

## **APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA ESTIMATIVA DE TEMPERATURA DE SUPERFÍCIE DO MAR**

**PERES, M. V.<sup>1</sup>; FILIPPO, A.M. <sup>1</sup>**

*<sup>1</sup>Universidade do Estado do Rio de Janeiro – UERJ.*

*Rua São Francisco Xavier, 524 - Rio de Janeiro, RJ- CEP 20550-900*

*marinaveiga.peres@gmail.com*

### **RESUMO**

Os processos de interação oceano-atmosfera influenciam diretamente variações climáticas em diversas escalas no tempo e no espaço. A proposta é aplicar uma metodologia capaz de prever as variações de TSM utilizando uma combinação de variáveis meteorológicas e oceanográficas como dados de entrada de uma Rede Neural Artificial (RNA). A principal contribuição dos modelos neurais é o reconhecimento de padrões não-lineares, característica que ocorre frequentemente em dados ambientais observados. Neste estudo, foi visto que as redes neurais artificiais são capazes de prever satisfatoriamente a intensidade da TSM, enquanto em relação a variabilidade a performance da rede demonstrou ser mais baixa, porém considerados significativos.

### **INTRODUÇÃO**

Atualmente, os modelos meteorológicos de previsão do tempo são bons na previsão qualitativa de eventos meteorológicos severos, porém existe uma dificuldade de prever a intensidade da ocorrência dos mesmos, deixando o aspecto quantitativo da previsão ainda necessitando de melhorias (SOUZA *et al.*, 2012). Os processos de interação oceano-atmosfera são responsáveis por parte da variabilidade climática em diversas escalas no espaço e no tempo. Essa troca entre o oceano e a atmosfera se dá pela superfície livre do oceano e a Temperatura da Superfície do Mar (TSM) tem um papel fundamental neste processo.

O entendimento da interação de um gradiente de TSM na intensificação ou redução da magnitude de um evento severo de tempo é que vem motivar o desenvolvimento de técnicas de previsão da variação da TSM ao longo do tempo. Uma das possíveis saídas para o problema é desenvolver um método de como prever as variações de TSM devido a uma combinação de forças meteorológicas usando uma Rede Neural Artificial (RNA). Esta ferramenta já se mostrou eficiente na previsão de baixa frequência das anomalias de temperatura de superfície do mar na região do Pacífico (TANGANG *et al.*, 1998; WU *et al.*, 2006).

Denominam-se Redes Neurais Artificiais os modelos, os quais tentam reproduzir a estrutura e o funcionamento das redes biológicas (cérebro). Uma rede neural compõe-se de um elevado número de elementos denominados neurônios e um grande número de ligações, conhecidas como sinapses (FREITAS, 1996). De acordo com Kovacs (2006), as redes neurais artificiais são redes de múltiplos neurônios chamadas perceptron. O perceptron é uma rede, onde os elementos representam neurônios dispostos em várias camadas. A primeira camada (camada de entrada) recebe diretamente os dados fornecidos para o treinamento, sendo a última camada (camada de saída) associada ao dado que se deseja prever. As camadas intermediárias são chamadas de camadas ocultas e não representam as variáveis em si, mas sim a interação entre essas variáveis com a atribuição de pesos representando as sinapses dos sistemas biológicos.

A RNA é uma ferramenta muito utilizada nas áreas financeiras e econômicas. Contudo, não tem sido usada de forma mais efetiva em oceanografia e meteorologia. Como exemplo,

Hsieh e Pratt (2002) usaram a RNA para recompor séries de dados de campo relativos à maré. Além disso, a vantagem desta ferramenta computacional se deve a sua estrutura matemática bastante flexível e capacidade de identificar relações não-lineares e descrever processos complexos.

## OBJETIVOS

O objetivo principal deste estudo é explorar a capacidade das Redes Neurais Artificiais em generalizar os padrões de variação da Temperatura de Superfície do Mar por meio de seleção de variáveis meteocenográficas e, conseqüentemente, seu potencial de previsão.

Este trabalho também aborda a interpretação dos resultados obtidos pelo modelo neural de modo que seja possível extrair informações dos processos físicos que envolvem as interações oceano-atmosfera.

## METODOLOGIA

As séries temporais utilizadas como entrada da Rede Neural Artificial são provenientes do Projeto PIRATA (*Prediction and Research Moored Array in the Tropical Atlantic*), mais precisamente da boia fundeada localizada em 19°S 34°O.

O tratamento realizado nos dados consistiu em verificar a existência de lacunas nas séries temporais, retirada das médias para trabalhar apenas com as anomalias, filtragem do tipo passa baixa para retirada de ruído branco, normalização no range de -1 a 1 e, para finalizar, as séries foram separadas para uso no treinamento da RNA e para simulação do modelo neural.

A tipologia da Rede Neural Artificial utilizada ao longo deste projeto foi a MLP (do inglês, *Multilayer Perceptron*) com camada oculta de 10 neurônios que são processados com a função de ativação tangente hiperbólica. Além disso, o ajuste dos pesos sinápticos e vies são realizados no treinamento através do algoritmo da Retropropagação do Erro.

As funções de eficiência MAE (do inglês, *Mean Absolute Error*) e MSE (do inglês, *Mean Squared Error*) foram utilizadas para mensurar a capacidade do modelo neural em prever a intensidade da TSM, pois estas são medidas associadas à distância entre curvas. Para avaliar se o modelo simula a variabilidade da TSM foram utilizados os parâmetros Coeficiente de Correlação de Pearson (R) e o Coeficiente de Determinação ( $R^2$ ).

No treinamento da rede foi utilizada uma série temporal compreendida entre 3 de novembro de 2011 e 16 de novembro de 2012. Nesta etapa, foram testados empiricamente os conjuntos para compor a camada de entrada da RNA, sendo ao todo 7 variáveis elegíveis. Para que estes testes fossem realizados, foi utilizada a técnica de crescimento da rede descrita por Haykin (2001), onde inicialmente é proposta a rede mais simples possível e, conforme a rede não atenda às necessidades de previsão, são acrescentados novos neurônios e, portanto, sinapses. Neste caso, o acréscimo de complexidade se deu, especificamente, na camada de entrada.

Este procedimento foi dividido em 7 rodadas, a primeira rodada conta com uma única variável de entrada e todas as variáveis elegíveis são testadas, ou seja, inicialmente foram testadas 7 diferentes RNA's. A segunda rodada utiliza 2 variáveis de entrada, uma delas é a que apresentou o melhor resultado na rodada anterior e as outras 6 são testadas uma a uma, ou seja, na segunda rodada são testadas 6 diferentes RNA's. O experimento segue de forma análoga até que a última rede testada contenha todas as variáveis como camada de entrada, totalizando 28 RNA's.. Após a escolha da rodada mais adequada, ficou estabelecido o melhor conjunto de dados para a camada de entrada e apenas para esta RNA escolhida é realizada a simulação para validação do modelo neural.

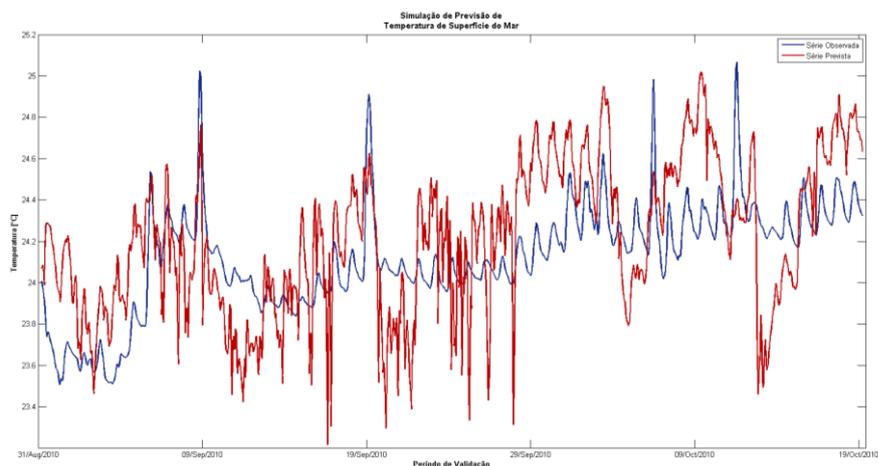
Na simulação do modelo neural foi utilizada uma série temporal compreendida entre 31 de agosto de 2010 e 19 de outubro de 2010. Nesta etapa, foi utilizada a estrutura da RNA treinada que continha 6 variáveis como camada de entrada, estas variáveis são: Temperatura

do Ar, Radiação de Onda Longa, Radiação de Onda Curta, Umidade Relativa e Vento (componentes Meridional e Zonal). A simulação é utilizada como uma validação do modelo neural, pois, esta não oferece ao programa os valores da TSM observada.

## RESULTADOS

Ao longo do treinamento, a classificação da importância das variáveis conforme aumento da eficiência da RNA mostrou pouco impacto promovido pela variável precipitação, portanto esta foi excluída do conjunto de entrada da RNA.

A Figura 1 compara os valores da simulação do modelo neural com a TSM observada.

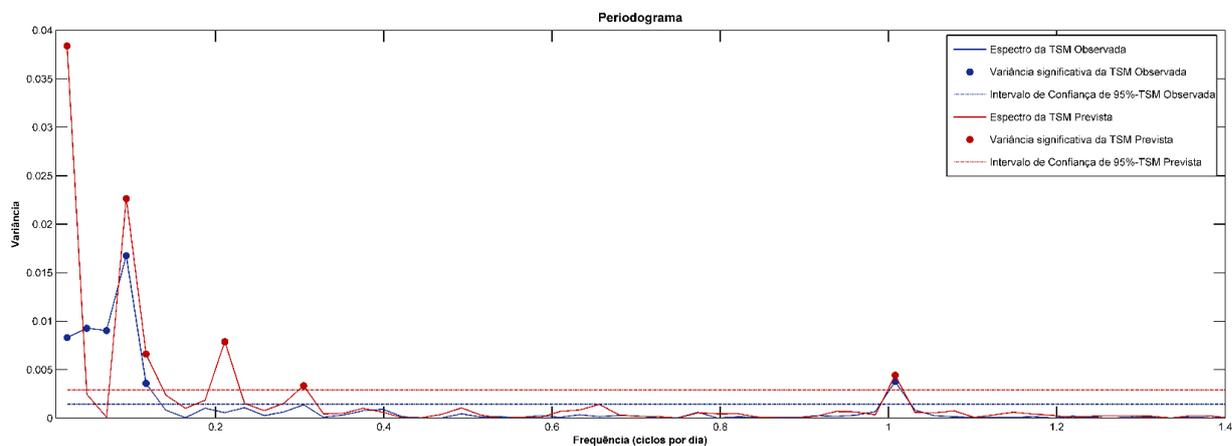


Como pôde ser visto a simulação apresentou bom resultado em termos de magnitude, porém apresentou uma série muito ruidosa e com muita variabilidade. A Tabela 1 mostra matematicamente estes parâmetros e compara com os valores obtidos no treinamento.

**Tabela 1 Comparação de eficiência entre treinamento e simulação.**

|                    | MSE   | MAE   | R     | R <sup>2</sup> |
|--------------------|-------|-------|-------|----------------|
| <b>Simulação</b>   | 0.105 | 0.281 | 0.537 | 0.288          |
| <b>Treinamento</b> | 0.151 | 0.283 | 0.941 | 0.885          |

Como o coeficiente de correlação e determinação não são influenciados pela dispersão ou média, mas sim por desvio de fase ou diferenças na periodicidade dos ciclos, então também foi realizada a comparação do espectro de variância da série temporal observada e prevista na simulação. A Figura 2 mostra essa comparação e destaca os pontos em que a variância se encontra acima do intervalo de confiança de 95%.



## CONCLUSÕES

Neste estudo, os resultados mostram que o modelo neural apresentou boa eficiência em prever a magnitude da TSM, já que as medidas de erro MAE e MSE apresentam pouca diferença entre as obtidas no treinamento (0,28 e 0,15, respectivamente) e na simulação (0,28 e 0,10, respectivamente). Entretanto, os coeficientes de correlação e determinação do treinamento (0,94 e 0,88, respectivamente) foram mais elevados do que os encontrados na simulação (0,54 e 0,29, respectivamente).

Cabe ressaltar que o espectro de variância da série de TSM prevista ao longo da simulação mostra periodicidades que não estão presentes na TSM observada do mesmo período. A hipótese levantada para este caso é de que estas periodicidades são referentes a ciclos atmosféricos que mesmo com o treinamento foram preservados pelo modelo neural, ou seja, a rede mantém um comportamento típico de variáveis meteorológicas.

Para adquirir maior clareza e aprimorar este aspecto da rede, são sugeridas algumas mudanças técnicas na metodologia em trabalhos futuros: a) a filtragem utilizada foi padronizada para todas as variáveis, porém realizar uma filtragem individualizada baseada na análise espectral de cada variável independente faria com que todos os vetores da camada de entrada se tornassem menos ruidosos e expressassem apenas as frequências relevantes para a janela de tempo desejada numa previsão operacional; b) realizar uma análise espectral cruzada para avaliar uma possível defasagem de fase entre as variações da TSM e das variáveis independentes. Desta forma, torna-se possível criar um delay na séries temporais de entrada conforme o tempo levado para aquela variável ser capaz de alterar a TSM; c) devido à alta capacidade térmica da água do mar, a variabilidade da TSM ocorre de forma lenta quando comparada a processos atmosféricos. Então, outra forma de tornar a previsão mais acurada seria incluir a TSM no treinamento como uma espécie de memória do sistema, isto pode ser feito através de redes neurais recorrentes, tais como: Nonlinear AutoRegressive with eXogenous Inputs (NARX), Jordan Neural Network (JNN) e Elman Neural Network (ENN), por exemplo.

## REFERÊNCIAS BIBLIOGRÁFICAS

FREITAS, A. A. C. DE. Previsão de Séries Temporais via Seleção de Variáveis , Reconstrução Dinâmica , ARMA-GARCH e Redes Neurais Artificiais. 2007. Universidade Estadual de Campinas, 2007.

HAYKIN, S. Redes Neurais - Princípios e Prática. 2nd. ed. Porto Alegre: Bookman, 2001. p. 901

HSIEH, B. B.; PRATT, T. C. Field data recovery in tidal system using artificial neural networks (ANN). . Vicksburg, MS: U.S. Army Engineer Research and Development Center, CHETN-IV-38. Disponível em: <http://chl.wes.army.mil/library/publications/chetn/>, 2001.

HSIEH, W. W.; TANG, B. Applying Neural Network Models to Prediction and Data Analysis in Meteorology and Oceanography. Bulletin of the American Meteorological Society, v. 79, n. 9, p. 1855–1870. 1998.

KOVACS, Z. Redes Neurais Artificiais: Fundamentos e Aplicações. 4.ed.Ver.- São Paulo: Editora Livraria da Física, 2006.

SOUZA, L. S. DE et al. Avaliação do modelo cosmo durante um evento severo de chuvas na região serrana do rio de janeiro. In: XVII Congresso Brasileiro de Meteorologia, 2012, Gramado – RS. Anais do XVII CBMET, 2012.

TANGANG,F.T.; HSIEH, W. W.; TANG, B. Forecasting regional sea surface temperatures in the tropical Pacific by neural network models, with wind stress and sea level pressure as predictors. Journal of Geophysical Research, v. 103, n. C4, p. 7511-7522. 1998.

WU, A.; HSIEH, W. W.; TANG, B. Neural Network forecasts of the tropical Pacific sea surface temperatures. Neural Networks, v. 19, p. 145–154. 2006.