

DOI: 10.13476/j.cnki.nsbdkj.2019.0110

刘墨阳,李巧玲,李致家,等.基于小波分析的 NARX 神经网络在水位预测中的应用[J].南水北调与水利科技,2019,17(5):56-63. LIU M Y, LI Q L, LI Z J, et al. The application of NARX neural network model based on wavelet analysis for water level prediction[J]. South-to-North Water Transfers and Water Science & Technology, 2019, 17(5): 56-63. (in Chinese)

基于小波分析的 NARX 神经网络在 水位预测中的应用

刘墨阳¹, 李巧玲¹, 李致家¹, 马亚楠¹, 张汉辰¹, 蒋飞卿¹, 姚玉梅²

(1. 河海大学 水文水资源学院, 南京 210098; 2. 海河流域水土保持监测中心站, 天津 300170)

摘要:高精度的水位预测能为防洪决策、水资源管理等提供重要的调度依据,减少洪旱灾害损失。为提高预报精度,提出一种基于小波分析的 NARX 神经网络模型(DWT-NARX),综合考虑洪泽湖入湖流量、出湖流量、周边用水、前期水位等因素,对洪泽湖日水位进行预报,并与 BP 神经网络、NARX 神经网络模型进行比较。结果表明,三种模型在短历时预报中均取得了较好的模拟预测效果。当预见期为 1 或 2 天时, Nash-Sutcliffe 效率系数均大于 0.9, 合格率大于 85%; 当预见期超过 3 d, NARX 模型在水位变幅较大的时段预测结果变差, BP 模型出现严重的震荡现象, NARX 和 DWT-NARX 模型结果均优于 BP 神经网络, DWT-NARX 在整体上结果最优。研究成果可为洪泽湖的水位预报提供一定的参考价值。

关键词: NARX 神经网络; 小波分析; BP 神经网络; 水文模型; 水位预测; 洪泽湖

中图分类号: TV123 文献标志码: A 开放科学(资源服务)标识码(OSID):



The application of NARX neural network model based on wavelet analysis for water level prediction

LIU Moyang¹, LI Qiaoling¹, LI Zhijia¹, MA Yanan¹, ZHANG Hanchen¹, JIANG Feiqin¹, YAO Yumei²

(1. College of Hydrology and Water Resources, Hohai University, Nanjing 210098, China;

2. Soil and Water Conservation Monitoring Center of Haihe Basin, Tianjin 300170, China)

Abstract: Reliable water level forecasting is essential for flood prevention decision-making and water resources management, which can effectively reduce the loss of flood and droughts disasters. In order to improve the accuracy of forecasting, a nonlinear autoregressive with exogenous inputs neural network (NARX) model based on wavelet analysis (DWT-NARX) was proposed and compared with BP neural network, and NARX neural network model. The daily inflow, outflow, water utilization and the previous daily water level of Hongze Lake were considered to forecast the water level of Hongze Lake. The results indicated that three models achieved good simulation results with higher accuracy when the leading time was short, such as 1 or 2 days. The results exhibited that Nash-Sutcliffe coefficient was higher than 0.9, and the qualified rates surpass was not less than 85%. When the prediction period was further increased to 3 days, the NARX model showed poor prediction and the water level changed greatly, while BP model suggest severe oscillations. In overall performance, the NARX and DWT-NARX models showed superiority in comparison of BP neural network, while DWT-NARX yields the best performance among all other models. The research results can provide a certain reference value for the water level forecast of Hongze Lake.

Key words: NARX neural network; wavelet analysis; BP neural network; hydrological model; water level prediction; Hongze lake

收稿日期: 2019-03-21 修回日期: 2019-05-17 网络出版时间: 2019-05-24

网络出版地址: <http://kns.cnki.net/kcms/detail/13.1334.TV.20190523.1618.016.html>

基金项目: 国家重点研发计划(2016YFC0402705); 国家自然科学基金(51679061; 41130639)

作者简介: 刘墨阳(1995—), 女, 湖北荆门人, 主要从事水文学物理规律模拟与预报方面研究。E-mail: inkly@hhu.edu.cn

神经网络模型因其具有良好的非线性映射能力,在水文领域有大量研究应用,目前应用最广泛的神经网络模型是 BP 模型^[1]。在 BP 模型中,信息由输入层单向流动到输出层,只能利用有限步历史信息输出结果,而循环神经网络(RNN)模型则可以通过反馈连接结构利用长期历史信息,在时间序列预测上应用广泛^[2]。其中,NARX 神经网络是 Chen 等^[3]基于线性自回归模型提出的一种非线性有源网络结构,属于循环神经网络。Shen 等^[4]将 NARX 模型应用于洪水淹没深度多步预测,Chang 等^[5]应用 NARX 模型预测水体中的氨氮含量,Guzman 等^[6]运用该模型预测地下水水位,这些研究结果均表明,NARX 模型在模拟非线性系统和时间序列预测上有显著优势。

近年来,国内外学者将人工神经网络与小波分析、主成分分析等数据预处理方法相结合,用于日水位、日径流、降水量等水文要素的预测。其中,Nourani 等^[7]指出,与小波分析耦合的神经网络模型在序列消噪、多分辨率分析、时间序列预测等方面具有显著优势;王文圣等^[8]将小波分析与 BP 神经网络结合,预测长江寸滩站日径流,延长了预见期;Seo 等^[9]将小波分析分别与 BP 神经网络、模糊神经网络结合,预测安东流域日水位;Shoaiib 等^[10]将小波分析分别与 5 种前馈型神经网络耦合,比较耦合模型与单一模型在降雨径流模拟中的精度。这些研究也表明,耦合了小波分析等预处理技术的神经网络模型通常比单一模型的效果更好,但这些研究大多数集中在小波分析与前馈型神经网络的耦合,而对 NARX 神经网络与小波分析的耦合研究较少。

洪泽湖汇集淮河中上游 15.8 万 km² 的流域径流,是淮河流域重要的防洪控制工程,在南水北调东线工程也发挥着十分重要的调蓄功能。近年来,淮河流域受人类活动影响较大^[11],影响洪泽湖水位的因素也愈发复杂。朱全银等^[12]以入湖流量、出湖流量、降雨等作为预报因子,用 BP 网络对洪泽湖水位进行了预测,但由于样本序列较短,无法利用前期输入的历史信息,模拟序列的长期动态^[13]。因此本文详细考虑洪泽湖水位变化影响因素,结合 NARX 模型在时间序列预测的优势,将小波分析与 NARX 神经网络相结合,建立耦合模型,预测洪泽湖未来 1~6 d 的水位,希望可以提高水位预报精度,为防汛防旱调度决策提供参考。

1 方法原理

1.1 NARX 神经网络

NARX 神经网络的全称是带有外部输入的非

线性自回归神经网络,这种神经网络可以接受来自输出神经元的反馈,属于动态的循环神经网络。NARX 模型基于线性 ARX 模型思想,通常用于时间序列建模,也可以用于非线性滤波^[14]。定义为

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), u(t-1), u(t-2), \dots, u(t-n_u)) \quad (1)$$

式中: $y(t)$ 代表输出信号; $u(t)$ 代表外部输入信号; f 为非线性函数。即输出信号 $y(t)$ 可由输出信号前 n_y 个值和外部输入信号 $u(t)$ 前 n_u 个值通过 f 非线性映射得到。

NARX 神经网络结构见图 1,其结构相当于具有输入延时的 BP 网络和输出到输入的延时反馈连接单元。

与 BP 网络相比,NARX 网络在训练过程中可以反馈输出结果,因此包含序列长时间的信息,具有长期记忆能力,可以模拟时间序列长期动态。同时在网络训练过程中,网络需在时序上展开,输出延迟为传播梯度信息提供了更短的路径,减少了网络对长期时间依赖的敏感性^[15],所以收敛性能和泛化能力较好。




图 1 NARX 神经网络结构

Fig. 1 Architecture of NARX neural network

1.2 小波分析

小波分析是在傅里叶变换的基础之上发展起来的,它通过选择不同的母小波函数,控制尺度和位移,在不同分辨率下分解时间序列^[9],有效提取时频信息。

小波分析一般分为连续小波变换(CWT)和离散小波变换(DWT),在水文序列中一般采用离散小波变换,它是连续小波变换的离散化形式,其表达式为

$$W(a, b)_D = 2^{-j/z} \int_{j=1}^{j=J} \Psi^* (2^{-j/z} - k) f(t) dt \quad (2)$$

式中: $W(a, b)_D$ 为离散小波变换系数; $\Psi(t)$ 为小波函数;"*"表示取共轭; j, k 分别为控制小波尺度和位置的参数。

通过小波变换,可以把时间序列分解为概貌成分和细节成分。概貌成分表示信号低频部分,反映信号整体趋势,细节成分表示高频部分,能详细刻画信号局部信息。小波分析方法能够同时从时域和频域揭示时间序列局部特性,因此在研究具有多时间尺度变化特性和非平稳特性的水文时间序列上具有显著优势^[16]。

1.3 与小波分析耦合的 NARX 神经网络

DWT-NARX 模型主要包括两个步骤:(1)利用小波分析对输入数据进行预处理,即根据输入序列(如前期水位、前期径流等)本身特性确定分解水平,选择合适的小波函数,两者确定后采用小波分析将原始序列分解为概貌成分和细节成分;(2)将分解后序列输入 NARX 神经网络,根据序列自相关系数、互相关系数选择滞时,确定 NARX 网络结构参数(输入层、隐含层神经元个数),最后将分解子序列输入神经网络,进行网络训练预测。

1.4 评价指标

本文采用的评价指标有合格率(Q_{QR})、Nash-Sutcliffe 效率系数(N_{NSE})、均方根误差(R_{RMSE})、平均相对误差(M_{MRE})^[17]。 N_{NSE} 越接近 1,表示预测效果越好。 R_{RMSE} 和 M_{MRE} 反映预测值偏离实测值的程度, R_{RMSE} 和 M_{MRE} 越小,表明预测效果越好。

2 应用实例

2.1 研究区概况

洪泽湖形成于 17 世纪末期,位于淮河中上游末端,总库容 135 亿 m^3 ,正常蓄水位 13.0 m,是淮河流域最大的湖泊。洪泽湖也是淮河中下游调节水量的枢纽,承接上中游 15.8 万 km^2 流域面积的来水,发挥着重要的调蓄作用。

洪泽湖主要有 7 条入湖河流,分别是:淮河干流;淮北区间的怀洪新河、濉河、新汴河、徐洪河等;淮南区间的池河。主要的入湖水文控制站点分别为小柳巷、双沟、金锁镇、泗洪(濉河)、泗洪(老濉河)、团结闸、明光,其中位于淮河干流的小柳巷水文站的多年平均入湖水量占入湖总水量的 80%~90%^[18]。出湖口门位于洪泽湖东岸,主要为三河闸、二河闸、高良涧闸、高良涧水电站。出湖河道主要为淮河入江水道、苏北灌溉总渠、淮沭新河、淮河入海水道,以入江水道为主。另外还有两个灌溉涵洞洪金洞、周桥洞,视为周边用水。洪泽湖湖区水位测站共计 4 个,分别为老子山、蒋坝、高良涧、尚嘴,位于洪泽湖湖区东南侧的蒋坝站为洪泽湖代表水位站。

2.2 预报因子、样本选择

洪泽湖入湖流量、出湖流量、湖面产流、周边用水是洪泽湖水位的主要影响因素。本文从水量平衡的角度出发,将预报因子划分为 3 类:湖水增加量(Q_{in})、湖水损失量(Q_{out})、湖水位。湖水增加量包括入湖流量、湖面降雨,入湖流量为 2.1 节中 7 个水文站流量之和,其中,金锁镇和泗洪(老濉河)水文站因上游灌溉等需要,有时出现倒流,相应日期流量计入出湖流量。湖水损失量包括出湖流量、湖面蒸发,出湖流量为 2.1 节中 4 个出湖闸门,周边用水洪金洞、周桥洞流量之和,出湖控制闸门二河闸在分沂入淮时,会出现水流倒灌到洪泽湖的情况,因此将相应日期流量纳入入湖流量。采用洪泽湖附近的盱眙、尚咀、老子山、三河闸、高良涧闸 5 个雨量站雨量计算湖面平均雨量。三河闸蒸发站距洪泽湖最近,将此站点蒸发值作为湖面蒸发。

本文选取蒋坝水位站、洪泽湖入湖水文站、出湖闸门、湖周边雨量站、蒸发站 2005—2016 年资料进行研究。本文以 2005—2013 年为训练数据样本,2014—2016 年数据为测试样本,建立以 DWT-NARX 为基础的洪泽湖水位预测模型,并与基于 BP 神经网络、NARX 神经网络的预测模型进行比较。

2.3 模型结构确立

2.3.1 BP 模型

本文采用自相关系数、互相关系数确定输入序列的滞时^[19]。由图 2 可知,水位的六阶自相关系数均大于 0.9,水位与 Q_{in} 、 Q_{out} 的互相关系数变化不明显,但与水位有一定的相关性,为计算方便,综合考虑水位的自相关系数、水位与其他的互相关系数,确定滞时为 6,即将前 6 d 的日平均水位、湖水增加量、湖水损失量作为神经网络的输入。




图 2 水位自相关系数与水位与 Q_{in} 、 Q_{out} 的互相关系数

Fig. 2 The autocorrelation of water level and its cross-correlation with the inflow and outflow of the lake

Hornik^[20]证明,拥有足够隐层神经元的三层神经网络可以逼近任何连续函数,所以本文选择的网络层数一共为 3 层,即输入层、隐含层、输出层个数

均为 1。

通过上述分析,对于 BP 神经网络,最终确定的神经网络结构为 18—10—1,输入数据需进行归一化处理。网络隐层的转移函数为“tansig”,输出层的转移函数为“purelin”,误差函数采用均方误差函数,最大迭代次数为 10 000,学习算法采用 Levenberg-Marquart 算法(以下简称为 LM)。LM 算法是最常用的训练神经网络的优化算法之一^[6],具体公式为

$$\Delta w = [J^T J + \mu I]^{-1} J^T(w) e(w) \quad (3)$$

式中: w 为权重阈值参数; $J^T J$ 代表海塞矩阵; J 为雅克比矩阵; μ 为学习常数; I 代表单位矩阵; e 代表误差向量。

LM 算法是高斯牛顿法和最速下降法的结合,当 $\mu=0$,相当于高斯牛顿法;当 μ 取较大值,更接近最速下降法。该算法根据每次迭代的误差调整 μ ,对网络权重和阈值进行优化。

2.3.2 NARX 模型

NARX 模型的输入有两类。一是自回归输入,即前期水位,二是外部输入,前期的湖水增加量和湖水损失量,与 BP 模型预报因子一致。

为了比较不同神经网络结构对相同输入响应,结合上文对水位自相关系数,水位与 Q_{in} 、 Q_{out} 互相关系数的分析,NARX 神经网络输入延迟也设置为 6,输入到输出的反馈延迟也设置为 6,相当于输入前 6 天日平均水位、湖水增加量、湖水损失量。隐层和输出层转移函数、隐层神经元个数等网络结构参数以及训练算法选择与 BP 神经网络一致。与 BP 模型不同的是,在模型训练过程中,NARX 模型当前时刻模拟输出的水位会反馈到下一时刻输入。

2.3.3 DWT-NARX 模型

在建立 DWT-NARX 模型时,首先需要对输入序列进行分解。利用小波分析进行序列分解时需要考虑两类问题:(1)采用何种小波函数对信号进行分解;(2)小波分解水平。

常用的小波函数有 Daubechies、Symmlet 和 Coiflet 族小波。Shoaib 等^[2]研究表明,对于水文序列,采用‘db8’小波进行分解的预测效果较好。因为该小波是紧支撑的,且消失矩较高,具有较好的时频局部化属性^[1]。因此选择‘db8’小波对日水位资料进行离散小波变换,得到日平均水位概貌成分 A_i 和细节成分 D_i 。

小波函数确定后,需要确定分解水平,Nourani 等^[21]提出根据时间序列长度确定分解水平的经验公式为

$$L = \text{int}[\log(N)] \quad (4)$$

式中: $\text{int}[\]$ 为取整函数。本文时间序列长度为 4 383,计算得到分解层数为 3。

为便于与单一模型进行比较,模型输入的延迟设置与 NARX 模型保持一致,即将前 6 天日平均水位、 Q_{in} 、 Q_{out} 的分解序列输入 NARX 模型进行训练和预测。该模型其他结构参数设置与 NARX 模型一致。DWT-NARX 模型建立流程见图 3。




图 3 DWT-NARX 模型建模流程

Fig. 3 Flow chart of DWT-NARX neural network model

对水文序列进行多步预测有直接法、递归法、多输入输出法等^[22],这里采用直接法进行单步预测。即对每个预见期建立神经网络模型,本文一共建立了三类模型,预见期为 1~6 d,因此一共建立了 18 个神经网络模型分别对不同预见期进行模拟预测。

2.4 结果分析

表 1 为 3 种模型对应的不同预见期结果。由表 1 可知,在预见期较短时,如预见期为 1、2 d,3 种模型率定期精度相当。NARX 与 DWT-NARX 的 Nash-Sutcliffe 效率系数在所有预见期内均大于 0.9,合格率在 87%以上。BP 模型的 Nash-Sutcliffe 效率系数在不同预见期大于 0.85,合格率在 80%以上。

在同一预见期,NARX 模型 4 项评价指标在率定期的表现与 BP 模型无明显差别。而在校验期,NARX 模型结果明显优于 BP 模型,虽然 BP 模型率定期合格率和平均相对误差有时优于 NARX 模型,但在校验期模型表现下降幅度较大。这是因为与传统 BP 神经网络模型相比,NARX 模型有反馈连接结构,可有效减弱过拟合现象,因此在校验期有较好表现。

随着预见期增加,3 种模型的预测效果均不同程度削弱,而 DWT-NARX 模型表现相对稳定,预见期延长并没有使模型精度迅速降低,在 3 种模型中表现效果最好。而且对于同一预见期,耦合模型

各项评价指标在率定期和校验期数值相当,说明该 模型泛化能力较好。

表 1 3 种模型不同预见期结果

Tab.1 Simulation results of three kinds of models at different leading times

模型	预见期	率定期(2005—2013 年)				校验期(2014—2016 年)			
		QQR/%	NNSE	RRMSE	MMRE/%	QQR/%	NNSE	RRMSE	MMRE/%
BP	1	96.9	0.991	0.04	0.24	92.0	0.971	0.08	0.39
	2	96.2	0.987	0.05	0.29	86.9	0.935	0.12	0.53
	3	94.3	0.978	0.07	0.36	85.3	0.930	0.12	0.57
	4	92.3	0.966	0.08	0.44	83.9	0.913	0.14	0.66
	5	90.1	0.944	0.11	0.55	82.8	0.903	0.14	0.74
	6	87.6	0.933	0.12	0.61	81.9	0.863	0.17	0.82
NARX	1	99.7	0.995	0.03	0.14	98.8	0.995	0.03	0.15
	2	96.0	0.986	0.05	0.26	96.4	0.987	0.05	0.27
	3	93.6	0.975	0.07	0.41	92.8	0.973	0.08	0.39
	4	92.3	0.952	0.10	0.51	90.4	0.962	0.09	0.46
	5	91.0	0.946	0.11	0.57	88.0	0.948	0.11	0.54
	6	86.4	0.941	0.11	0.64	87.9	0.941	0.11	0.60
DWT-NARX	1	99.3	0.992	0.04	0.19	99.4	0.993	0.04	0.19
	2	97.2	0.983	0.06	0.31	97.4	0.983	0.06	0.30
	3	93.3	0.977	0.07	0.37	93.5	0.981	0.06	0.36
	4	92.2	0.969	0.08	0.44	90.1	0.963	0.09	0.45
	5	90.4	0.964	0.09	0.47	89.8	0.965	0.09	0.46
	6	90.2	0.960	0.09	0.52	88.1	0.961	0.09	0.52

图 4 为 2016 年汛期实测水位过程线和 3 个模型预见期分别为 1、3、6 d 的预测水位过程线。2016 年汛期,淮河发生 4 次明显涨水过程,淮河干流出现一次超警戒水位洪水过程,洪泽湖水位在 7 月 14 日至 7 月 30 日处于上涨阶段。受强降雨过程影响,淮河又遭受了自 1996 年以来最严重的秋汛。10 月 31 日,洪泽湖蒋坝站出现秋汛最高水位 13.80 m^[23]。

由图 4 可知,NARX 模型对水位过程整体预测效果较好,这与表 1 中 Nash-Sutcliffe 效率系数的分析结果一致。而 BP 模型在水位序列波动较大与极值出现时变化剧烈,且有震荡现象。同一预见期下,DWT-NARX 模型率定、校验期过程线接近实测过程线,在某些时段有锯齿,但是该模型对水位上涨趋势模拟较好,较为平滑。




图 4 3 种模型不同预见期 2016 年日水位过程线(校验期)

Fig.4 Daily water level hydrograph for three kinds of models with different leading times in 2016 (test set)

图 5 为 3 种模型不同预见期下校验期预报与实测日水位散点。随着预见期增加,BP 和 NARX 模型点据更加分散,其中 BP 模型较为明显。汛前湖水预泄、农作物需水、汛期上游洪水入湖均会导致湖水水位大幅波动。结合图 4 可知,NARX 模型在实测水位变幅较大时预测效果不好,但与 BP 模型相比,只出现小幅度偏离。BP 模型在预测水位过程线呈

现锯齿状且变幅较大时震荡明显,说明 BP 模型预测结果不稳定,这与表 1 分析结果一致。

图 6 是校验期 3 种模型不同预见期绝对误差累积概率分布曲线。从图中可以明显看出,在同一预见期,BP 模型预测误差在 3 种模型中都是最大的。随着预见期增长,在水位变幅较大的时段,NARX 模型预测效果劣于 DWT-NARX 模型。




图 5 3 种模型校验期不同预见期预报与实测日水位散点(2014—2016 年)

Fig. 5 The scatter plot of forecast and observed daily water level for three kinds of models with different leading times of test set(2014-2016)




图 6 3 种模型不同预见期绝对误差累积概率分布曲线(校验期)

Fig. 6 The cumulative probability distribution function of absolute error for three kinds of models with different leading times (test set)

结合图 4 可知,在实测水位变幅较大时,NARX 模型预测水位过程线不平滑。实测湖水位有时处于波动状态,呈现小锯齿状,而 NARX 模型具有长期记忆能力,可以捕捉此类细节,并未出现类似 BP 模型的震荡现象。

与小波分析耦合的 NARX 模型,在整体过程预测上是 3 种模型中表现最好的。该模型采用小波分

解的各尺度成分做预报因子,这些成分能充分反映水文序列更多的细节信息,因此在同一预见期下精度最高。说明使用小波分析技术能够显著改善模拟预报效果。

同时,分析本次试验结果也主要受到以下 3 个不确定性因素的影响。

(1)训练与验证数据样本选择的影响。

(2) 本文的预报因子为湖水增加量、湖水损失量、水位。实际影响洪泽湖水位变化的因素较多,除了入湖流量、出湖流量、周边用水情况、湖面产流之外,还有水利工程、湖底地形因素等。这些因素之间有一定相关性,如淮河中上游降雨与水利工程控制均会影响洪泽湖入湖流量。而且洪泽湖入湖河流众多,除了本文选取的 7 个入湖水文站,还存在没有水文站控制的中小河流,如位于宿迁市的淮北区域,因此难以精确获取总入湖流量。

(3) 对于神经网络的结构选择,如层数、转移函数、神经元个数等,目前没有成熟系统的方法进行选择,多采用试错法。本文参考的是文献中的推荐数值,而不同的结构可能会影响训练预测效果。

3 结论与展望

本文建立了基于小波分析的非线性自回归神经网络模型(DWT-NARX),对洪泽湖日水位进行预报,并与 BP 神经网络、NARX 神经网络进行了比较。研究发现,3 种模型在预见期较短时,都有比较好的预测效果,说明具有非线性映射能力的神经网络模型在预报水文时间序列上具有一定优势。随着预见期增加,BP 模型出现严重的震荡现象,NARX 与 DWT-NARX 模型表现好于 BP 模型,体现 NARX 神经网络模型结构的优越性,网络泛化能力较强。DWT-NARX 模型总体上表现最优,表明与小波分析结合的 NARX 神经网络模型可以延长预见期,提高水位预测精度,不仅在汛期可以提高防洪调度决策依据的可靠性,在枯水期也可以为水资源高效利用提供参考。

由于影响洪泽湖水位变化的因子较多,今后可进一步考虑模型输入复杂性对预测结果的影响。同时本文采用 LM 算法对网络进行训练,未采用其他算法对比,因而考虑多种不同学习算法对神经网络训练过程的影响也是未来研究中的重要内容。

参考文献(References):

[1] 孙娜,周建中,朱双,等. 基于小波分析的两神经网络耦合模型在月径流预测中的应用[J]. 水电能源科学, 2018,36(4),14-17,32. (SUN N, ZHOU J Z, ZHU S, et al. Application of hybrid models based on wavelet analysis and two different neural networks in prediction of monthly runoff[J]. Water Resources and Power, 2018, 36(4), 14-17, 32. (in Chinese))

[2] SHOAI B M, SHAMSELDIN A Y, MELVILLE B W, et al. A comparison between wavelet based static and dynamic neural network approaches for runoff

prediction[J]. Journal of Hydrology, 2016, 535: 211-225. DOI: 10.1016/j.jhydrol.2016.01.076.

[3] CHEN S, BILLINGS S A. Non-linear system identification using neural networks [J]. International Journal of Control, 1990, 51 (6): 1191-1214. DOI: 10.1080/00207179008934126.

[4] SHEN H Y, CHANG L C. On-line multistep-ahead inundation depth forecasts by recurrent NARX networks[J]. Hydrology and Earth System Sciences, 2013, 17(3): 935-945. DOI: 10.5194/hess-17-935-2013

[5] CHANG F J, TSAI Y H, CHEN P A, et al. Modeling water quality in an urban river using hydrological factors-Data driven approaches [J]. Journal of Environmental Management, 2015 (151): 87-96. DOI: 10.1016/j.jenvman.2014.12.014.

[6] GUZMAN S M, PAZ J O, TAGERT M L M. The use of NARX neural networks to forecast daily groundwater levels[J]. Water Resources Management, 2017, 31(5): 1591-1603. DOI: 10.1007/s11269-017-1598-5.

[7] NOURANI V, HOSSEINI BAGHANAM A, ADAMOWSKI J, et al. Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review[J]. Journal of Hydrology, 2014, 514: 358-377. DOI: 10.1016/j.jhydrol.2014.03.057.

[8] 王文圣,熊华康,丁晶. 日流量预测的小波网络模型初探[J]. 水科学进展, 2004, 15(3): 382-386. (WANG W S, XIONG H K, DING J. Study on wavelet network model and its application to the prediction of daily discharge[J]. Advances of Water Science, 2004, 15(3): 382-386. (in Chinese)) DOI: 10.14042/j.cnki.32.1309.2004.03.021.

[9] SEO Y, KIM S, KISI O, et al. Daily water level forecasting using wavelet decomposition and artificial intelligence techniques[J]. Journal of Hydrology, 2015, 520: 224-243. DOI: 10.1016/j.jhydrol.2014.11.050

[10] SHOAI B M, SHAMSELDIN A Y, KHAN S, et al. A comparative study of various hybrid wavelet feedforward neural network models for runoff forecasting[J]. Water Resources Management, 2018, 32(1): 83-103. DOI: 10.1007/s11269-017-1796-1.

[11] 邓恒,徐国宾,段宇,等. 淮河与洪泽湖河湖关系研究进展及展望[J]. 水资源与水工程学报, 2018, 29(5): 142-147. (DENG H, XU G B, DUAN Y, et al. Research progress and prospect of the relationship between Huaihe River and Hongze Lake[J]. Journal of Water Resources and Water Engineering, 2018, 29(5): 142-147. (in Chinese))

[12] 朱全银,戴峻峰. 洪泽湖水位预测模型的研究[J]. 计算机仿真, 2009, 26(4): 113-115, 157. (ZHU Q Y,

- DAI J F. A water level prediction model of Hongze Lake[J]. Computer Simulation, 2009, 26(4): 113-115, 157. (in Chinese))
- [13] TIAN Y, XU Y-P, YANG Z, et al. Integration of a parsimonious hydrological model with recurrent neural networks for improved streamflow forecasting [J]. Water, 2018, 10 (11): 1655. DOI: 10. 3390/w10111655.
- [14] 柴琳娜, 屈永华, 张立新, 等. 基于自回归神经网络的时间序列叶面积指数估算[J]. 地球科学进展, 2009, 24(7): 756-768. (CHAI L N, QU Y H, ZHANG L X, et al. Estimating time series leaf area index based on recurrent neural networks [J]. Advances in Earth Science, 2009, 24(7): 756-768. (in Chinese))
- [15] Lin T, Horne B G, Tino P, et al. Learning long-term dependencies in NARX recurrent neural networks[J]. IEEE Transactions on Neural Networks, 1996, 7(6): 1329-1338. <https://doi.org/10.1109/72.548162>.
- [16] 桑燕芳, 王中根, 刘昌明. 小波分析方法在水文学研究中的应用现状及展望[J]. 地理科学进展, 2013, (9): 1413-1422. (SANG Y F, WANG Z G, LIU C M. Applications of wavelet analysis to hydrology: Status and prospects [J]. Progress in Geography, 2013, 32 (9): 1413-1422. (in Chinese))
- [17] GB/T 22482—2008 水文情报预报规范[S]. (GB/T 22482—2008 Specification for Hydrological Information Forecasting[S]. (in Chinese))
- [18] 虞邦义, 郁玉锁. 洪泽湖泥沙淤积分析[J]. 泥沙研究, 2010 (6): 36-41. (YU B Y, YU Y S. Sediment deposition in Hongze Lake [J]. Journal of Sediment Research, 2010 (6): 36-41. (in Chinese)) DOI: 10. 16239/j. cnki. 0468-155x. 2010. 06. 005.
- [19] SUDHEER K P, GOSAIN A K, RAMASASTRI K S. A data-driven algorithm for constructing artificial neural network rainfall-runoff models [J]. Hydrological Processes, 2002, 16 (6): 1325-1330. DOI: 10. 1002/hyp. 554.
- [20] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feedforward networks are universal approximators [J]. Neural Networks, 1989, 2(5): 359-366. DOI: 10. 1016/0893-6080(89)90020-8.
- [21] NOURANI V, ALAMI M T, AMINFAR M H. A combined neural-wavelet model for prediction of watershed precipitation, Ligvanchai, Iran [J]. Engineering Applications of Artificial Intelligence, 2008, 22 (3): 466-472. DOI: 10. 1016/j. engappai. 2008. 09. 003.
- [22] BEN TAIEB S, BONTEMPI G, ATIYA A F, et al. A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition [J]. Expert Systems with Applications, 2012, 39(8): 7067-7083. DOI: 10. 1016/j. eswa. 2012. 01. 039.
- [23] 肖幼. 淮河防总 2017 年工作报告 [J]. 治淮, 2017, 2017(5): 7-10. (XIAO Y. 2017 work report of the Huai River flood control and drought relief headquarters [J]. Zhi Huai, 2017, 2017(5): 7-10. (in Chinese))

(上接第 28 页)

- [27] 黄国如, 张灵敏, 雒翠, 等. SWMM 模型在深圳市民治河流域的应用 [J]. 水电能源科学, 2015, 33(4): 10-14. (HUANG G R, ZHANG L M, LUO C, et al. Application of SWMM model in Minzhi River basin of Shenzhen City [J]. Water Resources and Power, 2015, 33(4): 10-14. (in Chinese))
- [28] 胡爱兵, 任心欣, 丁年, 等. 基于 SWMM 的深圳市某区域 LID 设施布局与优化 [J]. 中国给水排水, 2015, 31(21): 96-100. (HU A B, REN X X, DING N, et al. LID facilities layout and optimization in an area in Shenzhen based on SWMM [J]. China Water & Wastewater, 2015, (21): 96-100. (in Chinese))
- [29] 黄国如, 洗卓雁, 成国栋, 等. 基于 GIS 的清远市瑶安小流域山洪灾害风险评价 [J]. 水电能源科学, 2015, 33(6): 43-47. (HUANG G R, XIAN Z Y, CHENG G D, et al. Risk assessment of mountain torrent disaster at Yaoan small watershed in Qingyuan city based on GIS Technique [J]. Water Resources and Power, 2015, 33(6): 43-47. (in Chinese))