

# Rede ARTMAP Nebulosa Aplicada ao Estudo de Agitação Marítima no Porto de Sines/Portugal

Francisco L. dos Santos, Anna Diva P. Lotufo e  
Geraldo de F. Maciel  
UNESP/UNEMAT  
Ilha Solteira – São Paulo - Brasil  
[francisco\\_lledo@yahoo.com.br](mailto:francisco_lledo@yahoo.com.br),  
[annadiva@dee.feis.unesp.br](mailto:annadiva@dee.feis.unesp.br) e [maciel@dec.feis.unesp.br](mailto:maciel@dec.feis.unesp.br)

Maria Teresa Reis e Conceição Juana Fortes  
Laboratório Nacional de Engenharia Civil - LNEC  
Lisboa - Portugal  
[treis@lnec.pt](mailto:treis@lnec.pt) e [jfortes@lnec.pt](mailto:jfortes@lnec.pt)

**Resumo** — Neste trabalho, é descrito a aplicação de um sistema de redes neurais ARTMAP-Fuzzy na previsão de agitação marítima na costa oeste portuguesa e, mais concretamente, no Porto de Sines. O treinamento desta rede neural é efetuado com dados de medição de boia-ondógrafo ao largo do porto e resultados do modelo numérico de propagação de ondas na zona de entrada do porto, de 01/07/2010 a 30/06/2012. Posteriormente, avaliou-se o desempenho da rede quer para diferentes meses e uma semana selecionados aleatoriamente no anterior período, quer para um ano desconhecido à rede, o de 2009. Estes testes mostram as potencialidades e limitações da rede neste tipo de aplicações.

**Palavras-Chaves** — Redes Neurais Artificiais – ARTMAP Fuzzy – Agitação Marítima

## I. INTRODUÇÃO

A ocupação de zonas costeiras sempre foi muito atrativa para o ser humano. Associada a essa ocupação reside a tentativa de amenizar os efeitos naturais, com estruturas de proteção a serem projetadas a fim de garantir qualidade de vida e segurança às populações.

Os riscos associados a zonas costeiras e portuárias são uma das principais preocupações no planeamento e gestão destas zonas. Exemplos desses riscos são os associados aos fatores: à instabilidade de estruturas marítimas de proteção, à ocorrência de galgamentos, à inundação, à erosão costeira e à navegação. As consequências de situações indesejadas podem ser graves quando existe manifesta falta de segurança, nomeadamente no que se refere a perdas de bens materiais, de vidas e a consequências para o meio ambiente (Fig. 1). O exposto justifica a importância crescente do desenvolvimento de metodologias capazes de avaliar o risco neste tipo de situações.

Atendendo à natureza das zonas costeiras e portuárias, o cumprimento do acima proposto se traduz em necessidade de caracterização da agitação marítima nestes locais. Para isso, realiza-se a integração de dados de agitação marítima, 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.



Fig. 1. Ilustração de situações de risco associadas a zonas costeiras e portuárias (Arquivo Fotográfico do LNEC).

No que diz respeito a medições da agitação marítima, embora sejam a metodologia mais confiável, na maioria dos locais são escassas, pontuais ou mesmo inexistentes. No caso da modelação numérica, a utilização de modelos de propagação e deformação da agitação marítima 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 da agitação marítima do largo até à costa. 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. Nas últimas décadas, técnicas baseadas em redes neurais artificiais têm-se

mostrado muito úteis na prática da Engenharia [1], mas apresentam ainda limitações relacionadas essencialmente com a falta de capacidade de generalização. Outro fator de relevante importância, é a utilização somente de redes do tipo MLP (Perceptron Multi Camadas), as quais são apresentadas com diversas topologias recentemente [2].

Na tentativa de sobressair essas limitações supracitadas é que, neste âmbito, é apresentada uma aplicação de Redes Neurais Artificiais tipo ARTMAP-Fuzzy, na caracterização da agitação marítima, utilizando para o seu treinamento dados medidos por uma boia-ondógrafo e resultados de modelação numérica, de 01/07/2010 a 30/06/2012. O caso de estudo é o Porto de Sines, na costa Oeste de Portugal. São efetuados posteriormente testes com a rede, para avaliação do seu desempenho, considerando diferentes períodos de tempo, quer incluídos no período de treinamento, quer fora desse período.

## II. ESTADO DA ARTE

### A. Redes Neurais Artificiais ART

Com o intuito de simular a capacidade humana de aprendizagem, através de estruturas semelhantes à rede neural biológica, surgiram as Redes Neurais Artificiais (RNAs). Estas, por sua vez, são uma forma de programação não algorítmica, baseada em processamento distribuído paralelo de suas unidades, os neurônios artificiais. Uma construção bastante popular no domínio de reconhecimento de padrões é a rede multicamada, 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. Uma vez treinada, se apresentado um exemplo novo, sozinho, à rede, informações anteriores podem ser perdidas no processo. Sendo assim, passa-se a analisar outra família de redes, a saber: redes ART.

As redes denominadas ART (*Adaptive Resonance Theory*) [3] parecem resolver satisfatoriamente estes requisitos. A camada de reconhecimento (Y) classifica a entrada, resultando o neurônio com maior valor na função de ativação. Esta envia os resultados de volta à camada de comparação (X), capaz de avaliar se a classificação escolhida corresponde razoavelmente à entrada. Esta comparação resulta na classificação definitiva ou na criação de um novo neurônio na camada de reconhecimento, para este novo exemplo.

A teoria de Ressonância Adaptativa, ou ART, foi introduzida como uma teoria sobre o processamento cognitivo de informações no cérebro humano. Essa teoria levou ao desenvolvimento de uma série de modelos de redes neurais capazes de um aprendizado não supervisionado para classificação de padrões em tempo real. Os modelos nessa família compreendem: a rede ART<sub>1</sub>, que pode aprender a categorizar padrões de entrada binários apresentados em ordem arbitrária; a rede ART<sub>2</sub>, que pode aprender a categorizar padrões de entrada analógicos ou binários; e a rede ART<sub>3</sub>, que pode fazer uma busca paralela, ou teste de hipóteses, em códigos com reconhecimento distribuído.

A incorporação de elementos de lógica nebulosa no modelo ART clássico, possibilitou o tratamento analógico de imprecisão, característicos da maneira como a linguagem representa o mundo. Os modelos conhecidos como Fuzzy ART [4] possuem tais características. A proposta de construção de um ser artificial com memória consiste, portanto, na construção de um modelo desta natureza.

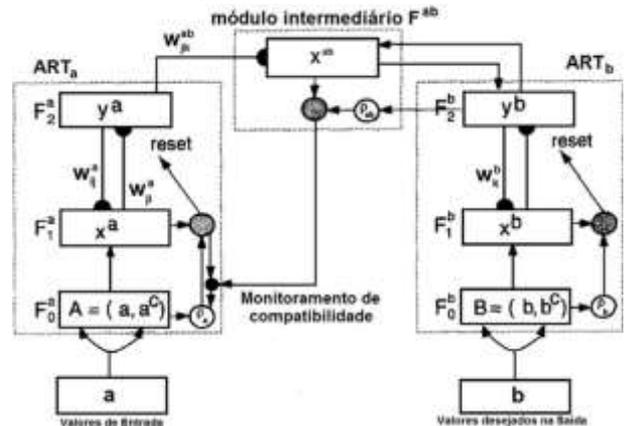


Fig 2. Modelo Adaptado de ARTMAP-Fuzzy [5].

O desenvolvimento do modelo FAM (ARTMAP-Fuzzy), ilustrado na Fig. 2, permitiu a adaptação da rede ARTMAP para a utilização de padrões analógicos tanto na entrada como na saída. A rede ARTMAP-Fuzzy é uma generalização da rede binária ARTMAP. Ela é capaz de um aprendizado supervisionado incremental, atualizando-se durante a operação sem “esquecer” o que já aprendeu anteriormente. A rede ARTMAP-Fuzzy pode ser usada para classificação e/ou associação de padrões binários e/ou analógicos de entrada e saída com dimensão arbitrária (sendo esse último considerado nessa comunicação). Este modelo é constituído de dois módulos Fuzzy ART, ART<sub>a</sub> e ART<sub>b</sub>, ligados por um módulo intermediário F<sub>ab</sub>. As operações realizadas internamente na propagação dos sinais são alteradas para as operações definidas pela lógica nebulosa, trabalhando com conjuntos e operadores nebulosos.

O módulo ART<sub>a</sub> realiza o reconhecimento dos valores de entrada e a ART<sub>b</sub> dos valores desejados na saída. O módulo de interconexão é utilizado no treinamento para mapear entrada e saída.

### B. Área de Estudo

O Porto de Sines localiza-se no Sudoeste da Europa, na costa Oeste de Portugal Continental, a 58 milhas náuticas a sul de Lisboa, no cruzamento das principais rotas marítimas internacionais - Este-Oeste e Norte-Sul (Fig. 3).

Com uma construção recente (1978), dispõe de um ordenamento de referência, livre de pressões urbanas, com excelentes acessibilidades marítimas sem constrangimentos e é uma das principais entradas comerciais e econômicas da Península Ibérica, considerando-se um porto de extrema importância geográfica e estratégica para Portugal e Espanha.

É um porto aberto ao mar, de águas profundas, abrigado por dois molhes principais, o Oeste e o Este, que protegem um conjunto de cinco terminais (terminal XXI, terminal de gás

natural liquefeito, terminal petrolífero, terminal petroquímico e terminal multiusos), o porto de recreio, o porto de pesca e a praia Vasco da Gama. Devido aos modernos terminais especializados, pode movimentar os diferentes tipos de mercadorias, sendo líder nacional na quantidade de mercadorias movimentadas (essencialmente grãos líquidos e sólidos) e apresentando condições naturais ímpares para acolher todos os tipos de navios.



Fig. 3. Porto de Sines.

O Porto de Sines apresenta um elevado potencial de crescimento para ser uma referência ibérica, europeia e mundial. De fato, o porto e a sua zona industrial e logística de retaguarda, com mais de 2.000 ha, são já uma plataforma logística de âmbito internacional com capacidade para receber os grandes atores dos setores marítimo-portuário, industrial e logístico.

No entanto, dada a sua configuração portuária e tratando-se de um porto de águas profundas, está especialmente desprotegido a temporais vindos do setor oeste e sul. Torna-se assim importante a caracterização da agitação marítima no porto de modo a assegurar as condições de segurança, quer para a navegação, quer para a operacionalidade portuária.

Nesse âmbito, o porto dispõe de uma boia-ondógrafo localizada ao largo do porto ( $37^{\circ}55'N$  e  $08^{\circ}55'W$ ), designada por “Sines 1D”, em fundos da ordem de -93 m (ZH), cujos dados são disponibilizados pelo Instituto Hidrográfico. Em condições normais, os parâmetros das ondas, tais como a altura de onda significativa (HS), o período médio (TZ) e a direção da onda (DIR), são determinados de hora a hora, baseados em medições da boia com uma duração de 20 minutos. Por outro lado, para a previsão das condições de agitação marítima na zona de entrada do porto, e em particular no Ponto P (Fig. 3), que se localiza numa profundidade de -40 m (ZH) em frente ao trecho do molhe Oeste que protege o posto 2 do terminal de grãos líquidos, recorre-se à modelação numérica, e, mais concretamente, ao modelo de propagação e deformação da agitação SWAN [6], utilizando como forçamento os dados da boia. Os resultados (HS, TZ, DIR) neste ponto foram obtidos entre maio de 1988 e dezembro

de 2002. A Tabela 1 apresenta os valores estatísticos dos máximos, médias, mínimos, desvios padrões e gamas mais frequentes dos parâmetros HS, TP e DIR na boia e os resultados correspondentes obtidos no Ponto P por aplicação do modelo SWAN. Estes resultados são a base do treinamento da rede neuronal que se pretende aplicar na caracterização da agitação marítima em frente ao molhe Oeste do Porto de Sines.

TABELA 1. PARÂMETROS ESTATÍSTICOS DA BOIA DE SINES E NO PONTO P.

Local	Parâmetros	Máximo	Média	Mínimo	Desvio Padrão	Gama mais Frequente
<b>Estatísticos</b>						
Boia	HS (m)	7,35	1,60	0,27	0,90	[1,0 - 2,0] (48,05%)
	TP (s)	1,0	8,8	4,2	2,3	[6,0 - 7,0] (17,78%)
	DIR ( $^{\circ}$ )	358,0	299,0	5,0	18,6	[300 - 310] (32,68%)
Ponto P	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 ( $^{\circ}$ )	352,7	302,8	71,8	24,7	[310 - 320] (32,34%)

### III. METODOLOGIA

Foi desenvolvido o algoritmo ARTMAP-Fuzzy em plataforma MatLab® com tratamento gráfico em plataforma EXCEL®. As lacunas no banco de dados foram eliminadas (dados faltantes). O processador utilizado foi um Intel® Core i7 2.2 GHz – 8 GB RAM. Os parâmetros da rede adotados após uma análise de sensibilidade prévia foram:  $\beta = 1,0$  (taxa de treinamento rápida),  $\alpha = 0,1$  (parâmetro de escolha da categoria),  $\rho_a$  (inicial) = 0,10 e  $\rho_{ab} = 0,95$  (parâmetros de vigilância – ART<sub>a</sub> e do Módulo InterART<sub>ab</sub>),  $\rho_b = 1,0$  (parâmetro de vigilância da ART<sub>b</sub>),  $\epsilon = 0,001$  (acréscimo no parâmetro de vigilância da ART<sub>a</sub>).

Usou-se como valores de entrada a altura de onda, o período de onda e a direção de onda ao largo (medições na boia de Sines). Os valores que foram utilizados para saída são, respectivamente, altura de onda, período de onda e direção de onda na costa (i.e., no ponto P). Treinou-se a rede com dados num intervalo de dois anos (01/07/2010 a 30/06/2012), aproximadamente 5850 valores. A posteriori, efetuou-se o diagnóstico (teste) para alguns meses aleatórios, meses esses compreendidos na primavera, verão, outono e inverno. Com esse mesmo treinamento, efetuou-se o diagnóstico para uma semana aleatória. Foi efetuado também o teste para um ano desconhecido da série de treinamento (01/01/2009 a 22/11/2009). Os resultados são apresentados no ponto seguinte.

### IV. RESULTADOS

As Fig. 4 a Fig. 9 apresentam os resultados obtidos dos casos estudados em forma gráfica. O tempo total de treinamento foi de 7.270,98 s, aproximadamente 2 horas de cálculo.

As Tabelas 2 a 4 contêm, para cada caso estudado, os valores calculados do erro médio percentual absoluto (MAPE), do erro médio quadrático (RMSE), da média ( $\mu$ ) e do desvio padrão ( $\sigma$ ) dos erros viés (EV) para HS, TP e DIR, respetivamente.

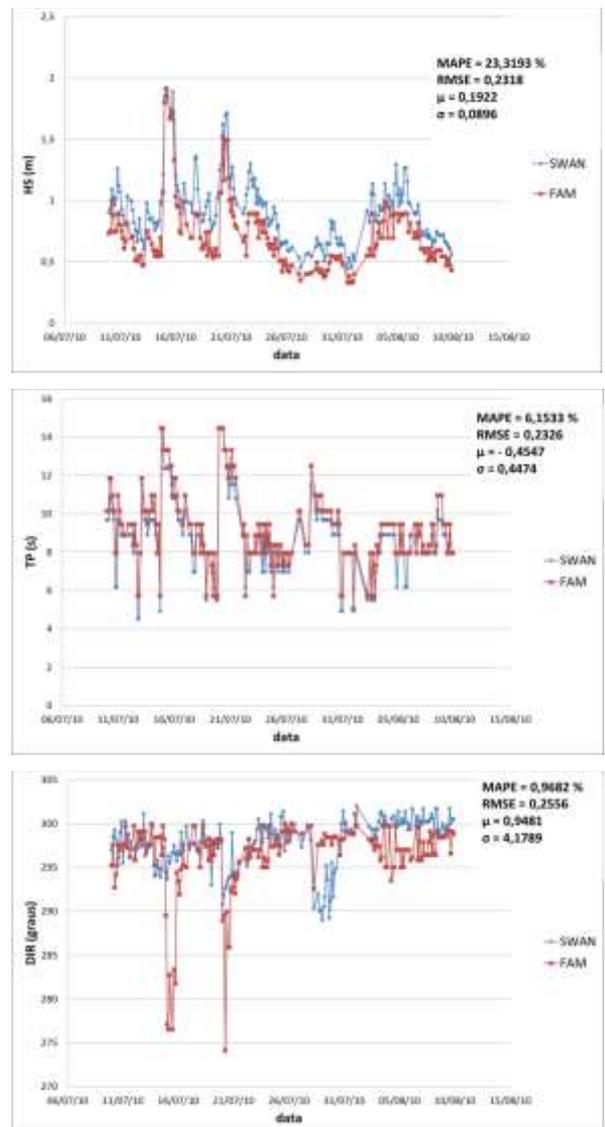
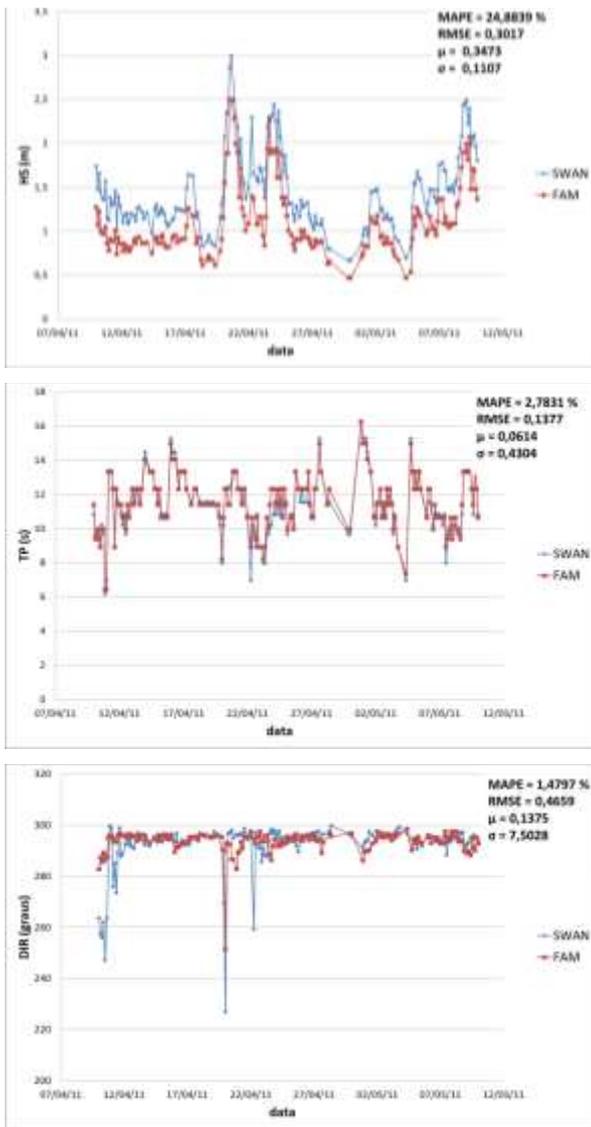


Fig. 4. Comparação ARTMAP-Fuzzy com os dados de HS, TP e DIR do SWAN na costa – PRIMAVERA (10/04/2011 a 10/05/2011).

Fig. 5. Comparação ARTMAP-Fuzzy com os dados de HS, TP e DIR do SWAN na costa – VERÃO (10/07/2010 a 10/08/2010).

$$MAPE = \frac{1}{N} \sum_{n=1}^N \frac{100 \cdot |C^{Swan}(n) - C^{FAM}(n)|}{C^{Swan}(n)}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (C^{Swan}(n) - C^{FAM}(n))^2}$$

$$EV = C^{Swan}(n) - C^{FAM}(n)$$

TABELA 2. MAPEAMENTO DOS ERROS DE HS.

CASO	MAPE (%)	RMSE (m)	Erro Viés	
			$\mu$ (m)	$\sigma$ (m)
PRIMAVERA	24,88	0,30	0,35	0,11
VERÃO	23,32	0,23	0,19	0,09
OUTONO	8,38	0,18	0,22	0,23
INVERNO	26,01	0,31	0,33	0,15
SEMANA	12,48	0,16	0,18	0,08
PERIODO DESC.	13,24	0,19	0,20	0,17

TABELA 3. MAPEAMENTO DOS ERROS DE TP.

CASO	MAPE (%)	RMSE (m)	Erro Viés	
			$\mu$ (m)	$\sigma$ (m)
PRIMAVERA	2,78	0,14	0,06	0,43
VERÃO	6,15	0,23	0,45	0,45
OUTONO	0,20	0,04	0,00	0,13
INVERNO	0,18	0,04	0,00	0,15
SEMANA	3,68	0,18	-0,13	0,45
PERIODO DESC.	0,07	0,02	0,00	0,07

TABELA 4. MAPEAMENTO DOS ERROS DE DIR.

CASO	MAPE (%)	RMSE (m)	Erro Viés	
			$\mu$ (m)	$\sigma$ (m)
PRIMAVERA	1,48	0,47	0,14	7,50
VERÃO	0,97	0,26	0,95	4,18
OUTONO	2,91	0,70	-4,32	8,90
INVERNO	2,05	0,54	-2,87	7,79
SEMANA	2,48	0,49	6,49	4,25
PERIODO DESC.	2,88	0,70	-4,67	8,71

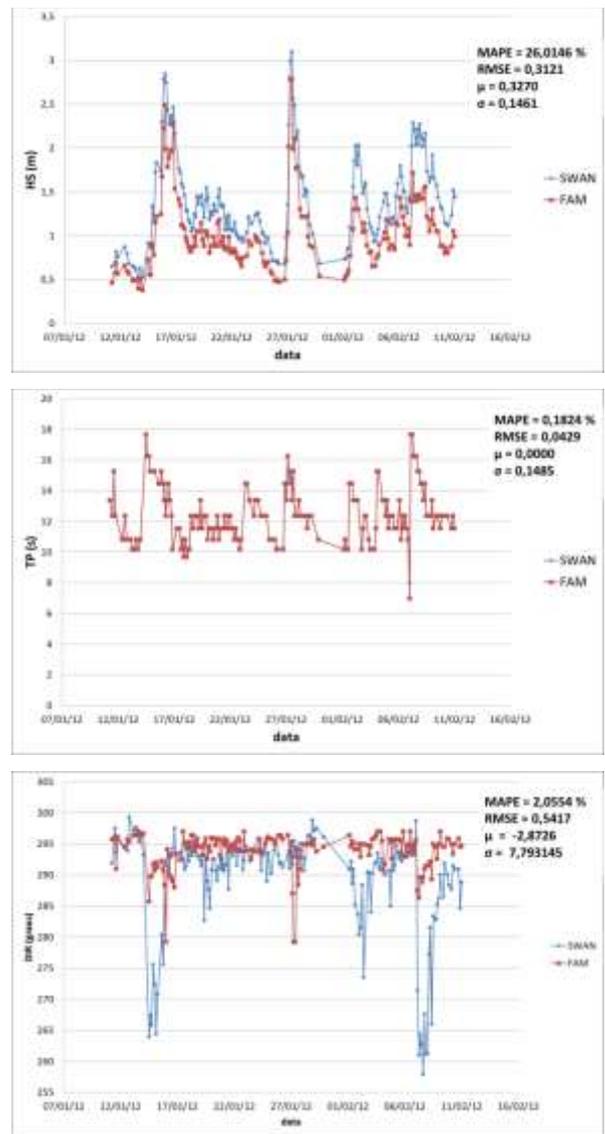
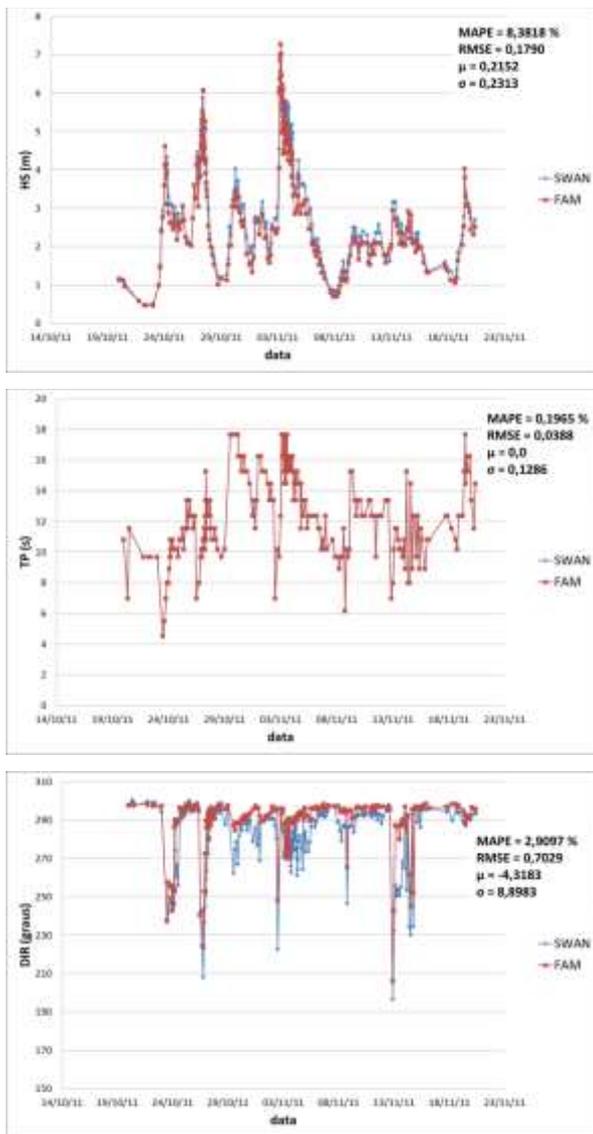


Fig. 6. Comparação ARTMAP-Fuzzy com os dados de HS, TP e DIR do SWAN na costa – OUTONO (20/10/2011 a 20/11/2011).

Fig. 7. Comparação ARTMAP-Fuzzy com os dados de HS, TP e DIR do SWAN na costa – INVERNO (11/01/2012 a 11/02/2012).

## V. DISCUSSÃO E CONCLUSÕES

Dos resultados apresentados, pode-se verificar que:

- As alturas significativas (HS) em todos os casos da rede ARTMAP parecem estar subdimensionadas, mesmo que pouco, quando comparadas aos resultados do modelo SWAN, (correção essa a ser analisada em trabalhos futuros);

- Para o caso dos períodos de pico (TP) e das direções (DIR) das ondas, existem alguns casos em que os resultados apresentados pela rede estão sobredimensionados;

- Em geral, os resultados fornecidos pela rede em todos os casos acompanham o perfil das alturas, dos períodos e das direções de onda na costa, sugerindo uma boa adaptação da rede aos resultados do modelo SWAN;

- Os resultados da rede para o período desconhecido são muito positivos, sendo DIR a variável menos bem representada pela rede;

- A análise comparativa dos erros das variáveis em questão (HS, TP e DIR) indica que para a altura significativa (HS) e para o período de pico (TP) o comportamento da rede se mostrou mais adequado, alternando com valores de erros maiores ou menores. Já, para os valores das direções a rede apresentou, em quase todos os casos, erros superiores aos obtidos na representação de HS e TP;

- O tempo de treinamento com aproximadamente 5.850 dados (dois anos completos) é baixo, menos de 125 minutos. O tempo de cálculo é inferior a 2,0 s para um cálculo e a 30,0 s para a série desconhecida.

A análise efetuada aponta para a necessidade de variar numa escala bem mais ampla os parâmetros da rede, bem como treinar a rede para uma base de dados mais longa - 10 anos (realizar-se-á a posteriori). Será também interessante a aplicação da rede para estimação dos valores da agitação marítima no interior do porto, onde outros efeitos mais complexos, como a difração e a reflexão das ondas, estão presentes.

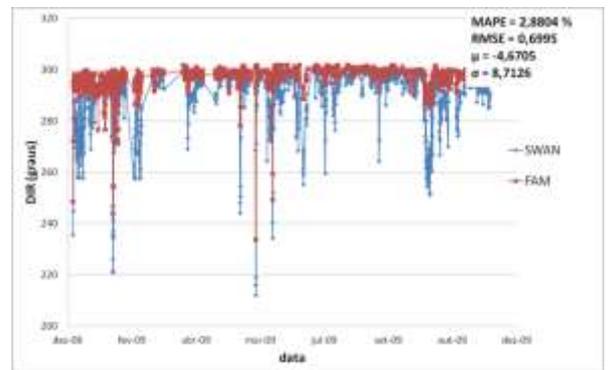
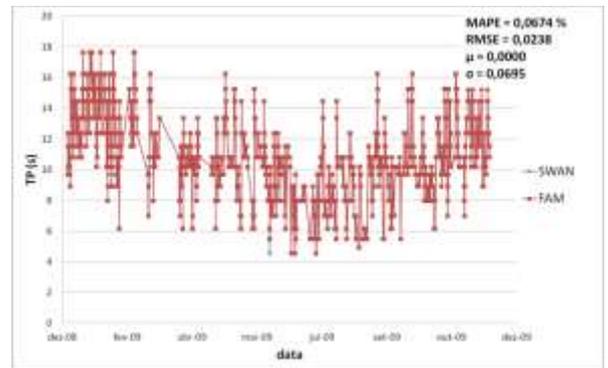
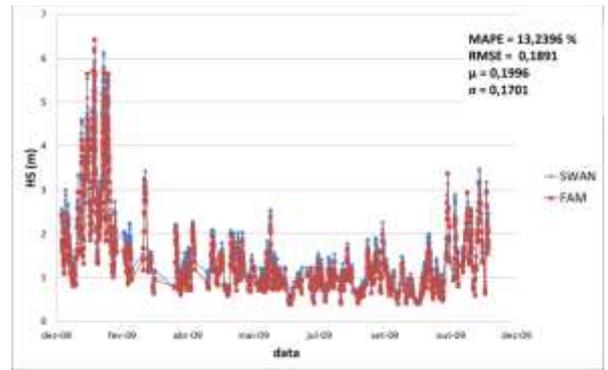
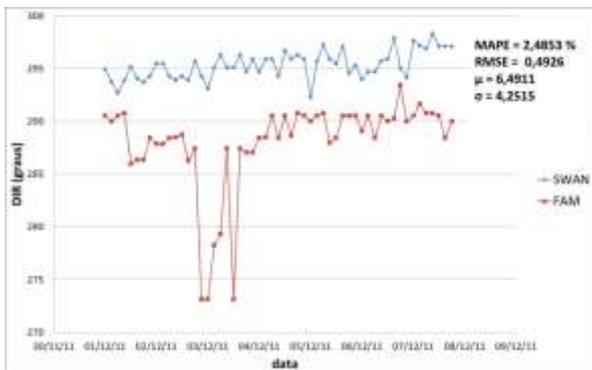
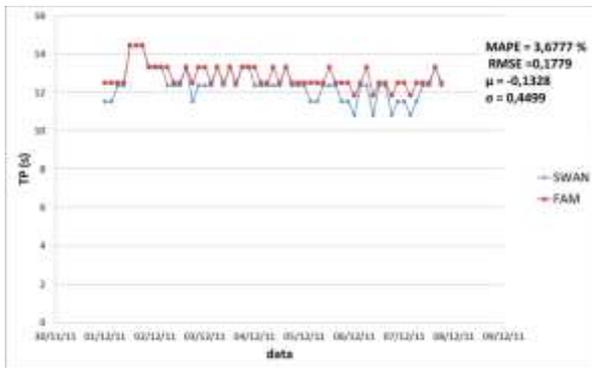
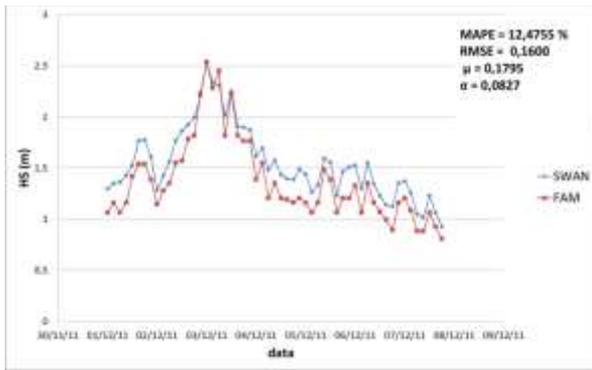


Fig. 8. Comparação ARTMAP-Fuzzy com os dados SWAN na costa – SEMANA (01/12/2011 a 07/12/2011).

Fig. 9. Comparação ARTMAP-Fuzzy com os dados de HS do SWAN na costa para o período desconhecido da rede (01/01/2009 a 22/11/2009).

### AGRADECIMENTOS

- Fundação CAPES, Ministério da Educação do Brasil, Brasília. Processo: 18911-12-9.
- Fundação para a Ciência e a Tecnologia, Portugal, Suporte Financeiro através do Projeto HIDRALERTA - PTDC/AAC-AMB/120702/2010.
- Administração do Porto de Sines, S.A., Portugal, Autorização do uso dos dados da boia de Sines e sua publicação.

### REFERÊNCIAS

[1] S.N. Londhe e M.C. Deo. "Artificial neural networks for wave propagation", J. Coastal research, Vol. 20, No. 4, pp. 1061-1069, 2004.

[2] H. Verhaeghe. "Neural Network Prediction of Wave Overtopping at Coastal Structures". Belgium: Universiteit Gent – Tese de Doutorado. 2005.

[3] G.A. Carpenter e S. Grossberg. "A massively parallel architecture for a self-organizing neural pattern recognition machine," Computer Vision, Graphics, and Image Processing, Vol. 37, pp. 54-115, 1987.

[4] G.A. Carpenter; S. Grossberg e J.H. Reynolds. "ARTMAP: Supervised real-learning and classification of non-stationary data by a self-organizing neural network," Neural Network, Vol. 4, No. 5, pp. 565-588, 1991.

[5] G.A. Carpenter; S. Grossberg et al. "Fuzzv ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps." IEEE Transactions on Neural Networks, Vol 3, No 5, 1992.

[6] B.N. Booij; R.C. Ris e L.H. Holthuijsen. "A third-generation wave model for coastal regions, Part I, Model description and validation," J. Geophysical Research, Vol. 104, C4, pp. 7649-7666, 1999.