

APLICAÇÃO DE REDES NEURONAIS NA INTER-RELAÇÃO DE PARÂMETROS DE AGITAÇÃO AO LARGO E JUNTO À COSTA

António Alberto Pires Silva

Departamento de Engenharia Civil, Instituto Superior Técnico
Av. Rovisco Pais 1049-001, Lisboa

Oleg Makarynskyy

Departamento de Engenharia Civil (Bolseiro FCT de Pós-Doutoramento), Instituto Superior Técnico
Av. Rovisco Pais 1049-001, Lisboa

Carlos Ventura Soares

Divisão de Oceanografia, Instituto Hidrográfico
Rua das Trinas 49, 1249-093 Lisboa

SUMÁRIO

Na presente comunicação aplicou-se o conceito de redes neuronais artificiais para representar séries temporais de parâmetros integrais de agitação marítima, como a altura significativa e o período médio de zero ascendente, estimadas a partir de medições simultâneas obtidas em pontos espacialmente diferentes. As observações em causa foram realizadas simultaneamente ao largo e junto à costa, numa área adjacente à praia de Pinheiro da Cruz, a norte de Sines. No primeiro caso, o sensor utilizado foi a bóia direccional tipo "WAVEC", fundeada em sonda reduzida de 97 m, e explorada operacionalmente desde 1988 pelo Instituto Hidrográfico. Junto à costa esteve instalado um sensor de pressão a uma profundidade de 10 m (ZH). O período total de medição decorreu de 9 de Dezembro de 1999 a 13 de Janeiro de 2000. Foram também utilizadas séries de valores simulados pelo modelo WAM, em ponto da malha próximo da localização da bóia. Os valores da altura significativa e do período médio de zero ascendente obtidos do modelo foram combinados com os correspondentes valores estimados das observações de campo.

As redes neuronais constituem uma técnica de modelação empírica que se tem revelado apropriada para representar sistemas não lineares. No presente caso, foi usada uma arquitectura de três camadas, com uma função de transferência sigmóide na camada oculta e uma função linear na saída. No treino da rede foi utilizado o algoritmo de retropropagação, com um gradiente descendente sobre todo o vector de pesos da rede e uma função de erro quadrático.

Os resultados, que incluem gráficos das séries temporais simuladas, gráficos de comparação e estatísticas de verificação, como o valor médio quadrático, o coeficiente de correlação e um coeficiente de variação, mostram que a altura significativa é representada com boa precisão. Por outro lado, as comparações relativas ao período médio de zero ascendente não são satisfatórias. Todavia, a inclusão de valores simulados pelo modelo WAM permite melhorar a qualidade da representação deste último parâmetro.

INTRODUÇÃO

A extensão da linha de costa portuguesa e a dificuldade inerente a observações de campo num meio hostil como o ambiente marinho, concorrem para tornar o seu custo apreciável, quer do ponto de vista do investimento inicial, quer da manutenção, especialmente no caso de uma rede de exploração operacional. Estes factos sentem-se com particular acuidade no caso das observações da agitação marítima. A grande maioria destas faz-se com recurso a bóias ondógrafo. Em águas pouco profundas são também utilizados outro tipo de equipamentos, de que são exemplo os sensores de pressão e os perfiladores acústicos por efeito doppler. As informações recolhidas tem vasto campo de aplicações, directas ou indirectas. No caso das primeiras podem citar-se a aferição de modelos de simulação numérica da propagação das ondas de superfície geradas pelo vento, e a correcção do viés de carácter sistemático que afecta os sensores de detecção remota. Acresce ainda que os algoritmos necessários à estima do espectro direccionado, com base neste tipo de medições, conduzem a uma indeterminação de 180 graus, de carácter essencial, que requer uma estimativa inicial para se resolver.

Deste modo, correlacionar medições obtidas em diferentes localizações tem grande interesse e pode ser útil numa situação de existência de estações permanentes em simultâneo com campanhas temporárias.

Diversas metodologias podem ser empregues para alcançar este objectivo, como sejam os modelos de resolução de fase ou espectrais de média em fase, ambos com uma base fenomenológica física. A partir de diferentes aproximações aos princípios fundamentais da mecânica de fluidos, que se traduzem num conjunto de equações diferenciais e consequente discretização numérica, estes modelos representam os fenómenos físicos pertinentes à propagação da agitação marítima nas escalas envolvidas.

No presente trabalho adoptou-se uma perspectiva diferente, mais restrita, no sentido que não se baseia na modelação explícita dos referidos fenómenos. A metodologia usada considera o domínio entre os pontos distintos do espaço como um sistema, em que as entradas são os valores das séries temporais de parâmetros integrais observados numa determinada localização e as saídas valores dos mesmos parâmetros noutra ponto. O sistema foi modelado com redes neuronais artificiais que constituem um sistema de processamento paralelo de carácter empírico.

Esta capacidade das redes neuronais de simular sistemas complexos, sem a consideração formal das suas relações internas, tem sido recentemente aproveitada em estudos de engenharia costeira. As aplicações estendem-se desde avaliação da estabilidade de quebra-mares de talude (*Mase et al.*, 1995) até à previsão do perfil de praias (*Tsai et al.*, 2000), níveis de maré (*Tsai and Lee*, 1999), níveis do mar (*Roske*, 1997), correntes marítimas (*Babovic*, 1999), alturas de ondas (*Deo et al.*, 2001) e sobrelevação de origem meteorológica (*Sztobryn*, 2003).

Makarynsky et al. (2002a) aplicaram redes neuronais artificiais para prever directamente parâmetros de agitação marítima com horizontes de 3, 6, 12 e 24 horas. As previsões de curto prazo (até 6 horas) mostraram resultados promissores, excepto no caso do período de pico. Em *Makarynsky et al.* (2002b) são ensaiadas diversas configurações das redes neuronais e experimentados vários algoritmos de treino.

O plano da comunicação inclui, para além desta secção introductória, uma secção com uma breve referência à técnica das redes neuronais artificiais. Segue-se a descrição dos dados de agitação e as escolhas adoptadas para configurar a rede usada. A análise dos resultados conseguidos e considerações finais concluem o trabalho.

REDES NEURONAIS ARTIFICIAIS

As redes neuronais artificiais inspiram-se no sistema de ligações paralelas que caracteriza o cérebro humano, e que lhe confere grande robutez no processamento da informação (Fausett, 1994). A unidade de base constituinte da rede é o neurónio, representado esquematicamente na Figura 1. O valor de entrada (p) é multiplicado pelo peso (w) e sumado ao viés (b), formando o argumento (n) da função de activação (f) que origina a saída (a). Este processo pode ser repetido, constituindo a saída (a) a variável de entrada da camada seguinte.

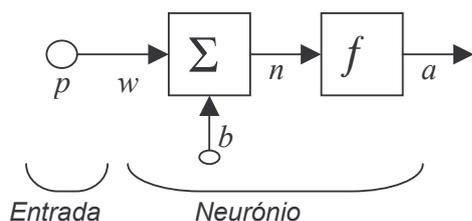


Figura 1. Representação esquemática de um neurónio com uma entrada singular.

Se a camada de entrada apresentar um número de nós N ($i=1, \dots, N$) e a primeira camada oculta for constituída por um número R de neurónios ($j=1, \dots, R$), então o argumento da função de activação do neurónio j é dado por

$$\sum_{i=1}^N p_i w_{ij} + b_j = n_j . \quad (1)$$

As redes podem ser formadas por uma ou várias camadas interligadas num padrão de interconexões pesadas entre as diversas unidades, caracterizando a arquitectura da rede particular escolhida. As funções de activação das camadas intermédias ocultas devem apresentar um comportamento não linear, necessário para simular sistemas físicos complexos (Haykin, 1999).

A fase de determinação do valor dos pesos e viés designa-se por treino. A partir das saídas da rede e de valores alvo constroi-se uma função objectivo, envolvendo as variáveis citadas. O ajustamento desta função, segundo um determinado critério, conduz aos valores óptimos dos pesos e viés no sentido do critério escolhido.

DADOS DE AGITAÇÃO MARÍTIMA E CARACTERÍSTICAS DAS REDES

As medições de campo associadas ao presente trabalho foram realizadas simultaneamente ao largo e junto à costa, numa área adjacente à praia de Pinheiro da Cruz, a norte de Sines (Pires Silva *et al.*, 2000). No primeiro caso, o sensor utilizado foi a bóia direccional tipo "WAVEC", fundeada em sonda reduzida de 97 m ao largo do porto de Sines, e explorada operacionalmente desde 1988 pelo Instituto Hidrográfico. Junto à costa esteve instalado um sensor de pressão a uma profundidade de 10 m (ZH). O período total de medição decorreu de 9 de Dezembro de 1999 a 13 de Janeiro de 2000. Os registos da posição da superfície livre do mar, obtidos pelos dois tipos de sensores, servem de base para a estima da função densidade espectral de energia. Seguidamente, foram calculadas a altura significativa ($H_s = \sqrt{4m_0}$) e o período médio de zero

ascendente ($T_{02}=\sqrt{m_0/m_2}$), em que m_n representa o momento espectral de ordem n . Estas grandezas formaram séries temporais com uma periodicidade de três horas.

Foram também utilizadas séries de valores simulados, dos parâmetros acima descritos, pelo modelo WAM em ponto da malha próximo da localização da bóia, e em período correspondente ao das observações. Este modelo WAM está implementado no Programa de Clima Marítimo (Ente Público Puertos del Estado – Espanha) e utiliza como função forçadora o campo de ventos do modelo de área limitada HIRLAM do Serviço Meteorológico Espanhol (*Carretero et al.*, 2000).

A totalidade do período de medição foi dividido em duas partes. A primeira, com uma extensão de 2/3 serviu de treino das redes. Neste, foi utilizado o algoritmo de retropropagação, com um gradiente descendente sobre todo o vector de pesos da rede e uma função de erro quadrático, como função objectivo a minimizar. O terço restante constituiu a parte de verificação.

A configuração da camada de entrada vai estar condicionada pela escolha do sentido da relação largo-costa ou a inversa. No primeiro caso visa-se reproduzir os valores medidos pelo sensor de pressão a partir de dois tipos de informação: a recolhida pela bóia e as saídas do modelo WAM. Para este fim usaram-se duas redes por parâmetro, o que dá um total de quatro (o que significa quatro treinos independentes). Em todos as situações a entrada foi formada por três nós, o que, atendendo à periodicidade acima referida, equivale a um intervalo de nove horas.

No caso da relação costa-largo o objectivo era simular os valores medidos pela bóia. Também aqui as entradas foram de dois tipos: conjunto de medições do sensor de pressão ao longo das últimas nove horas (três nós) e esta mesma informação combinada com a informação do modelo WAM correspondente à última medição, num total de quatro nós de entrada. A conjugação de dois tipos de entradas e dois parâmetros perfaz, também neste caso, um total de quatro redes.

As diversas redes usadas caracterizaram-se por uma arquitectura de três camadas, com uma função de activação log-sigmóide na camada oculta intermédia, constituída por sete nós (neurónios), e uma função linear na camada de saída. Esta apresenta dois nós, que correspondem ao valor da mais recente entrada no outro ponto do domínio (nowcast) e uma previsão a três horas (forecast).

ANÁLISE DE RESULTADOS

A avaliação do comportamento da metodologia proposta envolveu gráficos das séries temporais simuladas, gráficos de comparação e estatísticas de verificação, como o valor médio quadrático (VMQ), o coeficiente de correlação (R) e um coeficiente de variação (SI), cuja definição se apresenta de seguida

$$VMQ = \sqrt{\frac{\sum_{i=1}^N (y_i - x_i)^2}{N}}, \quad (2)$$

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}}, \quad (3)$$

$$SI = \frac{VMQ}{\bar{x}} \quad (4)$$

Nas expressões acima indicadas, x_i representa o valor observado no instante i , y_i o valor simulado no mesmo instante, N o número total de pontos de observação no período de verificação, \bar{x} o valor médio das observações e \bar{y} o valor médio dos valores simulados.

A Figura 2 apresenta a evolução temporal de H_s e T_{02} , ao longo de todo o período de observação, registada na bóia, no sensor de pressão e simulada pelo modelo WAM.

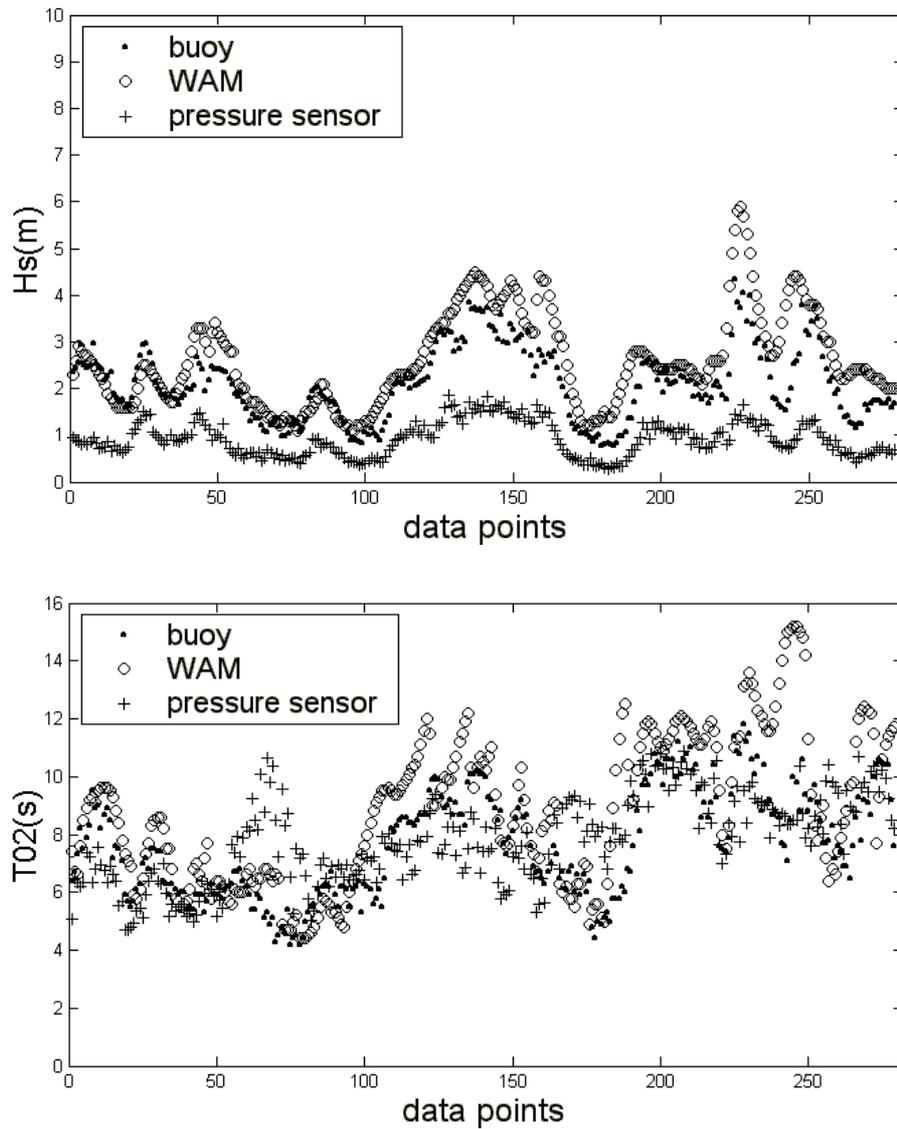


Figura 2. Evolução temporal de H_s e T_{02} de 9 de Dezembro de 1999 a 13 de Janeiro de 2000.

O gráfico de H_s mostra boa concordância entre as estimas obtidas da bóia e os resultados do modelo WAM, excepto na parte final do período. No que diz respeito a T_{02} pode constatar-se uma maior irregularidade e também menor distinção entre os valores medidos ao largo e junto à costa.

De seguida mostra-se um primeiro conjunto de gráficos de comparação entre os resultados das apropriadas redes neuronais e os valores medidos pelo sensor de pressão. Trata-se portanto, da relação largo-costa. Este conjunto diz respeito a H_s (Figuras 3 e 4) e T_{02} (Figuras 5 e 6). A Tabela 1 resume do ponto de vista quantitativo a informação apresentada nos gráficos.

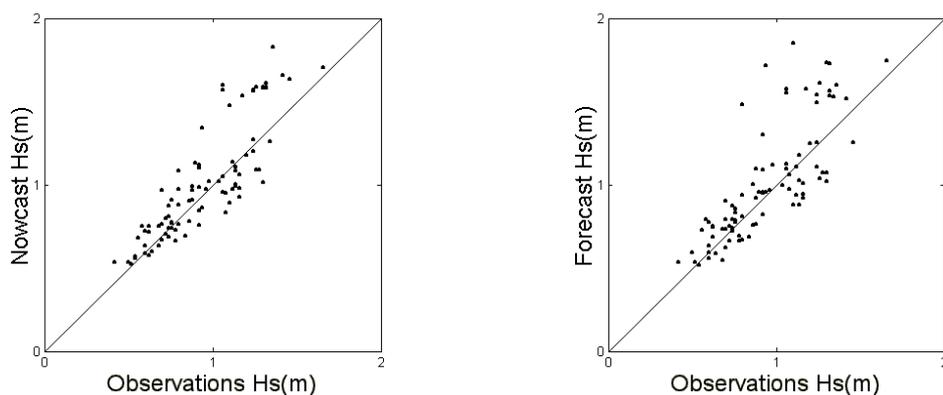


Figura 3. Comparação entre os valores de H_s obtidos pela rede neuronal e as observações do sensor de pressão usando a bóia como entrada (largo-costa).

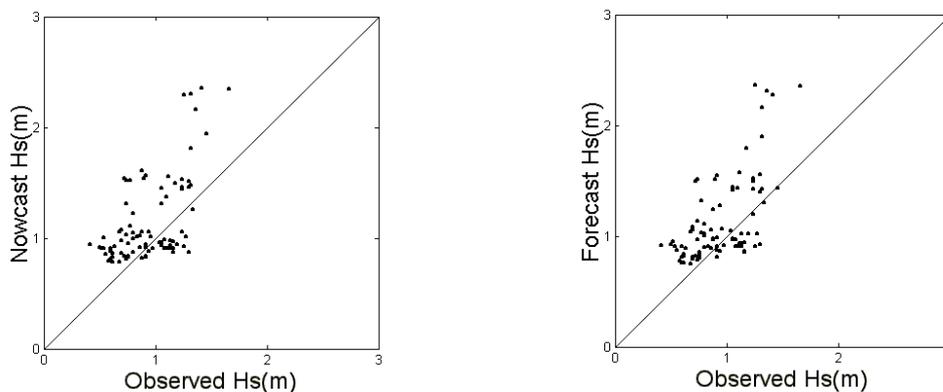


Figura 4. Comparação entre os valores de H_s obtidos pela rede neuronal e as observações do sensor de pressão usando o WAM como entrada (largo-costa).

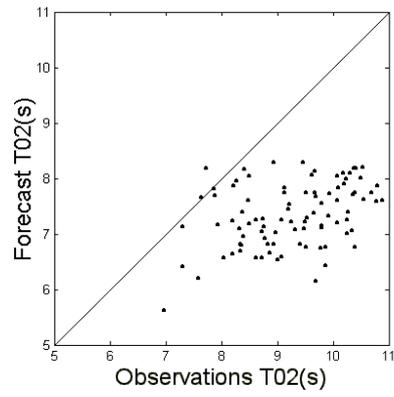
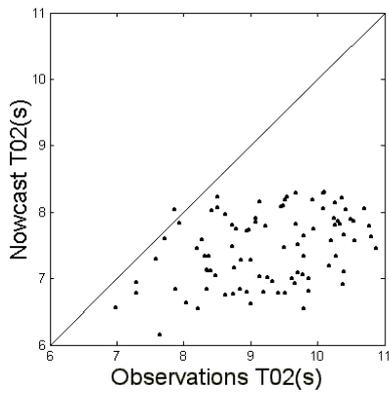


Figura 5. Comparação entre os valores de T_{02} obtidos pela rede neuronal e as observações do sensor de pressão usando a bóia como entrada (largo-costa).

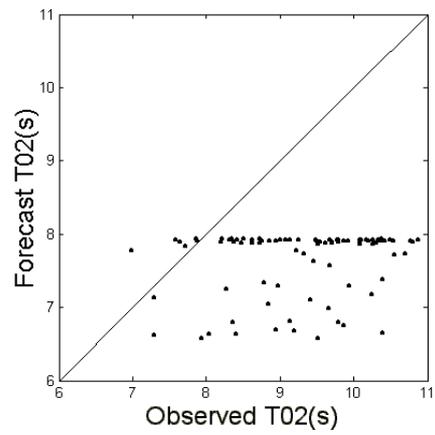
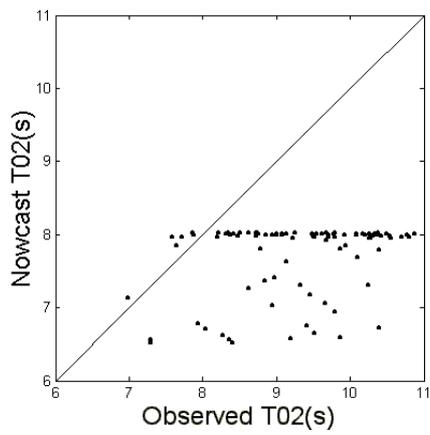


Figura 6. Comparação entre os valores de T_{02} obtidos pela rede neuronal e as observações do sensor de pressão usando o WAM como entrada (largo-costa).

Tabela 1. Estatísticas de comparação de H_s e T_{02} na relação largo-costa com diferentes entradas, usando as medições do sensor de pressão.

	nowcast			forecast		
	VMQ	R	SI	VMQ	R	SI
H_s						
bóia	0.18m	0.85	0.20	0.22m	0.78	0.23
WAM	0.37m	0.58	0.40	0.35m	0.61	0.38
T_{02}						
bóia	2.01s	0.38	0.22	2.12s	0.38	0.23
WAM	1.81s	0.27	0.20	1.88s	0.16	0.20

As Figuras 3 e 4 e a Tabela 1 mostram que a altura significativa é bem representada pelas redes neurais quando se usam como variáveis de entrada as medições da bóia, com uma ligeira degradação na previsão (forecast). Os resultados pioram para a situação de serem as simulações do modelo WAM as variáveis de entrada, não havendo diferença apreciável entre nowcast e forecast. No que diz respeito ao período médio de zero ascendente os resultados não são satisfatórios, qualquer que seja a forma das variáveis forçadoras (Figuras 5 e 6).

O conjunto de figuras que se segue mostra a comparação entre os resultados das apropriadas redes neurais e os valores medidos pela bóia, evidenciando a relação costa-largo. Este conjunto diz respeito a H_s (Figuras 7 e 8) e T_{02} (Figuras 9 e 10). A Tabela 2 resume do ponto de vista quantitativo a informação apresentada nos gráficos.

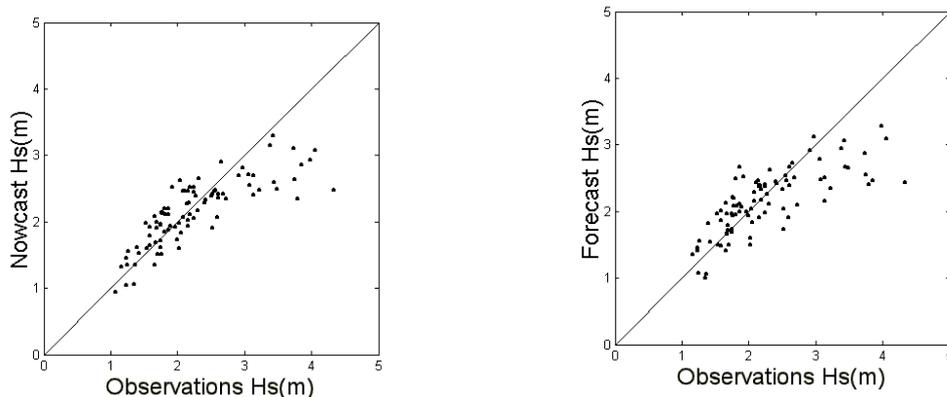


Figura 7. Comparação entre os valores de H_s obtidos pela rede neuronal e as observações da bóia usando o sensor de pressão como entrada (costa-largo).

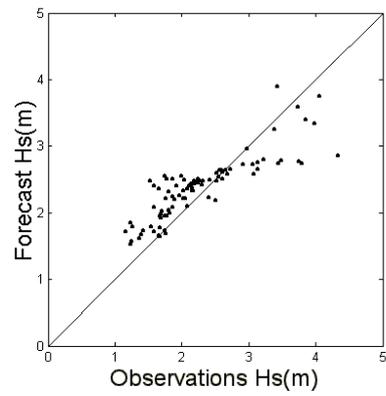
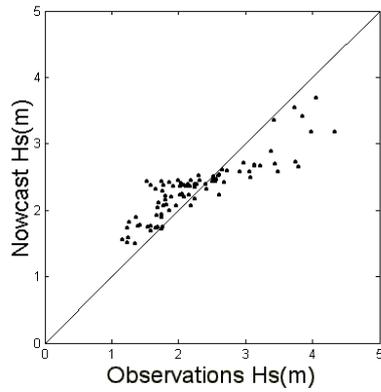


Figura 8. Comparação entre os valores de H_s obtidos pela rede neuronal e as observações da bóia usando o sensor de pressão combinado com o modelo WAM como entrada (costa-largo).

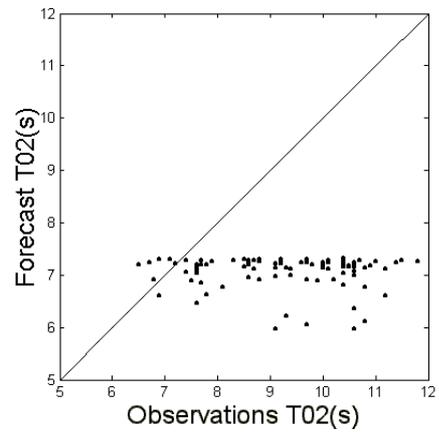
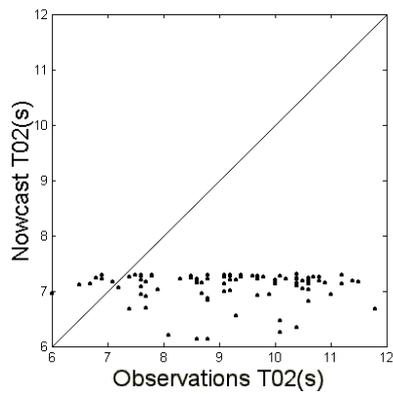


Figura 9. Comparação entre os valores de T_{02} obtidos pela rede neuronal e as observações da bóia usando o sensor de pressão como entrada (costa-largo).

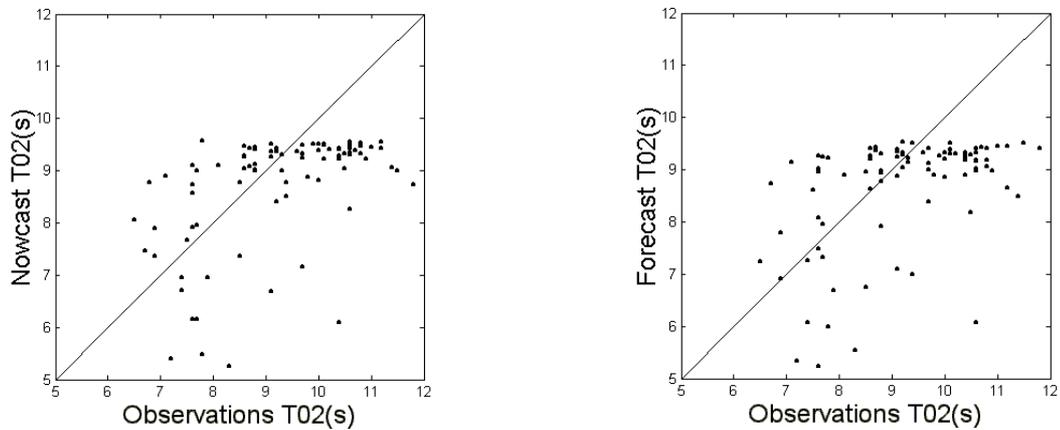


Figura 10. Comparação entre os valores de T_{02} obtidos pela rede neuronal e as observações da bóia usando o sensor de pressão combinado com o modelo WAM como entrada (costa-largo).

Tabela 2. Estatísticas de comparação de H_s e T_{02} na relação costa-largo com diferentes entradas, usando as medições da bóia.

	nowcast			forecast		
	VMQ	R	SI	VMQ	R	SI
H_s						
sensor de pressão	0.46m	0.82	0.20	0.50m	0.76	0.22
sensor de pressão + WAM	0.41m	0.88	0.18	0.42m	0.86	0.18
T_{02}						
sensor de pressão	2.54s	0.02	0.28	2.58s	-0.07	0.28
sensor de pressão + WAM	1.31s	0.51	0.14	1.35s	0.48	0.15

A qualidade da representação de H_s na relação costa-largo não é do mesmo nível da relação inversa. E a inclusão do valor simulado pelo WAM não traz uma alteração significativa (Figuras 7 e 8). A Figura 9 mostra que, nesta experiência, T_{02} não pode ser representado pelas redes neuronais escolhidas. A combinação com o valor do modelo WAM melhora sensivelmente os resultados (Figura 10).

APRECIÇÕES FINAIS

Neste trabalho aplicou-se a metodologia de redes neuronais artificiais para relacionar parâmetros integrais, como a altura significativa e o período médio de zero ascendente, em pontos espacialmente diferentes. Em particular, a bóia direccional tipo “WAVEC”, fundeada em sonda reduzida de 97 m ao largo do porto de Sines e um sensor de pressão instalado a uma profundidade de 10 m (ZH) constituíram as bases do estudo. As simulações foram levadas a cabo no sentido largo-costa e no sentido inverso. Neste último, os valores estimados a partir de medições foram combinados com simulações do modelo WAM.

As redes neuronais usadas tinham uma arquitectura de três camadas, com uma função de transferência log-sigmoid na camada oculta e uma função linear na saída.

Os resultados mostram que a altura significativa é representada com boa precisão. Por outro lado, as comparações relativas ao período médio de zero ascendente não são satisfatórias. Todavia, a inclusão de valores simulados pelo modelo WAM permite melhorar a qualidade da representação deste último parâmetro.

O período total das medições não foi especialmente longo, o que é uma desvantagem numa técnica como as redes neuronais artificiais que se baseiam no conceito de aprendizagem e treino. Por outro lado, a combinação de dados observados e simulações de modelos pode abrir perspectivas interessantes para transferir informação entre zonas desprovidas de sensores.

AGRADECIMENTOS

O trabalho apresentado enquadra-se no projecto *Previsão da Agitação Marítima Junto à Costa: Modelos Espectrais e Assimilação de Dados*, financiado pelo Ministério da Ciência e Tecnologia no âmbito do “Programa Dinamizador de Ciências e Tecnologias do Mar” da FCT (PDCTM-MAR-15242-99).

Oleg Makarynskyy é bolseiro de pós-doutoramento da Fundação para a Ciência e Tecnologia (SFRH/BDP/1507/2000), a quem se agradece.

Agradece-se ao Instituto Hidrográfico da Marinha a disponibilidade dos dados da bóia de Sines, especialmente a Dr^a Mariana Costa, bem como os dados do sensor de pressão.

Parte do trabalho foi realizado durante a licença sabática do primeiro autor como professor visitante na Katholieke Universiteit Leuven. A estadia foi parcialmente apoiada pela Fundação para a Ciência e Tecnologia (SFRH/BSAB/276/2002), a quem se agradece.

REFERÊNCIAS

- Babovic, V., (1999), Subsymbolic process description and forecasting using neural networks. *Proc. of the Int. Workshop: Numerical Modelling of Hydrodynamic Systems*, (eds. P. Garcia-Navarro and E. Playan), 57-79.
- Carretero, J.C., Alvarez, E., Gomez, M., Perez, B., Rodríguez, I., (2000), Ocean forecasting in narrow shelf seas: application to the Spanish coasts. *Coastal Engineering.*, **41** (1-3), 269-293.
- Deo, M.C., Jha, A., Chaphekar, A.S. and K. Ravikant, (2001), Neural networks for wave forecasting. *Ocean Engng.*, **28**, 889-898.
- Fausett, L., (1994), *Fundamentals of neural networks. Architectures, algorithms, and applications*, Prentice-Hall, 462pp.
- Haykin, S., (1999), *Neural networks: a comprehensive foundation*. Prentice-Hall, 842pp.
- Makarynsky, O., Pires-Silva, A. A., Makarynska, D., Ventura-Soares, C. (2002a), Artificial Neural Networks in the Forecasting of Wave Parameters, *Proc. 7th Intern. Workshop on Wave Hindcast and Forecasting*, October 21-25, 2002, Banff, Alberta, Meteorological Service of Canada, 514-522.
- Makarynsky, O., Pires-Silva, A.A., Makarynska, D., Ventura-Soares, C., (2002b). Optimizing Neural Networks Employed in Predictions of Wave Parameters, *Proc. HYDRO 2002: Conference on Hydraulics, Water Resources & Ocean Engineering*, December 16-17, 2002, Bombay, India.
- Mase, H., Sakamoto, M. and T. Sakai, (1995), Neural network for stability analysis of rubble-mound breakwaters. *J. Waterway, Port, Coastal and Ocean Engng.*, ASCE, **121** (6), 294-299.
- Pires-Silva, A. A., Makarynsky, O., Monbaliu, J., Ventura-Soares, C., Coelho, E. (2000), Modelling Wave Transformation in an Open Beach on the West Coast of Portugal, *Proc. COASTAL WAVE MEETING*, A. Sanchez-Arcilla, S. Ponce de Leon (Eds.), Universitat Politècnica de Catalunya, Barcelona, 4.3.
- Roske, F., (1997), Sea level forecasts using neural networks. *German J. of Hydrography*, **49** (1), 71-99.
- Stzobryn, M. (2003), Forecast of Storm Surges by Means of Artificial Neural Network, *J. Sea Res.*, **49**, 317-322.
- Tsai, C.P., and T.L. Lee, (1999), Back-propagation neural network in tidal-level forecasting. *J. Waterway, Port, Coastal and Ocean Engng.*, ASCE, **125** (4), 195-202.
- Tsai, C.P., Hsu, J.R.-C., and Pan, K.L, (2000), Prediction of storm-built beach profile parameters using neural network, *Proc. 27th Int. Conf. Coastal Engineering*, ASCE, **4**, 3048-3061.