas em estudo. A base de dados inclui ainda informação geral sobre a fiabilidade do teste e a complexidade das estruturas. Como características do galgamento medido apresenta, para cada teste, o valor do caudal médio de galgamento por metro linear de estrutura, q .

Inicialmente, a entrada da rede ARTMAP-Fuzzy consistiu num vetor de 15 parâmetros (Figura 31), vetor esse que fora escolhido para uma padronização com as outras redes neurais utilizadas:

Figura 31 - Parâmetros de entrada da rede ARTMAP-Fuzzy.



Fonte: Bravo (2013).

H_{m0} [m]: Altura de onda significativa, calculada com o momento espectral m_0 , em frente da estrutura;

$T_{m-1,0}$ [s]: Período médio, calculado com os momentos espectrais m_{-1} e m_0 , em frente da estrutura;

β_t [°]: Ângulo entre a direção de propagação da agitação e a normal à estrutura;

h [m]: Profundidade junto à estrutura, mais precisamente, a altura de água imediatamente a montante da estrutura;

h_t [m], B_t [m]: Parâmetros que dizem respeito à profundidade e à largura da banquetta de fundo da estrutura, respectivamente. Se não existir banquetta de fundo B_t é igual a zero;

$\cot \alpha_d$ [-], $\cot \alpha_u$ [-]: Parâmetros usados para descrever o(s) declive(s) da estrutura. O fundo e o coroamento da estrutura já são descritos em outros parâmetros, portanto não são incluídos nestes dois parâmetros;

B [m], h_b [m], $\tan \alpha_B$ [-]: Parâmetros que descrevem a berma da estrutura: B é a largura, medida horizontalmente e h_b é a profundidade de água na berma, medida no centro da mesma. Se a berma estiver acima do nível de água, h_b é negativo. No caso da berma ser horizontal, $\tan \alpha_B = 0$;

R_c [m], A_c [m], G_c [m]: Parâmetros que descrevem o coroamento da estrutura: R_c é o bordo livre, A_c é a distância entre o meio da berma de coroamento e o nível da água e G_c é a largura de coroamento;

γ_f [-]: Parâmetro indicativo da rugosidade e da permeabilidade da estrutura: quanto maior a rugosidade/permeabilidade da estrutura, menor será o caudal galgado e maior será a energia dissipada na superfície da estrutura, consequentemente este parâmetro tomará valores inferiores.

Além dos 15 parâmetros anteriormente referidos, houve a necessidade de considerar 4 parâmetros adicionais que levam em consideração o sinal de h , h_t , $\cot \alpha_u$ e h_b , sendo eles 1 para valores positivos e 0 para valores negativos, para cada um dos parâmetros. Esta atribuição foi necessária para que o vetor de entrada possuísse os parâmetros normalizados no intervalo [0,1], necessidade imposta pelo tipo de rede desenvolvida.

O vetor de saída da rede consistiu nos valores dos caudais médios de galgamento por metro linear de estrutura, q_{ART} .

Devido à grande variação de alguns dos parâmetros de entrada e saída da rede ARTMAP-Fuzzy, houve a necessidade de realizar uma adimensionalização dos mesmos. Conforme Coeveld *et al.* (2005) e Verhaeghe (2005), foi utilizada a escala de Froude.

O conceito em que se baseia a teoria da semelhança de Froude, ou de qualquer outra, é que dois sistemas (no caso, o protótipo e o respetivo modelo reduzido) dizem-se fisicamente semelhantes relativamente a um conjunto de grandezas quando há uma relação constante entre valores homólogos dessas grandezas nos dois sistemas. Essa semelhança pode ser de índole geométrica, cinemática ou dinâmica (BRAVO, 2013).

Ainda em Bravo (2013), na semelhança dinâmica existe uma relação constante não só entre a resultante das forças como também entre as componentes das forças

homólogas atuando nos dois sistemas dinamicamente semelhantes, qualquer que seja a sua natureza. Para assegurar a semelhança dinâmica das forças atuantes sobre partículas homólogas de dois sistemas basta que sejam iguais as relações entre cada uma das forças de uma dada natureza e a força tomada como referência.

Após algumas considerações, optou-se por adimensionalizar os parâmetros conforme a Tabela 6.

Tabela 6 - Adimensionalização dos parâmetros de entrada e saída da rede ARTMAP-Fuzzy.

Parâmetros de Entrada	Parâmetro de Saída
H_{m0} / H_{m0}	
$T_{m-1,0} / (H_{m0})^{0.5}$	
β_t	
h / H_{m0}	
h_t / H_{m0}	
B_t / H_{m0}	
γ_f	
$\cot\alpha_d$	$q / (H_{m0})^{3/2}$
$\cot\alpha_u$	
B / H_{m0}	
h_b / H_{m0}	
$\tan \alpha_B$	
R_c / H_{m0}	
A_c / H_{m0}	
G_c / H_{m0}	

Fonte: Bravo (2013).


5.3 Descrição da Área de Estudo: Lago de Ilha Solteira

Este capítulo é uma adaptação da dissertação de mestrado de Moraes (2009) e dos relatórios técnicos do projeto ONDISA. Os mesmos foram escolhidos devido ao fato de conter grande parte da história de pesquisas desenvolvidas até o presente momento no Lago de Ilha Solteira.

É importante destacar que essa revisão bibliográfica, a base de dados de vento, juntamente com a previsão de altura de onda nela descrita, através de alguns métodos clássicos citados *a posteriori*, servirão de base referencial para caracterização do Lago para a aplicação da rede neural ARTMAP- Fuzzy.

É disponibilizado o mapa digital do lago de Ilha Solteira (Figura 32). A base cartográfica foi composta a partir de imagens de satélite (imagens já em arquivo eletrônico), e digitalizada com o auxílio de um *software CAD*.

Figura 32 - Reservatório de Ilha Solteira.



Fonte: Moraes (2009).

a) Sistema de Transmissão de Dados


O Anemômetro Ultrassônico 3D CSAT3 da Campbell instalado no farol São Martinho, coleta os dados brutos de vento e os envia por rádio - telemetria ao laboratório de Hidrologia e Hidrometria na UNESP/FEIS, onde ficam armazenados para um posterior tratamento.

O atual sistema é composto por duas etapas: sistema de transmissão em campo e sistema de recepção na UNESP/FEIS.

A Figura 33 ilustra o sistema de transmissão em campo composto por:

- (a) Anemômetro Ultrassônico 3D CSAT3,
- (b) Datalogger CR1000,
- (c) Rádio RF 450 transmissor e
- (d) Antena unidirecional transmissora.

Figura 33 - Sistema de transmissão de dados em campo.




Fonte: Moraes (2009).

Já a Figura 34 ilustra o sistema de recepção no laboratório de Hidrologia e Hidrometria da UNESP/FEIS. E composto por:

- (a) Antena Omni multidirecional receptora,
- (b) Rádio RF 450 receptor e
- (c) PC receptor de dados.

Figura 34 - Sistema de recepção de dados na UNESP/FEIS



Fonte: Moraes (2009).

b) Dados de Ventos em Ilha Solteira (2008/2009)

Para o estudo de casos do presente trabalho será utilizado o banco de dados captados pelo Anemômetro Ultrassônico 3D CSAT3 localizado na torre do farol São Martinho, referente a atuais medições realizadas entre os anos de 2008 e 2009.

O software ONDISACSAT3 já fornece os dados tratados do arquivo bruto gerado pela recepção direta dos dados de vento, gerando assim os dados necessários para caracterizar os ventos no lago de Ilha Solteira.

A seguir são apresentadas algumas tabelas e rosas-dos-ventos para facilitar a interpretação dos dados emitidos pelo software OndisaCsat3.

A Tabela 7 mostra, nesse contexto, os dados médios mensais de intensidade dos ventos. A frequência de ocorrência, no mesmo período de tratamento dos dados, está disposta na Tabela 8. Agrupando as duas tabelas anteriores, obtém-se a Tabela 9 em termos de aspectos energéticos.

Tabela 7 - Velocidades médias mensais do vento para a campanha de 2008-2009.

Velocidades Médias Mensais (m/s)																
Mês	E	ENE	NE	NNE	N	NNO	NO	ONO	O	OSO	SO	SSO	S	SSE	SE	ESE
Junho	4,68	4,35	4,39	4,95	4,15	3,73	3,91	3,76	2,66	2,38	1,55	1,77	2,86	2,45	2,74	3,73
Julho	3,62	3,19	5,34	6,29	4,73	4,53	4,48	3,82	3,47	3,03	1,72	1,32	1,57	1,80	2,25	2,54
Agosto	5,65	4,92	5,86	6,12	5,10	4,59	4,54	4,50	3,84	3,81	3,28	2,90	3,10	1,57	5,42	5,97
Setembro	5,55	5,03	5,08	6,49	5,79	5,09	5,31	4,98	4,57	2,87	2,47	2,79	3,41	2,79	5,19	5,34
Outubro	4,52	3,91	4,42	5,75	4,69	4,59	4,94	4,81	3,91	2,91	2,71	3,77	4,74	4,38	4,42	4,96

Fonte: Moraes (2009).

Tabela 8 - Frequências mensais do vento para a campanha de 2008-2009.

Frequências (%)																
Mês	E	ENE	NE	NNE	N	NNO	NO	ONO	O	OSO	SO	SSO	S	SSE	SE	ESE
Junho	7,36	5,83	5,20	6,41	6,32	11,08	17,63	13,87	4,21	3,08	1,86	1,98	3,22	2,97	3,73	5,26
Julho	0,86	0,87	4,75	13,33	10,47	18,14	25,28	16,48	3,97	1,82	0,68	0,77	0,71	0,60	0,60	0,66
Agosto	0,86	1,38	4,48	9,08	8,15	16,39	26,78	19,30	5,24	3,52	1,64	0,90	0,51	0,28	0,59	0,88
Setembro	9,86	7,84	9,76	10,36	9,41	6,77	10,03	10,22	3,24	1,67	1,31	1,69	2,32	1,58	5,62	8,30
Outubro	4,26	5,42	6,57	10,23	6,40	11,11	19,35	13,91	4,11	3,03	1,99	2,50	2,59	1,49	2,43	4,61

Fonte: Moraes (2009).

Tabela 9 - Ventos dominantes mensais para a campanha de 2008-2009.

Ventos Dominantes																
Mês	E	ENE	NE	NNE	N	NNO	NO	ONO	O	OSO	SO	SSO	S	SSE	SE	ESE
Junho	161,2	110,3	100,2	157,1	108,8	154,2	269,5	196,1	29,8	17,4	4,5	6,2	26,3	17,8	28,0	73,2
Julho	11,3	8,9	135,4	527,4	234,2	372,2	507,4	240,5	47,8	16,7	2,0	1,3	1,8	1,9	3,0	4,3
Agosto	27,5	33,4	153,8	340,1	212,0	345,3	552,0	390,8	77,3	51,1	17,6	7,6	4,9	0,7	17,3	31,4
Setembro	303,7	198,4	251,9	436,4	315,5	175,4	282,8	253,5	67,7	13,8	8,0	13,2	27,0	12,3	151,4	236,7
Outubro	87,0	82,9	128,4	338,2	140,8	234,1	472,2	321,8	62,8	25,7	14,6	35,5	58,2	28,6	47,5	113,4

Fonte: Moraes (2009).

A partir desses dados, tirou-se a média para todo o período, tanto para as frequências como para as velocidades médias, organizando assim a Tabela 10, que resume os dados das tabelas anteriores em uma análise das médias das velocidades dos ventos, das frequências e dos ventos dominantes de todo período.


Tabela 10 – Resumo das médias durante a campanha de 2008-2009.

Médias de todo período															
E	ENE	NE	NNE	N	NNO	NO	ONO	O	OSO	SO	SSO	S	SSE	SE	ESE
Média das Velocidades															
4,80	4,28	5,02	5,92	4,89	4,51	4,64	4,37	3,69	3,00	2,35	2,51	3,14	2,60	4,00	4,51
Média das Freqüências															
4,64	4,27	6,15	9,88	8,15	12,70	19,81	14,76	4,15	2,62	1,50	1,57	1,87	1,38	2,59	3,94
Média dos Ventos Dominantes															
107,1	78,2	154,9	346,3	195,0	257,8	425,9	282,3	56,6	23,6	8,2	9,9	18,4	9,3	41,6	80,1

Fonte: Morais (2009).

Apresentam-se as rosas dos ventos (Figura 35) para os dados de 2008-2009, como se segue:


Figura 35 - Rosas-dos-ventos reinantes mensais, campanha 2008-2009.



Fonte: Morais (2009).

As imagens da Figura 36 representam as rosas-dos-ventos dominantes mensais.


Figura 36 - Rosas-dos-ventos dominantes mensais, campanha 2008-2009.



Fonte: Moraes (2009).

As imagens da Figura 37 ilustram uma comparação entre as rosas-dos-ventos reinantes (a) e dominantes (b) de todo período de medição.

Figura 37 - Rosas-dos-ventos de todo período de medição da campanha 2008-2009 (a) reinantes e (b) dominantes.



Fonte: Moraes (2009).

Segundo Moraes (2009), a partir dessas análises de dados de vento, nota-se que os ventos predominantes (reinantes) característicos da região, no período de medição, ocorreram na direção Noroeste com uma intensidade média de 4,64 m/s e frequência de 19,81%, com resultados de dominância (aspecto energético) de 425,9%. Há de se notar que a direção dos ventos predominantes é coincidente com a direção dos ventos dominantes. Já a maior média dos ventos ocorre na direção NNE e possui uma intensidade de 5,92 m/s com uma frequência de 9,88%, resultando em uma dominância de 346,3%.

5.3.1 Dados de Ondas

I) Modelos Numéricos

Segundo Moraes (2009), os programas de determinação da pista de vento possuem formulação geométrica, pois dependem única e exclusivamente do entorno da margem para uma definição completa. Já nos processos de estimativa de altura de ondas, o comprimento da pista é somente uma das variáveis envolvidas.

Os programas aplicáveis às ondas foram fundamentados na mesma ideia de percorrer os nós de uma malha de modo a estimar a altura da onda na posição relativa a cada nó.

A altura da onda é estimada por equações que recebem o comprimento da pista e a intensidade do vento como variáveis independentes.


Estão disponíveis no programa os métodos JONSWAP, SMB, Wolf, Creager e SGM. Foi utilizado o resultado obtido pelo método JONSWAP pela sua grande utilização em estudos anteriores. Assim, os ventos médios e máximos serão analisados através do OndisaCAD, e os resultados encontram-se a seguir.

A Figura 38 e a Figura 39 ilustram, para o lago de Ilha Solteira, os mapas de altura de ondas para as direções NNE (maior vento médio) e NNO (vento máximo). Como se pode verificar, as maiores ondas estão localizadas nos mesmos pontos em que se têm as maiores pistas de vento, quando se trata de uma mesma direção. Assim as maiores ondas na direção NNE estão à sudeste do lago de Ilha Solteira, cerca de 0,4 m

de altura, assim como as maiores pistas também. Lembrando que para essa direção o vento utilizado foi de 5,92 m/s.


Já para o caso da direção NNO, as maiores ondas também estão à sudeste do lago de Ilha Solteira, porém com cerca de 1,20 m de altura, já que a intensidade de vento incidente nessa direção foi de 24,62 m/s.

Figura 38 - Mapa de altura de onda para o lago de Ilha Solteira, direção NNE, maior vento médio (5,92 m/s).



Fonte: Morais (2009).

Figura 39 - Mapa de altura de onda para o lago de Ilha Solteira, direção NNO, vento máximo 24,62 m/s.



Fonte: Morais (2009).

II) Dados Medidos em Campo

A série de dados utilizada no escopo dessa pesquisa é apenas uma pequena parte dos dados coletados atualmente. Isso, devido ao fato do sistema de aquisição estar em desenvolvimento. No entanto, algumas considerações já podem ser tecidas. Segundo Oliveira (2012), depois de finalizada a instalação de todos os equipamentos, a estação deverá se tornar autossuficiente quanto à alimentação, com margem excedente de 50% de toda a energia coletada (Figura 40). O gargalo do sistema acabou por ser transmissão dos dados, devido à necessidade de amostragem em frequências relativamente elevadas (10Hz de amostragem do sensor de distância e 5Hz do sensor de pressão). O grande fluxo de dados armazenados ocasiona o total preenchimento da memória de 4MB do sistema de aquisição em apenas 5 horas. Ainda segundo Oliveira (2012), embora o link de transmissão dos dados tenha capacidade de pelo menos dez vezes o fluxo de dados gerados, um período de 5 horas é demasiado estreito para qualquer problema que venha a ocorrer com o link. Sendo assim, optou-se por processar os dados de ondas, enviando uma amostra por minuto, armazenando os dados brutos totais de forma condicional, ou

seja, apenas quando o evento de onda for significativo; caso contrário, a malha de dados é desprezada, aliviando o estouro de memória.

Figura 40 - Estação em operação autônoma.



Fonte: Moraes (2009).

Em uma das atualizações de software de aquisição (OLIVEIRA, 2012), foi incluída uma rotina que desconsidera dados brutos levando em consideração o desvio padrão destas amostras e a velocidade do vento, podendo caracterizar eventos significativos ou não. Para uma melhor visualização dos eventos, o software calcula em tempo real a amplitude máxima das ondas, considerando a diferença entre o mínimo e máximo valor registrado dentro de um intervalo de um minuto, armazenando apenas

esta amostra em uma tabela separada, exigindo menos recursos para exibição dos resultados (Tabela 11).

Tabela 11 - Exemplo da base de dados utilizada.

TOA5	Boisa	CR1000	22937	CR1000.Std.24	CPU:Boisa.CR1	10681	Minute						
TIMESTAMP	RECORD	Vento_Vel_Med	Vento_Dir_Med	Vento_Vel_Max	BattV_Min	Nivel_Avg	Nivel_Std	Distancia	H_inst_Max	H_inst_Min	Amplitude		
TS	RN	Metros/Segundo	Deg	Metros/Segundo	Volts	Metros	Metros	Metros	Metros	Metros	Metros		
		WVc	WVc	Max	Min	Avg	Std	Avg	Max	Min	Smp		
23/02/2013 13:10	27207	1,188	1,416	1,79	12,1	1,024	0,002	1,935	0,096	-0,061	0,14		
23/02/2013 13:11	27208	2,401	19,91	3,23	12,1	1,023	0,002	1,935	0,065	-0,057	0,157		
23/02/2013 13:12	27209	2,587	23,47	3,21	12,08	1,023	0,001	1,934	0,056	-0,046	0,122		
23/02/2013 13:13	27210	2,94	38,61	4,39	12,04	1,023	0,002	1,934	0,069	-0,077	0,102		
23/02/2013 13:14	27211	4,3	25,52	6,58	12,07	1,021	0,002	1,936	0,061	-0,065	0,146		
23/02/2013 13:15	27212	5,38	40,48	6,99	12,12	1,019	0,003	1,938	0,055	-0,056	0,126		
23/02/2013 13:16	27213	4,921	51,51	6,14	12,1	1,019	0,003	1,937	0,065	-0,05	0,111		
23/02/2013 13:17	27214	6,081	54,6	7,62	12,03	1,02	0,002	1,938	0,06	-0,053	0,115		
23/02/2013 13:18	27215	6,837	54,65	8,53	12,06	1,021	0,002	1,939	0,084	-0,069	0,113		
23/02/2013 13:19	27216	6,871	66,72	7,97	12,07	1,023	0,002	1,94	0,065	-0,074	0,153		
23/02/2013 13:20	27217	6,166	76,2	7,57	12,07	1,022	0,002	1,939	0,094	-0,075	0,139		
23/02/2013 13:21	27218	6,012	81,4	6,82	12,06	1,022	0,002	1,941	0,081	-0,077	0,169		
23/02/2013 13:22	27219	5,421	77,58	6,22	12,08	1,023	0,002	1,941	0,075	-0,084	0,158		
23/02/2013 13:23	27220	5,966	89,9	7,03	12,1	1,021	0,003	1,943	0,074	-0,092	0,159		

Fonte: Laboratório de Hidrologia e Hidrometria – LH².

Sendo assim, em posse de uma série de dados de 23/02/2013 a 14/03/2013, com intervalos de 1 min de apresentação dos dados e, no que tange a altura de ondas, o software só apresentava a maior amplitude das ondas que ali passavam naquele minuto.

Mas, para testar a viabilidade futura da utilização da rede neural desenvolvida, acredita-se que os resultados apresentados *a posteriori* são de grande interesse para a comunidade de pesquisa do Laboratório de Hidrologia e Hidrometria da Faculdade de Engenharia de Ilha Solteira.

6 RESULTADOS E DISCUSSÃO

6.1 Análise de Sensibilidade dos Parâmetros da Rede fora do Porto


São apresentados resultados relativos à análise de sensibilidade dos parâmetros da rede ARTMAP-Fuzzy. Isso se fez necessário, para a posteriori, ocorrer a utilização dos parâmetros no treinamento, diagnóstico e previsão com uma tentativa de minimizar os erros gerados. Sendo assim, foram escolhidos dentro da base de dados, cerca de 3000 dados para fins de treinamento, a partir dos quais, realizou-se a variação dos parâmetros da rede para outros 1000 dados aleatórios desconhecidos da rede. Mantendo-se assim uma análise acerca de aproximadamente 30% dos dados (porcentagem muito utilizada quando se trata de avaliação de utilização de redes neurais). Todos os resultados são referentes ao ponto P6 descrito anteriormente e comparados com o modelo SWAN. Em tempo, salienta-se que a denominação de erros, no caso, caracteriza-se pela divergência dos resultados apresentados na comparação com outras ferramentas neurais e outros modelos.

6.1.1 Variação da Vigilância na Saída (ρ_b)

Optou-se por iniciar uma varredura em relação à vigilância dos parâmetros de saída da rede (H_s , T_p e DIR), haja vista que os mesmos estão diretamente relacionados com os erros de previsão no futuro. Inicialmente, tomou-se um valor de $\rho_b = 1,0$, o mais alto possível, para que, apesar da criação de muitas classes, isso tornaria, em princípio, a rede mais refinada. Logo em seguida, foi-se diminuindo o valor da vigilância até a rede se desestabilizar ou até se atingirem valores de erros mais baixos, isso na tentativa de minimizar os erros.


Os gráficos que se seguem são referentes à variação da vigilância de saída para alturas significativas (H_s), períodos de pico (T_p) e direção das ondas (DIR). Cabe destacar que foram escolhidos apenas algumas visualizações para se evitar a repetitividade das mesmas, quando da variação dos outros parâmetros.

Figura 41 - Comparação de H_s entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 1,0$.




Fonte: Próprio autor.

Figura 42 - Correlação de H_s provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para $\rho_b = 1,0$.




Fonte: Próprio autor.

Figura 43 - Comparação de T_p entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 1,0$.




Fonte: Próprio autor.

Figura 44 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para $\rho_b = 1,0$.




Fonte: Próprio autor.

Figura 45 - Comparação de DIR entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 1,0$.




Fonte: Próprio autor.

Figura 46 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\rho_b = 1,0$.




Fonte: Próprio autor.

Figura 47 - Comparação de Hs entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,995$.




Fonte: Próprio autor.

Figura 48 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para $\rho_b = 0,995$.




Fonte: Próprio autor.

Figura 49 – Comparação de T_p entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,995$.




Fonte: Próprio autor.

Figura 50 – Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para $\rho_b = 0,995$.




Fonte: Próprio autor.

Figura 51 – Comparação de DIR entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,995$.




Fonte: Próprio autor.

Figura 52 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\rho_b = 0,995$.




Fonte: Próprio autor.

Figura 53 – Comparação de H_s entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,984$.




Fonte: Próprio autor.

Figura 54 – Correlação de H_s provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para $\rho_b = 0,984$.




Fonte: Próprio autor.

Figura 55 – Comparação de T_p entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,984$.




Fonte: Próprio autor.

Figura 56 – Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para $\rho_b = 0,984$.




Fonte: Próprio autor.

Figura 57 – Comparação de DIR entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,984$.



Fonte: Próprio autor.


Figura 58 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\rho_b = 0,984$.



Fonte: Próprio autor.


A seguir, acha-se de bom tom, realizar apresentação de um exemplo onde a rede desestabilizou-se, para que, quando *a posteriori*, houver a utilização do termo desestabilização, se possa ter uma ideia desse comportamento. Conforme dito anteriormente, quando da variação de outros parâmetros, a rede pode não encontrar uma solução razoável. Assim, fica exemplificado em termos gráficos, esse tipo de desempenho da rede ARTMAP_Fuzzy.

Figura 59 – Comparação de H_s entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,983$.




Fonte: Próprio autor.

Figura 60 – Correlação de H_s provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para $\rho_b = 0,983$.




Fonte: Próprio autor.

Figura 61 – Comparação de T_p entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,983$.




Fonte: Próprio autor.

Figura 62 – Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para $\rho_b = 0,983$.




Fonte: Próprio autor.

Figura 63 – Comparação de DIR entre ARTMAP-Fuzzy e SWAN na Costa para $\rho_b = 0,983$.



Fonte: Próprio autor.

Figura 64 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\rho_b = 0,983$.



Fonte: Próprio autor.

Foram apresentados anteriormente apenas os resultados referentes às variações principais, ou seja: a primeira tentativa (vigilância máxima); o gráfico referente ao melhor resultado encontrado em se tratando do erro; a última geração antes da rede se desestabilizar; e um exemplo da mesma já desestabilizada. Como verificado, quando do valor da vigilância $\rho_b = 0,983$, a rede não foi capaz de se auto organizar em várias classes de saída, e sim, somente foi ativado um neurônio vencedor para todos os padrões apresentados, o que não comunga com o esperado. Isso pode ser verificado, pois o valor do critério de vigilância da saída atingiu o valor da vigilância da rede em seu limiar, ou seja, todos os elementos, seja qual for a escolha que for feita pela rede, passará por essa vigilância, assim fica visível qualquer classe ativa, nesse caso sempre a mesma, passará por essa vigilância.

São apresentados os valores dos erros com suas respectivas tendências para alguns dos casos testados referentes à altura de onda significativa (H_s), períodos de pico (T_p) e direções de ondas (DIR). Salienta-se que, a apresentação das referidas linhas de tendência é apenas para visualização das mesmas, no sentido de se tentar verificar o aparecimento de um comportamento da rede relativamente aos erros calculados. Não se efetuou a análise desse comportamento ao longo desse estudo, mas esse seria um

trabalho a ser desenvolvido futuramente. A seguir, apresentam-se os erros principais calculados:

$$MAPE = \frac{1}{N} \sum_{n=1}^N \frac{100 \cdot |v^r(n) - v^c(n)|}{v^r(n)} \quad (24)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (v^r(n) - v^c(n))^2} \quad (25)$$

$$EV = v^r(n) - v^c(n) \quad (26)$$

Sendo: v^r = valor a ser comparado ou correlacionado;

v^c – valor obtido pela rede ARTMAP-Fuzzy


a) MAPE (Erro Médio Absoluto Percentual)

Tabela 12 - Erro Médio Absoluto Percentual em relação à variação do critério de vigilância de saída.

ρ_b	MAPE(%)		
	Hs	Tp	DIR
1,000	8,615	0,072	0,763
0,995	7,688	0,079	0,952
0,990	7,573	0,181	1,547
0,985	8,200	0,208	1,550
0,984	7,946	0,181	1,587


Fonte: Próprio autor.

Figura 65 - Erro Médio Absoluto Percentual em relação à variação do critério de vigilância de saída para Hs.




Fonte: Próprio autor.

Figura 66 - Erro Médio Absoluto Percentual em relação à variação do critério de vigilância de saída para Tp.



Fonte: Próprio autor.

Figura 67 - Erro Médio Absoluto Percentual em relação à variação do critério de vigilância de saída para DIR.



Fonte: Próprio autor.

Como verificado, o valor do menor erro médio absoluto se diferenciou em relação às alturas de onda (H_s), períodos de pico (T_p) e direções de ondas (DIR). Mas, como a maior variação fora referente à altura significativa, optou-se por escolher um valor intermediário, ou seja $\rho_b = 0,995$.


b) RMSE (Erro Médio Quadrático)

Tabela 13 - Erro Médio Quadrático em relação à variação do critério de vigilância de saída.

ρ_b	RMSE		
	H_s (m)	T_p (s)	DIR (°)
1,000	0,115	0,026	0,228
0,995	0,111	0,027	0,245
0,990	0,125	0,041	0,352
0,985	0,115	0,038	0,334
0,984	0,113	0,036	0,340


Fonte: Fonte: Próprio autor.

Figura 68 - Erro Médio Quadrático em relação à variação do critério de vigilância de saída para Hs.




Fonte: Próprio autor.

Figura 69 - Erro Médio Quadrático em relação à variação do critério de vigilância de saída para Tp.



Fonte: Próprio autor.

Figura 70 - Erro Médio Quadrático em relação à variação do critério de vigilância de saída para DIR.



Fonte: Próprio autor.

A partir da Tabela 13, o menor erro médio quadrático (RMSE) também apresentou diferenças em relação à Hs, Tp e DIR. Mas, ainda parece ser evidente a escolha de $\rho_b = 0,995$.


c) Média dos Erros Viés (μ)

Tabela 14 - Média dos Erros Viés em relação à variação do critério de vigilância de saída para Hs.

ρ_b	Média dos Erros Viés(μ)		
	Hs (m)	Tp (s)	DIR (°)
1,000	-0,1023	-0,0007	0,6780
0,995	-0,0849	-0,0015	1,2691
0,990	-0,1033	-0,0029	2,1518
0,985	-0,0312	0,0101	3,1620
0,984	-0,0313	0,0082	3,3351


Fonte: Próprio autor.

Figura 71 - Média dos Erros Viés em relação à variação do critério de vigilância de saída para Hs.




Fonte: Próprio autor.

Figura 72 - Média dos Erros Viés em relação à variação do critério de vigilância de saída para Tp.



Fonte: Próprio autor.

Figura 73 - Média dos Erros Viés em relação à variação do critério de vigilância de saída para DIR.



Fonte: Próprio autor.

O cálculo da média dos erros viés vem demonstrar um fator importante para o caso da aplicação futura no que tange a previsão de agitação marítima, ondas em lagos ou galgamento. Ou seja, ele é capaz de nos fornecer a relação entre superestimação ou subestimação da rede, através de uma análise do sinal do mesmo para o período testado. Em síntese, pode-se avaliar se a rede está superdimensionada ou subdimensionada em relação a outros modelos numéricos, modelos reduzidos ou medições experimentais. Mas isso será discutido em cada item referente posteriormente.


d) Desvio Padrão dos Erros Viés (σ)

Tabela 15 - Desvio Padrão dos Erros Viés em relação à variação do critério de vigilância de saída.

ρ_b	Desvio Padrão dos Erros Viés (σ)		
	Hs (m)	Tp (s)	DIR ($^{\circ}$)
1,000	0,127	0,092	3,705
0,995	0,133	0,096	3,868
0,990	0,181	0,146	5,431
0,985	0,155	0,121	4,654
0,984	0,153	0,117	4,664


Fonte: Próprio autor.

Figura 74 - Desvio Padrão dos Erros Viés em relação à variação do critério de vigilância de saída para Hs.




Fonte: Próprio autor.

Figura 75 - Desvio Padrão dos Erros Viés em relação à variação do critério de vigilância de saída para Tp.



Fonte: Próprio autor.

Figura 76 - Desvio Padrão dos Erros Viés em relação à variação do critério de vigilância de saída para DIR.




Fonte: Próprio autor.

Em se tratando do desvio padrão dos erros viés, pode-se observar que os valores mínimos dos erros foram encontrados para o mesmo critério de vigilância da saída, ou seja, para um $\rho_b = 1,0$ (valor máximo).


Apresenta-se o resumo em gráficos de barras dos erros de Hs, Tp e DIR na mesma visualização.

Figura 77 - MAPE em relação à variação do critério de vigilância de saída para Hs, Tp e Dir.




Fonte: Próprio autor.

Figura 78 - RMSE em relação à variação do critério de vigilância de saída para Hs, Tp e Dir.




Fonte: Próprio autor.

Figura 79 – Média dos Erros Viés em relação à variação do critério de vigilância de saída para Hs, Tp e Dir.



Fonte: Próprio autor.

Figura 80 - Desvio Padrão dos Erros Viés em relação à variação do critério de vigilância de saída para Hs, Tp e Dir.



Fonte: Próprio autor.

Conforme visto previamente, as redes ART são muito sensíveis a variações em seus parâmetros durante o treinamento. O parâmetro mais crítico é o parâmetro de vigilância (ρ_b) que controla a resolução do processo de classificação. Se ρ_b assume um valor baixo, a rede permite que padrões não muito semelhantes sejam agrupados na mesma categoria de reconhecimento, criando poucas classes, e se for atribuído um valor alto (muito próximo a um), pequenas variações nos padrões de entrada levarão à criação de novas classes.

Outro fator de interesse referente ao estudo efetuado, se refere ao fato da escolha do valor do parâmetro ρ_b para o menor erro relativo às alturas significativas Hs. Isso se dá, devido ao fato, por exemplo, da utilização posterior dos resultados fornecidos pela rede. Por exemplo: para o cálculo do galgamento, o fator de impacto de Hs é muito mais evidente do que os demais parâmetros Tp e DIR. Portanto, a escolha de um ρ_b que minimize os erros relativos a Hs se justifica a princípio.

No entanto, isso pode ser sugestivo, haja vista que na utilização da rede para estimativa de cálculo de estruturas, a média dos erros viés μ , se torna o fator com mais impacto, o que nos remete a tentativa de minimizar μ , e ficar a favor da segurança, trabalhando com o superdimensionamento da estrutura.

Outro caso a ser previsto, seria a tentativa de emissão de alerta em tempo real. Para esse caso, dever-se-ia observar tanto o valor para minimizar os erros referentes à

Hs, quanto para minimizar a média dos erros viés, já agora no sentido de se evitar emissão de alertas falsos. Isso, trabalhando com uma linha tênue entre superestimação e subestimação.

No entanto, para o estudo em questão, optou-se pela escolha de $\rho_b = 0,995$ olhando-se apenas para o caso das alturas significativas Hs.

6.1.2 Variação do parâmetro de escolha (α)

Apresenta-se uma análise da variação do parâmetro α (escolha da categoria). Mas *a priori*, é de bom alvitre lembrar o funcionamento da função de escolha em relação à variação de α . Conforme apresentado anteriormente, tem-se:

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (27)$$


A presença de α no denominador, tendo seu valor $\alpha > 0$, implicará na variação da amplitude dos valores da função de escolha. A mesma está diretamente ligada também ao valor do somatório do numerador e denominador. Ou seja, *a priori*, uma variação no valor de α implicará uma variação da amplitude da função escolha. Mas, a categoria vencedora a ser escolhida continuará restrita à de maior valor numérico, conforme teoria já apresentada.

A categoria é escolhida como sendo o nó j ativo, ou seja:

$$J = \arg \max T_j, j = 1, \dots, N$$


São apresentados abaixo alguns resultados quando da variação do parâmetro de escolha das categorias, considerando um valor de $\rho_b = 0,995$ previamente analisado, para alturas significativas (Hs), períodos de pico (Tp) e direções de onda (DIR).

Figura 81 - Correlação de H_s provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para $\alpha = 0,1$.




Fonte: Próprio autor.

Figura 82 – Correlação de T_p provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para $\alpha = 0,1$.




Fonte: Próprio autor.

Figura 83 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\alpha = 0,1$.




Fonte: Próprio autor.

Figura 84 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART} , e do modelo SWAN, Hs_{SWAN} , para $\alpha = 10$.




Fonte: Próprio autor.

Figura 85 – Correlação de T_p provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para $\alpha = 10$.




Fonte: Próprio autor.

Figura 86 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\alpha = 10$.




Fonte: Próprio autor.

Figura 87 – Correlação de H_s provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para $\alpha = 100$.




Fonte: Próprio autor.

Figura 88 – Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para $\alpha = 100$.



Fonte: Próprio autor.

Figura 89 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\alpha = 100$.



Fonte: Próprio autor.

Como se pode perceber, foram apresentados somente alguns resultados gráficos, pois a seguir, será apresentada a sensibilidade em relação aos erros. Mas, antes, achou-se de bom tom, fazer uma análise da variação da amplitude das funções de escolhas (T_j) (Tabela 16) de alguns resultados. Isso, para demonstrar em princípio um pouco do comportamento quando da variação de α .

Tabela 16 – Variação de T_j em relação à variação de α .

α	0,001	10	1000
T_j	0,7860	0,1814	0,0024
	0,8115	0,1873	0,0024
	0,7903	0,1824	0,0024
	0,7962	0,1827	0,0024
	0,7718	0,1782	0,0023
	0,7422	0,1713	0,0022
	0,7470	0,1725	0,0022
	0,7700	0,1763	0,0023
	0,7131	0,1646	0,0021
	0,7787	0,1798	0,0023

Fonte: Próprio autor.

Verifica-se que, para uma variação crescente no parâmetro α , ocorre diretamente uma diminuição na amplitude dos valores da função de escolha da categoria (T_{ajd}). Para

o valor de $\alpha = 1000$, a rede já não é capaz de escolher o maior valor, pois os mesmos encontram-se muito próximos, desestabilizando a mesma.

É apresentada uma análise de sensibilidade dos erros conforme executado anteriormente para o parâmetro de vigilância da saída.


a) MAPE (Erro Médio Absoluto Percentual)

Tabela 17 - Erro Médio Absoluto Percentual em relação à variação do parâmetro de escolha da categoria.

α	MAPE (%)		
	Hs	Tp	DIR
0,001	7,6885	0,0794	0,9569
0,01	7,6849	0,0794	0,9540
0,1	7,6879	0,0794	0,9522
1	7,8998	0,0664	0,9561
10	8,2885	0,0991	0,9637


Fonte: Próprio autor.

Figura 90 - Erro Médio Absoluto Percentual em relação à variação do parâmetro de escolha da categoria para Hs.




Fonte: Próprio autor.

Figura 91 - Erro Médio Absoluto Percentual em relação à variação do parâmetro de escolha da categoria para Tp.



Fonte: Próprio autor.

Figura 92 - Erro Médio Absoluto Percentual em relação à variação do parâmetro de escolha da categoria para DIR.



Fonte: Próprio autor.


b) RMSE (Erro Médio Quadrático)

Tabela 18 - Erro Médio Quadrático em relação à variação do parâmetro de escolha da categoria.

α	RMSE		
	Hs (m)	Tp (s)	DIR (o)
0,001	0,1106	0,0272	0,2460
0,01	0,1104	0,0272	0,2455
0,1	0,1105	0,0272	0,2453
1	0,1117	0,0254	0,2452
10	0,1164	0,0281	0,2507


Fonte: Próprio autor.

Figura 93 - Erro Médio Quadrático em relação à variação do parâmetro de escolha da categoria para Hs.




Fonte: Próprio autor.

Figura 94 - Erro Médio Quadrático em relação à variação do parâmetro de escolha da categoria para Tp.



Fonte: Próprio autor.

Figura 95 - Erro Médio Quadrático em relação à variação do parâmetro de escolha da categoria para DIR.



Fonte: Próprio autor.


c) Média dos Erros Viés (μ)

Tabela 19 - Média dos Erros Viés em relação à variação do parâmetro de escolha da categoria.

α	Média dos Erros Viés (μ)		
	Hs (m)	Tp (s)	DIR (o)
0,001	-0,0843	-0,0015	1,2849
0,01	-0,0843	-0,0015	1,2766
0,1	-0,0849	-0,0015	1,2691
1	-0,0884	-0,0013	1,3058
10	-0,0908	-0,0005	1,2764


Fonte: Próprio autor.

Figura 96 – Média dos Erros Viés em relação à variação do parâmetro de escolha da categoria para Hs.




Fonte: Próprio autor.

Figura 97 - Média dos Erros Viés em relação à variação do parâmetro de escolha da categoria para Tp.



Fonte: Próprio autor.

Figura 98 - Média dos Erros Viés em relação à variação do parâmetro de escolha da categoria para DIR.



Fonte: Próprio autor.


d) Desvio Padrão dos Erros Viés (σ)

Tabela 20 - Desvio Padrão dos Erros Viés em relação à variação do parâmetro de escolha da categoria.

α	Desvio Padrão dos Erros Viés (σ)		
	Hs (m)	Tp (s)	DIR (o)
0,001	0,1339	0,0960	3,8761
0,01	0,1337	0,0960	3,8697
0,1	0,1334	0,0960	3,8680
1	0,1315	0,0902	3,8556
10	0,1327	0,0941	3,9565


Fonte: Próprio autor.

Figura 99 – Desvio Padrão dos Erros Viés em relação à variação do parâmetro de escolha da categoria para Hs.




Fonte: Próprio autor.

Figura 100 - Desvio Padrão dos Erros Viés em relação à variação do parâmetro de escolha da categoria para Tp.



Fonte: Próprio autor.

Figura 101 - Desvio Padrão dos Erros Viés em relação à variação do parâmetro de escolha da categoria para DIR.



Fonte: Próprio autor.

Como verificado, pode-se observar que para o MAPE e RMSE a minimização dos erros parece ocorrer no intervalo $0,01 < \alpha < 1,0$. Já, analisando o desvio padrão dos erros viés, o melhor valor parece ser para a $\alpha = 1,0$. Lembrando que, foram escolhidos


valores intermediários *a posteriori*, mas não ocorreram variações significativas nos erros quando da previsão. Ou seja, para fins desse estudo de caso, optou-se então por um valor de $\alpha = 0,1$.

6.1.3 Variação da Taxa de Treinamento (β)

Como visto anteriormente, há dois tipos de treinamento para a rede neural: o aprendizado rápido e aprendizado lento. No aprendizado rápido, os pesos de conexão são ajustados para seus valores ótimos em poucos ciclos, geralmente em apenas um ciclo de treinamento. No aprendizado lento, os pesos são ajustados lentamente em vários ciclos de treinamento. Assim, o parâmetro que define o tipo de treinamento é o parâmetro β , tendo sua variação definida em $0 < \beta < 1$, sendo 1 para treinamento rápido e 0 para lento.


Passa-se então a uma apresentação da variação de β para o caso em questão (variação do tipo de treinamento). Serão apresentados apenas alguns casos, pois, para o treinamento rápido ($\beta = 1$) pode-se visualizar nas análises anteriores.

Figura 102 - Comparação de Hs entre ARTMAP-Fuzzy e SWAN na Costa para $\beta = 0,8$.



Fonte: Próprio autor.


Figura 103 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para $\beta = 0,8$.



Fonte: Próprio autor.


É apresentado nesse momento uma visualização completa (Hs, Tp e DIR) para um treinamento lento, ou seja $\beta = 0,3$, isso a título de exemplificação.

Figura 104 - Comparação de Hs entre ARTMAP-Fuzzy e SWAN na Costa para $\beta = 0,3$.




Fonte: Próprio autor.

Figura 105 - Correlação de H_s provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para $\beta = 0,3$.




Fonte: Próprio autor.

Figura 106 – Comparação de T_p entre ARTMAP-Fuzzy e SWAN na Costa para $\beta = 0,3$.




Fonte: Próprio autor.

Figura 107 – Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para $\beta = 0,3$.




Fonte: Próprio autor.

Figura 108 – Comparação de DIR entre ARTMAP-Fuzzy e SWAN na Costa para $\beta = 0,3$.



Fonte: Próprio autor.

Figura 109 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para $\beta = 0,3$.



Fonte: Próprio autor.

Como pode ser verificado, mesmo sabendo que um treinamento lento força os pesos a se adaptarem em mais ciclos, parece que para o caso em estudo, isso faz com que apareçam componentes nos vetores de atualização dos pesos que, em sendo aplicados a determinadas categorias ativas, resultam em saídas distantes das desejadas. Sabe-se que, conforme Lopes (2005), quando ocorre o treinamento rápido, $\beta = 1$, o hiperretângulo se expandirá apenas o suficiente para incluir o ponto representado pelo vetor de entrada. Entretanto, quando o treinamento for lento, o hiperretângulo irá se estender em direção ao ponto na proporção do tamanho de β .

Mas, para o caso em estudo, parece que o aumento dos hiperretângulos geram pesos adaptados que aplicados às categorias ativas não nos fornecem resultados satisfatórios. A rede ganha em capacidade de generalização, mas, como no caso em questão se mantém uma consistência elevada da base de dados, essa generalização tende a atrapalhar o processo, criando classes não desejadas para o caso.

É apresentada a tentativa de encontrar tendências em se variando o parâmetro β .


a) MAPE (Erro Médio Absoluto Percentual)

Tabela 21 - Erro Médio Absoluto Percentual em relação à variação da taxa de treinamento.

β	MAPE (%)		
	Hs	Tp	DIR
1	7,688	0,079	0,952
0,95	267,512	32,345	2,789
0,9	148,427	20,902	2,596
0,8	117,972	15,893	2,518
0,5	65,842	24,627	5,008
0,3	53,084	16,433	4,021


Fonte: Próprio autor.

Figura 110 – Erro Médio Absoluto Percentual em relação à variação da taxa de treinamento para Hs.




Fonte: Próprio autor.

Figura 111 – Erro Médio Absoluto Percentual em relação à variação da taxa de treinamento para Tp.



Fonte: Próprio autor.

Figura 112 – Erro Médio Absoluto Percentual em relação à variação da taxa de treinamento para DIR.




Fonte: Próprio autor.

b) RMSE (Erro Médio Quadrático)

Tabela 22 - Erro Médio Quadrático em relação à variação da taxa de treinamento.


β	RMSE		
	Hs (m)	Tp (s)	DIR (o)
1	0,111	0,027	0,245
0,95	4,075	1,678	0,826
0,9	2,939	1,245	0,803
0,8	2,418	1,028	0,691
0,5	0,859	0,963	1,157
0,3	0,890	0,708	1,044

Figura 113 – Erro Médio Quadrático em relação à variação da taxa de treinamento para Hs.




Fonte: Próprio autor.

Figura 114 - Erro Médio Quadrático em relação à variação da taxa de treinamento para Tp.



Fonte: Próprio autor.

Figura 115 - Erro Médio Quadrático em relação à variação da taxa de treinamento para DIR.



Fonte: Próprio autor.


c) Média dos Erros Viés (μ)

Tabela 23 - Média dos Erros Viés em relação à variação da taxa de treinamento.

β	Média dos Erros Viés (μ)		
	Hs (m)	Tp (s)	DIR (o)
1	-0,085	-0,001	1,269
0,95	-2,345	-2,750	-4,808
0,9	-1,166	-1,129	-3,245
0,8	-0,812	-0,854	-3,881
0,5	-0,637	-0,511	8,212
0,3	-0,432	0,104	7,924


Fonte: Próprio autor.

Figura 116 – Média dos Erros Viés em relação à variação da taxa de treinamento para Hs.




Fonte: Próprio autor.

Figura 117 - Média dos Erros Viés em relação à variação da taxa de treinamento para Tp.



Fonte: Próprio autor.

Figura 118 - Média dos Erros Viés em relação à variação da taxa de treinamento para DIR.



Fonte: Próprio autor.


d) Desvio Padrão dos Erros Viés (σ)

Tabela 24 - Desvio Padrão dos Erros Viés em relação à variação da taxa de treinamento.

β	Desvio Padrão (σ)		
	Hs (m)	Tp (s)	DIR (o)
1	0,133	0,096	3,868
0,95	2,879	3,838	12,243
0,9	2,368	3,125	12,187
0,8	1,924	2,504	10,448
0,5	0,795	2,825	17,591
0,3	1,042	2,149	15,609


Fonte: Próprio autor.

Figura 119 – Desvio Padrão dos Erros Viés em relação à variação da taxa de treinamento para Hs.




Fonte: Próprio autor.

Figura 120 - Desvio Padrão dos Erros Viés em relação à variação da taxa de treinamento para Tp.



Fonte: Próprio autor.

Figura 121 - Desvio Padrão dos Erros Viés em relação à variação da taxa de treinamento para DIR.



Fonte: Próprio autor.

6.1.4 Variação dos Parâmetros de Vigilância da Entrada (ρ_a) e de Entrada/Saída (ρ_{ab})

Em se tratando da variação do parâmetro de vigilância da entrada (ρ_a) e do mapeamento entre entrada e saída (ρ_{ab}), algumas considerações podem ser efetuadas:


- a) Quando do mapeamento entre as classes ativas na entrada e saída, como optou-se por um critério elevado no parâmetro de vigilância da saída (ρ_b), muitas classes foram criadas, e isso diretamente influenciou na vigilância ρ_{ab} . Ou seja, qualquer variação, nesse caso de estudo, em ρ_{ab} , não afeta de maneira acentuada o treinamento da rede. Assim, não há, em princípio, a necessidade de tentar calibrar o parâmetro em questão.
- b) Quando da variação do critério de vigilância da formação de classes na entrada (ρ_a), conforme explícito na teoria, iniciava-se com um determinado valor de ρ_a e incrementava-se o mesmo à medida em que os ciclos ocorriam. Assim, a variação do mesmo ocorreria no decorrer do treinamento da rede, não sendo necessária uma análise *off-line* de sua sensibilidade. Além do mais, para fins de treinamento, optou-se em iniciar, em todos os casos, a vigilância de entrada com um valor já significativo, ou seja, $\rho_a = 0,90$. O que, ao término de cada ciclo já se incrementava ($\epsilon = 0,001$), quando necessário, e retornava ao valor da vigilância inicial, até um valor máximo $\rho_a = 1,0$ ou próximo do mesmo.

6.2 Diagnóstico da ARTMAP-Fuzzy para Agitação Marítima fora do Porto (comparação com o modelo numérico SWAN)

Para diagnóstico do comportamento da agitação marítima ao longo do tempo, utilizou-se como valores de entrada altura de onda ao largo (H_s), período de pico da onda ao largo (T_p) e direção de ataque da onda ao largo (DIR). Os valores que foram utilizados para saída são respectivamente altura, período e direção fora do porto. Treinou-se a rede com dados no período compreendido entre 27/01/2005 a 31/12/2010, com aproximadamente 14.200 valores válidos (desprezados os períodos em que a boia ao largo não apresentou medições). O tempo total de treinamento foi de aproximadamente 56.335 segundos, ou seja, da ordem de 15 horas e 40 minutos. Sendo

assim, procedeu-se ao diagnóstico da rede (Figura 122), para uma amostra desconhecida representada em sua amplitude de 30% do total de dados treinados, com os seguintes parâmetros de treino da rede: $\beta = 1,0$ (taxa de treino rápida), $\alpha = 0,1$ (parâmetro de escolha da categoria), $\rho_a = 0,9$ (parâmetro de monitorização inicial do módulo ART_a), $\rho_{ab} = 0,95$ (parâmetro de monitorização entrada/saída), $\rho_b = 0,995$ (parâmetro de monitorização de ART_b), $\varepsilon = 0,001$ (incremento na monitorização de ART_a). Fora apresentado o diagnóstico apenas para os valores das alturas significativas, para evitar a repetição de resultados.

Figura 122 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART}, e do modelo SWAN, Hs_{SWAN}, para 30% do total de treinamento.



Fonte: Próprio autor.

6.3 Previsão da ARTMAP-Fuzzy para Agitação Marítima fora do Porto


Para previsão do comportamento da agitação marítima ao longo do tempo, utilizaram-se os mesmos valores de entrada e saída apresentados anteriormente e o mesmo período de treinamento quando do diagnóstico. Efetuou-se a previsão para alguns meses aleatórios, meses esses compreendidos na primavera, verão, outono e inverno. Com esse mesmo treinamento, efetuou-se a previsão também para quatro semanas aleatórias. Ao final, utilizando um novo período adquirido (mais recente),

também fora executada a previsão para uma parte do ano de 2012 compreendida entre 02/01/2012 e 30/06/2012.

São apresentados os resultados referentes ao caso de estudo comparados com o modelo numérico SWAN fora do Porto.


a) Ano de 2011 Completo

Figura 123 – Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Ano: 2011.




Fonte: Próprio autor.

Figura 124 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para o Ano : 2011.




Fonte: Próprio autor.

Figura 125 - Comparação ARTMAP-Fuzzy com os dados de T_p do SWAN na Costa – Ano: 2011.




Fonte: Próprio autor.

Figura 126 – Correlação de T_p provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para o Ano : 2011.




Fonte: Próprio autor.

Figura 127 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Ano: 2011.



Fonte: Próprio autor.


Figura 128 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para o Ano : 2011.



Fonte: Próprio autor.


b) Mês compreendido na Primavera de 2011 (20/04 a 20/05)

Figura 129 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Primavera de 2011 (20/04 a 20/05).




Fonte: Próprio autor.

Figura 130 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para a Primavera de 2011 (20/04 a 20/05).




Fonte: Próprio autor.

Figura 131 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – Primavera de 2011 (20/04 a 20/05).




Fonte: Próprio autor.

Figura 132 – Correlação de T_p provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para a Primavera de 2011 (20/04 a 20/05).




Fonte: Próprio autor.

Figura 133 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Primavera de 2011 (20/04 a 20/05).



Fonte: Próprio autor.


Figura 134 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para a Primavera de 2011 (20/04 a 20/05).



Fonte: Próprio autor.


c) Mês compreendido no Verão de 2011 (20/07 a 20/08)

Figura 135 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Verão de 2011 (20/07 a 20/08).




Fonte: Próprio autor.

Figura 136 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para o Verão de 2011 (20/07 a 20/08).




Fonte: Próprio autor.

Figura 137 - Comparação ARTMAP-Fuzzy com os dados de T_p do SWAN na Costa – Verão de 2011 (20/07 a 20/08).




Fonte: Próprio autor.

Figura 138 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para o Verão de 2011 (20/07 a 20/08).




Fonte: Próprio autor.

Figura 139 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Verão de 2011 (20/07 a 20/08).



Fonte: Próprio autor.


Figura 140 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para o Verão de 2011 (20/07 a 20/08).



Fonte: Próprio autor.


d) Mês compreendido no Outono de 2011 (20/10 a 20/11)

Figura 141 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Outono de 2011 (20/10 a 20/11).




Fonte: Próprio autor.

Figura 142 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para o Outono de 2011 (20/10 a 20/11).




Fonte: Próprio autor.

Figura 143 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – Outono de 2011 (20/10 a 20/11).




Fonte: Próprio autor.

Figura 144 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para o Outono de 2011 (20/10 a 20/11).




Fonte: Próprio autor.

Figura 145 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Outono de 2011 (20/10 a 20/11).



Fonte: Próprio autor.


Figura 146 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para o Outono de 2011 (20/10 a 20/11).



Fonte: Próprio autor.


e) Mês compreendido no Inverno de 2011 (20/01 a 20/02)

Figura 147 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Inverno de 2011 (20/01 a 20/02).




Fonte: Próprio autor.

Figura 148 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, H_{sART} , e do modelo SWAN, H_{sSWAN} , para o Inverno de 2011 (20/01 a 20/02).




Fonte: Próprio autor.

Figura 149 - Comparação ARTMAP-Fuzzy com os dados de Tp do SWAN na Costa – Inverno de 2011 (20/01 a 20/02).




Fonte: Próprio autor.

Figura 150 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para o Inverno de 2011 (20/01 a 20/02).




Fonte: Próprio autor.

Figura 151 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Inverno de 2011 (20/01 a 20/02).



Fonte: Próprio autor.

Figura 152 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para o Inverno de 2011 (20/01 a 20/02).




Fonte: Próprio autor.

Como pode ser verificado através dos gráficos anteriores, relativamente aos meses compreendidos nas estações: primavera, verão, outono e inverno; a rede ARTMAP-Fuzzy, parece se comportar de maneira satisfatória no que tange à previsão do comportamento da agitação marítima em relação aos valores fornecidos pelo modelo numérico SWAN. As divergências entre a rede e o modelo serão apresentadas e analisadas a *posteriori*.

A partir do item que se segue, far-se-á um refinamento do intervalo de previsão; agora, trabalhando-se com semanas escolhidas de forma aleatória, para verificação do comportamento da precisão da rede comparada ao modelo.


f) 1ª Semana aleatória (10/05/2011 a 16/05/2011)

Figura 153 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – 1ª Semana aleatória (10/05/2011 a 16/05/2011).




Fonte: Próprio autor.

Figura 154 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para a 1ª Semana aleatória (10/05/2011 a 16/05/2011).




Fonte: Próprio autor.

Figura 155 - Comparação ARTMAP-Fuzzy com os dados de T_p do SWAN na Costa – 1ª Semana aleatória (10/05/2011 a 16/05/2011).




Fonte: Próprio autor.

Figura 156 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para a 1ª Semana aleatória (10/05/2011 a 16/05/2011).




Fonte: Próprio autor.

Figura 157 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – 1ª Semana aleatória (10/05/2011 a 16/05/2011).



Fonte: Próprio autor.


Figura 158 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para a 1ª Semana aleatória (10/05/2011 a 16/05/2011).



Fonte: Próprio autor.


g) 2ª Semana aleatória (10/11/2011 a 16/11/2011)

Figura 159 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – 2ª Semana aleatória (10/11/2011 a 16/11/2011).




Fonte: Próprio autor.

Figura 160 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para a 2ª Semana aleatória (10/11/2011 a 16/11/2011).




Fonte: Próprio autor.

Figura 161 - Comparação ARTMAP-Fuzzy com os dados de T_p do SWAN na Costa – 2ª Semana aleatória (10/11/2011 a 16/11/2011).



Fonte: Próprio autor.

Figura 162 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para a 2ª Semana aleatória (10/11/2011 a 16/11/2011).




Fonte: Próprio autor.

Figura 163 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – 2ª Semana aleatória (10/11/2011 a 16/11/2011).



Fonte: Próprio autor.


Figura 164 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para a 2ª Semana aleatória (10/11/2011 a 16/11/2011).



Fonte: Próprio autor.


h) 3ª Semana aleatória (10/10/2011 a 16/10/2011)

Figura 165 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – 3ª Semana aleatória (10/10/2011 a 16/10/2011).




Fonte: Próprio autor.

Figura 166 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para a 3ª Semana aleatória (10/10/2011 a 16/10/2011).




Fonte: Próprio autor.

Figura 167 - Comparação ARTMAP-Fuzzy com os dados de T_p do SWAN na Costa – 3ª Semana aleatória (10/10/2011 a 16/10/2011).




Fonte: Próprio autor.

Figura 168 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para a 3ª Semana aleatória (10/10/2011 a 16/10/2011).




Fonte: Próprio autor.

Figura 169 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – 3ª Semana aleatória (10/10/2011 a 16/10/2011).



Fonte: Próprio autor.


Figura 170 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para a 3ª Semana aleatória (10/10/2011 a 16/10/2011).



Fonte: Próprio autor.


i) 4ª Semana aleatória (10/08/2011 a 16/08/2011)

Figura 171 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – 4ª Semana aleatória (10/08/2011 a 16/08/2011).




Fonte: Próprio autor.

Figura 172 - Correlação de H_s provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para a 4ª Semana aleatória (10/08/2011 a 16/08/2011).




Fonte: Próprio autor.

Figura 173 - Comparação ARTMAP-Fuzzy com os dados de T_p do SWAN na Costa – 4ª Semana aleatória (10/08/2011 a 16/08/2011).




Fonte: Próprio autor.

Figura 174 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, $T_{p_{ART}}$, e do modelo SWAN, $T_{p_{SWAN}}$, para a 4ª Semana aleatória (10/08/2011 a 16/08/2011).




Fonte: Próprio autor.

Figura 175 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – 4ª Semana aleatória (10/08/2011 a 16/08/2011).



Fonte: Próprio autor.

Figura 176 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} , para a 4ª Semana aleatória (10/08/2011 a 16/08/2011).




Fonte: Próprio autor.

Como pôde ser verificada, para o caso das semanas previstas, com o refinamento do intervalo de previsão, a precisão dos valores obtidos pela rede, quando comparados ao modelo numérico, diminui razoavelmente, mas, de maneira aceitável. Os erros relativos à comparação com o modelo SWAN, serão apresentados e discutidos subsequentemente.

A seguir, efetuou-se a previsão de uma parte do ano de 2012, o que se tinha de posse dos dados para esse período.


j) Ano de 2012 parcial (02/01 a 30/06)

Figura 177 - Comparação ARTMAP-Fuzzy com os dados de Hs do SWAN na Costa – Ano: 2012 (parcial).




Fonte: Próprio autor.

Figura 178 - Correlação de H_s provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo SWAN, $H_{s_{SWAN}}$, para o Ano : 2012 (parcial).




Fonte: Próprio autor.

Figura 179 - Comparação ARTMAP-Fuzzy com os dados de T_p do SWAN na Costa – Ano: 2012 (parcial).




Fonte: Próprio autor.

Figura 180 - Correlação de T_p provenientes da rede ARTMAP-Fuzzy, T_{pART} , e do modelo SWAN, T_{pSWAN} , para o Ano : 2012 (parcial).




Fonte: Próprio autor.

Figura 181 - Comparação ARTMAP-Fuzzy com os dados de DIR do SWAN na Costa – Ano: 2012 (parcial).



Fonte: Próprio autor.

Figura 182 - Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo SWAN, DIR_{SWAN} para o Ano : 2012 (parcial).



Fonte: Próprio autor.

São apresentadas tabelas, contendo para cada caso, os valores calculados do erro médio percentual absoluto (MAPE), do erro médio quadrático (RMSE), da média (μ) e do desvio padrão (σ) dos erros viés (EV) para Hs, Tp e DIR, respetivamente.

Tabela 25 – Erros calculados para Hs.

PERÍODO	MAPE (%) Hs	RMSE Hs (m)	EV	
			μ Hs (m)	σ Hs (m)
2011 primavera verão outono inverno	3,720	0,048	0,011	0,050
	20,600	0,218	0,226	0,097
	19,359	0,189	0,176	0,052
	3,317	0,051	0,006	0,071
	15,085	0,179	0,200	0,089
1ª Semana	9,780	0,100	0,091	0,045
2ª Semana	7,108	0,122	-0,058	0,182
3ª Semana	20,564	0,172	0,142	0,034
4ª Semana	9,175	0,096	0,076	0,042
2012	22,032	0,235	0,241	0,090

Fonte: Próprio autor.

Tabela 26 - Erros calculados para Tp.

PERIODO	MAPE (%) Tp	RMSE Tp (s)	EV	
			μ Tp (s)	σ Tp (s)
2011	0,017	0,009	0,000	0,023
primavera	2,367	0,098	-0,079	0,309
verão	5,928	0,221	-0,435	0,375
outono	0,213	0,034	0,015	0,090
inverno	0,172	0,040	-0,014	0,113
1ª Semana	4,394	0,148	-0,420	0,223
2ª Semana	3,507	0,143	-0,338	0,323
3ª Semana	3,624	0,152	-0,257	0,448
4ª Semana	5,697	0,237	-0,363	0,453
2012	0,954	0,125	-0,059	0,319

Fonte: Próprio autor.

Tabela 27 - Erros calculados para DIR.

PERIODO	MAPE (%) DIR	RMSE DIR (°)	EV	
			μ DIR (°)	σ DIR (°)
2011	0,957	0,201	2,553	2,263
primavera	1,898	0,346	5,570	2,071
verão	2,675	0,529	7,873	4,492
outono	1,786	0,359	3,498	4,854
inverno	1,276	0,247	3,043	2,850
1ª Semana	3,022	0,557	8,994	3,403
2ª Semana	2,977	0,539	6,457	6,740
3ª Semana	3,046	0,566	8,814	3,884
4ª Semana	2,903	0,596	8,488	5,685
2012	1,044	0,252	2,346	3,558

Fonte: Próprio autor.

Em se tratando dos erros (divergência do modelo numérico SWAN no caso), pode-se verificar que:

i) para o caso das alturas significativas (Hs):

- os valores dos erros percentuais médios absolutos (MAPE) ficaram compreendidos entre 3% a 22%, o que reflete uma adaptação relativamente

aceitável da previsão. No entanto, isso poderá ser melhorado, em tese, por uma abrangência mais quantitativa dos dados de treinamento. Mas, para fins de observações iniciais, a rede responde de maneira plausível;

- os valores dos erros médios quadráticos (RMSE) ficaram compreendidos entre 4,8 cm a 23,5 cm que, para uma altura de onda significativa da grandeza de 1 a 5 metros, por exemplo, é bem aceitável;
- para o caso da média e desvio padrão dos erros viés, também, verificou-se que os erros se mantiveram em seu valor máximo, na casa de 22 cm, o que, conforme avaliado anteriormente, é de certa forma aceitável para uma primeira observação. O que ficou evidenciado neste caso, é que há uma ocorrência de uma, e apenas uma, média com valor negativo, mostrando que, em sua grande maioria, a rede tende a subdimensionar os valores de H_s em relação aos encontrados pelo modelo numérico SWAN.

ii) para o caso dos períodos de pico (T_p):

- no caso do MAPE máximo, o mesmo se refere a um valor de 6 %, já para o caso do valor de RMSE máximo, o mesmo fica na faixa de 0,23 s; isso em se tratando do valor de períodos de pico (T_p), é relativamente baixo para o problema em questão. Ficou evidente também, que, para todos os casos, a previsão dos períodos de pico se mostrou mais próximos aos calculados pelo modelo SWAN, isso devido à consistência no intervalo de dados de treinamento referentes aos períodos e sua pouca variação temporal ao longo dos anos;
- já, para o caso das médias, verificou-se que neste caso, a rede parece superestimar a maioria dos resultados, contrariando o previsto quando das alturas significativas.

iii) para o caso das direções das ondas (DIR):

- há de se notar que os valores para todos os erros estão muito abaixo dos aceitáveis;
- no entanto, cabe ressaltar que a visualização gráfica apresentada anteriormente quando se trata da análise da direção das ondas, parece não corresponder aos

baixos erros calculados, mas isso se reflete devido ao fato do eixo vertical estar em *zoom*. Isso para uma melhor visualização, no entanto, pode se ter uma falsa perspectiva de discrepância dos valores fornecidos pela rede ARTMAP-Fuzzy e os valores fornecidos pelo modelo numérico SWAN.

6.4 Previsão da ARTMAP-Fuzzy para Agitação Marítima dentro do Porto


Em se tratando da previsão da rede na análise de agitação marítima em pontos dentro do Porto de Sines, utilizou-se como valores de entrada e saída os mesmos quando do estudo no item anterior. Para o treinamento da rede foram escolhidos dados no período compreendido entre 27/01/2005 a 31/12/2008, com aproximadamente 9170 valores válidos (desprezados os períodos em que a boia ao largo não apresentou medições). O tempo total de treinamento variou para cada ponto estudado, tendo seu valor mínimo aproximado de 1170 s (19,5 minutos) e máximo de 2429 s (40,5 minutos).

Os seguintes parâmetros de treino adotados (conforme análise de sensibilidade prévia, efetuada quando da análise fora do porto): $\beta = 1,0$ (taxa de treino rápida), $\alpha = 0,1$ (parâmetro de escolha da categoria), $\rho_a = 0,9$ (parâmetro de monitorização inicial do módulo ART_a), $\rho_{ab} = 0,95$ (parâmetro de monitorização entrada/saída), $\rho_b = 0,995$ (parâmetro de monitorização de ART_b), $\varepsilon = 0,001$ (incremento na monitorização de ART_a).

Efetuuou-se a previsão para o ano de 2009 completo para todos os pontos. A seguir realizou-se a previsão para um período de aproximadamente um mês, período esse que contempla o dia de medição em campo no ano de 2009. O mesmo foi efetuado para o ano de 2011. Serão apresentados os resultados referentes à altura significativa (Hs) e direção das ondas (DIR) de todos os pontos. Já para períodos (Tp), como a rede diverge muito pouco do previsto pelo modelo DREAMS, será apresentado somente um a título de exemplo uma visualização.


a) Ponto A – Ano de 2009 – Completo

Figura 183 - Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto A – Ano: 2009.




Fonte: Próprio autor.

Figura 184 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo DREAMS, $H_{s_{DREAMS}}$, no Ponto A - Ano: 2009.




Fonte: Próprio autor.

Figura 185 – Comparação ARTMAP-Fuzzy com os dados de Tp do DREAMS no Ponto A – Ano: 2009.




Fonte: Próprio autor.

Figura 186 – Correlação de Tp provenientes da rede ARTMAP-Fuzzy, Tp_{ART} , e do modelo DREAMS, Tp_{DREAMS} , no Ponto A - Ano: 2009.




Fonte: Próprio autor.

Figura 187 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto A – Ano: 2009.



Fonte: Próprio autor.


Figura 188 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto A - Ano: 2009.



Fonte: Próprio autor.


b) Ponto B – Ano de 2009 – Completo

Figura 189 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto B – Ano: 2009.




Fonte: Próprio autor.

Figura 190 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo DREAMS, $H_{s_{DREAMS}}$, no Ponto B - Ano: 2009.




Fonte: Próprio autor.

Figura 191 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto B – Ano: 2009.



Fonte: Próprio autor.


Figura 192 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto B - Ano: 2009.



Fonte: Próprio autor.


c) Ponto C – Ano de 2009 – Completo

Figura 193 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto C – Ano: 2009.




Fonte: Próprio autor.

Figura 194 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo DREAMS, $H_{s_{DREAMS}}$, no Ponto C - Ano: 2009.




Fonte: Próprio autor.

Figura 195 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto C – Ano: 2009.



Fonte: Próprio autor.


Figura 196 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto C - Ano: 2009.



Fonte: Próprio autor.


d) Ponto D – Ano de 2009 – Completo

Figura 197 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto D – Ano: 2009.




Fonte: Próprio autor.

Figura 198 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo DREAMS, $H_{s_{DREAMS}}$, no Ponto D - Ano: 2009.




Fonte: Próprio autor.

Figura 199 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto D – Ano: 2009.



Fonte: Próprio autor.


Figura 200 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto D - Ano: 2009.



Fonte: Próprio autor.


e) Ponto E – Ano de 2009 – Completo

Figura 201 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto E – Ano: 2009.




Fonte: Próprio autor.

Figura 202 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo DREAMS, $H_{s_{DREAMS}}$, no Ponto E - Ano: 2009.




Fonte: Próprio autor.

Figura 203 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto E – Ano: 2009.



Fonte: Próprio autor.


Figura 204 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto E - Ano: 2009.



Fonte: Próprio autor.


f) Ponto F – Ano de 2009 – Completo

Figura 205 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto F – Ano: 2009.




Fonte: Próprio autor.

Figura 206 – Correlação de H_s provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo DREAMS, $H_{s_{DREAMS}}$, no Ponto F - Ano: 2009.




Fonte: Próprio autor.

Figura 207 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto F – Ano: 2009.



Fonte: Próprio autor.


Figura 208 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto F - Ano: 2009.



Fonte: Próprio autor.


g) Ponto G – Ano de 2009 – Completo

Figura 209 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto G – Ano: 2009.




Fonte: Próprio autor.

Figura 210 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo DREAMS, $H_{s_{DREAMS}}$, no Ponto G - Ano: 2009.




Fonte: Próprio autor.

Figura 211 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto G – Ano: 2009.



Fonte: Próprio autor.

Figura 212 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto G - Ano: 2009.




Fonte: Próprio autor.

Conforme apresentado nos gráficos anteriores, pôde-se verificar que, para os pontos em análise (A, B, C, D, E, F e G) dentro do porto, a rede ARTMAP-Fuzzy,

acompanhou o perfil apresentado pelo modelo numérico DREAMS. Uma análise mais completa se faz necessária, no entanto, a mesma será efetuada quando da apresentação dos erros. Sendo assim, apresenta-se agora, os gráficos que compreendem os pontos de medição nos seus respectivos meses e anos.


h) Ponto E – Mês da Medição em campo em 2009

Figura 213 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto E – Ano: 2009 (parcial).




Fonte: Próprio autor.

Figura 214 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo DREAMS, $H_{s_{DREAMS}}$, no Ponto E - Ano: 2009 (parcial).




Fonte: Próprio autor.

Figura 215 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto E – Ano: 2009 (parcial).



Fonte: Próprio autor.


Figura 216 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto E - Ano: 2009 (parcial).



Fonte: Próprio autor.


i) Ponto G – Mês da Medição em campo em 2009

Figura 217 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto G – Ano: 2009 (parcial).




Fonte: Próprio autor.

Figura 218 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo DREAMS, $H_{s_{DREAMS}}$, no Ponto G - Ano: 2009 (parcial).




Fonte: Próprio autor.

Figura 219 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto G – Ano: 2009 (parcial).



Fonte: Próprio autor.


Figura 220 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto G - Ano: 2009 (parcial).



Fonte: Próprio autor.


j) Ponto G – Mês da Medição em campo em 2011

Figura 221 – Comparação ARTMAP-Fuzzy com os dados de Hs do DREAMS no Ponto G – Ano: 2011 (parcial).




Fonte: Próprio autor.

Figura 222 – Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do modelo DREAMS, $H_{s_{DREAMS}}$, no Ponto G - Ano: 2011.




Fonte: Próprio autor.

Figura 223 – Comparação ARTMAP-Fuzzy com os dados de DIR do DREAMS no Ponto G – Ano: 2011 (parcial).



Fonte: Próprio autor.

Figura 224 – Correlação de DIR provenientes da rede ARTMAP-Fuzzy, DIR_{ART} , e do modelo DREAMS, DIR_{DREAMS} , no Ponto G - Ano: 2011 (parcial).



Fonte: Próprio autor.

A seguir são apresentadas tabelas, contendo para cada caso, os valores calculados do erro médio percentual absoluto (MAPE), do erro médio quadrático (RMSE), da média (μ) e do desvio padrão (σ) dos erros viés (EV) para HS, TP e DIR, respectivamente.

Tabela 28 – Erros calculados para Hs.

PONTOS	MAPE (%) Hs	RMSE Hs (m)	EV	
			μ Hs (m)	σ Hs (m)
PONTO A	19,013	0,234	0,287	0,182
PONTO B	15,518	0,077	0,016	0,059
PONTO C	39,878	0,183	0,087	0,075
PONDO D	29,103	0,183	0,111	0,137
PONTO E	27,233	0,143	0,068	0,079
PONTO F	21,760	0,053	0,010	0,024
PONTO G	14,176	0,128	0,048	0,142
PONTO E (MÊS/2009)	52,806	0,323	0,194	0,112

PONTO G (MÊS/2009)	51,317	0,416	0,326	0,205
PONTO G (MÊS/2011)	48,089	0,372	0,277	0,132

Fonte: Próprio autor.

Tabela 29 - Erros calculados para Tp.

PONTOS	EV			
	MAPE (%) Tp	RMSE Tp (s)	μ Tp (s)	σ Tp (s)
PONTO A	0,046	0,023	-0,005	0,080
PONTO B	0,043	0,022	-0,005	0,078
PONTO C	0,048	0,022	-0,004	0,080
PONDO D	0,034	0,019	-0,004	0,070
PONTO E	0,027	0,015	-0,002	0,050
PONTO F	0,047	0,022	-0,005	0,076
PONTO G	0,049	0,023	-0,004	0,080
PONTO E (MÊS/2009)	0,536	0,083	-0,046	0,241
PONTO G (MÊS/2009)	0,536	0,083	-0,046	0,241
PONTO G (MÊS/2011)	0,069	0,024	-0,008	0,081

Fonte: Próprio autor.

Tabela 30 - Erros calculados para DIR.

PONTOS	EV			
	MAPE (%) DIR	RMSE DIR (°)	μ DIR (°)	σ DIR (°)
PONTO A	0,849	0,209	1,757	3,002
PONTO B	8,780	1,038	11,886	2,972
PONTO C	1,197	0,380	2,994	6,824
PONDO D	2,748	0,438	5,844	2,654

PONTO E	4,180	0,629	9,221	1,549
PONTO F	7,826	0,823	7,963	2,488
PONTO G	2,191	0,658	1,750	7,638
PONTO E (MÊS/2009)	4,898	0,784	10,630	4,578
PONTO G (MÊS/2009)	13,654	2,014	25,653	12,098
PONTO G (MÊS/2011)	7,689	1,392	-1,520	18,531

Fonte: Próprio autor.

Como se pôde verificar, os erros relativos à previsão dentro porto são, de certa forma, bem mais expressivos do que no interior do mesmo. Isso pode ser evidenciado devido ao fato do surgimento de fenômenos como difração, reflexão e refração das ondas, o que dificulta a tentativa da rede em conseguir identificar o comportamento do fenômeno. Mas, por outro lado, a rede deveria ser capaz de absorver esses fenômenos em questão em seu processo de aprendizagem, o que nos remete a avaliar a falta da análise de sensibilidade dos parâmetros dentro do porto. A princípio, fora considerados os parâmetros ótimos com *input* da rede, os mesmos quando da análise fora do porto. Mas, isso parece que, em tese, não resultou de maneira satisfatória na execução do treinamento da rede.


No entanto, esses erros são referentes ao confronto entre os resultados fornecidos pelo modelo DREAMS e a rede. Sendo assim, em posse dos dados de medição em campo conforme Tabela 4, pode-se realizar uma análise do comportamento do modelo e da rede.

Cabe salientar que, exatamente nos dias 25/02/2009 e 26/02/2009, a boia-ondógrafo não efetuou a aquisição dos dados, resultando em uma lacuna na previsão do modelo e da rede para esse período.

Para sobressair essa problemática, optou-se pela utilização do modelo WAVEWATCH III™ (TOLMAN 1997, 1999a, 2009), para previsão dos dados faltantes e logo após, lançou-se na matriz de transferência do SWAN e DREAMS.


Apresenta-se novamente os gráficos que compreendem o período em questão, agora, adicionando os resultados das medições através dos sensores de pressão.

Figura 225 - Comparação ARTMAP-Fuzzy, DREAMS e MiniTroll, para Hs no Ponto E – 26/02/2009.




Fonte: Próprio autor.

Figura 226 - Comparação ARTMAP-Fuzzy, DREAMS e LevelTroll, para Hs no Ponto G – 26/02/2009.



Fonte: Próprio autor.

Figura 227 - Comparação ARTMAP-Fuzzy, DREAMS e Infinity, para Hs no Ponto G – 25/02/20011.



Fonte: Próprio autor.

Pode-se verificar que: para todos os casos, os resultados referentes à medição em campo encontram-se mais próximos da previsão do modelo DREAMS.

No entanto, há de se destacar que, como a falha na aquisição de dados, não há a garantia do comportamento da agitação marítima nesse intervalo, se tratando assim, apenas de uma avaliação, notadamente simplória. Mas, para efeitos de uma observação prévia, a rede parece estar subdimensionada em relação ao modelo DREAMS e às medições com as sondas, o que, seria facilmente corrigido se houvesse a necessidade de melhorar o sistema preditivo, através de um fator de correção calculado para o caso.

6.5 Aplicação da Rede ARTMAP-Fuzzy ao Estudo do Galgamento no Porto de Sines

Apresenta-se os resultados quando da aplicabilidade da rede neural artificial do tipo ARTMAP com lógica Fuzzy ao estudo do galgamento num trecho do molhe Oeste do Porto de Sines. Os resultados produzidos pela ferramenta foram comparados com dados de galgamento obtidos em ensaios em modelo físico bidimensional realizados no LNEC (2008), para o perfil em estudo. Os resultados da nova ferramenta foram ainda comparados com os provenientes de duas ferramentas neuronais do tipo *multi-layer feed-*

forward: NN_OVERTOPPING2 (COEVELD *et al.*, 2005) e OVERTOPPING (VERHAEGHE, 2005).

Com base nos itens anteriores, os valores dos parâmetros de treino da rede adotados foram: $\beta = 1,0$ (taxa de treino rápida), $\alpha = 0,1$ (parâmetro de escolha da categoria), $\rho_a = 0,1$ (parâmetro de monitorização inicial do módulo ART_a), $\rho_{ab} = 0,95$ (parâmetro de monitorização do módulo F^{ab}), $\rho_b = 0,99$ (parâmetro de monitorização de ART_b), $\varepsilon = 0,001$ (incremento na monitorização de ART_a).


Algumas alterações nos valores dos parâmetros foram realizadas, mas isso, sem uma análise de sensibilidade completa, apenas verificou-se que para esses valores a rede se comportou de maneira melhor.

6.6 Diagnóstico da ARTMAP-Fuzzy para o Estudo do Galgamento no Porto de Sines

Para efeitos de diagnóstico (teste) da rede, foram escolhidos cerca de 3.000 casos da base de dados CLASH, entre os quase 10.500 utilizados para treino, ou seja, cerca de 30% dos valores conhecidos da rede. Isto é necessário para se obter um perfil de comportamento da rede ARTMAP-Fuzzy para os casos da base de dados. Na Figura 228 apresenta-se a comparação dos galgamentos estimados pela rede ARTMAP-Fuzzy, q_{ART} , e extraídos da base de dados do projeto CLASH, q_{CLASH} , para esses 3.000 testes. Pode observar-se que, mesmo utilizando para parâmetros de treino da rede valores ainda não otimizados, em geral, a rede apresenta estimativas do caudal médio de galgamento muito próximas dos valores constantes da base de dados CLASH (coeficiente de correlação, $R^2=1,0$), sobretudo para caudais $q_{CLASH} > 0,00005 \text{ m}^3/\text{s}/\text{m}$.


Subsequentemente, para completar o diagnóstico da rede para casos já conhecidos da mesma, achou-se importante escolher 18 configurações distintas das estruturas marítimas contempladas na base de dados CLASH (Figura 229), para visualizar, mais em pormenor, a resposta da rede a essas diferentes configurações (Figura 230). Para as diferentes geometrias consideradas, verifica-se uma total adaptabilidade da rede aos dados CLASH, ou seja, a rede retornou valores de galgamento exatamente iguais aos encontrados na base de dados, apesar de ter como base valores ainda não otimizados dos seus parâmetros.

Figura 228 – Correlação dos galgamentos provenientes da rede ARTMAP-Fuzzy, q_{ART} , e da base de dados do projeto CLASH, q_{CLASH} , para 3.000 testes: a) todos os valores; b) valores para $q_{CLASH} < 0,0005 \text{ m}^3/\text{s/m}$; c) valores para $q_{CLASH} < 0,00005 \text{ m}^3/\text{s/m}$.




Fonte: Próprio autor.

Figura 229 - Diferentes geometrias da base de dados CLASH testadas com a rede ARTMAP-Fuzzy.



Fonte: Próprio autor.

Figura 230 – Correlação dos galgamentos provenientes da rede ARTMAP-Fuzzy, q_{ART} , e da base de dados do projeto CLASH, q_{CLASH} , para os tipos de geometria analisados.



Fonte: Próprio autor.

6.7 Previsão da ARTMAP-Fuzzy para o Cálculo de Galgamento (Comparação com os Resultados do Modelo Reduzido)


Na Tabela 31 e Figura 231 apresenta-se uma comparação dos caudais médios de galgamento obtidos com a rede ARTMAP-Fuzzy e provenientes do modelo físico reduzido para os 12 ensaios analisados.

Tabela 31 - Comparação dos galgamentos provenientes da rede ARTMAP-Fuzzy, q_{ART} , e do modelo reduzido, q_{MF} , para os 12 ensaios analisados.

Ensaio	Nível de Maré (m ZH)	T_p (s)	H_s (m)	q_{MF} ($10^{-3} \text{ m}^3/\text{s/m}$)	q_{ART} ($10^{-3} \text{ m}^3/\text{s/m}$)
1	0,0	10	6	0,0	0,4
2		14	9	0,0	0,7
3		18	11,5	1,8	3,9
4		16	12	0,3	1,0
5		20	13	13,5	17,1
6		20	14	35,3	48,2
7	4,0	10	6	0,0	2,2
8		14	9	0,6	2,1
9		18	11,5	44,2	46,8
10		16	12	33,3	45,8
11		20	13	138,6	178,9
12		20	14	246,8	200,0

Fonte: Próprio autor.

Figura 231 - Correlação dos galgamentos provenientes da rede ARTMAP-Fuzzy, q_{ART} , e do modelo reduzido, q_{MF} , para os 12 ensaios analisados.



Fonte: Próprio autor.

A Tabela 32 contém os valores calculados do erro médio quadrático (RMSE) e da média (μ) e do desvio padrão (σ) do erro viés (EV) para os caudais médios de galgamento. O Erro Médio Percentual Absoluto não foi calculado devido a baixa quantidade de pontos, o que torna o valor do mesmo pouco representativo.

Tabela 32 – Mapeamento dos erros dos caudais médios de galgamento obtidos através da rede ARTMAP-Fuzzy para os 12 ensaios analisados.

Nível de Maré (m ZH)	Erros		
	(m³/s/m)		
0,0	RMSE		0,0055
	EV	μ	-0,0034
		σ	0,0048
4,0	RMSE		0,0258
	EV	μ	-0,0021
		σ	0,0282

Fonte: Próprio autor.

Como se pode verificar, à exceção dos ensaios para os quais os caudais médios de galgamento foram nulos no modelo físico, a rede ARTMAP-Fuzzy foi capaz de estimar valores de galgamento próximos dos valores observados no modelo. Outro fator de interesse, verificado através da análise da média dos erros viés, é que a rede tende a sobrestimar os valores de galgamento quando comparada com os valores apresentados

no modelo físico (à exceção do ensaio 12). No que diz respeito à análise do maior desvio padrão dos erros viés, o valor de $0,0282 \text{ m}^3/\text{s}/\text{m}$, ou seja $28,2 \text{ l/s}/\text{m}$, ainda é muito alto.

Assim, os valores previstos pela rede ARTMAP-Fuzzy terão que ser refinados através de uma análise de sensibilidade aos parâmetros de treino da rede. Essa análise fará parte de um trabalho futuro devido a complexidade e tempo de execução da mesma.

6.8 Previsão da ARTMAP-Fuzzy para o Cálculo de Galgamento (Comparação com Outras Ferramentas Neurais)

Bravo *et al.* (2013) comparam os caudais médios de galgamento obtidos pelas ferramentas neuronais NN_OVERTOPPING2 (Coeveld *et al.*, 2005) e OVERTOPPING (Verhaeghe, 2005) com os caudais medidos no modelo físico reduzido para o caso de estudo em questão. A Tabela 33 e a Figura 232 apresentam essa comparação para a representação da estrutura que conduziu aos melhores resultados de galgamento para cada nível de maré com cada uma das duas ferramentas. Inclui-se também na Tabela 33 os correspondentes resultados da rede ARTMAP-Fuzzy. Os erros apresentam-se na Tabela 34.

Como se pode verificar, as ferramentas NN_OVERTOPPING2 e OVERTOPPING estimam valores de galgamento bastante próximos dos valores observados no modelo físico. Para os caudais médios de galgamento mais reduzidos, os quais são muitas vezes condicionantes do ponto de vista da operação da estrutura e da utilização das áreas circundantes, as ferramentas tendem a sobrestimar os caudais medidos e a ferramenta NN_OVERTOPPING2 nem sempre foi capaz de produzir uma estimativa de galgamento (ensaio 1), limitada pelo seu domínio de aplicabilidade. Ao contrário da ferramenta NN_OVERTOPPING2 e ARTMAP-Fuzzy, a ferramenta OVERTOPPING é capaz de identificar estados de agitação incidentes na estrutura que originam galgamentos nulos (ensaio 1). Contudo, para alguns estados de agitação que deram origem a galgamentos nulos no modelo físico reduzido, OVERTOPPING estimou também galgamento diferente de zero. As previsões de galgamento da ferramenta OVERTOPPING foram, na maior parte dos casos, mais próximas das medições no modelo físico reduzido do que aquelas estimadas por NN_OVERTOPPING2 e ARTMAP-Fuzzy, quando o nível de maré foi de $+4,0 \text{ m}$ (ZH).

No caso do nível de maré 0,0 m (ZH), verificou-se que a rede ARTMAP-Fuzzy foi a que conduziu a resultados mais próximos do modelo físico no caso dos testes 3, 4 e 5, sendo a ferramenta OVERTOPPING a melhor nos restantes testes.


Tabela 33 - Comparação dos galgamentos provenientes das ferramentas NN_OVERTOPPING2, q_{NN} , OVERTOPPING, q_{OVER} , e ARTMAP-Fuzzy, q_{ART} , com os medidos no modelo reduzido, q_{MF} , para os 12 ensaios analisados.


Ensaio	Nível de Maré (m ZH)	T_p (s)	H_s (m)	q_{MF} ($10^{-3} \text{ m}^3/\text{s/m}$)	q_{NN} ($10^{-3} \text{ m}^3/\text{s/m}$)	q_{OVER} ($10^{-3} \text{ m}^3/\text{s/m}$)	q_{ART} ($10^{-3} \text{ m}^3/\text{s/m}$)
1	0,0	10	6	0,0	---	0,0	0,4
2		14	9	0,0	0,3	0,2	0,7
3		18	11,5	1,8	5,1	4,9	3,9
4		16	12	0,3	4,3	4,3	1,0
5		20	13	13,5	21,2	20,3	17,1
6		20	14	35,3	37,4	34,6	48,2
7	4,0	10	6	0,0	0,1	0,1	2,2
8		14	9	0,6	3,3	3,5	2,1
9		18	11,5	44,2	38,0	45,5	46,8
10		16	12	33,3	33,3	39,6	45,8
11		20	13	138,6	131,3	140,0	178,9
12		20	14	246,8	199,0	261,0	200,0

¹ Parâmetro de entrada fora do intervalo de aplicabilidade. Nenhuma previsão é dada.

Fonte: Próprio autor.

Figura 232 – Correlação dos galgamentos provenientes das ferramentas a) NN_OVERTOPPING2, q_{NN} , e b) OVERTOPPING, q_{OVER} , e do modelo reduzido, q_{MF} , para os 12 ensaios analisados.





Fonte: Próprio autor.

Tabela 34 – Mapeamento dos erros dos caudais médios de galgamento obtidos através das ferramentas NN_OVERTOPPING2, OVERTOPPING e ARTMAP-Fuzzy para as melhores representações da estrutura.

Nível de Maré (m ZH)		Erros (m³/s/m)		
		NN_OVERTOPPING2	OVERTOPPING	ARTMAP-Fuzzy
0,0	RMSE	0,0042	0,0035	0,0055
	EV	μ	-0,0035	-0,0022
		σ	0,0027	0,0029
4,0	RMSE	0,0199	0,0065	0,0258
	EV	μ	0,0098	-0,0021
		σ	0,0190	0,0282
				0,0053

Fonte: Próprio autor.

De uma forma global, a comparação dos resultados apresentados para as três redes permite concluir que, em termos de RMSE, a rede ARTMAP-Fuzzy apresentou resultados piores que as outras duas ferramentas neuronais. Contudo, em termos de EV, a rede ARTMAP-Fuzzy apresenta melhores resultados que as outras ferramentas para o nível de maré de 0,0 m (ZH) e para o nível de +4,0 m (ZH) aproxima-se mais do modelo físico que a rede NN_OVERTOPPING2. Tal como referido na secção anterior, os valores previstos pela rede ARTMAP-Fuzzy terão que ser refinados através de uma análise de sensibilidade aos parâmetros de treino da rede.

Devido à complexidade da estrutura analisada, algumas considerações foram relaizadas para simplificar o comportamento das mesmas. Sendo assim, apresenta-se os resultados referentes a algumas geometrias escolhidas, notadamente as que obtiveram os melhores resultados (BRAVO *et al.*, 2013)

Note-se que os melhores resultados de galgamento das três ferramentas utilizadas foram obtidos para representações distintas da estrutura (diferente combinação de parâmetros geométricos): com a rede ARTMAP-Fuzzy, a berma fictícia estava colocada à cota +6,20 m (ZH) para o nível de maré de 0,0 m (ZH) e a berma estava a -7,00 m (ZH) para o nível de maré de +4,0 m (ZH); no entanto, o valor de γ_f abaixo do ZH era 0,60 e acima do ZH era 0,80 para ambos os níveis. Com NN_OVERTOPPING2, a berma fictícia estava colocada à cota +6,20 m (ZH), o valor de γ_f abaixo do ZH era 0,47 e acima do ZH era 0,85 para o nível de maré de 0,0 m (ZH) e era 0,60 abaixo do ZH e 0,80 acima do ZH para o nível de maré de +4,0 m (ZH). Com OVERTOPPING, para o nível de maré de 0,0 m (ZH), a berma fictícia estava coincidente com o nível de maré e os valores de γ_f eram 0,55 abaixo do ZH e 0,80 acima do ZH, enquanto que para o nível de maré de +4,0 m (ZH), a berma fictícia estava colocada à cota +6,20 m (ZH) e os de valores de γ_f eram iguais aos utilizados para o nível de maré de 0,0 m (ZH).

6.9 Previsão da ARTMAP-Fuzzy para Comportamento de Ondas no Lago de Ilha Solteira

Em se tratando do diagnóstico da rede na análise do comportamento de ondas no lago da Barragem de Ilha Solteira, utilizou-se como valores de entrada a velocidade média do vento (m/s) e a direção média do vento (graus) e, como saída altura significativa de onda (m). Cabe salientar que, na base de dados, o pesquisador desenvolvedor do software de aquisição nomeia essa altura de onda como sendo significativa (verificação informal); no entanto, parece que a mesma se trata da altura proveniente da máxima amplitude da onda medida em um intervalo de 1 min. Para o treinamento da rede foram escolhidos dados no período compreendido entre 23/02/2013 (13:10) a 05/03/2013 (23:50), com aproximadamente 15.000 valores válidos. O tempo total de treinamento foi de aproximadamente 25.600 s (7,1 horas).


Os seguintes parâmetros de treino adotados: $\beta = 1,0$ (taxa de treino rápida), $\alpha = 0,1$ (parâmetro de escolha da categoria), $\rho_a = 0,95$ (parâmetro de monitorização

inicial do módulo ART_a), $\rho_{ab} = 0,95$ (parâmetro de monitorização entrada/saída), $\rho_b = 1,00$ (parâmetro de monitorização de ART_b), $\varepsilon = 0,001$ (incremento na monitorização de ART_a). É importante ressaltar que não fora executada a análise de sensibilidade dos parâmetros devido ao baixo intervalo constante na base de dados, isso provavelmente deverá ser objeto de trabalho futuro.

Efetuiu-se o diagnóstico para 30, 50 e 70 % de dados desconhecidos. A seguir realizou-se a previsão para dois períodos de aproximadamente 3 horas conforme apresentado nas


Figura 233, Figura 234 e Figura 235 como se segue.

Figura 233 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, Hs_{ART}, e do ondógrafo óptico, Hs_{OND}, para 30% de dados desconhecidos.




Fonte: Próprio autor.

Figura 234 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do ondógrafo óptico, $H_{s_{OND}}$, para 50% de dados desconhecidos.



Fonte: Próprio autor.

Figura 235 - Correlação de Hs provenientes da rede ARTMAP-Fuzzy, $H_{s_{ART}}$, e do ondógrafo óptico, $H_{s_{OND}}$, para 70% de dados desconhecidos.



Fonte: Próprio autor.

Como pode ser verificado, relativo ao diagnóstico de 30, 50 e 70%, a rede não foi capaz de se estabilizar e encontrar os devidos padrões pretendidos. Isso se deve principalmente ao fato, da pouca representatividade da base de dados. A mesma abrange um período muito curto, que não é capaz nem de representar um ciclo sazonal completo das quatro estações. Sendo assim, é pretendida uma análise futura, quando a base já tenha adquirido corpo suficiente.

7 CONCLUSÃO E PERSPECTIVAS FUTURAS

O objetivo principal deste trabalho foi aplicar a rede ARTMAP-Fuzzy à previsão de agitação marítima e galgamento na costa portuguesa e do comportamento de ondas no lago de Ilha Solteira. No que tange a agitação marítima, pôde-se obter com êxito respostas satisfatórias a problemática imposta; mas, em relação ao comportamento de ondas geradas por vento em lago, ainda existe a necessidade de utilização de uma base de dados mais substancial e representativa do fenômeno.

Em todos os casos estudados, em posse de uma base de dados, seja ela fornecida por outros modelos numéricos, ou, encontrada na literatura (galgamento), foi realizada uma tentativa de previsão de alguns parâmetros hidráulicos (evidenciados no escopo dessa pesquisa) para fins análise do comportamento dos mesmos e, subsequentemente, pôde-se obter algumas conclusões que se seguem.

Em se tratando dos resultados obtidos nesse trabalho, pode-se verificar que, em termos gerais:

- Os resultados fornecidos pela rede em todos os casos acompanham o perfil dos fenômenos estudados, sugerindo uma boa adaptação da rede.
- O gasto computacional da rede ARTMAP-Fuzzy é bem inferior aos demais modelos. Nesse ponto, cabe ressaltar que não fora realizada uma análise quantitativa clássica de tempo computacional, e sim, uma pesquisa junto aos usuários do modelo SWAN e DREAMS no Laboratório Nacional de Engenharia Civil (LNEC). Mas, acredita-se ser de grande interesse, ressaltar que, o tempo de processamento de previsão da ARTMAP-Fuzzy é muito inferior ao dos outros métodos, chegando a alguns casos, a ordem de 10 a 100 vezes menor do que os outros modelos. Uma análise comparativa criteriosa se faz necessária, mas como perspectiva futura a esse trabalho.
- Os resultados fornecidos pela rede em todos os casos acompanham o perfil das alturas de onda medidas na boia também, isso sugeriu uma adaptação boa da rede aos casos.

Em se tratando da análise de sensibilidade dos parâmetros pode-se notar que:

- Foi fundamental para execução de um treinamento e previsão com qualidade, no entanto, esse processo ainda é muito dispendioso, exigindo muito do operador. Mas, há a possibilidade de implementação de rotinas para avaliar a sensibilidade desses parâmetros futuramente, o que deixaria a rede mais refinada. Isso, de maneira bem evidente, não é encontrado na literatura bibliográfica, o que foi passível de grande motivação para ser realizado. No entanto, como colocado anteriormente, não houve tempo para se aperfeiçoar o processamento e nem para realizar essa análise para todos os casos, ficando assim, como sugestão para trabalhos futuros.

Em se tratando do estudo da agitação marítima dentro e fora do Porto de Sines, pode-se verificar que:

- A resposta da rede foi extremamente eficiente quando da comparação com o modelo SWAN (fora do porto). No entanto, os valores dos erros aumentaram significativamente quando da comparação com o modelo DREAMS (dentro do porto). Isso pode ser explicado, levando-se em consideração o surgimento de fenômenos inerentes a esse processo, sejam eles: reflexão, refração e difração das ondas, o que parece contribuir para o aumento da complexidade do problema em questão.

No que se refere à tentativa de previsão do galgamento no trecho estudado, verifica-se que:

- Em relação aos resultados do modelo físico, à exceção dos ensaios para os quais os caudais médios de galgamento medidos foram nulos, a rede ARTMAP-Fuzzy foi capaz de estimar valores de galgamento próximos dos valores observados no modelo, embora a rede tenda a sobrestimar os valores de galgamento.
- Comparativamente aos resultados obtidos com as ferramentas NN_OVERTOPPING2 e OVERTOPPING (redes essas, do tipo MLP – *Multi Layer Perceptron*), verificou-se que, em termos do erro médio quadrático (RMSE), a rede ARTMAP-Fuzzy apresentou resultados desfavoráveis em relação às outras duas ferramentas neurais. Contudo, em termos de erro viés (EV), a rede ARTMAP-Fuzzy apresenta melhores resultados que as outras ferramentas para o nível de maré

de 0,0 m (ZH) e para o nível de +4,0 m (ZH) aproxima-se mais do modelo físico que a rede NN_OVERTOPPING2. Com efeito, para o caso do nível de maré de 0,0 m (ZH), verificou-se que a rede ARTMAP-Fuzzy foi a que conduziu a resultados mais próximos do modelo físico no caso de três dos seis testes analisados, sendo a ferramenta OVERTOPPING a melhor nos restantes testes. Verificou-se também que, ao contrário da ferramenta NN_OVERTOPPING2 e ARTMAP-Fuzzy, a ferramenta OVERTOPPING, que pode ser considerada a ferramenta que apresentou melhor desempenho, é capaz de, em alguns casos, identificar estados de agitação incidentes na estrutura que originam galgamentos nulos.

- Assim, os resultados da rede ARTMAP-Fuzzy são muito promissores e, no sentido de melhorar o seu desempenho, a análise de sensibilidade aos parâmetros de treino da rede para o caso de galgamento constitui trabalho futuro.

Em se tratando do estudo de ondas geradas pelo vento no lago da barragem de Ilha Solteira, pode-se verificar que:

- A base de dados utilizada ainda é demasiadamente pequena, o que deixa a mesma sem representatividade em relação ao fenómeno. Isso poderá ser ultrapassado, à medida que a captação de dados no lago tenha uma amplitude elevada. Mas, para superar o fato da aquisição ainda estar em implementação, é sugerido, como trabalho futuro, a implementação do treinamento continuado, o que já vem sendo desenvolvido pela equipe de redes para outros fenómenos atualmente.

Finalmente, nesta pesquisa realizada, percebe-se que a aplicação desse tipo de rede neural para os fenómenos estudados, sejam eles: agitação marítima, galgamento e comportamento de ondas geradas por vento, parece responder de forma satisfatória a previsão dos mesmos.

8 PUBLICAÇÕES RESULTANTES

1 - SANTOS, F. L. ; REIS, M. T. ; FORTES, C. J. ; LOTUFO, A. D. P. ; MACIEL, G. F. . “*ARTMAP Artificial Neural Networks with Fuzzy Logic. Their Application to Study the Wave Conditions at Sines Port, Portuga*”.. In: 6th International Short Course/Conference on Applied Coastal Research, 2013, Lisbon. 6th SCACR Proceedings, 2013.

2 - SANTOS, F. L. ; REIS, M. T. ; FORTES, C. J. ; LOTUFO, A. D. P. ; MACIEL, G. F. “*Estudo do Galgamentos Utilizando Redes Neurais Artificiais do Tipo ARTMAP com Lógica Fuzzy*”. In: 8th Jornadas Portuguesas de Engenharia Costeira e Portuária, 2013, Lisboa - Portugal. Proceedings, 2013.

3 - SANTOS, F. L. ; LOTUFO, A. D. P. ; MACIEL, G. F. ; REIS, M. T. ; FORTES, C. J. “*Rede ARTMAP Nebulosa Aplicada ao Estudo de Agitação Marítima no Porto de Sines/Portugal*”. In: 11th Congresso Brasileiro de Inteligência Computacional, 2013, Porto de Galinhas. Proceedings of BRICS-CCI & CBIC, 2013.

4 - SANTOS, F. L. ; NEVES, D. R. C. B.; REIS, M. T. ; FORTES, C. J.; POSEIRO, P.; LOTUFO, A. D. P. ; MACIEL, G. F. “*Definition of Sines Port Wave Regime Using na ARTMAP Artificial Neural Network with Fuzzy Logic*”. In: 3rd IAHR Europe Congress, Book of Proceedings, Porto –Portugal, 2014. (no prelo).

REFERÊNCIAS

- ABELÉM, A. J. G. **Redes neurais artificiais na previsão de séries temporais**. 1994. Dissertação (Mestrado em Engenharia Elétrica) - Curso de Mestrado em Engenharia Elétrica, Pontifícia Universidade Católica, Rio de Janeiro, 1994.
- ALMEIDA, M. S. S. Análise do desempenho de Redes Neurais Artificiais no preenchimento de falhas em séries de precipitação diária. Learning and Nonlinear Models (L&NLM) – **Journal of the Brazilian Neural Network Society**, Rio de Janeiro, v. 10, n. 3, p. 175-180, 2012.
- ALMEIDA, P. E. M.; EUSUKOFF, A. G. Sistemas *fuzzy*. In: REZENDE, S. O. (Org.). **Sistemas inteligentes: fundamentos e aplicações**. Barueri: Manole, 2005. p. 169 – 200.
- ALTRAN, A. B.; LOPES, M. L. M.; MINUSSI, C. R.; ALVARADO, F. V. Um estudo das funções de base radial aplicadas à previsão de cargas elétricas via redes neurais artificiais. In: CONGRESSO NACIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL (CNMAC), 28, 2005, Santo Amaro. **Anais...** Santo Amaro: [S.n.] Disponível em: <<http://200.231.172.253/cnmac/index.php>>. Acesso em: 04 nov. 2005.
- ANDRADE, M. C. et al. Estimativa de padrões espaço-temporais utilizando redes neurais artificiais do tipo *multilayer perceptron* com aplicação em física solar. In: WOKSHOP DOS CURSOS DE COMPUTAÇÃO APLICADA DO INPE, 1, 2001, São José dos Campos. **Anais...** São José dos Campos: INPE, 2001. p. 6 – 8.
- ANOCHI, J. A. Uso de redes neurais artificiais e teoria dos conjuntos aproximativos no estudo de padrões climáticos sazonais: learning and nonlinear models. **Revista da Sociedade Brasileira de Redes Neurais**, São José dos Campos, v. 7, n.2, p. 83-91, 2009.
- ANTUNES, A. F. **Previsão de carga multinodal usando a rede neural ART-ARTMAP fuzzy**. 2013. 110 f. Tese (Doutorado em Automação) - Faculdade de Engenharia, Universidade Estadual Paulista. Ilha Solteira. Área de conhecimento: Automação, 2013.
- BALESTRASSI, P. P. **Identificação de padrões em gráficos de controle estatístico de processos, em tempo real, utilizando séries temporais e redes neurais artificiais**. 2000. 217 f. Tese (Doutorado em Engenharia de Produção) – Universidade Federal de Santa Catarina, Florianópolis, 2000.
- BALLINI, R. Previsão de vazões médias mensais usando redes neurais nebulosas. **Revista Controle & Automação**. v. 14, n. 3, p. 680-693, 2003. Disponível em: <<http://www.scielo.br/pdf/ca/v14n3/a08v14n3.pdf>>. Acesso em: 01 03 abr. 2014.

BATJES, J. A.; GROENENDIJK, H. W. Wave height distributions on shallow foreshores. **Coastal Engineering**, Amsterdam, v. 40, p. 161-182. 2000.

BERKHOF, J. C. W. Computation of combined refraction-diffraction. In: **PROCEEDINGS OF THE. 13TH INTERNATIONAL CONFERENCE IN COASTAL ENGINEERING**, 13, 1972, Vancouver. **Proceedings of the...** Vancouver: [S.n.], 1972. v. 2, p. 471-490.

BOOIJ, N.; RIS, R. C.; HOLTHUIJSEN, L. H. A third-generation wave model for coastal regions, Part I, Model description and validation. **Journal of Geographical Research**, v. 104, n. c4, p. 7649-7666, 1999. Disponível em: < http://falk.ucsd.edu/modeling/swan1_jgr99.pdf>. Acesso em: 03 abr. 2014.

BRAGA, A. P.; CARVALHO, A. P. L. F. ; LUDEMIR, T. B. **Fundamentos de redes neurais artificiais**. Rio de Janeiro: DCC/IM, 1998. 246 p.

BRAVO, A. A. **Comparison of two wave overtopping calculation tools based on neural network analysis**. Disponível em: < http://6scacr.lnec.pt/55_Bravo_Andre.pdf>. Acesso em: 03 abr. 2014.

CARPENTER, G. A. ; GROSSBERG, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer Vision, Graphics, and Image Processing**, Maryland Heights, v. 37, p. 54-115, 1987.

CARPENTER, G. A. ; GROSSBERG, S. ART2: stable self-organization of pattern recognition codes for analog input patterns. **Applied Optics**, Washington, v. 26, p. 4919-4930, 1987.

CARPENTER, G. A.; GROSSBERG, S. ; REYNOLDS, J. H. ARTMAP: supervised real-learning and classification of non-stationary data by a selforganizing neural network. **Neural Network**, Kidlington, v. 4, n. 5, p. 565-588, 1991a.

CARPENTER, G. A.; GROSSBERG, S. ; ROSEN, D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Network**, Kidlington, v. 4, n. 1, p. 759-771, 1991b.

CARPENTER, G. A. ;GROSSBERG, S. A self-organizing neural network for supervised learning, recognition and prediction. **IEEE Communications Magazine**, New York, v. 30, n. 9, p. 38-49, 1992.

CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H.; ROSEN, D. B. Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, New York, v. 3, n. 5, p. 698-713, 1992.

CARPENTER, G. A. ; ROSS, W. D. ART-EMAP: a neural network architecture for object recognition by evidence accumulation. **IEEE Transactions on Neural Networks**, New York, v. 6, n. 4, p. 805-818, 1995.

CARPENTER, G. A. ; GROSSBERG, S. Adaptive resonance theory. In: ARBIB, M. A. (Ed.). **The handbook of brain theory and neural networks**. 2. ed. Cambridge: MIT Press, 2003. p. 87-90.

CASTRO, M. C. F. **Predição não-linear de séries temporais usando redes neurais rbf por decomposição de componentes principais**. 2001. Tese (Doutorado) – Faculdade de Engenharia Elétrica e Computação, Universidade Estadual de Campinas, Campinas, 2001.

CHEN, B.; WANG, W. Infrared target detection based on fuzz ART neural network. college of electronic information. In: Wuhan Universit, 2010. INTERNATIONAL CONFERENCE ON COMPUTATIONAL INTELLIGENCE AND NATURAL COMPUTING (CINC), 2, 2010, Wuhan. **Proceedings of the...** Wuhan: IEE, 2010. p. 240-244, 2010.

CIRIA/CUR/CETMEF. **The rock manual**: the use of rock in hydraulic engineering. 2. ed. Londres: CIRE, 2007. C683

COAKLEY, J. R. ;BROWN, C. E. Artificial neural networks in accounting and finance: modeling issues. **International Journal of Intelligent Systems in Accounting, Finance & Management**, Oxford, v. 9, n. 2, p. 119-144, 2000.

COVELD, E. M.; VAN GENT, M. R. A.; POZUETA, B. **Neural network manual**: NN_OVERTOPPING2. CLASH WP8, WL Delf Hydraulics, Delf, The Netherlands, June, 2005.

CORREIA, L. G. **Memória associativa em redes neurais realimentadas**. 2004. 119 f. Dissertação (Mestrado) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Paulo, 2004.

DAILEY, M. N.; COTTRELL, G. W. Empath: a neural network that categorize facial expressions. **Journal of Cognitive Neuroscience**, Cambridge, v. 14, p. 1158-1173, 2002.

DEO, M. C.; GONDANE, D. S. Analysis of wave directional spreading using neural networks. **Journal of Waterway, Port, Coastal and Ocean Engineering**, Reston, v. 128, p. 30-37, 2002.

DEO, M. C.; JAGDALE, S. S. Prediction of breaking waves with neural networks, **Ocean Engineering**, Kidlington, v. 30, p. 1163-1178, 2003.

DJUKANOVIC, M.; RUZIC, S.; BABIC, B.; SOBAJIC, D. J. ;PAO, Y. H. A neural-net based short term load forecasting using moving window procedure. **Electrical Power & Energy Systems**, London, v. 17, n. 6, p. 391-397, 1995.

DORNELLES, F. **Previsão contínua de níveis fluviais com redes neurais utilizando previsão de precipitação**. 2007 Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul, 2007.

ENGEL, P. M. **Redes neurais**. Porto Alegre: Universidade Federal do Rio Grande do Sul, 2002. Programa de Pós Graduação em Computação - Notas de aula.

FABRI, J. A. **Redes neurais artificiais**. 1999. Disponível em: <http://users.femanet.com.br/~fabri/RNAs.htm> . Acesso em: 03 mar. 2005.

FERREIRA, V. P. **Análise dinâmica de contingência de sistemas de energia elétrica por redes neurais baseadas na teoria da ressonância adaptativa**. 2003. Tese (Doutorado em Automação) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2003.

FERREIRA FILHO, W. M. ; LIMA, C. H. R. Análise de modelos de redes neurais aplicados ao processo chuva-deflúvio no semi-árido. In: SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS , 15., 2003, Curitiba. **Anais...** Curitiba: [S.n.], 2003. Disponível em: < <http://pt.scribd.com/doc/172603130/ANALISE-DE-MODELOS-DE-REDES-NEURAI-APLICADOS-AO-PROCESSO-CHUVADEFLUVIO>>. Acesso em: 03 abr. 2014.

FONSECA, I. M. **Projeto evolucionário de arquiteturas neurais**. 2005. Disponível em: <<http://www2.dem.inpe.br/ijar/ArqNeurais.html>>. Acesso em: 28 jul. 2005.

FORTES, C. J. E. M. **Modelação matemática da refração e difração combinadas de ondas marítimas (análise pelo método dos elementos finitos)**. 2003. Tese (Doutorado) - Engenharia Mecânica, Instituto Superior Técnico, Universidade de Lisboa, Lisboa, 2003.

FORTES, C. J. E. M. **Transformações não-lineares de ondas marítimas em zonas portuárias: análise pelo método dos elementos finitos**. 2002. Dissertação (Mestrado) - Engenharia Mecânica, Instituto Superior Técnico, Universidade de Lisboa, Lisboa, 2002.

GANASCIA, J. G.. **Inteligência artificial**. São Paulo: Ática, 1997. 142 p.

GEORGIOPOULOS, M.; FERNLUND, H.; BEBIS, G. ; HEILEMAN, G. L. Order of search in fuzzy ART and fuzzy ARTMAP: effect of the choice parameter. **Neural Networks**, Kidlington, v. 9, n. 9, p. 1541-1559, 1996.

GROSSBERG, S. Adaptive resonance theory: how a brain learns to consciously attend, learn, and recognize a changing world. **Neural Networks**, Kidlington, v. 37, p. 1-47, 2013.

GROSS, G. ; GALIANA, F. D. Short term load forecasting. **Proceedings of the IEEE**, New York, v. 75, n. 12, p. 1558-1573, 1987.

GROSSBERG, S. Adaptive pattern classification and universal recoding, I: parallel development and coding of neural feature detectors. **Biological Cybernetics**, New York, v. 23, n. 3, p. 121-134, 1976a.

GROSSBERG, S. Adaptive pattern classification and universal recoding, II: feedback, expectation, olfaction, and illusions. **Biological Cybernetics**, New York, v. 23, n. 4, p. 187-202, 1976b.

HASSELMANN K. T. P.; BARNETT, E.; BOUWS, H.; CARLSON, D. E.; CARTWRIGHT, K.; ENKE, J. A.; EWING, H.; GIENAPP, D. E.; HASSELMANN, P.; KRUSEMAN, A.; MEERBURG, P.; MILLER, D. J.; OLBERS, K.; RICHTER, W.; SELL, H. **Measurements of wind-wave growth and swell decay during the Joint North Sea Wave Project (JONSWAP)** 'Ergänzungsheft zur Deutschen Hydrographischen Zeitschrift Reihe, A8, n. 12, 95p. 1973.. Disponível em: <<http://repository.tudelft.nl/view/hydro/uuid%3Af204e188-13b9-49d8-a6dc-4fb7c20562fc/>>. Acesso em: 04 abr. 2014.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Upper Saddle River Prentice-Hall, 1994. 696 p.

HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001. 900 p.

HOPFIELD, J. J. Neural network and physical system with emergent collective properties. **Proceedings of the National Academic Science**, Washington, v. 79, p. 2554-2558, 1982.

JAIN, A. K. M. ; MOHIUDDIN, K. M. Artificial neural networks: a tutorial. **IEEE Computer**, New York, v. 29, n. 3, p. 31-44, 1996.

KADOWAKI, M. ; ANDRADE, M. G. Previsão de vazões mensais utilizando redes neurais multicamadas com algoritmo backpropagation. In: SIMPÓSIO BRASILEIRO DE REDE NEURAI, 4, 1997, Goiania. **Anais...** Goiânia: UFG, 1997.

KAISER, I. M. **Ondas geradas por ventos em reservatórios artificiais: um panorama**. 1995. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 1995.

KARTALOPOULOS, S. V. **Understanding neural networks and fuzzy logic: basic concepts and applications**. Piscataway: IEEE Press, 1996. 205 p.

KHAN, J.; WEI, J. S.; RINGNER, M.; SAAL, L. H.; LADANYI, M.; WESTERMANN, F.; BERTHOLD, F.; SCHWAB, M.; ANTONESCU, C. R.; PETERSON, C.; MELTZER, P. S. Classification and diagnostic prediction of cancers using gene expression profiling and artificial neural networks. **Nature Medicine**, New York, v. 7, n. 6, p. 673-679, 2001.

KOHONEN, T. Correlation matrix memories. **IEEE, Transactions on Computers**, New York, v. 21, p. 353-359, 1972.

KOVÁCS, Z. L. **Redes neurais artificiais: fundamentos e aplicações**. 3. ed. São Paulo: Livraria da Física, 2002. 174 p.

LEOCADIO, C. M. Inferência bayesiana no desenvolvimento de previsores neurais de vazão diária utilizando informações de precipitação. **Learning and Nonlinear Models**

(L&NLM) – Journal of the Brazilian Computational Intelligence Society, Rio de Janeiro, v. 10, n. 3, p. 157-165, 2012.

LIM, C. P. ;HARRISON, R. F. Modified fuzzy ARTMAP approaches bayes optimal classification rates: An empirical demonstration. **Neural Networks**, Kidlington, v. 10, n. 4, p. 755-774, 1997.

LIMA, C. M. ; LABIDI, S. **Introdução à inteligência artificial**. São Luiz: FAPEMA, 1999. 128 p.

LIMA, S. F. **Amortecimento de ondas gravitacionais por campos de vegetação simulados por elementos de grande flexibilidade**. 2005. Tese (Doutorado em Engenharia Oceânica) - Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

LIRIANO, S. L.; DAY, R. A. Prediction of scour depth at culvert outlets using neural networks. **Journal of Hydroinformatics**, London, v. 3, n. 4, p. 231-238, 2001

LNEC. **Ensaio em modelo reduzido da reconstrução do Molhe Oeste do Porto de Sines**. Lisboa: LNEC, 2008. Report 141/2008-NPE.

LONDHE, S. N. ; DEO, M. C. Artificial neural networks for wave propagation. **Journal Coastal Research**, Coconut Creek, v. 20, n. 4, p. 1061-1069, 2004.

LOPES, M. L. M. **Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica**. 2005. Tese (Doutorado em Automação) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.

LORENZI, A. **Aplicação de redes neurais artificiais para estimativa da resistência à compressão do concreto a partir da velocidade de propagação do pulso ultrassônico**. 2009. Tese (Doutorado em Engenharia Civil) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

MACHADO, F. W. **Modelagem chuva-vazão mensal utilizando redes neurais**. 2005. 174 f. Dissertação (Mestrado) – Universidade Federal do Paraná, Curitiba, 2005.

MALANGE, F. C. V. **Rede neuro-fuzzy-wavelet para detecção e classificação de anomalias de tensão em sistemas elétricos de potência**. 2010. 128 f. Tese (Doutorado em Automação) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.

MARCHIORI, S. C.; MINUSSI, C. R.; LOTUFO, A. D. P. Rede neural ARTMAP nebulosa para análise de estabilidade transitória de sistemas de energia elétrica. **Revista da Sociedade Brasileira de Redes Neurais - Learning and Nonlinear Models**, Rio de Janeiro, v. 1, n. 1, p. 61-78, 2002.

MARCHIORI, S. C. **Desenvolvimento de um sistema para análise da estabilidade transitória de sistemas de energia elétrica via redes neurais**. 2006. 110 f. Tese (Doutorado em Automação) - Faculdade de Engenharia Elétrica de Ilha Solteira (FEIS) - Universidade Estadual Paulista – UNESP, 2006.

MASE, H.; SAKAMOTO, M., SAKAI, T. Neural network for stability analysis of rubble mound breakwaters. **Journal of Waterway, Port, Coastal, and Ocean Engineering**, Reston, v. 121, n. 6, p.294-299, 1995.

MASE, H.; KITANO, T. Prediction model for occurrence of impact wave force. **Ocean Engineering**, Kidlington, v. 26, p. 949-961, 1999.

MARIZ, M. S. C. O. R. **Modelação numérica do galgamento em estruturas marítimas porosas**. 2012. Dissertação (Mestrado) - Instituto Superior Técnico. Universidade Técnica de Lisboa, Lisboa, 2012.

McCULLOCH, W. S.; PITTS, W. A Logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, New York, v.5, p. 115-133, 1943.

McNEIL, F. M.; THRO, E. **Fuzzy logic a practical approach**. New York: Academic Press, 1994. 292 p.

MEDINA, J. R. Neural network modelling of runup and overtopping. In: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON COASTAL STRUCTURES, 1999, Santander. **Proceedings of the...** Santander: Spain, 1999. p. 421-429.

MEDINA, J. R.; GONZALEZ-ESCRIVA, J. A.; GARRIDO, J.; DE ROUCK, J. Overtopping analysis using neural networks. In: PROCEEDINGS OF THE 28TH INTERNATIONAL CONFERENCE ON COASTAL ENGINEERING, 28, 2002, Cardiff. **Proceedings of the...** Cardiff: ASCE, 2002. p. 2165-2177.

MENDYK, A.; JACHOWICZ, R. Unified methodology of neural analysis in decision support system built for pharmaceutical technology. **Expert Systems with Application**, Kidlington, v. 32, n. 4, p. 1124-1131, 2007.

MORAIS, V. S. **Previsão de ondas geradas por ventos em águas interiores e sua alteração devido à presença de vegetação aquática em margens de lagos**. 2009. 250 f. Dissertação (Mestrado em Ciências Térmicas) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2009.

MORENO, A. L. **Análise da estabilidade transitória via rede neural ART-ARTMAP fuzzy euclidiana modificada com treinamento continuado**. 2010. 143 f. Tese (Doutorado) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.

MUELLER, D. N. **Inteligência artificial**. 2000. Disponível em: <http://www.ulbra.tche.br/~danielnm/ia/ia.html> . Acesso em: 28 jul. 2004.

MUELLER, A. **Uma aplicação de redes neurais artificiais na previsão do mercado acionário**. 1996. 103 f. Dissertação (Mestrado) - Programa de Pós Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina. Florianópolis, 1996.

NAFISI, H.; DAVARI, M.; ABEDI, M.; GHAREHPETIAN, G. B. Using fuzzy ARTmap neural network for determination of partial discharge location in power transformers. **IEEE Transactions on Neural Networks**, New York, v. 15, n. 5 p. 1-4, 2009.

NEVES, D. R. C. B. **Utilização de um sistema de informação geográfica na modelação numérica de propagação de ondas em zonas portuárias**. 2009. Dissertação (Mestrado) – Universidade de Lisboa, 2009, Lisboa.

NEVES, D. R. C. B.; RODRIGUES, S.; REIS, M. T.; FORTES, C. J. E. M.; SANTOS, J. A. Aplicação ao porto de Sines de uma nova metodologia de avaliação do risco para a navegação portuária utilizando o sistema de informação geográfica GUIOMAR.”. **Journal of Integrated Coastal Zone Management**, London, v. 10, n. 4, p. 483-504, 2010.

OLIVEIRA, M. M. F. Predição da variação extrema do nível do mar relacionada a tempestades severas utilizando redes neurais artificiais. **Learning and Nonlinear Models - Revista da Sociedade Brasileira de Redes Neurais (SBRN)**, Rio de Janeiro, v. 7, n. 1, p. 19-29, 2009.

PACKTER, L. **Neurosciência**: elementos de neurofisiologia farmacologia psiquiatria. [s.l.] 2005. Disponível em: <http://www.filosofia.com.br/disciplinas/Neurociências/Neurociências.html> . Acesso em: 27 jul. 2005.

PALHA, A. C. pyMOIA – Previsão, em tempo real, da agitação marítima em zonas portuárias. In: PROCEEDINGS OF THE JORNADAS PORTUGUESAS DE ENGENHARIA COSTEIRA E PORTUÁRIA, 5, 2007, Lisboa. **Proceedings of the...** Lisboa: [S.n.], 2007.

PANIZZO, A.; BRIGANTI, R.; VAN DER MEER, J. W.; FRANCO, L. Analysis of wave transmission behind low-crested structures using neural networks. In: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON COASTAL STRUCTURES, 2003, Portland. **Proceedings of the...** Portland: [S.n.], 2003. p. 555-566.

PARSONS, S.; JONES, G. Acoustic identification of twelve species of echolocating bat by discriminant function analysis and artificial neural networks. **Journal of Experimental Biology**, Cambridge, v. 203, n. 17, p. 2641-2656, 2000.

PEDROLLO, O. C. Previsão de níveis fluviais com redes neurais: aplicação para Rosário do Sul – RS. In: SIMPÓSIO DE RECURSOS HÍDRICOS DO SUL, 1., 2005, Santa Maria. **Anais...** Porto Alegre: IPH/UFRGS, 2005.

PEREIRA, B. B. **Data mining using neural networks: a guide for statisticians**. Rio de Janeiro: UFRJ, 2009.

PINHEIRO, C. A. R. **Redes neurais para prevenção de inadimplência em operadoras de telefonia**. 2005. 238 f. Tese (Doutorado) – Programa de Pós-Graduação de Engenharia, Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2005.

PINHEIRO, L. V.; COLI, A. B.; CAPITÃO, R.; SANTOS, J. A. **Caracterização da Agitação Marítima no Molhe oeste do Porto de Sines**. Lisboa: NPE, 2004. Regime de extremos e eventos notáveis. 2004. Relatório 370/04- NPE.

PINHEIRO, L.V.; FERNANDES, J. L. M.; FORTES, C. J. E. M. Sobre um gerador de malhas de elementos finitos com densidade local condicionada à batimetria para modelos de propagação de ondas em zonas portuárias. In: CONFERÊNCIA NACIONAL DE MÉTODOS NUMÉRICOS EM MECÂNICA DOS FLUIDOS E TERMODINÂMICA, 1, 2006, Lisboa. **Anais...** Lisboa: [S.n.], 2006.

PORTILHO, M. C. C. C. **Uma visão geral sobre redes neurais artificiais**. 2006. Trabalho de Graduação (Graduação em Engenharia Mecânica) Universidade Estadual do Oeste do Paraná, Toledo, 2006.

PORTUGUAL M. S.; FERNANDES L. G. L. **Redes neurais artificiais e previsão de séries econômicas: uma introdução**. Disponível em: <
http://www.ufrgs.br/ppge/pcientifica/1995_01.pdf>. Acesso em: 04 abr. 2014.

PULLEN, T.; ALLSOP, N. W. H.; BRUCE, T.; KORTENHAUS, A.; SCHUTTRUMPF, H.; VAN DER MEER, J. W. **EurOtop: wave overtopping of sea defences and related structures: assessment manual**. environment agency, reino unido, expertise network waterkeren, países baixos, and kuratorium fur forschung im Kusteningenieurwesen, Alemanha. 2007.

RAVEENDRAN, P.; PALANIAPPAN, R. ; OMATU, S. Fuzzy ARTMAP classification of invariant features derived using angle of rotation from a neural network. **Information Sciences**, Philadelphia, v. 130, n. 1-4, p. 67-84, 2000.

REIS, M. T.; NEVES, M. G.; LOPES, M. R.; HU, K.; SILVA, L. G. Rehabilitation of sines west breakwater: wave overtopping study. **Maritime Engineering Journal**, New York, v. 164, p. 15-32, 2011.

RIBEIRO, E. F. **Caracterização de Imagens utilizando redes neurais artificiais**. 2009. Dissertação (Mestrado) - Universidade Federal de Uberlândia, Uberlândia, 2009.

SANAD, A.; SAKA, M. P. Prediction of ultimate Shear Strenght of reinforced-Concrete deep beams using neural networks. **Journal of Structural Engineering**, Reston, v. 127, n. 7, p. 818-828, 2001.

SANTOS, S. M. **Caracterização de microorganismos aquáticos por processamento digital de imagens e redes neurais artificiais**. 2001. 154 f. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Mecânica, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2001a.

SANTOS, C. C. **Modelagem de bacias urbanas com redes neurais artificiais**. 2001. 105 f. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo, Universidade de São Paulo. São Paulo, 2001b.

SANTOS, J. A. ;GUILHERME, L.; FORTES, C. J. E. M.; PALHA, A.; SIMÕES, A. Metodologia para a previsão da agitação marítima implementada no pacote MOIA. In JORNADAS TÉCNICAS ENGENHARIA NAVAL, 11, 2008, Lisboa. **Anais...** Lisboa: CENTEC, 2008.

SILVA, I. N. ;SPATTI,D. H.; FLAUZINO R. A. **Redes neurais artificiais**: para engenharia e ciencias aplicadas. São Paulo: Artier, 2010. 230 p.

SIMEON, E. J. A **Aplicação de técnicas de inteligência artificial no desenvolvimento de um sistema**. 2008. Dissertação (Mestrado) – Universidade de Brasília, Brasília, DF, 2008.

SIMPSON, P. K. **Artificial neural systems**: foundations, paradigms, applications, and implementations. New York: Pergamon Press, 1989. 520 p.

TABACH, E. E.; LANCELOT, L.; SHAHROUR, I.; NAJJAR, Y. Use of artificial neural network simulation metamodeling to asses groundwater contamination in a road project. **Mathematical and Computer Modelling**, Kiglington, v. 45, n. 7-8, p. 766-776, 2007.

TATIBANA, C. Y.; KAETSU, D. K. **Uma introdução às redes neurais**. Disponível em: <<http://www.din.uem.br/ia/neurais/>>. Acesso em: 23 maio 2005.

TERANO, T.; ASAI, K. ; SUGENO, M. **Fuzzy systems theory and its applications**. New York: Academic Press, 1991.

TOLMAN, H. L. **User manual and system documentation of WAVEWATCH-III version 1.15**. New York: NOAA / NWS / NCEP / OMB, 1997. 97 p. (0.74MB PDF file).

TOLMAN, H. L. **User manual and system documentation of WAVEWATCH-III version 1.18**. New York: NOAA / NWS / NCEP / OMB, 1999a 110 p. (0.76Mb pdf file).

TOLMAN, H. L. **User manual and system documentation of WAVEWATCH III version 3.14**. New York: NOAA / NWS / NCEP / MMAB, 2009. 194 p. Technical Note **276**. (0.83Mb pdf file).

TOO, G. P. J.; CHE, S. R.; HWANG, S. InvrSION for acoustic impedance of a wall by using artificial neural network. **Applied Acoustics**, Kidlington, v. 68, n. 4, p. 337-389, 2007.

TSAI, C. P.; LEE, T. L. Back-propagation neural network in tidal level forecasting. **Journal of Waterway, Port, Coastal and Ocean Engineering**, Reston, v. 125, n. 4, p. 195-202.

TSAI, C. P. ; HSU, J. R. C.; PAN, K. L. Prediction of storm-built beach profile parameters using neural networks. In: PROCEEDINGS OF THE 27TH INTERNATIONAL CONFERENCE ON COASTAL ENGINEERING, 27, 2000, Sydney. **Proceedings of the...** Sydney: ASCE, 2000. p. 3048-3061.

TSAI, C. D.; WU, T. T.; LIU, Y. H., Application of neural networks to laser ultrasonic NDE of bonded structures. **NDT&E International**, New York, v. 34, n. 8, p. 537-546, 2001.

U.S. ARMY CORPS OF ENGINEERS. USACE. **Coastal engineering manual**. 3. ed.. Washington, D.C.: Department of Army Corps of Engineers, 2001/2004. CD-ROM.

U. S. ARMY CORPS OF ENGINEERS. – USACE. **Coastal engineering manual**. Part VI, Coastal and Hydraulics Laboratory, Vicksburg: USACE, 2006.

VAN DER MEER, J. W.; VAN GENT, M. R. A.; POZUETA, B.; VERHAEGHE, H.; STEENDAM, G. J.; MEDINA, J. R. Applications of a neural network to predict wave overtopping at coastal structures. In: PROC. ICE COASTLINES, STRUCTURES & BREAKWATERS, THOMAS TELFORD, 2005, London. **Proceedings of the...** London: [S.n], 2005. p. 259-268.

VAN DER MEER, J. W. The new wave overtopping database for coastal structures. **Coastal Engineering**, Amsterdam, v. 35, n.41, p. 108–120,2009.

VAN GENT, M. R. A.; VAN DEN BOOGAARD, H. F. P. Neural network modelling of forces on vertical structures. PROCEEDINGS OF THE INTERNATIONAL CONFERENCE COASTAL ENGINEERING, 26, 1998, Copenhagen. **Proceedings of the...** Denmark: ASCE, 1998. p. 2096-2109.

VAN GENT, M. R. A.; POZUETA, B.; VAN DEN BOOGAARD, H. F. P.; MEDINA, J. R. **D42 Final Report on generic prediction method**. Valencia: CLASH. WL Delft Hydraulics and Universidad Politecnica de Valencia, Dezembro 2005. 33 p.

VERHAEGHE, H. **Neural network prediction of wave overtopping at coastal structures**. 2005. Tesis (Doctor) - Universiteit Gent, Belgium 2005.

VON ZUBEN, F. J. Uma caricatura funcional de redes neurais artificiais. **Learning and Nonlinear Models**. Rio de Janeiro, v. 1, n. 2, p. 77-87, 2003.

WASSERMAN, P. D. **Neural computing: theory and practice**. New York: Van Nostrand Reinhold, 1989. 254 p.

WESTRA, M. R.; VAN VLEDDER, G. ; VAN BANNING, G. K. F. M.; HURDLE, D. P. Predicting water levels using artificial neural networks. In: PROCEEDINGS OF THE INTERNATIONAL CONFERENCE ON COASTAL ENGINEERING, 28, 2002, Cardiff. **Proceedings of the...** Cardiff: ASCE, 2002. p. 1292-1302.

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

ZADEH, L. Fuzzy sets. **Information and Control**, New York, v. 8, n. 3, p. 338-353, 1965.