

PREDIÇÃO DA VARIAÇÃO EXTREMA DO NÍVEL DO MAR RELACIONADA A TEMPESTADES SEVERAS UTILIZANDO REDES NEURAS ARTIFICIAIS

Marília M. F. de Oliveira¹, Nelson F. F. Ebecken¹ e Jorge L. F. de Oliveira²

¹Programa de Engenharia Civil – COPPE/UFRJ, Centro de Tecnologia-Bloco B, Cidade Universitária, CEP 21945-970, Rio de Janeiro

²Programa de Pós-Graduação em Geografia -Instituto de Geociências – IGEO/UFF
Campus da Praia Vermelha, CEP 24210-340, Niterói, RJ, Brszil
marilia@coc.ufrj.br; nelson@ntt.ufrj.br; jolufo@vm.uff.br

Resumo – Este artigo apresenta um modelo de Rede Neural Artificial (RNA) desenvolvido para prever variações extremas do nível do mar costeiro conhecido como *storm surge*, na região sudeste do Brasil, relacionado à passagem de sistemas frontais associados aos ciclones extratropicais que causam tempestades severas. As forçantes astronômicas são as principais causas da variação diária do nível do mar, porém, os efeitos de fenômenos meteorológicos são verificados também nos levantamentos e abaixamentos do nível observado e tendem a ser mais drásticos de acordo com o evento. Séries horárias do nível do mar referentes a duas estações maregráficas foram utilizadas, bem como dados de pressão atmosférica e componente zonal e meridional do vento das reanálises do NCEP/NCAR, nos horários de 00, 06, 12 e 18 UTC sobre a área oceânica. Foram verificadas as correlações entre as variáveis meteorológicas e o nível do mar costeiro para definir os atrasos entre as respostas relacionadas aos sistemas atmosféricos extremos. Essas correlações e atrasos foram utilizados como entradas do modelo neural. Simulações para previsão do nível do mar até 48 horas foram realizadas e os resultados comparados com o modelo de regressão linear multivariada. O modelo neural apresentou melhor desempenho, generalizando de forma adequada os efeitos das interações atmosféricas nas variações extremas do nível do mar.

Palavras-chave – Redes Neurais Artificiais, Variação do nível do mar, reanálises do NCEP/NCAR

Abstract – This paper presents an Artificial Neural Network (ANN) model developed to predict extreme coastal sea level variation (storm surges) on Southeast Region of Brazil, related to the passage of frontal systems associated with extratropical cyclones that cause severe thunderstorms. Tidal forcing is the main cause of sea level daily variation but the effects of meteorological phenomenon are also present in rising and lowering of the observed sea level and tend to be more drastic accordingly to the event. Hourly time series of water level were used from two tide gauge station. 6-hourly series of atmospheric pressure and wind components from NCEP/NCAR reanalysis data set were also used on some grid points over the oceanic area. Correlations were verified to define the time lag between the meteorological variables and the coastal sea level response to the occurrences of the extreme atmospheric systems. These correlations and time lags were used as input variables of the ANN model. Simulations until 48 hours were tested with the neural model. This model was compared with multivariate linear regression and presented the best performance, generalizing the effect of the atmospheric interactions on extreme sea level variations.

Keywords - ANN model, Sea level variation, NCEP/NCAR reanalysis data

1. Introdução

A zona costeira do litoral sul-sudeste brasileiro é bastante vulnerável à ação de ciclones evoluindo ao longo da costa sul americana, associados à passagem de sistemas frontais. Os ciclones induzem o levantamento do nível do mar na costa. Esse fenômeno é conhecido na literatura como *storm surge* (maré meteorológica de tempestade), resultando em grandes ondas (ressacas) com efeitos danosos no litoral. As cristas devido à influência do vento na superfície do mar durante a preamar são denominadas de *storm tide* ou maré de tormenta [1] e [2].

Muitas vezes os ciclones que acompanham as frentes frias em direção a latitudes mais baixas permanecem próximos à região costeira por um período que pode variar de horas a dias, com ventos e ondas na direção de sudeste-sudoeste, causando variações bruscas na altura do nível do mar costeiro. Quando esses ciclones evoluem para ciclones extratropicais e coincidem com as marés astronômicas de maior amplitude (Sizígias), a elevação do nível do mar é maior, provocando sérios danos às regiões costeiras. A interação de fatores meteorológicos e oceânicos é de extrema importância, pois alteram as condições marinhas nas regiões litorâneas. A figura 1 mostra as curvas relativas às forçantes meteorológicas e astronômicas que alteram o nível do mar observado, sendo obtidas a partir dos registros maregráficos.




Figura 1: Curvas referentes às variações nas alturas do nível do mar devidas às forçantes meteorológicas e astronômicas, verificadas a partir dos registros maregráficos, adaptado de [2].

O conhecimento do comportamento do *storm surge* é importante não só para a navegação, mas também para o planejamento e construção de estruturas *onshore* e *offshore*, pois a maior parte da população mundial vive em zonas costeiras, havendo uma tendência de aumento da concentração demográfica nessas regiões.

A variação do nível do mar, de um modo geral, como já foi mencionada, é fortemente influenciada por fatores meteorológicos, os quais não são considerados nos modelos harmônicos de previsão da maré, que levam em conta somente os aspectos astronômicos e fisiográficos locais. Por esse motivo, ocorre uma defasagem na altura prevista e observada do nível do mar, principalmente, durante a ocorrência de eventos meteorológicos extremos.

No Atlântico Sul são escassos os registros maregráficos em escala espacial e temporal apropriados às análises e simulações de *storm surges*. Os modelos numéricos, na sua maioria, são desenvolvidos para prever *storm surges* relacionados à passagem de furacões ou ciclones tropicais e, portanto, não são adequados para prever eventos ao longo da costa brasileira.

As redes neurais artificiais (RNA) conhecidas como modelos matemáticos conexionistas estão sendo amplamente utilizadas na modelagem de sistemas dinâmicos não-lineares, utilizando séries temporais que traduzam as relações físicas entre as variáveis de entrada (preditores) e o fenômeno a ser modelado (preditando). Nos estudos de tempo e clima [3] desenvolveram metodologias para prever séries temporais não-lineares de curto período com modelo de RNA. Um modelo de redes neurais foi desenvolvido por [4] para predição dos níveis de maré com observações de curto prazo para a região costeira de Taiwan. Uma rede neural para prever as variações do nível do mar devido ao vento foi desenvolvida por [5] e os resultados foram satisfatórios quando comparados com outros modelos. Métodos de aprendizado de rede neural funcional, utilizando equações na forma de diferenças finitas e aprendizado seqüencial, foram aplicados por [6] na previsão de marés, usando séries de curto período ao longo da costa de Taiwan.

No Brasil existem poucas aplicações de RNA na predição de *surges* e *storm surges* ao longo da costa brasileira. Uma RNA temporal foi desenvolvida por [7] para prever o nível do mar na cidade de São Francisco do Sul, SC. As variáveis de entrada foram definidas a partir das correlações existentes entre as forçantes atmosféricas e o *surge*. Para prever a variabilidade do nível do mar em Cananéia, SP e Ilha Fiscal, RJ [8] desenvolveu um modelo de RNA, tendo como variáveis de entrada a pressão atmosférica, vento e maré prevista. Dados meteorológicos de reanálises do NCEP/NCAR, em pontos de grade da área oceânica, próximo ao litoral sudeste foram utilizados por [9] na predição da variabilidade do nível médio do mar com redes neurais artificiais. Uma metodologia para prever com redes neurais artificiais as variações do *surge* e extremos do nível do mar, no litoral sudeste, relacionada aos eventos meteorológicos como frentes frias foi desenvolvida por [10] e [11] com resultados bastante satisfatórios.

Este artigo tem como objetivo apresentar parte da pesquisa de doutorado realizada pelo primeiro autor no desenvolvimento de um modelo de RNA para prever o levantamento extremo do nível do mar (*storm surge*) na região sudeste do Brasil, segundo as características meteorológicas, na área oceânica, considerando-se as principais trajetórias das frentes frias, desde o norte da Argentina ao estado do Rio de Janeiro.

2. Metodologia

2.1 Dados ambientais

Foram utilizados os dados maregráficos horários da estação de Cananéia – SP, localizada nas coordenadas geográficas de 25°01.0'S e 047°55.5'W, pertencente ao Instituto Oceanográfico da Universidade de São Paulo (IO-USP) e Ponta da Armação - Niterói, RJ, pertencente ao Centro de Hidrografia da Marinha (CHM), localizada nas coordenadas geográficas de 23°53'S e 043°08'W. Os dados meteorológicos de pressão atmosférica ao nível médio do mar e componentes zonal e meridional do vento foram obtidos das reanálises do *National Centers for Environmental Prediction* e *National Center for Atmospheric Research - NCEP/NCAR* [12] nos horários de 00, 06, 12 e 18 UTC. Foram utilizadas também as previsões da maré astronômica, cedidas pela Seção de Intercâmbio de Dados do CHM, para Cananéia e Ponta da Armação.

2.2 Área de estudo

A área de estudo foi determinada a partir da seleção de pontos de grade dos dados meteorológicos de reanálises do NCEP/NCAR e das escolhas das estações maregráficas de Cananéia e Ponta da Armação. Está compreendida entre as latitudes de 21°S a 41°S, e entre as longitudes de 42°W a 53° W, na região oceânica, do norte da Argentina ao sudeste do Brasil.

Os dados das reanálises de pressão atmosférica, ao nível médio do mar, foram obtidos nos seguintes pontos de grade:

- 40° S / 50° 00' W (**P₀**)
- 35° S / 50° 00' W (**P₁**)
- 30° S / 45° 00' W (**P₂**)
- 25° S / 47° 30' W (**P₃**)

As componentes zonal e meridional do vento foram obtidas em:

- 40° 56' S/52° 30' W (**V₀**)
- 35° 14' S/50° 37' W (**V₁**)
- 29° 31' S/45° 00' W (**V₂**)
- 25° 42' S/45° 00' W (**V₃**)
- 25° 42' S/46° 52' W (**V₄**)
- 23° 48' S/43° 07' W (**V₅**)

A Fig. 2 mostra a região de estudo com os pontos de grade dos dados meteorológicos das reanálises e as estações maregráficas.




Figura 2: Área de estudo com os pontos de grade dos dados de reanálises do NCEP/NCAR e estações maregráficas de Cananéia - SP e Ponta da Armação - RJ [11].

2.3 Metodologias

A escolha dos pontos de grade dos dados de reanálises ocorreu em função da trajetória predominante de frentes frias ao longo da costa sul americana. Foram utilizados pontos na direção paralela à linha de costa do norte da Argentina ao sudeste do Brasil. Esse critério foi adotado por ser também a região ciclogênica (área de intensificação de sistemas de baixa pressão). Foi calculada a velocidade do vento (V) para todos os pontos de grade. As séries meteorológicas de pressão atmosférica e velocidade do vento foram então interpoladas em dados horários para que ficassem compatíveis com o horário das previsões da maré.

As séries dos *surges*, para cada estação, foram obtidas através da diferença entre o nível do mar observado e previsto [13]. Optou-se em utilizar a componente meridional (v) e zonal (u) do vento ao invés da tensão superficial do vento [14], sendo então calculadas as correlações temporais entre as variáveis meteorológicas e o *surge*.

O período de 27/03 a 10/05/2003, com a ocorrência de extremo da altura do nível do mar em 13/04/2003, foi utilizado no treinamento da rede conforme metodologia utilizada por [15], [16] para prever *storm surges* com redes neurais relacionados à ocorrência de furacões. Essa metodologia foi adaptada às condições locais, segundo critérios descritos em [17] para prever o fenômeno com regressão linear multivariada, devido à passagem de ciclones extratropicais em Atlantic City.

Primeiramente, a rede foi testada para Cananéia, sendo selecionados 1057 pares de entrada/saída, conforme o período descrito acima, com 50% para treinamento, 25% para verificação e 25% para teste. Foi utilizada uma rede *feedforward* de múltiplas camadas (*MLP*) e testados os algoritmos de aprendizagem *Backpropagation*, *Conjugate Gradient Descendent*, *Levenberg-Marquardt* e *Quick-Propagation*. Como critério de parada utilizou-se o número de épocas, verificando-se o erro entre a saída da rede e a saída desejada até alcançar o melhor desempenho. A rede que apresentou o melhor ajuste foi designada de Rede Neural Espaço-Temporal Correlata (*RNETC*), sendo também utilizada na predição da altura do nível do mar para Ponta da Armação. Ambas as redes foram utilizadas na predição do nível do mar até 48 horas. Foram também consideradas, para treinamento da rede, séries mais longas com até dois

anos de dados. A técnica de regressão linear multivariada foi também utilizada na predição do nível do mar nas duas localidades e os resultados comparados com o modelo neural.

3. Resultados

A tabela 1 mostra os resultados das correlações obtidas entre a saída da rede e a saída desejada para os respectivos algoritmos utilizando-se os dados de Cananéia, com melhor desempenho alcançado para o *BP* juntamente com *CGD* para uma arquitetura otimizada com 19 variáveis de entrada, 11 neurônios na camada intermediária e 1 neurônio na camada de saída. O algoritmo *BP-CGD* foi então testado com os dados de Ponta da Armação, apresentando melhores resultados para uma arquitetura otimizada com 22 variáveis de entrada, 11 neurônios na camada intermediária e 1 neurônio na camada de saída. Os algoritmos Levenberg-Marquardt (*LM*) e *Quick-Propagation (QP)* também foram testados com o *BP* para avaliar a habilidade de generalização da rede.

As correlações entre a saída da rede e a saída desejada, obtidas para Ponta da Armação, foram de 99.72% para Treinamento, 99.30% para Seleção e 99.45% para Teste.

Tabela 1: Algoritmos testados para avaliar o desempenho da rede com os dados de Cananéia [11].

| Algoritmo | Treinamento (%) | Seleção (%) | Teste (%) |
|---------------|-----------------|--------------|--------------|
| <i>BP</i> | 98.11 | 97.11 | 97.49 |
| <i>BP-CGD</i> | 99.52 | 98.60 | 98.74 |
| <i>BP-LM</i> | 99.45 | 98.29 | 98.46 |
| <i>BP-QP</i> | 98.96 | 98.16 | 98.14 |

Neste artigo são apresentados somente os resultados referentes ao desempenho da rede para as simulações realizadas com os dados maregráficos de Ponta da Armação, RJ. A figura 2 mostra os gráficos comparativos entre as alturas do nível do mar observado e estimado pela rede na fase de teste e a previsão com o Modelo Harmônico (MH) de previsão de maré.

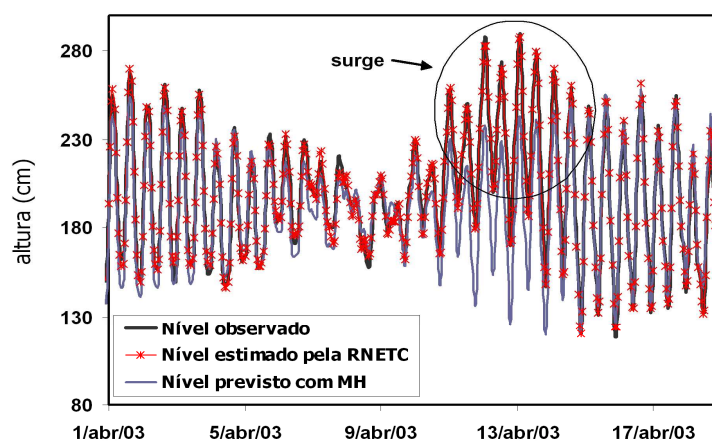


Figura 2: Gráficos comparativos das estimativas da altura do nível do mar extremo em Ponta da Armação - RJ com a RNETC e o MH. O círculo preto destaca o levantamento do nível do mar devido à ocorrência de um evento severo com picos máximos em 13/04/2003 [11].

A figura 3 mostra as previsões das alturas do nível do mar até 48 horas, considerando-se as mesmas entradas com os respectivos atrasos. Os resultados foram comparados com as previsões elaboradas com o MH.




Figura 3: Correlações entre a RNA e o MH para previsões até 48 horas [11].

A tabela 2 apresenta os resultados estatísticos do modelo de regressão, onde se verifica que o valor do coeficiente de correlação (R) é inferior ao obtido com a rede, considerando-se as mesmas variáveis de entrada.

Tabela 2: Estatísticas do desempenho do modelo de regressão para Ponta da Armação [11].

| | |
|---------------------------------|---------------|
| N° da amostra | 1057 |
| R² | 0.9309 |
| R² ajustado | 0.9294 |
| Erro Padrão (Estimativa) | 8.8133 |
| R (correlação) | 0.9648 |
| p-valor | 0.0000 |

A figura 4 mostra parte dos gráficos comparativos entre os valores da altura do nível do mar observado, estimado pela RNETC e pelo modelo regressional.

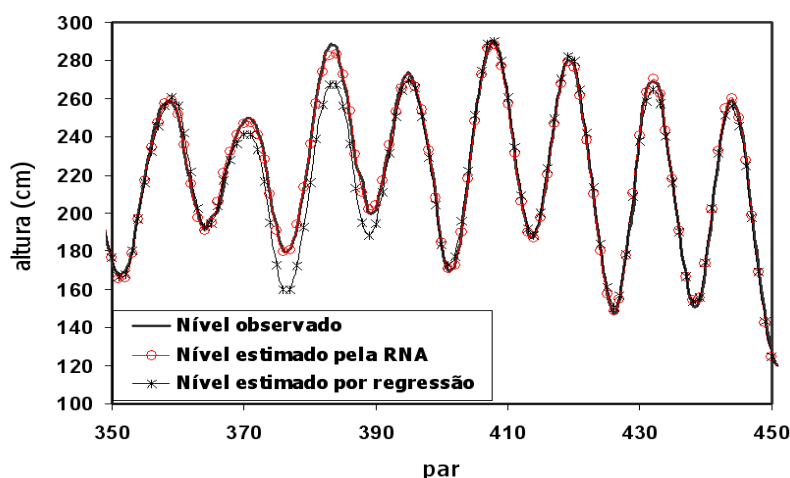


Figura 4: Gráficos comparativos das estimativas da altura do nível do mar em Ponta da Armação com RNETC e regressão linear multivariada, no período de 27/03 a 10/05/2003 [11].

A comparação entre os dois modelos foi, também, realizada através das análises residuais, entre a saída modelo neural, na fase de Teste, e o regressional. Esses resíduos referem-se à diferença entre os valores das alturas do nível do mar previstos com ambos os modelos e os valores observados. A tabela 3 apresenta os resíduos mínimos e máximos, para as duas localidades, utilizando-se os dois modelos, bem como as respectivas correlações, onde se verifica que o modelo neural (RNA) apresentou melhores resultados comparados ao modelo de regressão multivariada (RM).

Tabela 3: Comparação entre a RNA e o modelo regressional [11].

| Estação | Resíduo | | Correlação (%) | |
|-------------------|----------------|----------------|----------------|--------------|
| | RNA | RM | RNA | RM |
| Cananéia-SP | -22.92 / 36.58 | -34.70 / 38.62 | 99.06 | 95.59 |
| Pta da Armação-RJ | -14.88 / 13.87 | -26.63 / 30.03 | 99.45 | 96.48 |

4. Discussão

Na busca de uma arquitetura capaz de ajustar os dados com aproximações significativas entre o valor desejado e o previsto pela rede foram testados vários algoritmos de treinamento (tabela 1). A série com 1057 pares, relativa ao período de 27/03 a 10/05/2003, apresentou melhor desempenho do que as séries mais longas.

As variáveis de entrada foram definidas conforme as correlações máximas entre as variáveis meteorológicas e o nível do mar para ambas as estações maregráficas, considerando-se os respectivos atrasos.

Verifica-se na figura 2 que o modelo harmônico não prevê as variações ocorridas devidas às influências meteorológicas, onde se observa uma elevação significativa do nível do mar, caracterizando a presença do fenômeno conhecido com *surge*.

As previsões com redes neurais até 24 horas mostraram maiores correlações com os valores observados do nível do mar do que os previstos com o MH para ambas as estações maregráficas.

O modelo neural mostrou um melhor desempenho quando comparado com o modelo regressional (figura 4), considerando-se a ocorrência do evento extremo. Observou-se também que o modelo neural apresentou maior sensibilidade às variáveis representativas do fenômeno em questão

5. Conclusão

A escolha das variáveis de entrada do modelo neural seguiu os critérios estabelecidos pelas análises estatísticas para cada ponto de grade, descritos por uma malha de informações meteorológicas extremas espaço-temporais [11]. A rede desenvolvida para prever o nível do mar extremo em Cananéia e Ponta da Armação mostrou ser uma ferramenta eficiente, considerando-se os aspectos físicos relativos à ocorrência do fenômeno. O melhor resultado foi verificado para o tamanho da série com 1057 pares devido à proximidade dos dados em torno do evento extremo, confirmando metodologia descrita em [15] e [16] para eventos extremos como furacões. Os gráficos de treinamento, seleção e teste mostraram a capacidade do modelo em generalizar de forma adequada o padrão de resposta do nível do mar costeiro às variações ocorridas devido à passagem de frentes frias acompanhadas de sistemas de baixa pressão. As predições para os períodos de 06, 12, 24, 36 e 48 horas (hora local) apresentaram resultados satisfatórios até 24 horas. A partir daí, sugere-se uma atualização do modelo em relação às novas condições atmosféricas na região.

Os resultados obtidos utilizando o modelo regressional multivariado foram satisfatórios para ambos os locais, em torno de 95.6 e 96.5%, respectivamente, porém inferiores aos apresentados pela rede neural. Verificou-se, ainda que, a rede apresentou maior sensibilidade às alterações nas variáveis de

entrada, apresentando uma melhora no desempenho da predição, à medida que mais informações foram sendo acrescentadas ao modelo até alcançar estabilidade.

Agradecimentos: Os autores agradecem aos funcionários da Seção de Intercâmbio de Dados do Centro de Hidrografia da Marinha (CHM) pela atenção e fornecimento de dados maregráficos. Ao professor Patrick Caldwell da Universidade do Havá pelas informações sobre a aquisição dos dados maregráficos *on line* e ao CNPq pelo apoio financeiro. Este artigo é parte da tese de Doutorado do primeiro autor.

Referências:

- [1] T.S. Murty, Storm Surges, Meteorological Ocean Tides. Department of Fisheries and Oceans Ottawa (1984), 897 pp.
- [2] G. Gönner, The analysis of storm surge climate change along the German coast, **Quaternary International**, 56(1999), 115-121.
- [3] J. B. Elsner, A. A. Tsonis, Nonlinear Prediction, Chaos, and Noise, **Bulletin American Meteorological Society**, 73(1992), 49-60.
- [4] T. L. Lee, D. S. Jeng, Application of artificial neural network in tide-forecasting, **Ocean Engineering**, 29(2001), 1003-1022.
- [5] M. Sztobryn, Forecast of storm surge by means of artificial neural network, **Journal of Sea Research**, 49(2003), 317-322.
- [6] S. Rajasekaram, K. Thiruvenkatasamy, T. L. Lee, Tidal level forecasting using functional and sequential learning neural network, **Applied Mathematical Modelling**, 3(2006), 85-103.
- [7] R. A. Saraiva, Aplicação de uma rede neural temporal em um estudo de caso para previsão do nível do mar. In: **Workshop de Tecnologia da Informação Aplicada ao Meio Ambiente – Congresso Brasileiro de Computação**, (2003), 1759-1769.
- [8] A. M. Filippo, **Variabilidade do Nível do Mar em Função de Eventos Meteorológicos de Baixa Frequência**, Tese de D. Sc., UFF, Niterói, RJ, (2003).
- [9] M. M. F. de Oliveira, N. F. F. Ebecken, I. de A. Santos, C. de F. Neves, L. P. Calôba, J. L. F. de Oliveira, NCEP/NCAR Reanalysis data to predict the variability of the mean sea level on South Atlantic Ocean with ANN model, **Geophysical Research Abstracts**, 8(2006), EGU - European Geosciences Union.
- [10] M. M. F. de Oliveira, N. F. F. Ebecken, J. L. F. de Oliveira, I. A. Santos, Neural Network to predict a storm surge, **Journal of Applied Meteorology and Climatology**, 48(2009a), 143-155.
- [11] M. M. F. de Oliveira, **Análise Estatística de Dados Ambientais com Aplicação da Teoria de Valores Extremos e Predição do Nível do Mar Utilizando Redes Neurais Artificiais**, Tese de D. Sc. - COPPE/UFRJ, Rio de Janeiro, RJ, (2009b).
- [12] R. Kistler, E. Kalnay, W. Collins, S Saha, G. White, J. Woollen, M. Chelliah, W. Ebisuzaki, M. Kanamitsu, V. Kousky, H. van der Dool, R. Jenne, M. Fiorino. The NCEP/NCAR 50 Year Reanalysis: Monthly Means CD-ROM and Documentation, **Bulletin of American Meteorological Society**, 82(2001), 247-267.
- [13] D. T. Pugh Tides, Surges and Mean Sea Level, Great Britain, John Wiley & Sons, (1987).
- [14] M. M. F. de Oliveira, **Redes neurais artificiais na predição da maré meteorológica em Paranaguá - PR**, Dissertação de M. Sc., COPPE/UFRJ, Rio de Janeiro, RJ, (2004).
- [15] T. L. Lee, Neural network prediction of a storm surge, **Ocean Engineering**, 33(2006), 483-494.
- [16] T. L. Lee, Back-propagation neural network for the prediction of the short-term storm surge in Taichung harbor, Taiwan, **Engineering Application of Artificial Intelligence**, 21(2008),63-72.
- [17] N. A. Pore, The relation of Wind and Pressure to Extratropical Storm Surge at Atlantic City, **Journal of Applied Meteorology**, 3(1964), 155-163.