



ISSN:1984-2295

Revista Brasileira de Geografia Física

Homepage: www.ufpe.br/rbgfe



PROGNÓSTICO DE RADIAÇÃO SOLAR ATRAVÉS MODELOS QUE COMBINAM AS TÉCNICAS WAVELET E REDES NEURAIAS.

Samuel Vitor Saraiva¹; Ricardo Ferreira Carlos de Amorim²; Frede de Oliveira Carvalho³; Leonardo Domingues⁴

^{1,4}Graduandos em Engenharia Química, Universidade Federal de Alagoas, Maceió, Alagoas, Brasil, ¹samuk_saraiva@hotmail.com e ⁴leonardodomingues1994@gmail.com ²Prof. Doutor do Instituto de Ciências Atmosféricas, Universidade Federal de Alagoas, rfgamorim@gmail.com ³ Prof. Doutor do curso de Engenharia Química, Universidade Federal de Alagoas, fredecarvalho@yahoo.com.br.

Artigo recebido em 02/07/2014 e aceito em 21/08/2014

RESUMO

O prognóstico de variáveis meteorológicas, como radiação solar, sempre foi de grande importância para a tomada de decisão em ocasião de ocorrências de eventos incomuns. Nesse contexto é justificável a busca por modelos matemáticos e estatísticos que produzam melhores prognósticos para tais variáveis. Desta forma investiga-se a estratégia de junção que se compõe de duas técnicas muito utilizadas no tratamento de série temporal; a transformada Wavelet que mostra analiticamente o sinal no domínio do tempo e da frequência; e as RNA's a quais são modelos de inteligência artificial. A combinação dessas duas técnicas, o que se denomina modelo híbrido, tem se mostrado eficaz no prognóstico de variáveis meteorológicas. Os dados diários de radiação solar são do Instituto Agrônomo do Paraná/PR coletados no período de 1990 até 1995. Neste trabalho são estudadas junções de modelos híbridos com Redes Neurais e técnicas Wavelets, apresentando o resumo de alguns dos modelos sintetizados na literatura, para o prognóstico de radiação solar. Tais modelos híbridos estudados se mostraram satisfatórios no prognóstico dessa variável, pois apresentaram um melhor desempenho em relação aos modelos que não são híbridos, sendo o modelo que se mostrou mais eficiente no prognóstico foi o que utiliza as sub-séries da decomposição como entrada da Rede Neural, pois apresenta regressão com valores significativos (R próximo a 1).

Palavras chaves: Wavelet, Rede Neural, Prognóstico.

FORECAST OF SOLAR RADIATION THROUGH MODELS THAT COMBINE THE WAVELET AND NEURAL NETWORKS TECHNIQUES

ABSTRACT

The prognosis of meteorological variables such as solar radiation has always been of great importance for decision making in time of occurrence of unusual events. In this context it is justifiable to search for mathematical and statistical models that produce better prognosis for these variables. Thus investigates the combination strategy which uses two techniques widely used in the treatment time series; Wavelet transform analytically shows that the signal in the time domain and frequency; and the RNA's which models of artificial intelligence. The combination of these two techniques, which is called the hybrid models, has proven effective in predicting meteorological variables. Daily data of solar radiation are the Agronomic Institute of Parana / PR collected from 1990 to 1995. In this work conjunctions of hybrid models with neural networks and wavelets techniques are studied, presenting a summary of some of the synthesized models in the literature for the prediction of solar radiation. Such hybrid models studied were satisfactory prognosis with this variable because it showed better performance compared to models that are not hybrids in the model that is more efficient prognosis was that uses the sub-series decomposition as input the Network neural, it presents significant regression values (R close to 1).

Keywords: Wavelet, Neural Network, Forecast

* E-mail para correspondência:
samuk_saraiva@hotmail.com (Saraiva, S. V).

Introdução

Revisão Bibliográfica

O uso de energias renováveis é um tema que tem mobilizado em grandes proporções a comunidade científica. O uso da energia solar tem se destacado, mesmo sendo um processo de alto custo. O crescimento da sua utilização para a produção de energia elétrica tem sido muito procurado, se comparado as energias eólicas, marítima e etc.

A radiação solar é considerada de extrema importância social e econômica e influencia em todas as variáveis meteorológicas. Um modelo de prognóstico da radiação solar pode ser de fundamental importância para auxiliar projetos envolvendo energia renováveis.

Tal modelo de prognóstico de séries temporais, ou sinal, de radiação pode ser abordado por dois aspectos: os conceituais e os empíricos. Os conceituais requerem um estudo da física do problema, utilizando a construção de equações que descrevem o fenômeno estudado. Os empíricos se utilizam apenas da estatística das séries de radiação ou de outras variáveis meteorológicas que tenham correlação com a série. Estas variáveis meteorológicas podem ser precipitação, temperatura, velocidade do vento, etc. De uma forma geral os modelos empíricos são muito utilizados em fenômenos complexo, envolvendo multivariabilidade e altas não linearidades, como no tratamento de séries temporais de radiação.

Eventos de radiação solar, vazões, precipitação, secas prolongadas, velocidades de vento e outras diversas outras variáveis, que a partir de um monitoramento adequado possam ser caracterizadas como séries temporais, podem ser investigadas através de um prognóstico de curto e/ou até mesmo de longo prazo. Dessa forma, uma quantificação dos riscos e ações preventivas pode ser mais bem identificada, classificadas e gerenciadas a partir dessa análise, e as ações de mitigação podem ser direcionadas com mais eficiência.

Assim, o estudo das técnicas que possam melhorar a eficiência nas previsões baseadas em séries temporais são de grande importância e necessidade para sociedade como um todo. Kim e Valdés (2004) afirmam que tradicionalmente modelos estatísticos têm sido utilizados para prognóstico de acontecimento em séries temporais. Regressões simples e múltiplas e modelos autoregressivos de médias móveis - *Autoregressive Moving Average* (ARMA) são modelos que usam métodos estatísticos de prognóstico através de séries temporais. Entretanto, estes são basicamente lineares. Assumindo que os dados são estacionários tendo esses uma habilidade limitada em capturar as não estacionariedades e as não-linearidades presente no fenômeno. Variáveis meteorológicas como radiação solar e variáveis hidrológicas como vazão anual e mensal, além da precipitação de chuvas são extensivamente modelados pelo modelo ARMA, que tem sido utilizado e bem aceito nas últimas décadas. Entretanto, é necessário considerar modelos alternativos que melhor tratem a não linearidade e não-estacionariedade dos fenômenos que são representativos e significantes para uma melhor eficiência nos prognósticos.

Zhang (2003) já afirmava, antes de Kim e Valdés (2004), que os modelos matemáticos e estatísticos são usuais e aplicados à prognóstico de séries temporais, e podem ser baseados em processos lineares (box; jenkins, 1994). Contudo, os processos no mundo real, geralmente, são complexos e podem, ainda, conter partes lineares e/ou não-lineares. Esses autores afirmam que os modelos mais adequados à processos complexos e não-lineares seriam os baseados em técnicas de sistemas inteligentes tais como redes neurais artificiais.

Chen (2008) e Khashei e Bijari (2012), complementando as informações do Zhang (2003), afirmam que a combinação dos métodos de pré-tratamento de dados e obtenção de melhores estruturas para as redes neurais tem sido muito utilizada para prognóstico de séries temporais dando origem aos que são intitulados de sistemas híbridos. Os sistemas híbridos são a junção de duas ou mais técnicas em uma mesma metodologia, destacando ser essa uma tendência atual de investigação.

Yu, Yang e Liu (2013) fazem uso do princípio de seleções de variáveis de entrada para os modelos neurais na avaliação de dois tipos de mecanismos de prognósticos em longo prazo para dados hidro-meteorológicos utilizando modelos híbridos, combinando as transformadas Wavelet e as redes neurais artificiais. Os autores chamam atenção que muitos modelos híbridos têm sido propostos para melhorar a precisão de prognóstico de séries temporais de dados hidro-meteorológicos, os quais combinam transformada Wavelet, redes neurais, lógica fuzzy, algoritmos evolucionários trazendo várias referências. Porém, neste trabalho, os autores investigaram efetivamente os modelos híbridos fazendo a conjunção das transformadas Wavelets, redes neurais (DWT-NN) e neuro-fuzzy (DWT-NF) comparando seus desempenhos com outros quatro tipos de modelos puramente neurais *Neural-Network* (NN), *Back-Propagation Neural Network* (BP-ANN) e modelos híbridos Neuro-fuzzy (NF).

Ainda em relação ao trabalho de Yu, Yang e Liu (2013), foram analisadas diferentes composições para as entradas de dados nos modelos. Para cada diferente combinação de entradas, os modelos híbridos (DWT-NF e DWT-ANN) foram testados através de diversos treinamentos, utilizando diferentes algoritmos e funções de transferências para as redes neurais. Os dados utilizados no estudo corresponderam aos dados de precipitação e evaporação diárias de duas estações de um rio na província de Jiangsu monitorados por 14 anos (5113 dias) de 1998-2011 e foi verificado o prognóstico de três anos a frente de dados diários. Neste, a raiz quadrada do erro quadrático médio (RMSE) e o erro absoluto médio nas previsões foram utilizados para avaliar a eficiência da metodologia testada. Os autores concluíram o estudo afirmando que o modelo DWT-NF apresentou o melhor desempenho quando comparado aos outros modelos testados, afirmando inclusive que esta investigação, em sua abrangência, teria um caráter inédito.

Deve-se ressaltar que, através da literatura consultada, perceber-se que a utilização da conjunção

das transformadas Wavelets com redes neurais e sistemas híbridos neuro-fuzzy em diferentes aplicações na modelagem empírica de séries temporais, mais principalmente em aplicações relacionadas à tentativa de mitigação das consequências de desastres naturais através dos prognósticos das variáveis hidrológicas e meteorológicas causadoras dos mesmos, é o cerne dos estudos dessa área. Este fato mostra a importância do desenvolvimento de estratégias para a conjunção de diferentes técnicas para prognóstico de séries temporais que podem contribuir em muito na mitigação de desastres naturais.

O presente trabalho aborda o desenvolvimento de um conjunto de modelos híbridos baseados mais especificamente na avaliação dos tipos de conjunções reportados na literatura de Partal (2007), Nayak (2010) e Kim (2003) que se baseiam nas conjunções (DWT-NN).

Transformada Wavelet

Devido à complexidade da série temporal do fenômeno estudado e o seu comportamento não estacionário, onde há variações nas frequências durante todo o seu domínio de tempo, foi utilizada a transformada Wavelet com a finalidade de obter dados que descrevem o comportamento do sinal extraindo os seus componentes de frequência. A Transformada Wavelet é uma técnica matemática que transforma um

sinal no domínio do tempo para o domínio do tempo e da frequência por meio de um cálculo integral, essa transformada é descrita pela equação 1, onde $x(t)$ representa o sinal temporal.

$$W(a,b) = \int_{-\infty}^{+\infty} x(t) \varphi_{a,b}(t) dt \quad (1)$$


Onde se tem que;

$$\varphi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \left(\frac{t-b}{a} \right) \quad (2)$$

$\varphi(t)$ na Equação (1) é o que se chama de Wavelet-mãe. É uma função ondulatória cuja área sob seu gráfico é igual a zero, e cuja energia tem valor finito:

$$\int_{-\infty}^{\infty} \varphi(t) dt = 0$$

$$0 < \int_{-\infty}^{\infty} |\varphi(t)|^2 dt < \infty$$



Fonte: Autores

Figura 1 – Wavelets-Mãe

Existem diversas funções que foram criadas com essas características. Veja alguns exemplos de Wavelets-mãe na Figura 1.

Observando-se a equação 2, é possível verificar que variando o valor de a (parâmetro de escala) pode-se contrair ou “esticar” a Wavelet, variando o valor de b (parâmetro de posição) pode-se deslocar a função Wavelet para a esquerda ou para a direita o quanto se queira. Na transformada Wavelet, o parâmetro de escala se relaciona com a frequência do sinal, quanto menor a escala, maior a frequência correspondente do sinal. O parâmetro de posição se relaciona com os instantes de tempo do sinal.

A Análise Wavelet é dividida em transformada Wavelet discreta (DWT – *discrete Wavelet transform*), pacote de transformada Wavelet (WPT – *Wavelet packet transform*) e transformada Wavelet contínua (CWT – *continuous Wavelet transform*). Tendo sido aplicada a Equação (1), a transformada Wavelet discreta é a separação dos componentes de frequência do sinal de acordo com a magnitude. É a decomposição do sinal em seus coeficientes de aproximações (baixa frequência) e detalhe (alta frequência). Depois da primeira decomposição, apenas a aproximação é decomposta em um nível maior, funcionando basicamente como um filtro passa alta e passa baixa (Weeks 2012) como

mostra o exemplo na Figura 2, onde o nível desejado é o 7. Para o pacote de transformada Wavelet, depois do primeiro nível de decomposição, os detalhes e aproximações são decompostos nos níveis seguintes até o nível que é desejado.

Diferente da transformada Wavelet discreta, a CWT não separa (decompõe) o sinal em seus

componentes de frequência. Durante o processo de transformação, a Wavelet é escalonada e deslocada sobre todo o domínio do sinal analisado. A transformada discreta, DWT, tem como finalidade extrair os componentes de alta e baixa frequência sendo uma maneira excelente de extração de característica de séries temporais.




Figura 2. Decomposição Wavelet nível 7

Redes Neurais

Pode-se dizer que uma rede neural é um programa de computador que tenta imitar a intrincada estrutura de funcionamento do cérebro humano, refletindo no comportamento de uma máquina que aprende situações de causa-efeito. Uma característica marcante das redes neurais é a sua total independência do conhecimento da natureza fenomenológica do processo que se vai abordar, de modo que tal abordagem torna-se interessante quando as regras de um determinado processo não são determinísticas ou são muito complexas, como por exemplo, problemas onde ocorrem variáveis não-lineares. Tais problemas podem ser resolvidos com o uso de redes neurais artificiais, pois os neurônios artificiais apresentam resposta não-linear e são altamente conectados, podendo mapear uma relação multivariável de entrada-saída.

Redes neurais artificiais são compostas de vários elementos computacionais simples (nodos) que interagem localmente. A arquitetura destes modelos é especificada pelas características do nodo, topologia da rede e algoritmo de treinamento.

Os nodos em redes neurais artificiais são processadores bastante simples inspirados por seus similares biológicos (neurônios cerebrais).

Verifica-se que o neurônio artificial realiza seus cálculos baseados em suas informações de entrada. Ele faz o somatório do produto entre os vetores de entrada

e os pesos W_j , subtrai a ativação residual interna, representado como Th_j , e então passa este resultado para uma forma funcional, $f(\cdot)$, ou seja:

$$f(W_j \cdot A - Th_j) = f\left(\sum_{i=1}^n (W_{ij} \cdot a_i - Th_j)\right)$$

Esta forma funcional poderia ser qualquer função como logarítmica, exponencial, raiz quadrada e etc, mas os matemáticos e cientistas da computação reportam que as funções sigmoidais são vantajosas para esta aplicação. A função típica utilizada pode ser representada pela Eq. 3.

$$F(n) = \left(\frac{1}{1 + e^n}\right) \quad (3)$$

Esquemáticamente podemos ver um neurônio artificial na figura 3, onde a função de ativação representa a forma funcional neste comentado.

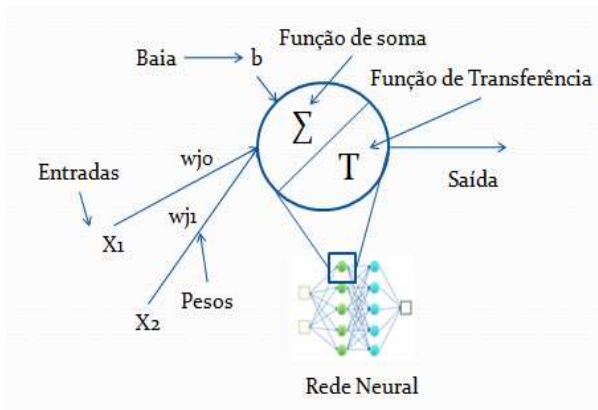


Figura 3 – Representação de um Neurônio Artificial.

Treinamento da rede neural

O aprendizado (ou treinamento) de uma rede neural é o processo pelo qual os parâmetros livres de uma rede neural são ajustados por meio de uma forma continuada de estímulo pelo ambiente externo, sendo o tipo específico de aprendizado definido pela maneira particular como ocorrem os ajustes dos parâmetros livres (Braga, 2007).

Aprendizado supervisionado é utilizado para treinamento da rede neural quando esta é utilizada como ajustadora de funções multivariáveis e não-lineares, caso dos analisadores virtuais. Neste tipo de aprendizado, necessariamente, pressupõe-se a existência de um supervisor, ou professor externo, o qual é responsável por estimular as entradas da rede por meio de padrões de entrada e observar a saída calculada pela mesma, comparando-a com a saída desejada. Como a resposta da rede é função dos valores atuais do seu conjunto de pesos, estes são ajustados num processo de otimização baseada em mínimos quadrados de forma a aproximar a saída da rede da saída desejada.

Para realização deste processo que, na realidade, matematicamente se trata de uma otimização, existem alguns algoritmos já estabelecidos que apresentam características peculiares nas suas utilizações.

Dentre os algoritmos citados na literatura, pode-se destacar, pela frequência de utilização, dois algoritmos baseados em métodos de otimização diferentes: o de retropropagação do erro (*backpropagation*), com a regra do delta generalizado, que é um método de gradiente descendente bastante utilizado e citado frequentemente na literatura; e o método de Levenberg-Marquardt, baseado no método quasi-Newton. Por se tratarem de algoritmos que envolvem o cálculo de derivadas, supõem-se a utilização de funções contínuas, principalmente as sigmóides. Neste analisador virtual as três principais funções de transferência são: Tan-sigmoid, Log-sigmoid e Linear.

Material e Métodos

Levantamento de Dados

Os dados diários de Radiação Solar foram coletados no Instituto Agrônomo do Paraná (IAPAR), no período de 1990 até 1995 numa Estação Meteorológica Automática.

Arquitetura da rede utilizada

No presente trabalho foram analisados 4 modelos distintos, sendo três baseados nas conjunções da transformada Wavelet com redes neurais, nomeados de modelo 1, modelo 2, modelo 3 e modelo 4. Em todos os modelos investigados, a defasagem utilizada foi 7, ou seja, sete dias anteriores são utilizados no prognóstico de um dia a frente.

Os modelos se diferenciam uns dos outros na relação das entradas, mas para todos utilizou-se 10 neurônios na camada oculta e o algoritmo de treinamento MLP (Perceptron de Múltiplas Camadas). Deve salientar que a esse arranjo para a rede MLP é estacionária, sendo assim usada para a modelagem de séries ou dados temporais.

Na arquitetura da rede, a função de transferência utilizada na camada oculta foi a Tan-sigmoid, como mostrada na Equação 3.

$$F(n) = \left(\frac{1}{1 + e^{-2n}} \right) - 1 \quad (3)$$

Onde n , representa a função soma do neurônio.

Modelo 1: Trata-se do modelo tradicional sem o uso das Wavelets, coloca-se apenas a série original sem pré tratamento como entrada da rede. A arquitetura da sua rede é apresentada na Figura 4. Esse modelo foi construído para uma avaliação comparativa com os outros modelos.

Modelo 2: A entrada na arquitetura da rede, diferente do modelo tradicional, foram inseridas as aproximações e detalhes da decomposição Wavelet {D1, D2, D3, A3} da série original de radiações (Figura 5).

Modelo 3: Como entrada na arquitetura da rede, diferente dos modelos 1 e 2, são inseridos a soma das 7 sub-séries de decomposições: aproximação e detalhe que apresentaram maiores correlações com a série original dos dados de radiação observados. A análise de correlação é realizada através da função de Pearson, apresentada na Equação 4.

$$\rho_{x,y} = \frac{\sum (y(t) - \bar{y}(t))(x(t) - \bar{x}(t))}{\sigma_x \sigma_y} \quad (4)$$

Onde σ_x , representa a variância e $\bar{x}(t)$ a média de um sinal:




Figura 4. Arquitetura do modelo 1




Figura 5. Arquitetura do modelo 2

$$\sigma_x = \sqrt{\sum (x(t) - \bar{x}(t))^2} \quad (5)$$

$$\bar{x}(t) = \frac{1}{n} \sum_{i=1}^n x_i \quad (6)$$

Tem-se assim que $p_{x,y}$ representa a correlação entre dois sinais: $x(t)$ e $y(t)$. As sub-séries escolhidas após a análise das correlações foram as {D2, D3, ..., D8}. O modelo é apresentado na Figura 6, onde DWS representa a soma.




Figura 6. Arquitetura do modelo 3

Modelo 4: Procede através da combinação das redes neurais para a previsão dos componentes de frequência até o nível 8, posteriormente combinando os valores simulados da rede para a reconstrução do sinal original, por meio de um técnica Wavelet chamada reconstrução, que funciona basicamente como o processo inverso da decomposição. O modelo 4 é apresentado na Figura 7.

Os parâmetros utilizados para avaliar a melhor estratégia de junção da transformada Wavelets com redes neurais no prognóstico de radiação solar foram: o erro quadrado médio (MSE-

Mean Square Error), definido pela (Equação 7) e a regressão linear entre os dados reais e o simulado pela rede.

$$MSE = \frac{1}{n} \sum (x_i - x_{si})^2 \quad (4)$$

Onde, x_i é o valor real e x_{si} o simulado.

Toda a metodologia foi desenvolvida em ambiente de programação Matlab®.

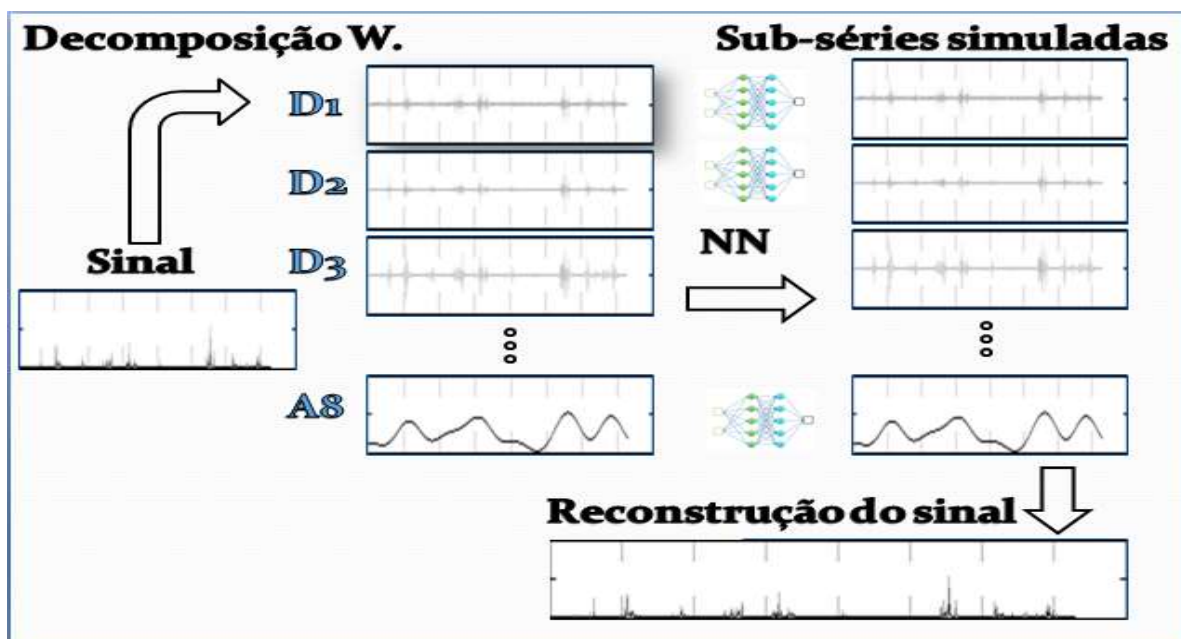


Figura 7. Arquitetura do modelo 4

Resultados e Discussões

Os resultados das simulações são apresentados na Tabela 1. Observa-se que o modelo 2 foi o que apresentou uma melhor performance em relação ao prognóstico da radiação solar. Também é observado que de uma forma geral os modelos 2, 3 e 4, que utilizam a conjunção transformada Wavelet com redes neurais, e o modelo 1, tradicional, se mostraram superiores.

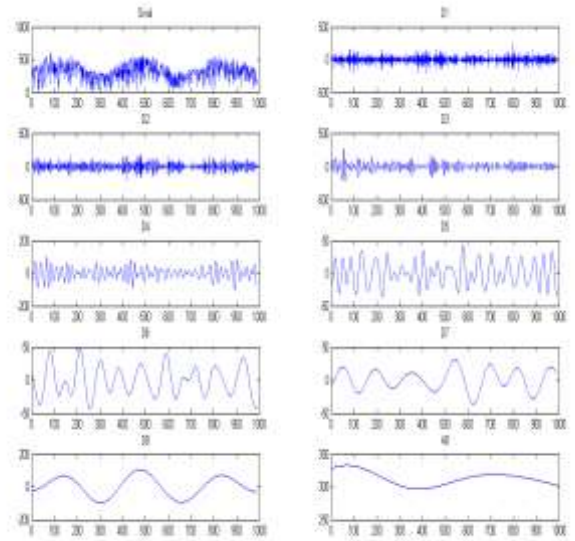
Modelos:	MSE: Total	R: Total
Modelo 1	890,43	0,581
Com a Conjunção Wavelet.		
Modelo 2	98,0	0,997
Modelo 3	666,5	0,717
Modelo 4	580,1	0,981

Tabela 1. Resultados dos Modelos

No treinamento da rede, os dados dos modelos 1,2 e 3 foram divididos em 15% para teste, 15% para validação e 70% para treinamento, já o modelo 4, como trata-se da reconstrução simulada dos dados das séries de decomposição, não apresentaram essa divisão. Para comparar os modelos desta forma, utiliza-se MSE e a Regressão total dos dados simulados e reais apresentado por cada modelo.

Figura 8. Decomposição do sinal de radiação

Os sinal de radiação e suas respectivas sub-séries da decomposição são apresentados na Figura 8



onde o nível de decomposição foi o 8 para utilização em todos os modelos aqui apresentados.

Foram utilizados diversos tipos de Wavelets-mãe para esse trabalho, e foi observado que os resultados não apresentaram diferenças em relação a essa escolha, visto que todas as Wavelets-mãe possuem a capacidade de extrair as mesmas características da série temporal.

A Figura 9 mostra as regressões lineares dos resultados da simulação dos modelos neste trabalho desenvolvidos. Regressão entre os valores experimentais ou reais em função dos simulados.

A Figura 10 apresenta a resposta da simulação,

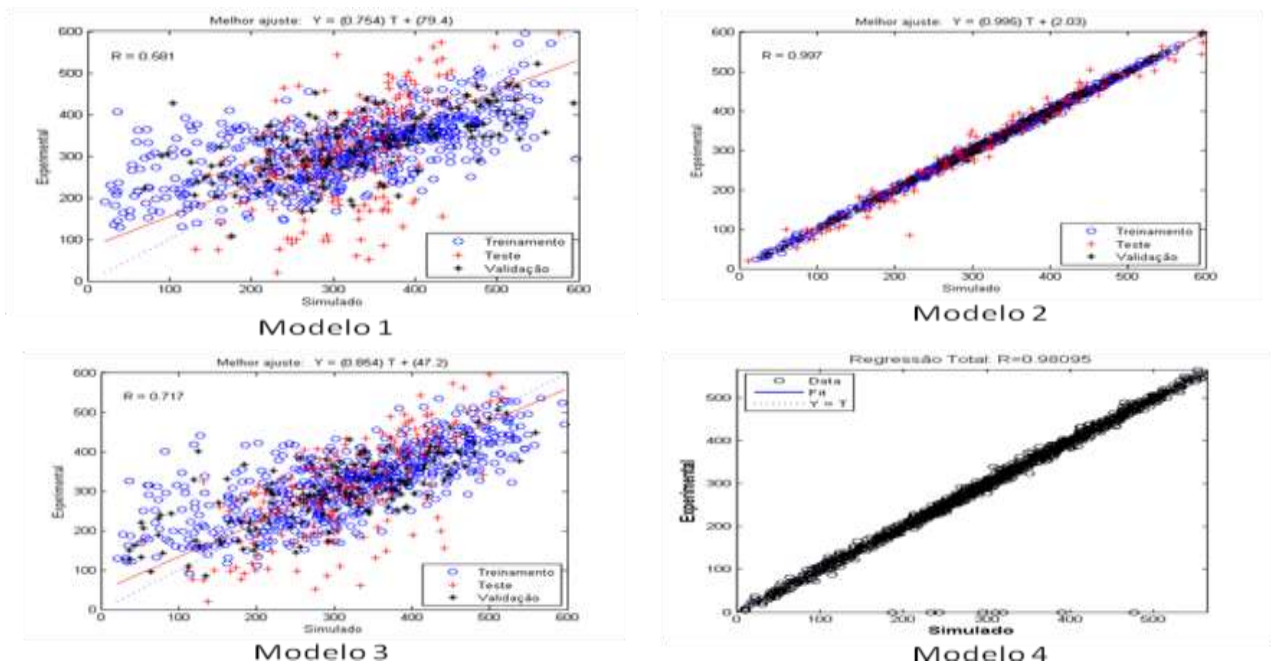


Figura 9. Regressão dos modelos entre os valores experimentais e simulados.

referente ao modelo que obteve o melhor resultado, modelo 2 que utiliza as sub-séries de decomposição {D1,D2,D3,A3} como entrada da rede.

Esses resultados mostram que os modelos compreendidos, apresentado nesse trabalho, apresentaram um alto grau de desempenho o que, de forma geral, para um prognóstico da variável a curto ou longo prazo seria de fundamental importância para pesquisas futuras.

Uma possível justificativa da superioridade do modelo 2 em relação aos outros, pode está na quantidade de variáveis de entrada na rede neural para modelagem da série temporal.

Conclusões

Foi observado por meio deste trabalho que as conjunções das transformadas Wavelet com as redes

neurais (Sistemas Híbridos) melhoraram o desempenho dos prognósticos da radiação solar. O modelo mais eficiente neste trabalho foi o 2, pois o mesmo apresentou um baixo MSE e a regressão mais significativa dos dados simulados e reais. Com esse resultado e com base na literatura consultada esses sistemas híbridos devem ser mais estudados para o prognóstico de séries temporais.

gradecimentos

Laboratório de Sistemas Inteligentes Aplicados (LABSIA), Universidade Federal de Alagoa (UFAL).




Figura 10. Resultado do modelo 2.

Referências

- Abbate, C.M. DeCusatis, P.K. Das, 2002. Wavelet and Subbands – Fundamentals and Applications, Birkhauser, Boston.
- Pedro A. Morettin, Clécia M. C. Tolo. 2004. Análise de séries temporais. São Paulo: Edgard Blucher.
- Belayneh ,A; Adamowski, J. 2012. Standard precipitation index drought forecasting using neural networks, wavelet neural networks, and support vector regression. Journal Applied Computational Intelligence and Soft Computing - Special issue on Applied Neural Intelligence to Modeling, Control, and Management of Human Systems and Environments archive, v. 2012,n. 6.
- Braga, A. P.; Carvalho, A.P.L.F.; Ludermir, T.B. 2007. *Redes Neurais Artificiais: Teoria e aplicações*. 2ªed., Rio de Janeiro: LTC.
- Chen X, Ba Y, Ma L, Cai X, Yin Y, Wang K *at al.*, 2008. Characterization of microRNAs in serum: a novel class of biomarkers for diagnosis of cancer and other diseases. Cell Res. Oct;18.
- Chen; A. S., Leung, M. T. Daouk, H.," 2003. Application of Neural Networks to an Emerging Financial Market: Forecasting and Trading the Taiwan Stock Index", Computers & Operations Research, Volume 30, pp. 901– 923.
- Dadu K. S., Deka P. C., 2012. Wavelet-Neural Network Conjunction Model in Flow Forecasting of Subhimalayan River Brahmaputra. International journal of civil engineering and technology (IJCIET), Volume 3, Issue 2, July- December, pp. 415-425.
- Fayal M. A. A., 2008. Previsão de Vazão por Redes Neurais Artificiais e Transformada Wavelet. PUC (Universidade Católica do Rio de Janeiro) – Dissertação de mestrado.
- J. Braz. Chem. Soc., 2007. Continuous wavelet transform and chemometric methods for quantitative resolution of a binary mixture of quinapril and hydrochlorothiazide in tablets. Journal of the Brazilian Chemical Society vol.18 no.5 São Paulo.
- Kalteh A. M., 2013. Monthly river flow forecasting using artificial neural network and support vector

- regression models coupled with wavelet transform. *Journal Computers & Geosciences*, 54, 1-8.
- Khashei, M., Hejazi, S. R., Bijari, M., " 2008. A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting ", *Fuzzy Set and Systems*, Volume 159, pp. 769- 786.
- Khashei, M., Bijari, M., 2006. "Forecasting and Analysis Esfahan Steel Company Production Price in Tehran Metals Exchange with Artificial Neural Networks (part I) ", *Steel Journal*, Volume 133, pp. 28 -32.
- Khashei, M., Bijari, M., 2006. "Forecasting and Analysis Esfahan Steel Company Production Price in Tehran Metals Exchange with Artificial Neural Networks (part II) ", *Steel Journal*, Volume 134, pp. 28 -32.
- Kim , T. W. ; Valdés, J. B. 2003. Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks. *Journal of Hydrologic Engineering*, v. 8, no.6, p. 319–328.
- Nayak P. C., Satyaji Rao Y. R., Krishna B., 2011. Time Series Modeling of River Flow Using Wavelets Neural Network. *Journal of Water Resource and Protection*, 3, 50-59.
- Ludwig Junior. O.; 2007. Montgomery, E. *Redes Neurais fundamentos e Aplicações com programas em C*, Editora Ciência Moderna, Rio de Janeiro.
- Partal T., Kisi O., 2007. Wavelet and neuro-fuzzy conjunction model for precipitation forecasting. *Journal of Hydrology ScienceDirect*, 2007, 342, 199-212.
- Tucci, C. E. M., Robin T. C., Dias P. L. da S., Collischon W., 2002. Previsão de médio prazo da afluência de reservatórios com base na previsão climática. In *Relatório Final do Projeto: BRA/00/029*, Instituto de astronomia, Geofísica e Ciências Atmosféricas da USP e Instituto de Pesquisa Hidráulica UFRGS.
- Weeks, Michael. 2012. *Processamento de sinais digitais utilizando MATLAB® e Wavelets / tradução e revisão técnica Edson Tanaka*.- Rio de Janeiro: LTC.
- Wensheng Wang, Jing Ding. 2003. *Wavelet Network Model and Its Application to the Prediction of Hydrology*. Department of Hydrology and Water Resources, Hydraulic School of Sichuan University, Chengdu, Sichuan, China.
- Yu, S. ; Yang, J. ; Liu, G. 2013. A novel discussion on two long-term forecast mechanisms for hydro-meteorological signals using hybrid wavelet-NN model. *Journal of Hydrology*, v. 497, p. 189–197.