

月降水量预测的粒子群_小波神经网络模型

龙 云 贺新光 章新平

(湖南师范大学资源与环境科学学院 长沙 410081)

摘 要 为了提高月降水量预测精度和处理神经网络隐藏层神经元个数优化问题,提出了一种基于粒子群优化的小波多神经网络模型,并将其应用于洞庭湖流域月降水量的预测。首先,将大尺度气候指数和标准化月降水量作为预测因子在不同时间尺度上分解,然后使用多个基于粒子群算法以确定各隐藏层神经元个数的 cascade-forward(CF)神经网络,用以对各频率下的标准月降水量子序列分别进行预测,最后通过重构和逆标准化得到月降水量预测值。结果表明,基于粒子群优化的小波多神经网络的预测精度高于小波单神经网络的预测精度,并且对极端月降水量的预测也有所改善。

关键词 小波神经网络,粒子群优化,洞庭湖流域,月降水量预测

中图法分类号 P457.6/TP183

文献标识码 A

Particle Swarm Optimized Wavelet Neural Network Models for Forecasting Monthly Precipitation

LONG Yun HE Xin-guang ZHANG Xin-ping

(College of Resources and Environmental Science, Hunan Normal University, Changsha 410081, China)

Abstract To improve the forecasting accuracy of monthly precipitation and deal with the determination of the number of hidden neurons in neural networks, this paper introduced a particle swarm optimized wavelet multiple neural network model, which was applied to the prediction of monthly precipitation in Dongting Lake Basin. The standardized monthly precipitation and large-scale climate index time series were first decomposed at different temporal scales as predictors. Then the standardized monthly precipitation subseries were forecasted, respectively, under different time scales by using the cascade-forward(CF) neural networks in which the number of hidden neurons is optimized by particle swarm optimization(PSO). Finally the monthly precipitation was forecasted by combining all predicted subseries and using the inverse transform of standardized monthly precipitation. The results show that PSO-based wavelet multiple neural network model provides more accurate forecasts than wavelet single neural network model for monthly precipitation in Dongting Lake Basin and improves the prediction accuracy of extreme monthly rainfall.

Keywords Wavelet neural networks, Particle swarm optimization, Dongting Lake Basin, Monthly rainfall prediction

1 引言

洞庭湖流域汛期降水异常,旱涝灾害频繁,为国民经济生产带来了很大的影响。洞庭湖流域在1951—1999年这40年间发生了不同程度的旱灾,进入二十一世纪以后,除开2004年,其他年份均出现了不同程度的旱灾。而洞庭湖流域60%~70%的降水量又集中在汛期(4—9月),更加使洞庭湖流域内水资源分配不均^[1]。因此,预测洞庭湖流域月降水量,不仅能给旱涝灾害提供有效的预警信息,而且对于水资源管理、农业耕种、作物增产有很大的参考价值。

在过去的几十年,许多方法用来研究和预测降水量。这些方法大概可以分为两类,一类是动力模型,如大气环流模型(General Circulation Models, GCMs),其使用一些物理规律来预测降水量;另一类是经验模型,其通过分析历史月降水量和

预测因子之间的关系来预测未来降水量。由于GCMs过于复杂,经验模型目前仍是主要的长期降水量预测模型^[2]。经验模型包括统计模型和神经网络(Artificial Neural Network, ANN)。在神经网络中,目前运用最多的是多层感知器(Multilayer Perceptron, MLP)^[3]。而在MLP中,使用最广泛的是前馈神经网络(Feed Forward Neural Network, FFNN)^[4],而其它结构神经网络的使用并不多见。Hartmann等^[5]使用多层感知前馈神经网络预测长江流域夏季月降水量。Sahai等^[6]使用前馈神经网络预测印度夏季月降水量。Abbot和Marohasy^[7]使用时延神经网络(TDNN)和Elman构建的复合神经网络预测澳大利亚昆士兰地区的月降水量。Ramana等^[8]使用小波前馈神经网络预测印度东部大吉岭的月降水量,并表明:小波神经网络的预测精度明显高于普通神经网络的预测精度。然而,小波神经网络模型的构造可以有多种不

本文受国家自然科学基金项目(41272271, 41171035),湖南省“十二五”重点学科地理学和湖南省教育厅科研项目(14A097)资助。

龙 云(1990—),男,硕士生,主要研究方向为人工智能及其应用, E-mail: 375159507@qq.com; 贺新光(1973—),男,博士,教授,硕士生导师,主要研究方向为多尺度数值计算、时间序列预测等, E-mail: xghe@hunnu.edu.cn; 章新平(1956—),男,博士,教授,博士生导师,主要研究方向为水文气象学, E-mail: zxp@hunnu.edu.cn。

同的方式,且不同的构造方式对模型精度有不同的影响。此外,对于神经网络而言,各隐藏层神经元个数决定了神经网络结构,并影响其拟合能力,但没有具体公式给出任意情况下的最优神经元个数。目前,最常用的方法是穷举法,但该方法搜索最优解的效率低且搜索范围不宜太大。为了有效确定隐藏层神经元最优个数,本文基于 Sheikhani 和 Mohammadi^[9] 的基本思想,应用粒子群优化算法来搜索神经网络隐藏层神经元的最优个数。

Cascade-forward 神经网络(CFNN)类似于前馈神经网络,但包含从输入到每一层和从每一层到下一层的一个权重连接,附加的连接可以改进神经网络学习的速度^[10]。Shahban^[10]认为 CF 神经网络是一种更有前景的网络预测模型。同时,Abbot 和 Marohasy^[7]指出,目前利用大尺度气候指数结合历史月降水量来预测未来月降水量的研究并不多见。因此,本文应用 CF 神经网络,结合小波变换和粒子群算法,使用大尺度气候指数及历史月降水量作为预测因子来预测未来一月的降水量。基于粒子群优化的小波神经网络模型(Wavelet Neural Network, WNN)被应用到洞庭湖流域月降水量的预测,并通过计算预测值与实测值之间的 Nash-Sutcliffe 系数和相对误差来评价模型的预测精度。

2 研究区域和数据

2.1 研究区域

本文研究区域为洞庭湖流域。洞庭湖流域属于亚热带季风气候区,降水分布不均匀,且年际之间的变化亦较大^[11]。图 1 展示了本文所挑选的洞庭湖流域 27 个降水观测站点的位置分布,及各个站点月降水量的变异系数。




图 1 洞庭湖流域降水观测站点分布图

2.2 月降水量数据

本文使用的洞庭湖流域月降水量数据的时间跨度为 1961—2012 年,下载于中国气象科学数据共享服务网(<http://cdc.cma.gov.cn/home.do>)。其中,1961—1992 年的标准化月降水量数据用于训练神经网络,1993—2002 年的数据用于校正神经网络,2003—2012 年的数据用于测试已训练的网络模型。标准化月降水量数据通过用各月降水量减去相应月降水量的长期平均值,然后再除以该月降水量的标准差而获得。

2.3 气候指数

影响洞庭湖流域降水过程的因素很多,但目前国内外还没有相关研究表明哪些大尺度气候指数与洞庭湖流域降水过程有必然关系。由此,本文根据相关研究文献以及国内外相关专家的具体实践,如,邓伟涛^[12]研究指出,北太平洋中纬度海温与中国东部降水有关;Saji 等^[13]提出印度洋偶极子(Indian Ocean Dipole, IOD),并证明 IOD 对东亚气候的影响;杨霞等^[14]指出,IOD 对中国夏季的降水有一定影响;王会军和范可^[15]指出,长江流域降水量和南极涛动(Antarctic Oscillation, AAO)有关联;武炳义和黄荣辉^[16]研究发现,冬季北大西洋涛动(North Atlantic Oscillation, NAO)与东亚冬季风有关;王永波和施能^[17]指出,夏季 NAO 与东亚夏季风和雨带位置有关;何丽等^[18]指出,随气温增加而增大,随气温的降低而减少;筛选如下 6 个大尺度气候指数作为洞庭湖流域月降水量的预测因子:(1)太平洋十年涛动(Pacific Decadal Oscillation, PDO),数据下载于 <http://jisao.washington.edu/pdo/PDO.latest>。(2)印度洋偶极子(IOD),数据可从 www.jamstec.go.jp 下载。(3)南极涛动(AAO),数据下载地址 www.cpc.ncep.noaa.gov。(4)北大西洋涛动(NAO),数据可从 www.cpc.ncep.noaa.gov 下载。(5)北方涛动指数(North Oscillation Index, NOI),数据下载于 www.pfeg.noaa.gov。(6)标准化全球平均气温(Global Mean Temperature Anomalies, GMTA),数据下载地址 <http://data.giss.nasa.gov/gistemp/tabledata/GLB.Ts.txt>。

3 方法

3.1 小波变换

小波变换具有多分辨特点,在时域和频域都具有表征信号局部特征的能力,可以通过不同时间尺度观察信号。目前常用的小波函数有 Morlet 小波、Mexican hat 小波和 haar 小波^[8]。小波变换最早于 1980 年应用于信号分析,是一种将信号表达成一系列小波函数和的数学方法,现已广泛用于气象、地理、水文等许多领域^[2]。小波变换的主要思想就是在不同的频率尺度下将信号分解。小波函数也被称为母小波,表示如下:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), a > 0, -\infty < b < +\infty \quad (1)$$

式中: a 表示尺度因子, b 表示平移因子。小波函数必须满足两点:(i) $\int_{-\infty}^{+\infty} \psi^2(t) dt = 1$; (ii) $\int_{-\infty}^{+\infty} \psi(t) dt = 0$ 。这说明小波函数 $\{\psi_{a,b}(t)\}$ 的平均值为零,且带宽有限。应用式(1),时间序列或能量有限信号 $f(t)$ 的连续小波变换(Continue Wavelet Transform, CWT)可定义如下:

$$\omega_{\psi}(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \bar{\psi}\left(\frac{t-b}{a}\right) f(t) dt \quad (2)$$

式中, $\bar{\psi}$ 是小波函数的共轭。如果固定伸缩因子 a 不变,则可以得到一组关于平移因子 b 的函数。在实际运用中,为处理离散信号,连续小波变换常常被离散化。对于离散小波变换(Discrete Wavelet Transform, DWT),目前运用最多的是二进小波。其表达式如下:

$$\omega_{\psi}(a,b) = 2^{-j/2} \int_{-\infty}^{+\infty} \bar{\psi}(2^{-j}t - k) f(t) dt$$

$$j=0,1,\dots,k\in Z \quad (3)$$

3.1.1 多分辨率分析

多分辨率分析是通过小波变换将信号分解成一组不同频率下的子时间序列。为了实现多分辨率分析,算法采用金字塔模式即通过一系列的带通滤波器,一方面通过低通滤波产生低频时间序列 A_j, A_j 表达了原始时间序列的整体趋势;另一方面通过带通滤波产生高频时间序列 D_j, D_j 表达了原始时间序列的细节信息。信号 f 的一个递归分解过程表示如下:

$$\begin{matrix} f & \cdots & A_1 & \cdots & A_2 & \cdots & A_3 & \cdots & \cdots & A_j \\ & \searrow & \searrow & \searrow & \searrow & \searrow & \searrow & \searrow & \searrow & \searrow \\ & D_1 & D_2 & D_3 & \cdots & D_j \end{matrix}$$

另外,对于小波函数的选取必须依据具体情况,一般来而言,小波函数的选取需根据其自身的属性、信号特征以及研究对象的波形特征与小波函数波形的相似度。依据文献[2]的建议,本研究采用 Meyer 小波进行多分辨率分析,分解层数 j 为 5。图 2 给出了荆州站标准化月降水量的离散小波分解结果。




图 2 荆州站标准化月降水量的离散小波分解

3.2 粒子群算法

本研究应用粒子群算法来优化各站点的小波神经网络结构。凭借粒子群算法强大的搜索能力,在一个较广的范围内找出拟合误差最小的各隐藏层神经元个数。具体做法为:首先,在寻找范围内随机产生一些粒子,然后通过计算适应度函数找出局部和全局最优粒子,并根据式(4)和式(5)依次更新粒子速度和粒子位置,最后检查是否满足迭代终止条件。适应度函数应用校正期神经网络的输出向量与目标向量之间的均方误差根。算法的详细描述可参见文献[9]。

$$v_i^{k+1} = \alpha v_i^k + c_1 \xi_i^k (p_{local,i}^k - p_i^k) + c_2 \eta_i^k (p_{global}^k - p_i^k) \quad (4)$$

$$p_i^{k+1} = p_i^k + r v_i^{k+1} \quad (5)$$

式中, α 是惯性常量, v_i^k, v_i^{k+1} 分别表示粒子 i 更新前和更新后的速度, c_1, c_2 分别表示继承自身和全局最优值的权重, ξ_i^k, η_i^k 是 $[0,1]$ 之间的随机数, $p_{local,i}^k, p_{global}^k$ 分别表示粒子 i 搜索到的自身最优和粒子群搜索到的全局最优位置, p_i^k, p_i^{k+1} 分别表示更新前和更新后粒子 i 的位置, r 代表速度约束因子。相比穷举法,粒子群算法为确定隐藏层神经元个数的最优解时,可节省大量的计算时间。例如,对于一个 3 隐藏层的神经网络,如果每隐藏层神经元个数搜索范围为 5~15,采用穷举法共需计算 11^3 次,而粒子群算法只需采用每代 15 个粒子,更

新 10 次,共计算 150 次就可得到各隐藏层神经元最优个数,所需 CPU 时间大约是穷举法的 11%。

3.3 神经网络

Cascade-forward 神经网络(CFNN)的结构示意如图 3 所示。基本网络结构与前馈神经网络(FFNN)类似,不同之处是输入层与隐藏层、隐藏层前层与后层都有连接。本文中,神经网络隐藏层运用 S 型传递函数,输出层运用线性传递函数。神经网络的一般表达式如下:

$$Z = f(\sum WX - \theta) \quad (6)$$

其中, Z 是神经网络的隐藏层或输出层的输出值。 $f(\cdot)$ 表示神经网络的传递函数。 X 是神经网络的输入层或隐藏层的输入值。 W 表示神经网络中神经元的权值。 θ 是神经网络中神经元的偏移值或阈值。




图 3 CF 神经网络结构示意图

本文使用 Levenberg-Marquardt(LM) 算法来训练神经网络,LM 算法可表示为:

$$W_{k+1} = W_k - (A^T A + \mu I)^{-1} A^T e \quad (7)$$

式中, W_k, W_{k+1} 分别表示神经网络更新前和更新后的权重值, A 是关于神经网络均方误差的雅克比矩阵, μ 是神经网络学习速率, e 是残差向量。虽然,LM 算法需要更多计算量和计算机内存,但是可以更快找到最优解,且不易陷入局部最优解[5]。

3.4 小波神经网络

本文介绍并对比两种小波神经网络模型:一种是粒子群优化的小波多神经网络模型(简记为:WNN1),构造方式如图 4(a)所示;另一种是粒子群优化的小波单神经网络模型(简记为:WNN2),构造方式如图 4(b)所示。




图 4 WNN1(a)和 WNN2(b)结构示意图

WNN1 采用 3 隐藏层的 CF 神经网络,并应用粒子群算法优化神经网络隐藏层神经元个数和 LM 算法训练神经网络。具体流程如图 4(a)所示:数据预处理阶段,预测因子时间序列通过离散小波变换进行多分辨率分析,分解层次为 5,得到 5 个高频子序列和 1 个低频子序列。在 WNN1 训练和预测阶段,建立 6 个 3 层神经网络。在每一时间尺度上,首先使用粒子群算法确定神经网络各隐藏层的神经元个数,然后使用该尺度上的所有子时间序列来训练此尺度下的神经网络。

络,从而预测相应尺度下的标准降水量时间序列,再通过合成各个预测子序列来获得标准月降水量序列预测值,最后使用逆标准化获得月降水量时间序列预测值。

WNN2 同样采用 3 隐藏层的 CF 神经网络,并应用粒子群算法优化神经网络隐藏层神经元个数和 LM 算法训练神经网络。具体流程如图 4(b) 所示;在数据预处理阶段,WNN2 输入时间序列 $X_i(n)$ 通过小波变换进行多分辨率分析,分解层次为 5,得到 5 个高频子序列和 1 个低频子序列。但在 WNN2 的训练和预测阶段,仅构建一个神经网络。然后将所有的高频和低频子序列同时输入该神经网络,以训练神经网络的权重,并预测标准月降水量,最后通过逆标准化得到月降水量预测值序列。

下面给出 WNN1 和 WNN2 的数学表达式,

$$X_i(n) = A_{X_i(n)}^j + \sum_{j=1}^J D_{X_i(n)}^j \quad (8)$$

$$Y_{WNN1}(n+1) = P_0(A_{X_i(n)}^j) + \sum_{j=1}^J P_j(D_{X_i(n)}^j) \quad (9)$$

$$Y_{WNN2}(n+1) = P(A_{X_i(n)}^j, D_{X_i(n)}^1, \dots, D_{X_i(n)}^J) \quad (10)$$

式(8)~式(10)中, $X_i(n)$ 表示第 i 个输入变量, n 为当前月份, $n+1$ 为预测月份, j 表示分解层数, $P(\cdot)$ 表示 CF 神经网络, $Y(\cdot)$ 表示标准月降水量序列。

3.5 评价标准

本文选取 Nash-Sutcliffe 系数(Nash-Sutcliffe Coefficient, NSC)和相对误差(Relative Absolute Error, RAE)两个统计指标来评价 WNN1 和 WNN2 的预测精度。其中,Nash-Sutcliffe 系数表示模型输出值的准确度,而相对误差表示预测值和实测值之间的相对差异。两种指标的计算公式如下:

$$NSC = 1 - \frac{\sum_{i=1}^N (Y_{Obs,i} - Y_{For,i})^2}{\sum_{i=1}^N (Y_{Obs,i} - \bar{Y}_{Obs})^2} \quad (11)$$

$$RAE = \frac{\sum_{i=1}^N |Y_{Obs,i} - Y_{For,i}|}{\sum_{i=1}^N Y_{Obs,i}} \quad (12)$$

式(11)、式(12)中, $Y_{Obs,i}$ 、 $Y_{For,i}$ 分别表示月降水量的实测值和预测值。 $\bar{Y}_{Obs}$ 表示月降水量实测值的平均值。 N 是预测的月份数。

4 结果讨论与分析

为评价两种小波神经网络的预测性能,图 5 和图 6 分别给出了 WNN1 和 WNN2 预测性能评价指标(Nash-Sutcliffe 系数和相对误差)的空间分布及其比较。两种预测方法为洞庭湖流域西部和北部的站点给予了比东南部站点更高的预测精度。然而,即便在整个洞庭湖流域,WNN1 的预测精度比 WNN2 仍有提升。具体而言,WNN1 预测结果的 Nash-Sutcliffe 系数在 0.51~0.82 之间波动,Nash-Sutcliffe 系数的平均值为 0.68,相对误差在 0.26~0.40 之间浮动,相对误差平均为 0.34;而 WNN2 预测结果的 Nash-Sutcliffe 系数在 0.43~0.81 之间波动,平均 Nash-Sutcliffe 系数仅为 0.62,相对误差在 0.27~0.43 之间浮动,平均相对误差为 0.37。对比 WNN2,WNN1 的 Nash-Sutcliffe 系数提升了 0.01~0.22,相对误差分别减少了 0.01~0.1。从 Nash-Sutcliffe 系数和相对误差的角度可知,WNN1 可以提供比 WNN2 更高精度的月降水量预测。




图 5 两种方法预测结果 Nash-Sutcliffe 系数的空间分布与比较




图 6 两种方法预测结果相对误差的空间分布与比较

本节选取月降水量变异系数较高的桑植站点和月降水量变异系数中等的三穗站点(见图 1),分别绘制了这两个降水观测站的观测值及两种方法的预测值(见图 7),以展示降水预测值和观测值之间的匹配程度。从图 7 可观察到,WNN1 与 WNN2 对月降水量的趋势性预测都较为准确,但从数值上而言,不管是月降水量极多或是极少的月份,WNN1 的预测值均比 WNN2 的预测值更加接近观测值。这对于预警极端降水事件是非常关键的。因为要提前做好防旱防涝的准备,不仅要正确预测其降水趋势,还需尽可能准确地预测该降水事件的降水量。为了更为详细地评价两种方法对洞庭湖流域极端月降水的预测能力,图 8 和图 9 分别给出了整个研究区域(2003—2012 年)内具有最大正距平和负距平月份的观测值与预测值的散点图。即从洞庭湖流域的每个站点分别依次选取 10 个最大正距平和负距平月份。尽管两种方法均低估了最大正距平月份的降水观测值,高估了最大负距平月份的降水观测值,但是 WNN1 提供了比 WNN2 更精确的预测结果。平均而言,对于最大正距平月份,WNN2 低估月降水量 37.0%,而 WNN1 低估月降水量为 30.0%。对于最大负距平月份,WNN2 高估月降水量 189.1%,而 WNN1 高估月降水量为 161.7%。WNN1 对于极端月降水预测精度的改进也可以从实测值与预测值之间的线性回归方程和决定性系数(R^2)这两方面明显地体现出来(见图 8 和图 9)。为了提高预测精度,WNN1 在不同频率下构建和训练 CF 神经网络来预测不同频率下的月降水量子序列,从而能更加有效地利用预测因子子序列中隐含的信息,并且通过不同频率下的训练,降低了神经网络输入数据的维度。




图 7 两种预测方法在桑植(a)和三穗站(b)的预测值与实测值比较




图8 两种预测方法对最大正距平月的预测值与实测值的比较




图9 两种预测方法对最大负距平月预测值与实测值的比较

结束语 本文介绍了基于粒子群优化的小波多神经网络模型,并将其用于预见期为1月的洞庭湖流域27个站点月降水量的预测,并与基于粒子群优化的小波单神经网络模型相比较。在研究区域内,小波多神经网络的预测值与实测值之间的 Nash-Sutcliffe 系数的平均值为 0.68,相对误差平均为 0.34。相比小波单神经网络, Nash-Sutcliffe 系数提升了 0.01~0.22,相对误差减少了 0.01~0.1。这表明,WNN1 通过数据预处理阶段,将预测因子时间序列分解为高频和低频子时间序列,并应用多个神经网络在不同频率下训练和预测标准化月降水量的子时间序列,使得原始时间序列中所包含的月降水量信息能更加充分地被不同的神经网络所利用。实验结果表明,基于粒子群算法优化的小波多神经网络的月降水量预测精度总体高于小波单神经网络的预测精度,且对于极端月降水量的预测精度也有不错的提升。

参考文献

- [1] 李景保,王克林,杨燕,等.洞庭湖区2000年~2007年农业干旱灾害特点及成因分析[J].水资源与水工程学报,2008,19(6):1-5
- [2] He X G, Guan H D, Zhang X P, Simmons C T. A wavelet-based multiple linear regression model for forecasting monthly rainfall[J]. International Journal of Climatology, 2014, 34(6): 1898-

1912

- [3] Power S, Plummer N, Alford P. Making climate model forecasts more useful[J]. Australian Journal of Agricultural Research, 2007, 58: 945-951
- [4] Karamouz M, Razavi S, Araghinejad S. Long-lead seasonal rainfall forecasting using time-delay recurrent neural networks: A case study[J]. Hydrological Processes, 2008, 22: 229-241
- [5] Hartmann H, Becker S, King L. Predicting summer rainfall in the Yangtze River basin with neural networks[J]. International Journal of Climatology, 2008, 28: 925-936
- [6] Sahai A K, Somaná M K, Satyan V. All India summer monsoon rainfall prediction using an artificial neural network[J]. Climate Dynamics, 2000, 16: 291-302
- [7] Abbot J, Marohasy J. Application of artificial neural networks to rainfall forecasting in Queensland, Australia[J]. Advances in Atmospheric Sciences, 2012, 29(4): 717-730
- [8] Ramana R V, Krishna B, Kumar S R, et al. Monthly rainfall prediction using wavelet neural network analysis[J]. Water Resource Manage, 2013, 27: 3697-3711
- [9] Sheikhan M, Mohammadi N. Time series prediction using PSO-optimized neural network and hybrid feature selection algorithm for IEEE load data[J]. Neural Computation and Application, 2013, 23: 1185-1194
- [10] Shaban K, El-Hag A, Matveev A. A cascade of artificial neural networks to predict transformers oil parameters[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2009, 16(2): 516-523
- [11] 张剑明,黎祖贤,章新平,等.湖南省近46年来降水时空分布特征及趋势分析[J].水文,2009,29(4):73-78
- [12] 邓伟涛,孙照渤,曾刚,等.中国东部夏季降水型的年代际变化及其与北太平洋海温的关系[J].大气科学,2009,33(4):835-844
- [13] Saji N H, Goswami B N, Vinayachandran P N. A dipole mode in the tropical Indian Ocean[J]. Nature, 1999, 401(6571): 360-363
- [14] 杨霞,管兆勇,朱保林. IOD 对 ENSO 影响中国夏季降水和气温的干扰作用[J]. 南京气象学院学报, 2007, 30(2): 170-177
- [15] Wang H J, Fan K. Central-North China precipitation as re-constructed from the Qing Dynasty: Signal of the Antarctic Atmospheric Oscillation[J]. Geophysical Research Letters, 2005
- [16] 武炳义,卞林根,张人禾. 冬季北极涛动和北极海冰变化对东亚气候变化的影响[J]. Chinese Journal of Polar Research, 2004, 16(3): 211-220
- [17] 王永波,施能. 夏季北大西洋涛动与我国天气气候的关系[J]. 气象科学, 2003, 21(3): 271-278
- [18] 何丽,吴宜进,但长军,等. 近百年全球气温变化对长江流域旱涝灾害的影响[J]. 中国农业气象, 2007, 28(4): 364-366

(上接第127页)

- [7] Karu K, Jain A. Fingerprint Classification[J]. Pattern Recognition, 1996, 29(3): 389
- [8] 王军. 机器视觉技术在电子白板中的应用及嵌入式软件设计[D]. 成都: 电子科技大学, 2011
- [9] 何浩,龙森,王晓婷等. 电子白板系统中基于机器视觉的目标识别技术[C]//第十五届计算机工程与工艺年会暨第一届微处理器技术论坛文集, A辑. 长沙: 国防科技大学出版社, 2011: 373-377
- [10] 关富敏,杜玉晓,陈崇义,等. 基于双模块定位的超宽屏电子白板[J]. 电子世界, 2014, 11: 139-140
- [11] 朱维宁,任明武. 基于红外图像的人眼定位算法[J]. 计算机工程与设计, 2014, 5: 1717-1721
- [12] Wong K. Electromagnetic Emission Based Monitoring Technique for Polymer ZnO Surge Arresters[J]. IEEE Transaction on Di-

electrics & Electrical Insulation, 2006, 13(1): 181-190

- [13] 祝思文. 基于宽带超声传感器的定位系统的研究[D]. 合肥: 安徽大学, 2007
- [14] 原玉磊,王安健,蒋理兴. 一种使用红外线和超声波的定位技术[J]. 电子测量技术, 2008, 31(10): 15-17
- [15] 李国华,刘宝玲,沈树群. 基于超声波技术的3D定位系统研制[J]. 计算机测量与控制, 2005(9): 926-928
- [16] 张起贵,秦城. 电磁感应式电子白板关键技术研究[J]. 电子器件, 2013, 1: 54-57
- [17] 徐杨,乔卫民,赵中. 基于AT91RM9200的触摸屏驱动及三点校正算法[J]. 嵌入式软件应用, 2007, 23: 73-75
- [18] 何世杰. S3C2410的触摸屏驱动开发及校准算法[J]. 电脑知识与技术, 2010, 6(19): 5321-5322
- [19] 杨娟. 在英语教学中感受电子白板的魅力[J]. 科教导刊, 2013(15)