

Aplicação da Função de Autocorrelação na Determinação de Parâmetros de Entrada em Rede RBF na Predição de Séries Temporais

Vinícius Leal do Forte, Getúlio Pontes de Melo, Robson Mariano

Depto de Matemática, Instituto de Ciências Exatas, UFRRJ,
BR-465, Km 7 Seropédica/Rio de Janeiro - CEP. 23.890-000
E-mail: varqq@ufrj.br, gpmelo@ufrj.br, robsonms@ufrj.br

A Predição da variação de temperatura é de extrema importância para o setor agrícola, pois auxilia na tomada de decisão sobre o cultivo de determinadas culturas, além de reduzir os riscos da atividade agrícola. A utilização da média compensada permite obter uma análise climatológica mais robusta, pois expressa com maior grau de confiabilidade as variações de temperaturas. Este trabalho tem como objetivo inicial verificar a aplicabilidade das Redes Neurais RBF na predição da variação de temperatura utilizando a série histórica da média compensada.

A aplicação de metodologias de análise de séries temporais, incorporando a correlação existente entre as observações, possibilita o desenvolvimento de modelos de predição e monitoramento mais adequados. Nos últimos anos, considerável atenção tem sido dedicada a métodos alternativos para o estudo de séries temporais com padrões não-lineares. Dentre as metodologias utilizadas, destacam-se as redes neurais.

As redes RBF tem sido aplicadas com sucesso em uma grande diversidade de aplicações incluindo interpolação [1,2], modelagem de séries temporais caóticas [3,4], identificação de sistemas, engenharia de controle [5], etc.

As funções de base radial (RBFs) são geralmente funções não-lineares cujo valor cresce ou decresce monotonicamente à medida que a distância do centro da função de base radial aumenta. Sua técnica consiste na escolha de uma função de aproximação F definida por:

$$F(x) = \sum_{i=1}^N w_i \varphi(\|x - x_i\|) \quad (1)$$

Onde $\{ \varphi(\|x - x_i\|) ; i=1,2,\dots,N \}$ é um conjunto de N funções arbitrárias, geralmente não-lineares, conhecidas como função de base radial e $\|\cdot\|$ representa uma norma euclidiana. A função de base radial do tipo Gaussiana, é mais utilizada em aplicações de redes neurais RBF.

As redes neurais RBF são redes de aprendizado local [6]. Originalmente utilizavam tantas funções

de base radial quanto fossem os padrões do conjunto de dados, obtendo assim uma exatidão da aproximação. Entretanto, esta abordagem, além de requerer um esforço computacional elevado gerava também uma super especialização da rede [7]. Atualmente nem todos os vetores de entrada possui uma função de base radial associada.

A rede neural RBF é constituída de uma camada de entrada que representa o vetor de entrada $x(n) \in \mathfrak{R}^{m^0}$; uma camada intermediária de neurônios não-lineares onde cada neurônio calcula a distância entre o vetor de entrada e o centro da função de base radial e a camada de saída constituída de um único neurônio linear, que é a soma das saídas de cada função de base radial, ponderadas pelos respectivos pesos sinápticos w_k , de modo que a combinação linear é expressa por:

$$y = \sum_{k=0}^{k-1} w_k \varphi_k(x, t_k, \sigma_k^2) + b_0 \quad (2)$$

Onde o termo $\varphi_k(x, t_k, \sigma_k^2)$ é a k -ésima função de base radial; $x(n) \in \mathfrak{R}^{m^0}$ representa o vetor de entrada x no instante n ; $t_k(n) \in \mathfrak{R}^{m^0}$ é o vetor centro da k -ésima função de base radial; k é o numero de funções de base radial, $\sigma_k^2(n) \in \mathfrak{R}$ é a variância associada a cada uma das funções no instante n ; w_k são os pesos sinápticos e b_0 é o termo constante de polarização ou bias.

O procedimento para a implementação de uma rede neural RBF consiste na determinação, através de um processo de aprendizagem, dos valores adequados para os parâmetros livres da RBF, que são variância, os centros e os pesos sinápticos [6]. Este processo é constituído de dois estágios. O primeiro, utiliza técnicas não-supervisionadas para determinar as funções de base radial e o segundo, utiliza técnicas supervisionadas para determinar os pesos na camada de saída.

A figura 1 representa a arquitetura da rede neural RBF.




Figura 1: Arquitetura da rede RBF.

Para a determinação do conjunto de dados de entrada foi utilizada a função de auto-correlação (ACF), a qual mede a correlação entre observações em tempos diferentes, assim determinando quais são as observações que contribuem para a formação do padrão da série temporal.

A equação abaixo determina a correlação entre observações separadas por um atraso k:

$$r_k = \frac{\sum_{i=1}^{N-k} (x_i - \bar{x})(x_{i+k} - \bar{x})}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (3)$$

O valor r_k é denominado coeficiente de auto-correlação em um atraso k.

Os dados utilizados foram coletados junto a Estação Meteorológica do INMET/PESAGRO no Município de Seropédica, Rio de Janeiro (Latitude: 22°45' sul, Longitude: 43°41' oeste, Altitude: 33m) ao longo dos anos 1970 a 2003.

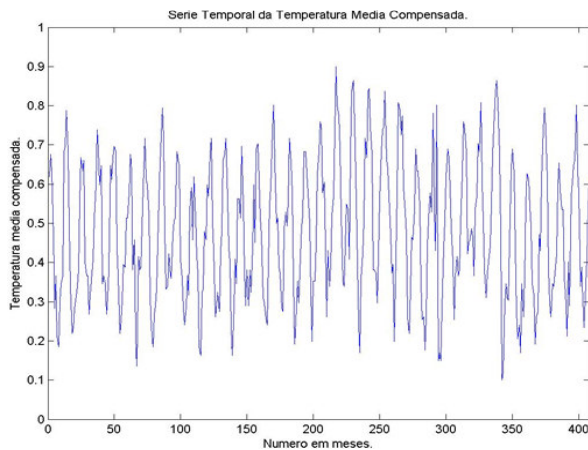


Figura 2: Representação gráfica da série temporal da Temperatura média compensada.

As redes foram implementadas utilizando a função *Newrb* existente no Toolbox de redes neurais (Neural Network Toolbox) do MATLAB. (*The*

MathWorks Inc.) versão 6.0. Para a função de base radial foi utilizada a função gaussiana.

Os dados foram normalizados no intervalo de [0,1;0,9], de sorte a evitar a saturação dos neurônios da rede neural. Sendo os mesmos divididos em três grupos - treinamento (13 anos), teste (11 anos) e validação (10 anos).

Para avaliar a capacidade de predição foi utilizada a raiz do erro quadrado médio normalizado (NRMSE), definido por:

$$NRMSE = \sqrt{\frac{\sum [x(t) - \hat{x}(t)]^2}{\sum x^2(t)}} \quad (4)$$

Onde $\hat{x}(t)$ é o valor predito pela rede neural, $x(t)$ é o valor original na série temporal.

A figura 3 mostra o gráfico obtido da ACF e o limite de confiança de *Bartlett* para a série em estudo.

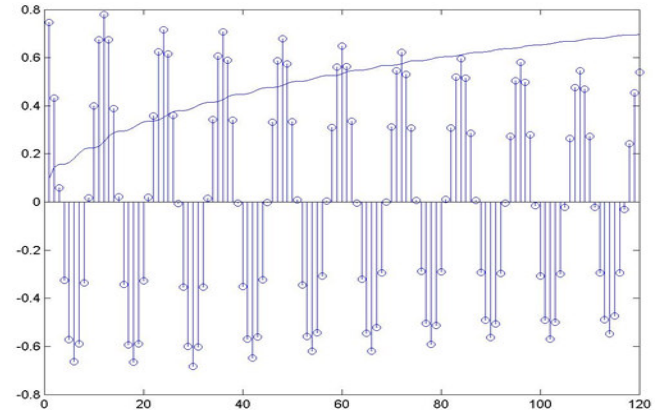


Figura 3: Gráfico da ACF para a série estudada

A função de autocorrelação para o conjunto de treinamento da série da temperatura média compensada (figura 3), mostrou os seguintes atrasos acima dos limites de confiança de *Bartlett*: 1,2,10,11,12,13,14,23,24,25, 35,36,37,47,48,49,59,60,61e71. Utilizou-se, portanto, como conjunto de entrada os elementos $\{x_{i-1}, x_{i-2}, x_{i-10}, x_{i-11}, x_{i-12}, x_{i-13}, x_{i-14}, x_{i-23}, x_{i-24}, x_{i-25}, x_{i-35}, x_{i-36}, x_{i-37}, x_{i-47}, x_{i-48}, x_{i-49}, x_{i-59}, x_{i-60}, x_{i-61} \text{ e } x_{i-71}\}$.

A figura 4 mostra o resultado obtido na predição do conjunto de validação para a série de temperatura média compensada.

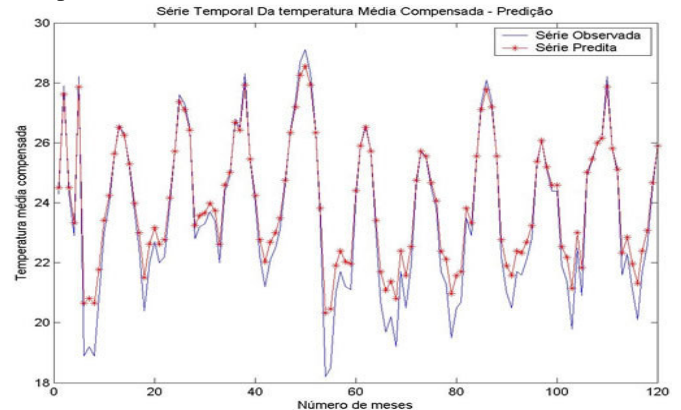


Figura 4: Predição obtida para conjunto de validação.

O erro NRMSE obtido pela rede neural implementada para o conjunto de validação foi de 0.028727, o que equivale aproximadamente 3%.

O resultado obtido pela rede neural RBF, com os parâmetros de entrada definidos pela função de autocorrelação para a série temporal em estudo, foi satisfatório. Indicando que a metodologia de função de autocorrelação possui potencial para se aplicada na determinação do conjunto de entrada da rede neural RBF.

Embora o resultado tenha sido satisfatório, é pertinente também compará-la a outros métodos de predição bem mais estruturados, como os modelos SARIMA e modelo linear dinâmico (DLM).

Agradecimento

Ao INMET/PESAGRO – Estação Meteorológica de Seropédica por ter cedido os dados.

Referências

- [1] Broomhead, D.S., Lowe, D, “Multivariable functional interpolation and adaptative networks,” *Complex System* , vol. 2, pp. 335-336. (1988).
- [2] Matej, S., Lewitt, R.M., “Practical Consideration for 3-D image reconstruction using spherically symmetric volume elements,” *IEEE Trans. on Medical Imaging*, vol. 15 , no. 1, pp. 68-78. (1996).
- [3] Moody, J., “Fast learning in networks of locally-tuned processing unit,” *Neural Computation*, vol. 1, pp.281-294. (1988).
- [4] Casdagli, M., “Nonlinear prediction of chaotic time series,” *Physica D*, vol. 35, pp. 335-356. (1989).
- [5] Sanner, R. M., Slotine, J.-J. E., “Gaussian networks for direct adaptive control,” *IEEE Trans. On Neural Networks*, vol. 3, no. 6, pp. 837-863 (1994).
- [6] Haykin, S., “Redes Neurais: Princípios e Prática, 2ª ed. Bookman, Av. Jerônimo de Ornellas, 670 – Porto Alegre, RS, Brasil, 2001. Tradução: Paulo Martins Engel.
- [7] Bishop, C. M., “Neural Networks for Pattern Recognition.” Oxford University Press, 1997.