

基于小波消噪的参考作物腾发量 RBF 网络预测方法

庾文武

(大唐观音岩水电开发有限公司,云南昆明 650011)

摘要 介绍小波消噪的原理和步骤。以北方某流域甲站 2001—2005 年逐日气象数据为基本资料,进行 10 阶 Dmey 小波消噪,然后构建预测 ET_0 的前馈网络模型(RBF- ET_0)用 2001—2004 年的资料作为训练样本,对 2005 年的 ET_0 进行预测,并与 Penman-Montieth 公式计算值进行比较。结果为:预测值与目标值的相关系数为 0.991 2,相对误差的平均值为 6.56%,相对误差小于 20%、15%、10% 的合格率分别为 93.88%、85.66%、73.51%,与未经小波消噪处理的 RBF- ET_0 模型预测结果相比,预测精度有明显提高。

关键词 参考作物腾发量;小波消噪;RBF 网络; ET_0 预测方法

中图分类号:TV211.1 文献标识码:A 文章编号:1006-7647(2011)02-0046-04

RBF network forecast method for evapotranspiration of reference crops based on wavelet denoising/YU Wen-wu (Datang Guanyinyan Hydropower Development Co., Ltd., Kunming 650011, China)

Abstract: The principles and procedures of the wavelet denoising were introduced. By using the daily meteorological data of a station in a northern river basin from 2001 to 2005 as the basic information, the daily meteorological data were denoised by the tenth order Dmey wavelet. A feed-forward neural network forecast model for evapotranspiration of reference crops(RBF- ET_0) was established. The meteorological data from 2001 to 2004 were taken as the training samples. The evapotranspiration of the reference crops in 2005 was predicted and compared with that calculated by the Penman-Montieth formula. The results show that the correlation coefficient of the predicted value and the target value is 0.991 2, and the average relative error is 6.56%. The qualified rates of the relative error less than 20%, 15% and 10% are 93.88%, 85.66% and 73.51% respectively. The prediction accuracy is obviously improved compared with that by the pure RBF- ET_0 model.

Key words: reference crop evapotranspiration; wavelet denoising; RBF network; evapotranspiration forecast method

参考作物腾发量(ET_0)是计算作物需水量的主要参数之一。刘志武等^[1]将 BP 神经网络用于 ET_0 的预测,顾世祥等^[2]建立了径向基(RBF)神经网络的 ET_0 预报模型,崔远来等^[3]运用进化神经网络预测了 ET_0 ,蔡甲冰等^[4]提出了预测 ET_0 的模糊神经网络方法,这些研究成果证明了人工神经网络作为 ET_0 预测方法的可行性,但是预测效果一般。这是由于 ET_0 预测所需的气象因子(日照时数 S 、平均气温 T_{mean} 、最高气温 T_{max} 、最低气温 T_{min} 、相对湿度 RH 和实际风速 W)在监测的过程中可能存在不同程度的噪声,即高频突出的无用成分,这就影响了神经网络对气象数据和 ET_0 的非线性逼近,所以剔除气象数据中的噪声对提高神经网络的预测精度有着十分重要的意义。1984 年法国地球学家 Morlet 提出的小波分析方法具有良好的多分辨功能,能将信号进行不同频率的分离,从而实现信号的消噪。

Giaouris 等^[5]将小波消噪应用到电气传动的信号处理中,Song 等^[6]运用了第 2 代小波变换对电气设备检测中的局部放电脉冲数据进行了降噪,孙涛等^[7]利用小波消噪提高了小波网络对水轮机故障的识别性能。这些学者的研究结果表明小波在非线性和非平稳信号中良好的消噪功能。因此,笔者尝试将小波消噪运用到预测 ET_0 的神经网络模型中,以前馈网络模型(RBF- ET_0 模型)为例,探讨小波消噪对其预测精度的影响。

1 小波消噪原理

1.1 小波分解与重构

1989 年 Mallat 基于多分辨分析思想提出了小波分解与重构的快速算法——Mallat 算法。该算法由小波滤波器 H, G 和 h, g 对信号进行分解与重构,算法如下^[8]:

分解算法

$$A_i[f(t)] = f(t) \quad (1)$$

$$A_j[f(t)] = \sum_k H(2t-k)A_{j-1}[f(t)] \quad (2)$$

$$D_j[f(t)] = \sum_k G(2t-k)A_{j-1}[f(t)] \quad (3)$$

重构算法

$$A_j[f(t)] = 2 \left\{ \sum_k h(t-2k)A_{j+1}[f(t)] + \sum_k g(t-2k)D_{j+1}[f(t)] \right\} \quad (4)$$

式中: t 为离散时间序列号; $f(t)$ 为原始信号; j 为层数; $H(2t-k)$, $h(t-2k)$ 为低通滤波器; $G(2t-k)$, $g(t-2k)$ 为高通滤波器; $A_j[f(t)]$ 为信号 $f(t)$ 在第 j 层低频部分的小波系数; $D_j[f(t)]$ 为信号 $f(t)$ 在第 j 层高频部分的小波系数。

1.2 小波消噪

在工程实际中被测对象检测的信号往往混有不同程度的噪声。一个含有噪声的信号模型为

$$s(n) = f(n) + \sigma \epsilon(n) \quad (5)$$

式中: $s(n)$ 为含有噪声的信号; $f(n)$ 为真实信号; $\epsilon(n)$ 为噪声; m 为等时间间隔; σ 为噪声水平。

消噪主要是抑制信号 $s(n)$ 中的噪声部分, 再现信号 $f(n)$ 。小波消噪主要包括以下 3 个步骤^[9-10]: ①选择小波和分解的最高层数 N , 采用式(1)~(3)计算信号 $s(n)$ 在各层的小波系数。②对第 1~ N 层的各层分别选择阈值, 对各层细节的小波系数用阈值处理。本文采用 SURE 阈值选择原则, 它是基于 Stein 无偏似然估计原理的自适应阈值选择。③将第 N 层的近似部分小波系数和第 1~ N 层经过处理的各细节小波系数代入式(4)重构信号, 即得真实信号。

2 RBF- ET_0 网络预测模型

RBF 网络由输入层、隐层和输出层构成, 以单输出神经元为例, 隐层采用径向基函数作为激励函数, 将隐层第 i 个神经元与输入层(共 m 个神经元)的权值向量 $W1_i$ ($w1_{1i}, w1_{2i}, \dots, w1_{mi}$) 和第 q 个输入矢量 X^q ($x_1^q, x_2^q, \dots, x_m^q$) 之间的距离乘上阈值 $b1_i$ 作为本身的输入, 由此可得隐层第 i 个神经元的输入为^[11-12]

$$k_i^q = \sqrt{\sum_j (w1_{ji} - x_j^q)^2} b1_i \quad (6)$$

输出为

$$r_i^q = \exp[-(k_i^q)^2] = \exp\left\{-\left[\sqrt{\sum_j (w1_{ji} - x_j^q)^2} b1_i\right]^2\right\} \quad (7)$$

输出层的输入为各隐层神经元(共 p 个神经元)的

加权求和。由于激励函数为纯线性函数, 因此输出为

$$y^q = \sum_{i=1}^p r_i^q w2_i \quad (8)$$

式中: $w2_i$ 为隐层权值。

阈值可调节函数的灵敏度, 实际工作中常用另一参数 α (扩展常数), 文中 $b1_i$ 与 C_i 的关系为 $b1_i = 0.8326/C_i$ 。

文中输入参数为 $S, T_{\text{mean}}, T_{\text{max}}, T_{\text{min}}, RH$ 和 W , 输出参数为 ET_0 , 因此构建的 RBF- ET_0 模型输入层有 6 个神经元, 输出层只有 1 个神经元。隐层神经元采用网络结构自适应确定法, 基本原理是从 0 个神经元开始训练, 检查输出误差, 使网络产生最大误差所对应的输入向量作为权值向量 $W1_i$, 产生 1 个新神经元, 然后再检查误差, 重复此过程直到误差满足要求。RBF 网络的创建函数采用 Matlab7 神经网络工具箱函数提供的 newrbe 函数, 传递函数采用 radbns 函数, C 以 SPREAD 值进行确定, 当小波消噪结合 RBF 网络预测时 SPREAD 值为 3.8, 单纯的 RBF 网络预测时 SPREAD 值为 4.0。为了提高网络的预测效果, 采用式(9)对数据进行归一化处理^[3]:

$$\hat{x} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (9)$$

式中: x 为参数值; x_{max} 为参数最大值; x_{min} 为参数最小值; \hat{x} 为参数归一化后的值。

采用相关系数 r 、合格率、相对误差的平均值 \bar{Q} 、拟合关系对 RBF 网络预测效果进行综合评价。其中 r 和 \bar{Q} 的计算分别见式(10)与式(11):

$$r = \frac{\sum_{i=1}^M (O_i - \bar{O})(P_i - \bar{P})}{\left[\sum_{i=1}^M (O_i - \bar{O})^2 \right]^{1/2} \left[\sum_{i=1}^M (P_i - \bar{P})^2 \right]^{1/2}} \quad (10)$$

$$\bar{Q} = \frac{\sum_{i=1}^m Q_i}{M} \quad (11)$$

其中

$$Q_i = \frac{|O_i - P_i|}{O_i} \times 100\%$$

式中: M 为预测点数; O_i 和 P_i 分别为第 i 个预测点的 ET_0 的目标值与预测值; \bar{O} 和 \bar{P} 分别为 ET_0 目标值和预测值的平均值。

3 实例分析

以北方某流域甲站 2001—2005 年逐日(共 1826 d)气象数据($S, T_{\text{mean}}, T_{\text{max}}, T_{\text{min}}, RH$ 和 W)为基本资料, 采用联合国粮食及农业组织(FAO)推荐的 Penman-Montieth 公式^[13]计算逐日的 ET_0 。首先将 6 种气象因子的原始序列代入式(1)~(3), 采用

Dmey^[14]小波 10 阶分解,利用 SURE 原则选择阈值,对其各层细节小波系数进行软阈值处理,然后代入式(4)重构信号,即得各种气象因子的真实值序列,结果如图 1 所示。从图 1 可以看出:6 种气象因子

都存在不同程度的噪声,实际风速和日照时数含噪声相对较多,相对湿度次之;平均气温、最高气温和最低气温相对较少。

采用 2001—2004 年逐日的 6 种气象因子作为

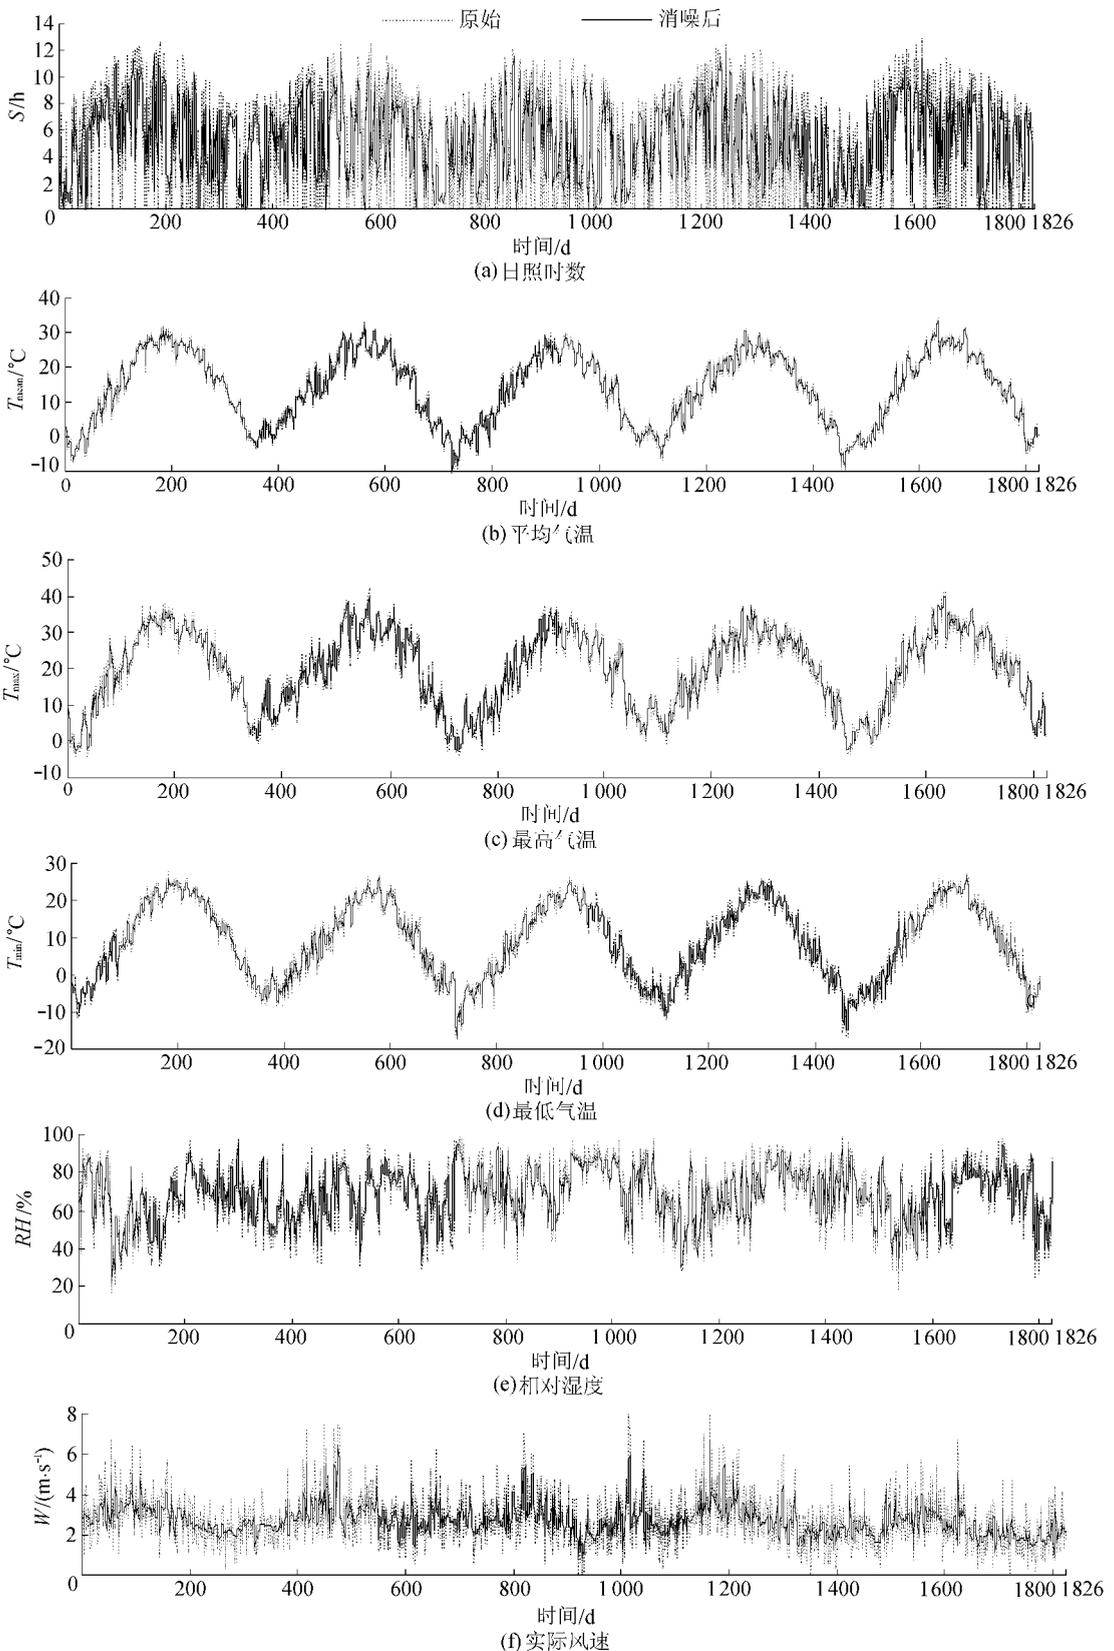


图 1 2001—2005 年 6 种气象因子消噪后序列与原始序列比较

输入参数,逐日的 ET_0 作为输出参数,来训练预测 ET_0 的前馈网络模型 RBF- ET_0 ,将训练好的 RBF- ET_0 模型对 2005 年逐日的 ET_0 进行预测,并与 Penman-Montieth 公式计算得出的 ET_0 进行比较,预测值与目标值的相关系数 r 为 0.9912,相对误差的均值 \bar{Q} 为 6.56%,合格率见表 1,拟合关系为 $y = 0.9924x - 0.0212$ ($R^2 = 0.9891$),2005 年 ET_0 预测值与目标值见图 2。图 2 表明预测值与目标值一致性较好,从整体上反映了 ET_0 序列的趋势和波动规律。

表 1 不同预测方法的效果比较

预测方法	r	$\bar{Q}/\%$	合格率/%		
			$Q_i < 20\%$	$Q_i < 15\%$	$Q_i < 10\%$
小波 + RBF 网络	0.9912	6.56	93.88	85.66	73.51
RBF 网络	0.9818	10.36	85.03	76.26	61.74

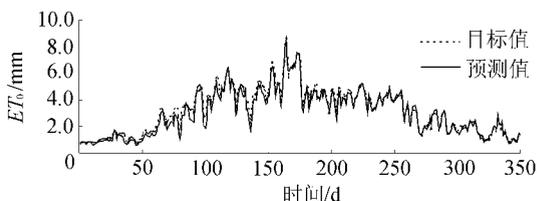


图 2 2005 年 ET_0 预测值与目标值比较

为了验证小波消噪结合 RBF 网络预测方法的优越性,对 6 种气象数据不进行小波消噪处理,而直接采用 RBF- ET_0 模型,用 2001—2004 年资料训练模型,对 2005 年的 ET_0 进行预测,结果如下:预测值与目标值的相关系数 r 为 0.9818,相对误差的均值 \bar{Q} 为 10.36%,合格率见表 1,拟合关系为 $y = 0.9734x + 0.0356$ ($R^2 = 0.9759$)。

从以上分析可以看出,小波消噪结合 RBF 网络对 ET_0 的预测效果比单纯 RBF 网络的预测效果好,各种相对误差标准下的合格率,前者比后者均高出 8% 以上。由此可见,小波消噪很大程度上提高了模型对 ET_0 的预测效果,主要原因是通过对气象数据的消噪去除了无用成分,消除了无用成分对气象因子与 ET_0 真实映射关系的掩盖。

4 结 论

a. 北方某流域甲站 2001—2005 年气象数据中存在不同程度的噪声,其中实际风速和日照时数含噪最多,其次是相对湿度,平均气温、最高气温和最低气温含噪最少。

b. 将气象数据进行小波消噪,剔除了里面的无用成分,然后再用 RBF 网络对 ET_0 进行预测,这比直接采用 RBF 网络预测的效果好。主要是因为小波消噪后避免了 RBF 网络预测 ET_0 时对一些高频

突出气象数据的学习。

c. 通过对 ET_0 预测方法的研究,验证了小波分析的多分辨功能以及处理大量非平稳信号的优势。

参考文献:

- [1] 刘志武,倪广恒,雷志栋,等.计算逐日潜在腾发量的 BP 神经网络方法[J].灌溉排水学报,2004,23(4):75-77.
- [2] 顾世祥,王士武,袁宏源.参考作物腾发量预测的径向基函数法[J].水科学进展,1999,10(2):123-128.
- [3] 崔远来,马承新,沈细中,等.基于进化神经网络的参考作物腾发量预测[J].水科学进展,2005,16(1):77-81.
- [4] 蔡甲冰,刘钰,雷廷武,等.根据天气预报估算参照腾发量的模糊神经网络方法[J].农业工程学报,2005,21(12):108-111.
- [5] GIAOURIS D, FINCH J W. Denoising using wavelets on electric drive applications [J]. Electric Power Systems Research, 2008, 78: 559-565.
- [6] SONG Xiao-di, ZHOU Cheng-ke, HEPBURN D M, et al. Second generation wavelet transform for data denoising in PD measurement [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2007, 14(6):1531-1537.
- [7] 孙涛,黄天戌,阔黎明,等.小波包消噪提高小波网络故障识别性能[J].哈尔滨工业大学学报,2005,37(4):561-564.
- [8] 杨建国.小波分析及其工程应用[M].北京:机械工业出版社,2005.
- [9] de DONOHO D H. Noising by soft-thresholding [J]. IEEE Transactions on Information Theory, 1995, 41(3):613-617.
- [10] 向晓燕,谭子尤,张书真.基于小波的阈值消噪方法讨论及实现[J].现代电子技术,2007(17):172-176.
- [11] 胡铁松.神经网络预测与优化[M].大连:大连海事大学出版社,1997.
- [12] 蒋晓辉,刘昌明.基于小波分析的径向基神经网络年径流预测[J].应用科学学报,2004,23(3):411-414.
- [13] ZANETTI S S, SOUSA E F, OLIVEIRA V P S, et al. Estimating evapotranspiration using artificial neural network and minimum climatological data [J]. Journal of Irrigation and Drainage Engineering, 2007(2):84-89.
- [14] LI Zhen, HE Zheng-jia, ZI Yan-yang, et al. Customized wavelet denoising using intra-and inter-scale dependency for bearing fault detection [J]. Journal of Sound and Vibration, 2008, 313: 342-359.
- [15] 庾文武,胡铁松,吕美朝.基于 Morlet 小波的 ET_0 序列多时间尺度分析[J].武汉大学学报:工学版,2009,42(2):182-185.

(收稿日期 2010-03-24 编辑 骆超)