

UMA REDE NEURAL TEMPORAL PARA PREVISÃO DO NÍVEL DO MAR: UM ESTUDO DE CASO

Rafael Medeiros Sperb¹; Eliane Cristina Truccolo²; Rodrigo Araújo Saraiva³.

¹ Dr. em Inteligência Aplicada, Curso de Engenharia Ambiental, Universidade do Vale do Itajaí, Rua Uruguai, 458 – Itajaí, SC. Fone: +55 47 341-7960. e-mail: rsperb@cttmar.univali.br

² MSc. em Engenharia Ambiental, Curso de Oceanografia, Universidade do Vale do Itajaí – Itajaí, SC. e-mail: nane@cttmar.univali.br

³ Acad. do Curso Ciência da Computação, Laboratório de Computação Aplicada, Universidade do Vale do Itajaí – Itajaí, SC. e-mail: saraiva@cttmar.univali.br

RESUMO

Este artigo avalia o desempenho das Redes Neurais Artificiais (RNA) Temporais para a solução de problemas onde os dados de entrada na rede têm uma relação temporal entre si, como as oscilações do nível do mar. As RNA Temporais consideram o tempo na sua operação, incorporando em sua arquitetura e operação uma memória de curto prazo em alguns neurônios, geralmente na camada oculta, ou nas camadas de saída em alguns casos. O desenvolvimento desta pesquisa envolveu três etapas: levantamento bibliográfico orientado à busca por uma arquitetura para RNA Temporal apropriada ao estudo das oscilações do nível do mar; implementação da rede; e aplicação em um estudo de caso. No trabalho optou-se pela utilização de uma arquitetura de redes com atraso de tempo, em função dos relatos indicarem um bom desempenho em aplicações de cunho temporal. No estudo de caso testou-se o desempenho da arquitetura utilizada em um conjunto de dados horários de nível do mar na Praia da Enseada, e dados meteorológicos da Praia Grande, ambos no município de São Francisco do Sul - SC, referentes ao período de julho a dezembro de 1996. Os resultados obtidos demonstraram que as RNA Temporais conseguem capturar as características dos processos temporais de uma forma muito eficiente, aprendendo diretamente o comportamento não estacionário das séries temporais.

ABSTRACT

This article studies the application of a Temporal Artificial Neural Network (ANN) to the resolution of problems where the data presented to the network have a temporal relationship to each other, such as coastal sea level forecast. Temporal ANN considers momentum in its operation, incorporating short period memory in its architecture, usually in the hidden neuron layer, or in the output layer to some cases. The development of this research involved three stages: literature review aiming at defining the most suitable Temporal ANN architecture; algorithm implementation; and application in a study case. An architecture with time delay was chosen due to positive performance in temporal applications. A data set for sea level in Enseada beach and meteorological data for Grande beach, both located in the São Francisco do Sul - SC, was used as study case. The application was tested for the period of July to December of 1996. The results indicate that Temporal ANN captures the characteristics of the temporal processes in an efficient way, learning non-stationary behavior temporal processes.

Palavras-Chave: rede neural artificial, processamento temporal, previsão do nível do mar.

1. INTRODUÇÃO

As Redes Neurais Artificiais (RNA) são compostas de “neurônios” inspirados nos neurônios biológicos, conectados uns com os outros através de sinapses modeladas como parâmetros ajustáveis chamados pesos. A literatura relata diversas arquiteturas de redes neurais, segundo a maneira que os neurônios são organizados, aos métodos pelos quais os pesos são determinados e ao domínio das aplicações. Entretanto, em todas as arquiteturas os pesos devem ser aprendidos e não programados [HAY94, CIC93, NUN98, SPE99].

Uma das RNA, a rede MLP (MultiLayer perceptron), treinada com o algoritmo de retro-propagação, é um modelo adaptativo não linear, e provou ser uma ferramenta altamente flexível para aplicações em problemas de reconhecimento de padrões, classificação e outros de natureza estática ou estacionária [NUN98, MOA99].

Em problemas dinâmicos ou temporais, como a previsão de séries temporais, a rede MLP é muito utilizada com um “artifício” na camada de entrada da rede - o mecanismo da janela. A janela ou lag space é um mecanismo através do qual os valores prévios da série nos quais é

baseada a previsão são submetidos à rede [HAY94, LUK00]. Esta janela constitui na realidade a incorporação de “memória” na entrada da rede, permitindo assim à rede MLP o aprendizado do comportamento das séries temporais [GOU97].

O mecanismo da janela, utilizado intuitivamente, pode ser generalizado para incorporar memória também nas camadas escondidas, fazendo assim com que a mesma rede MLP seja capaz de aprender o comportamento de sinais temporais não estacionários diretamente. Estes tipos de redes são as denominadas “redes neurais com atrasos no tempo”.

Esta maneira de utilizar a RNA dá bons resultados na solução de problemas de previsão de séries temporais, mostrando em muitos casos um melhor rendimento que os modelos puramente estatísticos, considerando o conhecimento prévio da dinâmica dos processos envolvidos [WEG97, NUN98, MOA99, SPE99, TSAI99]. A utilização destas técnicas será detalhada através de um estudo de caso para a previsão de marés meteorológicas.

2. REDES NEURAIS ARTIFICIAIS (RNA)

2.1 Descrição de Redes Neurais

Os neurônios artificiais tentam simular a estrutura e a função do neurônio biológico e, embora existam muitos estudos referentes aos neurônios biológicos, os artificiais apenas incluem algumas das características deles. Isto se deve aos seguintes fatos:

- Não se compreende completamente o comportamento dos sistemas nervosos biológicos, os quais são muito complexos;
- Somente parte da ação dos neurônios biológico é essencial para a capacidade de processamento de informação, a outra parte corresponde a efeitos de aspectos irrelevantes aos neurônios artificiais;
- Do ponto de vista de implementação técnica, talvez seja impossível e ineficiente simular todo o comportamento do neurônio biológico;
- As RNA são desenhadas para realizar problemas computacionais muito específicos, e suas arquiteturas e características dependem do problema a ser solucionado.

Mesmo assim, McCulloch e Pitts (1943, apud HAY94) propuseram o modelo básico do neurônio artificial e desde então o estudo das RNA vem avançando em diversas áreas de aplicação, como reconhecimento de padrões, previsão, controle, etc.

2.2 Composição de uma Rede Neural

A configuração básica do neurônio artificial é mostrada na Figura 1. Este pode se conectar com outros formando uma rede mediante enlaces que correspondem às conexões axônio sinapse-dendrito em um neurônio biológico.




Figura 1: Configuração básica do neurônio (modificado de HAY94).

Um neurônio “j” possui várias entradas “xi” que podem ser saídas provenientes de outros neurônios conectados a ele. Cada conexão tem associado um peso sináptico “wij” que determina a natureza e intensidade da influência de um nó sobre outro. Assim, a influência de um nó sobre outro é o produto da saída do neurônio antecessor com o peso do enlace que os conecta (“wijxi”). Cada neurônio combina as influências separadas que recebe em seus enlaces de entrada em uma influência global, que é a soma “sj” de todas. Para determinar a saída “yj” do neurônio, esta soma passa através de uma função de ativação “f”, podendo ser função linear ou não linear [HAY94].

2.3 Rede Neural Multicamada

Uma rede neural resulta da interconexão de vários nós básicos em várias configurações, denominado de arquitetura da rede.

A arquitetura mais popular é a rede feedforward multicamada [HAG96]. Nela a configuração consiste em camadas de neurônios na qual a saída de um neurônio, numa camada, alimenta todos os neurônios da camada seguinte. O fundamental desta arquitetura é que não existem laços de realimentação. A rede feedforward é referida também como multilayer perceptron (MLP) [HAY94, NUN98, MOA99, SPE99, LUK00].

Definido um vetor de entrada $x = [X_0, X_1, X_2, \dots, X_n]$ e um vetor de saída $y = [Y_0, Y_1, Y_2, \dots, Y_n]$, a MLP forma um mapeamento complexo $y = \Psi(w, x)$ da entrada da primeira camada para a saída da última camada, parametrizado pelos pesos sinápticos w . Dado um modelo de neurônio no qual os pesos são fixos, o mapeamento é estático, não apresentando dinamismo. Contudo, o MLP é uma ferramenta muito potente, pois com duas ou mais camadas e um número suficiente de neurônios, consegue-se aproximar qualquer função uniformemente contínua. Ou seja, é possível caracterizar um aproximador universal.

2.4 Redes Neurais Temporais com Atraso no Tempo

A idéia básica do processamento espaço-temporal utilizando atrasos no tempo é mostrada na Figura 2. A resposta da rede neural típica feedforward, no tempo t , é baseada nas entradas no tempo $(t-1)$, $(t-2)$, ..., $(t-n)$. Desta forma, considera-se um histórico da seqüência temporal. Esta arquitetura, onde os atrasos são utilizados somente na camada de entrada, é muito utilizada em aplicações temporais [LUK00]. Porém, existem generalizações do método para considerar atrasos também nas camadas escondidas e na de saída. Estas considerações complicam o uso deste tipo de rede. Em contrapartida melhoram o desempenho das redes, gerando uma significativa diferença entre a primeira arquitetura e esta [LUK00, GOU97].

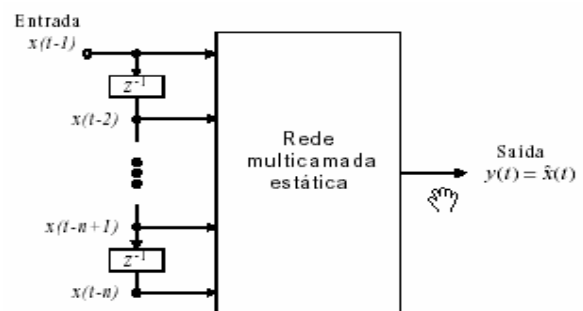


Figura 2: Processamento espaço-temporal utilizando atrasos no tempo (modificado de HAY94).

3. ESTUDO DE CASO

Para a aplicação dos conceitos e técnicas anteriormente apresentados, utilizou-se como estudo de caso a verificação da aplicabilidade de uma rede neural temporal na previsão do nível de mar observado, em função de uma janela de tempo (série temporal). Para isto foram utilizados os dados horários de níveis do mar da Praia da Enseada, e dados horários meteorológicos da Praia Grande, ambos no município de São Francisco de Sul, SC, obtidos para o período de julho a dezembro de 1996.

3.1 Problema

Para se estimar o nível do mar costeiro com uma RNA é necessário definir quais são os fenômenos que geram as oscilações de nível. Assim, a previsão do nível do mar realizada com a ferramenta de RNA deverá incluir as flutuações do nível do mar costeiro em períodos de horas a dias, visto que este contém diversas oscilações em um amplo espectro temporal. Estas oscilações propagam-se como ondas no oceano até atingirem as costas. Destas, as marés astronômicas representam as flutuações em períodos de horas e as marés meteorológicas referem-se as oscilações de dias no nível do mar.

As marés astronômicas são previsíveis e podem ser conhecidas tendo-se a mão as tábuas de marés. Já as marés meteorológicas, assim como o fenômeno atmosférico que as gerou, tem caráter aleatório e de difícil previsão com modelos analíticos e numéricos. Ambas marés têm processos geradores distintos e operam independentemente uma da outra.

As maré astronômicas referem-se a subida e descida do nível do mar de maneira periódica, repetitiva e determinística, geradas pela atração gravitacional entre o sistema Sol-Terra-Lua, e associadas à aceleração centrípeta. Estas marés fazem parte de um processo hidrodinâmico marinho totalmente relacionado com a astronomia.

As marés meteorológicas, por sua vez, são causadas por ventos fortes que atuam sobre grandes áreas da superfície do mar e variações na pressão atmosférica. Ocasionalmente, ocorre a combinação das marés meteorológicas com períodos de sizígia das marés astronômicas, causando consideráveis inundações em regiões costeiras, praias, baías e estuários. A combinação de ambas gera o nível do mar observado, objeto da aplicação da RNA neste trabalho.

As forçantes atmosféricas responsáveis pela maré meteorológica, componente do nível do mar costeiro, são o vento e a pressão atmosférica. Através da utilização de modelos de regressão linear múltiplos, no domínio do tempo e da frequência, observou que esta componente do nível do mar responde ao vento norte-sul e a pressão atmosférica após períodos de 6 e 37 horas para a área de estudo, respectivamente [TRU02a, TRU02b]. Assim, o modelo informação proposto deve contemplar esta dinâmica, com os seguintes dados de entrada para treinamento da rede: o nível do mar observado, o nível da maré astronômica, e as componentes ortogonais do vento E-W e S-N (eq. 1). A pressão, no modelo de informação proposto, encontra-se implícita na variável vetorial vento.

$$NOb_{(t+6)} = f(NOb_{(t)}, NA_{(t+6)}, VNS_{(t)}, VLO_{(t)}, VNS_{(t-6)}, VLO_{(t-6)}) \text{ (eq.1)}$$

Onde:

$NOb_{(t+6)}$ = nível do mar a ser estimado para 6 horas após

$NOb_{(t)}$ = nível do mar observado

$NA_{(t+6)}$ = nível da maré astronômica estimado para 6 horas após

$VNS_{(t)}, VLO_{(t)}$ = componentes ortogonais dos ventos observados

$VNS_{(t-6)}, VLO_{(t-6)}$ = componentes ortogonais dos ventos observado 6

horas antes

3.2 Implementação da RNA e testes

3.2.1 Ferramenta

A ferramenta escolhida para implementação da RNA foi o MatLab® (versão 6.0) por este oferecer um pacote de funções que trabalham com redes neurais, reduzindo o esforço para condução dos testes iniciais.

3.2.2 Preparação dos Dados

A série temporal com os dados do modelo de informação proposto foram obtidos em formato Excel®, contendo 3.692 observações. A série temporal foi dividida em dois conjuntos necessários para a o teste da aplicabilidade da RNA temporal, um para treinamento da rede, outro para teste. Para o conjunto de treinamento foram separadas as primeiras 3.000 observações, ou 81,4 % dos dados. Os 18,6 % restantes separados para o teste. A normalização dos dados de entrada foi realizada com uma função oferecidas pelo MatLab®.

3.2.3 Arquitetura da Rede

A escolha da MLP com atraso de tempo se deu em função dos significativos resultados encontrados por trabalhos com aplicações em estudos de séries temporais em previsão [e.g. GOU97, NUN98, SPE99, MOA99, LUK00]. Na implementação da arquitetura escolhida, vários testes com diferentes configurações foram feitos, variando-se o número de camadas ocultas, a função de treinamento e as funções de transferência. Ao final dos testes, optou-se pela configuração com os melhores resultados obtidos. Assim, a RNA temporal escolhida, cujo treinamento e resultados encontram-se apresentados neste artigo, têm a seguinte configuração: atraso no tempo, com a função de treinamento de gradiente instantâneo, e funções de transferências lineares. A rede é composta de quatro neurônios na camada de entrada, três camadas ocultas com sete, cinco e três neurônios nesta ordem, e uma camada de saída com apenas um neurônio.

3.2.4 Treinamento da Rede

Para o treinamento da rede foi definido um erro máximo para o treinamento de 0,15%, ou seja, um erro quase nulo, alcançado com pouco menos de 700 épocas de treinamento. Este fato demonstra que a arquitetura escolhida representa uma boa opção para a RNA temporal proposta para o modelo de informação do problema. Na Figura 3 é mostrada a evolução do treinamento.




Figura 3: Evolução do treinamento da rede frente a meta de erro.

3.2.5 Teste da Rede

A Figura 4 apresenta os resultados do teste de previsão efetuado com a RNA já treinada. Em poucos trechos do gráfico nota-se diferenças entre os dados previstos e os observados, mesmo assim sem valores extremos. Estes resultados serão comentados mais adiante no tópico resultados obtidos.




Figura 4: Comparação dos resultados da rede. Em azul encontra-se representada a maré observada, e em vermelho a maré prevista.

3.3 Resultados Obtidos

Comparando-se as alturas do nível do mar costeiro observado com o resultado previsto, e considerando-se um erro aceitável de 10 cm, os resultados obtidos foram satisfatórios em 577 acertos de previsão do conjunto de 692. Isto representa 83,4 % do total do conjunto de teste.

4. CONCLUSÕES FINAIS

Neste trabalho pode-se observar o comportamento da RNA temporal para a resolução de problemas com séries temporais, neste caso as marés astronômicas e meteorológicas responsáveis pela oscilação do nível do mar costeiro. Notou-se claramente a capacidade destas redes de captar (generalizar) o comportamento da série de uma forma eficiente e rápida, indicando a viabilidade deste tipo de modelo para previsões de níveis do mar.

A diminuição da porcentagem de erro de 10 cm na análise dos resultados das previsões pode ser alcançada com novas tentativas de aplicação da rede, incluindo novos parâmetros, e/ou o aumento da série de treinamento empregada. Sugestões estas que compõem o rol de atividades a serem desenvolvidas na evolução deste estudo.

REFERÊNCIAS BIBLIOGRÁFICAS

- [CIC93] A. Cichocki, R. Unbehauen. "Neural networks for optimization and signal processing". John Wiley & Sons. 1993.
- [GOU97] C. Goutte. Lag Space Estimation in Time Series Modelling. Proceedings of the International Conference on Acoustics, Speech, and Signal Processing. April 21-24, 1997, Munich, Germany.
- [HAG96] M.T.Hagan, H.B.Demuth, M.Beale. "Neural Network Design". PWS Publishing Company. 1996.
- [HAY94] Simon Haykin. "Neural Networks-A comprehensive foundation". Prentice Hall, 1994.
- [HAY97] S. Haykin, P. Yee, E. Derbez. "Optimum Nonlinear Filtering". IEEE Transactions on Signal Processing, special issue on Neural Networks, Nov. 1997.
- [KRA02] V. M. Krasnopolsky, D. V. Chalikov, H. L. Tolman. "A neural network technique to improve computational efficiency of numerical oceanic models". Ocean Modeling. 2002.
- [LUK00] K.C. Luk, J.E. Ball, A. Sharma. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting. Journal of Hydrology, v.227, 2000, p. 56-65.
- [MOA99] F. Moatar, F. Fessant, A. Poirel. pH modelling by neural networks. Application of control and validation data series in the Middle Loire river. Ecological Modelling, v.120, 1999, p.141-156.
- [NUN98] G. Nunnari, A. F. M. Nucifora, C. Randieri. "The application of neural techniques to the modelling of time-series of atmospheric pollution data". Ecological Modelling, v.111, 1998, p.187-205.
- [SPE99] G. Spellman. "An application of artificial neural networks to the prediction of surface ozone concentrations in the United Kingdom". Applied Geography, v.19, 1999, p.123-136.
- [TSAI99] C-P Tsai T-L Lee. Back-propagation neural network in tidal-level forecasting. Jour. of Waterway, Port, Coastal, and Ocean Engineering. 125(4): 195-202. 1999.
- [TRU01a] Truccolo, E.C.; Franco, D.; Schettini, C.A.F. 2002. Coastal sea level variability due to meteorological forcing in the northern coast of Santa Catarina, Brazil: observations. In: Littoral2002 – Sixth International Symposium – The Changing Coast, Porto. Proceedings – A Multi-Disciplinary Symposium on Coastal Zone Research, Management and Planing. Porto, Portugal. Eurocoast & EUCC. v.2, p.219-223.
- [TRU02b] Truccolo, E.C.; Franco, D.; Schettini, C.A.F. 2002. Coastal sea level variability due to meteorological forcing in the northern coast of Santa Catarina, Brazil: predictions. In: Littoral2002 – Sixth International Symposium – The Changing Coast. Proceedings – A Multi-Disciplinary Symposium on Coastal Zone Research, Management and Planing. Porto, Portugal. Eurocoast & EUCC. v.2,p.225-228.
- [WEG97] M.C. van de Weg. Prediction of the water level during storm situations using neural networks. Thesis, Department of Computer Science. Leiden University, The Netherlands.1997. 54p.