DOI:10.11705/j.issn.1672-643X.2015.05.09

# 三种模型在洞庭湖区域地下水资源量预测中的应用

付宏渊[a], 邱 祥[a], 曾 铃[b], 黄永和[b]
(长沙理工大学 a.交通运输工程学院; b.土木与建筑学院, 长沙 410004)

**摘　要**:为了建立适应于洞庭湖区域地下水资源量变化规律的预测模型,在分析洞庭湖区域河川天然径流量、长江三口入水量、城陵矶出水量与地下水资源量相关性的基础上,分别利用多因子逐步回归模型、BP神经网络模型和多变量时间序列CAR模型建立了3种洞庭湖区域地下水资源量预测模型,并对所建立的3种模型的预测精度和预测结果整体规律进行了对比分析。研究结果表明:地下水资源量与河川天然径流量、长江三口入水量、城陵矶出水量具有较好的相关性;多变量时间序列CAR模型的预测精度较好,BP神经网络模型的预测精度次之,而多因子逐步回归模型的预测精度较差;多变量时间序列CAR模型的预测结果整体规律优于BP神经网络模型,而BP神经网络模型的预测结果整体规律则优于多因子逐步回归模型。

**关键词**:多因子逐步回归; BP神经网络; 多变量时间序列; 地下水资源量预测; 洞庭湖区域
**中图分类号**:P641.2　　**文献标识码**:A　　**文章编号**:1672-643X(2015)05-0046-05

# Application of three models in prediction of groundwater resources in Dongting Lake area

**FU Hongyuan[a], QIU Xiang[a], ZENG Ling[b], HUANG Yonghe[b]**
(*a. School of Communication and Transportation Engineering*; *b. School of Civil Engineering & Architecture*, *Changsha University of Science & Technology*, *Changsha* 410004, *China*)

**Abstract**: In order to establish the predictive model adapt to the variation law of groundwater resources in the region of the Dongting Lake, on the basis of analyzing the relativity of nature river flow, Yangtze three inlet inflow water and Chenglingji outflow water with water resources, the paper respectively used multi-factor stepwise regression model, back-propagation neural network model and multivariate time series CAR model to set up three kinds of predictive model of groundwater resources in Dongting Lake area and compared and analyzed the overall law of prediction accuracy and prediction results of the three models. The results showed that the amount of groundwater resources have better relativity with the natural river flow, Yangtze three inlet inflow water resources, and Chenglingji outflow water; the prediction accuracy of CAR model of multivariate time series is better, and then that of Back-Propagation Neural Network is the second, and the prediction accuracy of multi-factor stepwise regression model is poor; the overall law of the prediction results of multivariate time series CAR model is better than that of back-propagation neural network model, and the overall law of prediction result of Back-Propagation neural network model is superior to that of multi-factor stepwise regression model.

**Key words**: multi-factor stepwise regression; back-propagation neural network; multivariate time series; prediction of groundwater resources; Dongting lake area

地下水资源量是指地层中以各种形式存在的重力水的总和,是水资源量的重要组成部分。近年来,随着长江上游众多水库的截流蓄水,洞庭湖区域长江三口入水量出现了周期性缓慢下降的变化趋势,

**收稿日期**:2014-12-03;　**修回日期**:2015-03-23
**基金项目**:国家自然科学基金项目(51278067);湖南省科学技术厅科技计划重点项目(2013FJ2008)
**作者简介**:付宏渊(1965-),男,湖北随州人,博士,教授,主要从事岩土工程、路堤稳定性等方面的研究。
**通讯作者**:邱 祥(1991-),男,湖南益阳人,硕士研究生,主要从事路堤稳定性方面的研究。

与此相适应,该区域洞庭湖湖面水位及地下水资源量也出现了相同的变化趋势[1-2]。根据饱和土有效应力原理可知[3],地下水资源量的减少将引起土体孔隙水压力的降低和有效应力的增大,土体被压缩从而引发地层变形,地层变形的发生将对该区域构筑物的安全和稳定产生严重影响,进而直接威胁洞庭湖区域人民群众生命财产的安全。

为了控制洞庭湖区域地下水资源量的不断下降和地层变形的持续发展,建立适应于该区域地下水资源量变化规律的预测模型就显得十分迫切。当前,关于小区域的地下水预测许多学者通过采用不同的模型进行了大量的研究,如:张霞等[4]对比分析了支持向量机模型和 BP 神经网络模型在陕西洛惠渠灌区地下水动态预测中的精度;张建芝等[5]根据济南降雨量、市区开采量、外围开采量建立了济南泉域地下水位多元回归模型,分析了不同阶段地下水位的主要影响因素;刘卫林等[6]以多变量相空间重构为基础,结合神经网络模型,建立了黑龙洞泉域地下水位预测模型,验证了该方法的有效性;吴丽英[7]通过建立地下水埋深和降雨量的相关关系,采用相关分析法对邢台县的地下水位变化进行了预测。对于具有季节性和周期性变化规律的地下水预测也取得了一定的进展,如:鲁魁锋等[8]分别利用季节性叠加趋势模型、季节周期 - ARMA 组合模型建立了奇台绿洲地下水位动态变化预测模型,并对两种模型的预测效果进行了比较研究;张盼等[9]应用时间序列模型揭示了长武塬区地下水位的多年变化规律;杨忠平等[10]运用时间序列分析理论分析了吉林西部地下水位的季节性和周期性变化规律。虽然这些研究都建立了适应于所研究区域的地下水预测模型,但是其研究对象具有区域较小或者季节性和周期性的变化规律。为了建立适应于洞庭湖区域地下水资源量这种具有大区域性和特定趋势的预测模型,本文尝试分别采用多因子逐步回归模型、BP 神经网络模型和多变量时间序列 CAR 模型建立了 3 种洞庭湖区域地下水资源量预测模型,并对所建立的 3 种模型的预测效果进行对比分析。

## 1　洞庭湖区域水文地质概况

洞庭湖区域涵盖长江荆江河段以南以洞庭湖为中心的冲积平原和环湖丘陵地区,该区的地质是以第四纪松散沉积层为主,总面积为 16 619 $km^2$。洞庭湖区域的水资源包括洞庭湖流域水系及其湖泊水,其北面有松滋、太平、藕池三口引入长江来水,南、西方向有湘、资、沅、澧四水注入,此外还有汨罗江、新墙河等周边的河流汇入,经湖泊调蓄后,在东面通过城陵矶注入长江[11]。根据 2000 - 2012 年湖南省水资源公报[12]中关于洞庭湖区域的水文资料(表 1)可知,洞庭湖区域河川天然径流量的年均值为 1 959.37 亿 $m^3$,长江三口入水量的年均值为 491.37 亿 $m^3$,前者占总入水量的 79.95%,后者占总入水量的 20.05%,城陵矶出水量的年均值为2 292.3亿 $m^3$,地下水资源量的年均值为 25.39 亿 $m^3$。

**表 1**　2000 - 2012 **年洞庭湖区域水文资料**　亿 $m^3$

| 年份 | 河川天然径流量 | 长江三口入水量 | 城陵矶出水量 | 地下水资源量 |
|---|---|---|---|---|
| 2000 | 2161.53 | 684.70 | 2595.00 | 26.36 |
| 2001 | 1957.08 | 493.10 | 2322.00 | 18.83 |
| 2002 | 3020.10 | 571.50 | 3393.00 | 26.40 |
| 2003 | 2183.55 | 568.80 | 2685.00 | 27.69 |
| 2004 | 1997.50 | 524.30 | 2329.00 | 25.52 |
| 2005 | 1950.18 | 643.30 | 2415.00 | 29.20 |
| 2006 | 2005.20 | 182.60 | 1990.00 | 25.74 |
| 2007 | 1751.96 | 543.60 | 2094.00 | 22.58 |
| 2008 | 1945.22 | 528.40 | 2256.00 | 24.58 |
| 2009 | 1734.07 | 444.90 | 2018.00 | 22.92 |
| 2010 | 2311.21 | 565.90 | 2799.00 | 26.65 |
| 2011 | 1331.99 | 258.50 | 1477.00 | 18.57 |
| 2012 | 2382.76 | 653.40 | 2860.00 | 30.46 |

## 2　洞庭湖区域地下水资源量影响因素的相关性分析

为了确保所建地下水资源量预测模型的预测精度,本文选取 2000 - 2012 年洞庭湖区域的河川天然径流量、长江三口入水量、城陵矶出水量、地下水资源量进行相关性分析,分析结果见表 2。由表 2 可知洞庭湖区域地下水资源量与河川天然径流量、长江三口入水量、城陵矶出水量的 $P$ 值均小于 0.5,表明地下水资源量与河川天然径流量、长江三口入水量、城陵矶出水量之间的差别具有统计学意义。且地下水资源量与河川天然径流量、长江三口入水量、城陵矶出水量的相关系数分别为 0.61、0.55、0.65,相关系数在 0.5 ~ 0.8 之间,表明地下水资源量与河川天然径流量、长江三口入水量、城陵矶出水量是显著相关的,可以利用洞庭湖区域河川天然净流量、长江三口入水量和城陵矶出水量来建立该区域的地下水资源量预测模型。

表2 地下水资源量影响因素相关性分析

| 相关系数 | 河川天然径流量 | 长江三口入水量 | 城陵矶出水量 | 地下水资源量 |
|---|---|---|---|---|
| 河川天然径流量 | 1.00 | | | |
| 长江三口入水量 | 0.49 | 1.00 | | |
| 城陵矶出水量 | 0.96** | 0.69** | 1.00 | |
| 地下水资源量 | 0.61* | 0.55* | 0.65* | 1.00 |

注:表中相关系数的上标*表示 $P<0.05$,即在0.05的水平上差异显著;**表示 $P<0.01$,即在0.01的水平上差异显著。

## 3 洞庭湖区域地下水资源量预测的3种模型

### 3.1 洞庭湖区域地下水资源量预测的多因子逐步回归模型

3.1.1 多因子逐步回归模型简介 在实际研究中,影响因变量的众多自变量之间可能存在着高度的相互依赖性关系,多因子逐步回归模型能够根据自变量对因变量贡献量的大小自动选择贡献量大的变量来建立模型[13]。

含有 $i$ 个自变量和一个因变量的多因子逐步回归模型,其形式为:

$$y = b_0 + b_1x_1 + b_2x_2 + \cdots + b_ix_i \tag{1}$$

式中:$x_i$ 为自变量;$y$ 为因变量;$b_i$ 为参数。

该模型是在建立所有自变量与因变量之间多因子逐步回归模型的基础上,剔除对因变量影响不显著的自变量,保留对因变量影响显著的自变量,从而得到包含所有对因变量影响显著的自变量的多因子逐步回归模型。

3.1.2 洞庭湖区域地下水资源量多因子逐步回归模型的建立 为了建立洞庭湖区域地下水资源量预测的多因子逐步回归模型,以该区域2000-2012年的河川天然径流量($X_1$:亿 $m^3$)、长江三口入水量($X_2$:亿 $m^3$)、城陵矶出水量($X_3$:亿 $m^3$)为自变量,以地下水资源量($Y$:亿 $m^3$)为因变量,建立多因子逐步回归模型。按上述建模方法,逐步筛选出具有显著影响的自变量作为因子,并建立包含所有对因变量有显著影响的自变量而不包含对因变量影响不显著的自变量的多因子逐步回归模型。从而得到洞庭湖区域地下水资源量预测的多因子逐步回归模型为:

$$Y = 12.2846 + 0.0073X_1 + 0.0115X_2 - 0.0034X_3 \tag{2}$$

### 3.2 洞庭湖区域地下水资源量预测的BP神经网络模型

3.2.1 BP神经网络模型简介 BP神经网络模型是由输入层节点、隐含层节点和输出层节点构成的正向传播输入信号、反向传递误差的学习算法[14-15]。其拓扑结构如图1所示。图1中,$X_1, X_2, \cdots, X_n$ 为BP神经网络模型的输入值,$Y_1, Y_2, \cdots, Y_m$ 为BP神经网络模型的预测输出值,$\omega_{ij}$、$\omega_{jk}$ 分别为BP神经网络模型隐含层节点、输出层节点的权值。

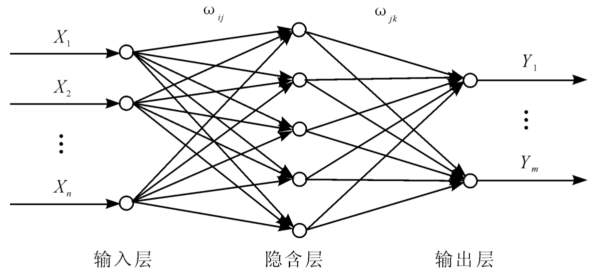


图1 BP神经网络模型拓扑结构

该模型的建模方法是在确定模型输入层节点数 $n$,隐含层节点数 $l$,输出层节点数 $m$ 的基础上,将输入层信号经隐含层处理后,传向输出层,如果输出层得不到期望输出,则转入误差信号反向传播,将误差信号沿原来的传播路径返回,通过预测输出误差调整各层神经元的权值,从而得到预测输出和期望输出误差最小的BP神经网络模型。

3.2.2 洞庭湖区域地下水资源量BP神经网络预测模型的建立 为了建立洞庭湖区域地下水资源量预测的BP神经网络模型,以该区域2000-2012年的河川天然径流量($X_1$:亿 $m^3$)、长江三口入水量($X_2$:亿 $m^3$)、城陵矶出水量($X_3$:亿 $m^3$)为输入层变量,以地下水资源量($Y$:亿 $m^3$)为输出层变量。按上述建模方法,首先确定模型的参数,本文取输入层节点数为3个,输出层节点数为1个,隐含层节点数设为2个,即构成一个3-2-1的BP神经网络模型。然后通过正向传递信号和反向传播误差调整各层神经元的权值,最后得到洞庭湖区域地下水资源量预测的BP神经网络模型的隐含层各个节点的权值,见表3,输出层各个节点的权值为:当 $k=1, j=1, \omega_{jk}=1.35$;$k=1, j=2, \omega_{jk}=-7.45$。

表3 隐含层各个结点的权值

| $i$ | $j$ | |
|---|---|---|
| | 1 | 2 |
| 1 | 1.36 | -3.19 |
| 2 | 0.10 | -0.03 |
| 3 | 1.55 | -1.46 |

### 3.3 洞庭湖区域地下水资源量预测的多变量时间序列CAR模型

3.3.1 多变量时间序列CAR模型简介 含有 $m$ 个

输入变量和一个输出变量的 $n$ 阶时间序列 CAR 模型，其形式为[16]：

$$y_t = a_1 y_{t-1} + a_2 y_{t-2} + \cdots + a_n y_{t-n} + b_{10} x_{1,t} + b_{11} x_{t-1} + b_{12} x_{t-2} + \cdots + b_{1n} x_{1,t-n} + b_{20} x_{2,t} + b_{21} x_{2,t-1} + b_{22} x_{2,t-2} \cdots + b_{2n} x_{2,t-n} \cdots + b_{m0} x_{1,t} + b_{m1} x_{1,t-1} + b_{m2} x_{1,t-2} \cdots + b_{mn} x_{m,t-n} + \varepsilon_t \tag{3}$$

式中：$x_{m,t-n}$ 为输入变量；$y_t$ 为输出变量；$\varepsilon_t$ 为残差；$\{a_n\}$，$\{b_{mn}\}$ 为参数，其中 $m$ 为正整数，$n$ 为非负整数，$t$ 为时间序列编号，$t > n$。

该模型的建模方法是在利用最小二乘法对模型参数进行估计的基础上，通过检验和判定模型的最高阶和真实阶，得到多变量时间序列 CAR 模型。

3.3.2　洞庭湖区域地下水资源量多变量时间序列 CAR 预测模型的建立　为了建立洞庭湖区域地下水资源量预测的多变量时间序列 CAR 模型，以该区域 2000－2012 年的河川天然径流量（$X_1$：亿 m$^3$）、长江三口入水量（$X_2$：亿 m$^3$）、城陵矶出水量（$X_3$：亿 m$^3$）为输入变量，以地下水资源量（$Y$：亿 m$^3$）为输出变量，建立多变量时间序列 CAR 模型。然后用递推最小二乘法对模型参数进行估计，最后通过对所建模型的最高阶和真实阶进行判定，得到洞庭湖区域地下水资源量的 CAR 预测模型为：

$$Y_t = 0.4456 Y_{t-1} + 0.1335 Y_{t-2} + 0.008 X_{1,t} - 0.0315 X_{1,t-2} + 0.0053 X_{2,t} - 0.0368 X_{2,t-2} + 0.0317 X_{3,t-2} \tag{4}$$

式中：$t$ 为时间序列编号，$t > 2$。

## 4　洞庭湖区域 3 种地下水资源量预测模型的对比分析

### 4.1　模型预测精度对比分析

为了对比分析上文所建 3 种地下水资源量预测模型的预测精度，分别将洞庭湖区域 2000－2012 年的河川天然径流量、长江三口入水量、城陵矶出水量代入上文所建 3 种预测模型，计算得到洞庭湖区域地下水资源量的预测值及预测值与实测值的绝对误差和相对误差如表 4 所示。

表 4　模型预测结果与误差分析

| 年份 | 实测值 | 多因子逐步回归模型 | | | BP 神经网络模型 | | | 多变量时间序列 CAR 模型 | | |
|---|---|---|---|---|---|---|---|---|---|---|
| | | 模拟值/亿 m$^3$ | 绝对误差/亿 m$^3$ | 相对误差/% | 模拟值/亿 m$^3$ | 绝对误差/亿 m$^3$ | 相对误差/% | 模拟值/亿 m$^3$ | 绝对误差/亿 m$^3$ | 相对误差/% |
| 2000 | 26.36 | 27.13 | 0.77 | 2.92 | 26.74 | 0.38 | 1.44 | | | |
| 2001 | 18.83 | 24.36 | 5.53 | 29.38 | 25.27 | 6.44 | 34.18 | | | |
| 2002 | 26.40 | 29.40 | 3.00 | 11.36 | 28.11 | 1.71 | 6.49 | 27.82 | 1.42 | 5.39 |
| 2003 | 27.69 | 25.65 | -2.04 | -7.36 | 26.90 | -0.79 | -2.84 | 28.37 | 0.68 | 2.45 |
| 2004 | 25.52 | 24.99 | -0.53 | -2.06 | 25.52 | 0.00 | 0.00 | 25.76 | 0.24 | 0.94 |
| 2005 | 29.20 | 25.72 | -3.48 | -11.92 | 25.52 | -3.68 | -12.61 | 29.26 | 0.06 | 0.22 |
| 2006 | 25.74 | 22.29 | -3.45 | -13.42 | 24.47 | -1.27 | -4.92 | 24.84 | -0.90 | -3.49 |
| 2007 | 22.58 | 24.22 | 1.64 | 7.25 | 23.06 | 0.48 | 2.10 | 23.52 | 0.94 | 4.16 |
| 2008 | 24.58 | 24.91 | 0.33 | 1.33 | 25.02 | 0.44 | 1.81 | 24.88 | 0.30 | 1.23 |
| 2009 | 22.92 | 23.21 | 0.29 | 1.28 | 22.57 | -0.35 | -1.52 | 21.21 | -1.71 | -7.47 |
| 2010 | 26.65 | 26.17 | -0.48 | -1.82 | 27.31 | 0.66 | 2.47 | 25.57 | -1.08 | -4.05 |
| 2011 | 18.57 | 19.97 | 1.40 | 7.56 | 18.96 | 0.39 | 2.12 | 19.78 | 1.21 | 6.5 |
| 2012 | 30.46 | 27.49 | -2.97 | -9.76 | 27.48 | -2.98 | -9.77 | 29.22 | -1.24 | -4.07 |
| 平均值 | 25.04 | 25.04 | 1.99 | 8.26 | 25.15 | 1.50 | 6.33 | 25.48 | 0.89 | 3.63 |

由表 4 可知，上文所建洞庭湖区域地下水资源量预测的多因子逐步回归模型、BP 神经网络模型、多变量时间序列 CAR 模型预测值与实测值平均绝对误差分别为 1.99 亿、1.50 亿、0.89 亿 m$^3$，平均相对误差分别为 8.26%、6.33%、3.63%。通过对比分析上文所建 3 种模型的平均绝对误差和平均相对误差可知，上文所建 3 种模型中，多变量时间序列 CAR 模型的预测精度较好，BP 神经网络模型的预测精度次之，而多因子逐步回归模型的预测精度较差。

### 4.2　模型预测结果整体规律对比分析

为了对比分析上文所建 3 种地下水资源量预测模型预测结果的整体规律，分别计算洞庭湖区域地

下水资源量实测值和通过上文所建3种模型得到的预测值的均值、5%修整均值、95%置信区间的上限和下限、99%置信区间的上限和下限、中值、标准差和极差及其与实测值的差值如表5所示。由表5可知，多因子逐步回归模型预测值与实测值的均值、5%修整均值、95%置信区间、99%置信区间、中值、标准差、极差的差值分别为0.00、-0.02、1.4、1.96、-2.75、-1.16、-2.46，BP神经网络模型预测值与实测值上述各参数的差值分别为0.11、0.23、1.28、1.80、-2.22、-1.06、-2.74，多变量时间序列CAR模型预测值与实测值上述各参数的差值分别为0.44、0.49、0.88、0.87、-2.17、-0.43、-2.40。

根据上文所建3种模型预测值与实测值的均值、5%修整均值、95%置信区间、99%置信区间、中值、标准差和极差的差值可知，多因子逐步回归模型的3个参数均值、5%修整均值和极差优于BP神经网络模型，而BP神经网络模型的4个参数95%置信区间、99%置信区间、中值和标准差均优于多因子逐步回归模型；BP神经网络模型的2个参数均值和5%修整均值优于多变量时间序列CAR模型，而多变量时间序列CAR模型的5个参数95%置信区间、99%置信区间、中值、标准差和极差均优于BP神经网络模型。通过上述对比分析可知，上文所建3种模型中，多变量时间序列CAR模型的预测结果整体规律优于BP神经网络模型的整体规律，而BP神经网络模型的整体规律则优于多因子逐步回归模型的预测结果整体规律。

**表5 模型预测值整体规律对比分析** 亿 $m^3$

| | | 观测值 | 多因子逐步回归模型 | | BP神经网络模型 | | 多变量时间序列CAR模型 | |
|---|---|---|---|---|---|---|---|---|
| | | | 模拟值 | 误差 | 模拟值 | 误差 | 模拟值 | 误差 |
| 均值 | | 25.04 | 25.04 | 0.00 | 25.15 | 0.11 | 25.48 | 0.44 |
| 5%修整均值 | | 25.10 | 25.08 | -0.02 | 25.33 | 0.23 | 25.58 | 0.49 |
| 95%置信区间 | 下限 | 22.89 | 23.59 | 0.70 | 23.64 | 0.75 | 23.38 | 0.49 |
| | 上限 | 27.19 | 26.49 | -0.70 | 26.66 | -0.53 | 27.57 | 0.39 |
| 99%置信区间 | 下限 | 22.03 | 23.00 | 0.98 | 23.04 | 1.01 | 22.49 | 0.46 |
| | 上限 | 28.05 | 27.07 | -0.98 | 27.26 | -0.79 | 28.46 | 0.41 |
| 中值 | | 27.74 | 24.99 | -2.75 | 25.52 | -2.22 | 25.57 | -2.17 |
| 标准差 | | 3.56 | 2.40 | -1.16 | 2.49 | -1.06 | 3.12 | -0.43 |
| 极差 | | 11.89 | 9.43 | -2.46 | 9.15 | -2.74 | 9.49 | -2.40 |

## 5 结 语

本文在分析2000-2012年洞庭湖区域河川天然径流量、长江三口入水量、城陵矶出水量与地下水资源量相关性的基础上，分别利用多因子逐步回归模型、BP神经网络模型和多变量时间序列CAR模型建立了3种洞庭湖区域地下水资源量预测模型，并对所建立的3种模型的预测精度和预测结果整体规律进行了对比分析，得到如下结论。

(1)洞庭湖区域河川天然径流量、长江三口入水量、城陵矶出水量与地下水资源量的相关系数分别为0.61、0.55、0.65，表明地下水资源量与河川天然径流量、长江三口入水量、城陵矶出水量具有较好的相关性。

(2)本文所建立的洞庭湖区域地下水资源量预测的3种模型预测值与实测值平均绝对误差分别为1.99亿、1.50亿、0.89亿 $m^3$，平均相对误差分别为8.26%、6.33%、3.63%，表明多变量时间序列CAR模型的预测精度较好，BP神经网络模型的预测精度次之，而多因子逐步回归模型的预测精度较差。

(3)本文所建立的洞庭湖区域地下水资源量预测的3种模型中，多变量时间序列CAR模型的预测结果整体规律优于BP神经网络模型的预测结果整体规律，而BP神经网络模型的预测结果整体规律则优于多因子逐步回归模型的预测结果整体规律。

**参考文献：**

[1] 史 璇，肖伟华，王 勇，等. 近50年洞庭湖水位总体变化特征及成因分析[J]. 南水北调与水利科技，2012，10(5)：18-22.

[2] 孟 熊，廖小红，黎昔春. 洞庭湖水位变化特性及影响研究[J]. 人民长江，2014，45(13)：17-21.

(下转第55页)

of florfenicol and thiamphenicol under direct UV irradiation, UV/$H_2O_2$ and UV/Fe(Ⅱ) processes [J]. Chemical Engineering Journal, 2015, 260: 826 - 834.
[17] Aleboyeh A, Moussa Y, Aleboyeh H. The effect of operational parameters on UV/$H_2O_2$ decolourisation of Acid Blue 74 [J]. Dyes and Pigments. 2005,66(2): 129 - 134.
[18] Cater S R, Stefan M I , Bolton J R, et al. UV/$H_2O_2$ Treatment of Methyl tert - Butyl Ether in Contaminated Waters [J]. Environmental science and Technology, 2000,34 (4): 659 - 662.
[19] Tang Walter Z. Physicochemical treatment of hazardous wastes [M]. Boca Raton: CRC Press, 2003.
[20] Yang Hai, Li Guiying, An Taicheng, et al. Photocatalytic degradation kinetics and mechanism of environmental pharmaceuticals in aqueous suspension of $TiO_2$: A case of sulfa drugs [J]. Catalysis Today, 2010, 153 (3 - 4): 200 - 207.
[21] Ghodbane H, Hamdaoui O. Decolorization of antraquinonic dye, C.I. Acid Blue 25, in aqueous solution by direct U V irradiation, UV/$H_2O_2$ and UV/Fe(Ⅱ) processes [J]. Chemical Engineering Journal, 2010, 160(1): 226 - 231.
[22] Liao Chih - Hsiang, Kang Shyh - Fang, Wu Fuan. Hydroxyl radical scavenging role of chloride and bicarbonate ions in the $H_2O_2$/UV process[J]. Chemosphere,2001,44 (5): 1193 - 1200.
[23] Daneshvar N, Behnajady M A, Asghar Y Z. Photooxidative degradation of 4 - nitrophenol (4 - NP) in UV/$H_2O_2$ process: Influence of operational parameters and reaction mechanism [J]. Journal of Hazardous Materials, 2007, 139(2):275 - 279.
[24] Guo Zhaobing, Zhou Fei, Zhao Yongfu, et al. Gamma irradiation - induced sulfadiazine degradation and its removal mechanisms [J]. Chemical Engineering Journal, 2012, 191:256 - 262.

(上接第 50 页)

[3] Terzaghi K. The shearing resistance of saturated soils and the angle between the planes of shear [C]//. Proceedings of First International Soil Mechanics and Foundation Engineering, Massachusetts: Graduate School of Engineering, Harvard University, 1936:54 - 56.
[4] 张 霞,李占斌,张振文,等. 两种预测模型在地下水动态中的比较与应用[J]. 生态学报,2012,32(21):6788 - 6794.
[5] 张建芝,邢立亭. 回归分析法在地下水动态分析中的应用[J]. 地下水,2010,32(4):88 - 90.
[6] 刘卫林,董增川,陈南祥,等. 基于多变量相空间重构的地下水动态神经网络预测模型[J]. 河海大学学报(自然科学版),2008,36(1):14 - 18.
[7] 吴丽英. 相关分析法在地下水位预测中的应用[J]. 地下水,2011,33(6):47 - 50.
[8] 鲁魁锋,熊黑钢,冒 静,等. 两种不同时间序列模型在地下水动态变化预测中的比较研究[J]. 水资源与水工程学报,2011,22(1):1 - 6.
[9] 张 盼,刘文兆. 应用时间序列模型分析长武塬区地下水水位的变化特征[J]. 水土保持研究,2010,17(3):22 - 27.
[10] 杨忠平,卢文喜,李 平. 时间序列模型在吉林西部地下水动态变化预测中的应用[J]. 水利学报,2005,36 (12):1475 - 1479.
[11] 李景保,周永强,欧朝敏,等. 洞庭湖与长江水体交换能力演变及对三峡水库运行的响应[J]. 地理学报,2013,68(1):108 - 117.
[12] 湖南省水利厅. 湖南省水资源公报[R]. 2000 - 2012.
[13] 赵 言,花向红,李 萌. 逐步回归模型在地表沉降监测中的应用研究[J]. 测绘信息与工程,2012,37(1):6 - 8 + 35.
[14] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagation errors[J]. Nature, 1986 (323):533 - 536.
[15] 武美先,张学良,温淑花,等. BP 神经网络及其改进[J]. 太原科技大学学报,2005,26(2):120 - 125 + 130.
[16] 管孝艳,王少丽,高占义,等. 基于多变量时间序列 CAR 模型的地下水埋深预测[J]. 农业工程学报,2011,27 (7):64 - 69.