

混沌理论与 BPNN 耦合的径流中长期预测模型

王树威¹, 李建林^{1,2}, 崔延华³, 高培强¹, 赵帅鹏¹

(1. 河南理工大学 资源环境学院, 河南 焦作 454000; 2. 煤炭安全生产与清洁高效利用省部共建协同创新中心, 河南 焦作 454000; 3. 广西大藤峡水利枢纽开发有限责任公司, 广西 南宁 530000)

摘要: 受诸多因素的影响, 径流时间序列具有非线性和混沌特征。单一的 BPNN 模型可以进行径流的中长期预测, 但存在对径流影响因素量化不够的缺点; 单一的混沌模型可以量化径流的影响因素, 但只能实现短期预测。为此建立了混沌理论与 BPNN 耦合的径流中长期预测模型。针对黑河上游莺落峡水文站 1944-2017 年的径流序列, 利用混沌理论计算了径流序列的延迟时间 τ 、嵌入维数 m 和最大 Lyapunov 指数 λ_{\max} , 并进行了径流序列的相空间重构, 以此确定 BPNN 的输入层神经元个数、取值和预测的周期时长; 利用 BPNN 对 1944 年 1 月-2012 年 12 月的径流量数据进行训练, 建立了混沌-BPNN 和混沌-BPNN 等维递补两种预测模型; 以 2013 年 1 月-2017 年 12 月 (5 a) 的径流量进行模型验证。结果表明: 混沌-BPNN 等维递补模型的预测精度达到了 91.84%, 预测效果较好。混沌理论与 BPNN 耦合的径流预测模型将两种方法的优势互补, 尤其是混沌-BPNN 等维递补模型, 在补充新信息的同时剔除因系统发展而使特征意义降低的老数据, 减小了 BPNN 训练的时间跨度, 提高了预测精度, 为径流的中长期预测提供了新的有效方法。

关键词: 混沌; BPNN; 等维递补; 径流中长期预测; 黑河出山径流

中图分类号: TV121+.4; P333

文献标识码: A

文章编号: 1672-643X(2021)03-0073-07

Medium and long term runoff prediction model coupled with chaos theory and BPNN

WANG Shuwei¹, LI Jianlin^{1,2}, CUI Yanhua³, GAO Peiqiang¹, ZHAO Shuaipeng¹

(1. Institute of Resources & Environment, Henan Polytechnic University, Jiaozuo 454000, China; 2. Collaborative Innovation Center of Coal Work Safety and Clean High Efficiency Utilization, Jiaozuo 454000, China; 3. Guangxi Datengxia Gorge Water Conservancy Development Co., Ltd., Nanning 530000, China)

Abstract: Under the influence of multiple factors, runoff time series shows nonlinear and chaotic characteristics. Back propagation neural network (BPNN) model alone can be used to the medium and long term prediction of the runoff, but it has the disadvantage of insufficient quantification of runoff influencing factors. Single chaos theory model can quantify the influencing factors of runoff, but it is only applicable to the short term prediction. In view of this situation, a medium and long term runoff prediction model coupled with chaos theory and BPNN was established. Time delay τ , embedding dimension m and maximum Lyapunov exponent λ_{\max} of the runoff series of Yingluoxia Hydrological Station in the upper reaches of Heihe River from 1944 to 2017 were calculated by chaos theory, and the phase space reconstruction of the runoff series was carried out to determine the number and values of neurons in the input layer of BPNN, and the time span of the prediction. Then BPNN was used to train the runoff data from January 1944 to December 2012, based on which two prediction models of chaos-BPNN and chaos-BPNN equal dimension replenishment were established. The runoff data from January 2013 to December 2017 were used to verify the models. The result showed that the prediction accuracy of the chaos-BPNN equal dimension replenishment model reached 91.84%, with a satisfactory prediction effect. The runoff prediction models coupled with chaos theory and BPNN combine the advantages of the two methods, especially the chaos-BPNN equal dimension replenishment model. It can not only

收稿日期: 2020-10-22; 修回日期: 2021-02-27

基金项目: 国家自然科学基金项目 (41672240、41573095); 河南省自然科学基金项目 (182300410155)

作者简介: 王树威 (1996-), 男, 河南开封人, 硕士研究生, 研究方向为水文时间序列的模拟与预测。

通讯作者: 李建林 (1973-), 男, 甘肃天水人, 博士, 教授, 研究方向为水文水资源和水文地质。

supplement new information but also eliminate the old data which has lost its purpose due to the development of the system, thus reducing the time span of BPNN training and improving the prediction accuracy. This model is a new effective approach to the prediction of medium and long term runoff.

Key words: chaos; back propagation neural network (BPNN); equal dimension replenishment; medium and long term runoff prediction; runoff of the upper reaches of Heihe River

1 研究背景

水资源短缺是长期限制干旱、半干旱区生产生活和区域经济发展的首要因素^[1]。科学、有效的中长期径流预测,有助于该地区水资源的合理规划及各种社会效益的可循环发展,并为解决旱涝灾害^[2]、水利建设^[3]、水能源调度^[4]等问题提供有效帮助。中长期径流预报始终是水文学研究中存在的重点、难点问题^[5]。目前,径流中长期预测主要分为过程驱动和数据驱动两大类^[6]。过程驱动模型主要以分布式水文模型预测为主,如王杰^[7]、赵奕等^[8]利用 SWAT 和 DHSVM 模型对黑河上游流域的水文过程进行模拟。数据驱动主要是利用数学统计和人工智能方法进行径流的模拟和预测,如运用灰色模型(GM)^[9]、支持向量机(SVM)^[10]、R/S 分析^[11]和人工神经网络(ANN)^[12]等。与过程驱动模型相比,数据驱动模型所需要的观测数据较少,可以快速建模并易于实现;而且,数据驱动模型可以通过从长期径流量时间序列中提取的非线性水流特征,产生比物理过程驱动模型更令人满意的预测效果^[13]。因此,目前数据驱动的方法在径流量预测的应用中更为广泛。

江河径流是受多种因素影响的复杂系统,仅依赖单一的方法进行径流预测往往难以达到所期望的效果^[14]。因而,选择合理的方法使其优点结合增补,是建立有效预测模型的关键。混沌理论(chaos theory)中的相空间重构技术可以让时间序列中隐藏的丰富的动力学分量信息得以恢复^[15],是研究复杂系统的有效工具。但目前,基于混沌理论预测的全域法、局域法等^[16]研究仅能实现对径流量的短期预测,对水文预报的利用意义不大。人工神经网络(ANN)可以模拟人脑神经元处理复杂未知信息的方式,具有极强的非线性映射能力,并在水文时间序列的中长期模拟与预测上具有独特的优势^[17];BP神经网络(BPNN)是一种应用较为广泛的神经网络,它具有训练误差反向传播和预测结果准确性高的优点^[18-19]。但利用 BPNN 进行径流量预测时,输入层神经元的个数及其取值(即径流影响因素的

选择及其取值)是决定模型精度的关键。而影响径流的因素往往交织在一起,所以有些影响因素难以收集、量化;或在众多影响因素中难以确定起关键作用的因素,这导致 BPNN 在预测时具有较大的主观性和局限性。通过混沌相空间重构,可以量化蕴藏在径流时间序列中的影响径流各因素的个数及其取值,所以将混沌理论与 BPNN 结合,可使其优势互补,实现结果更优的中长期预测模型。

黑河是位于中国西北干旱地区的内陆河,其上游的径流量将直接影响整个流域地区的社会经济可持续发展与水生态环境保护^[20]。所以,莺落峡径流中长期的科学预报对提高黑河出山干流水量调度的精确度、增强水量调用工作的实时动态性管理具有重要的现实意义^[21]。鉴于此,建立黑河出山径流中长期预测的混沌-BPNN 等维递补模型;同时也为径流中长期预测提供新的思路和方法。

2 数据来源与研究方法

2.1 研究区概况

莺落峡水文站是黑河上游干流出山径流的控制站,设站观测始于 1944 年,其总径流量达 $15.5239 \times 10^8 \text{ m}^3/\text{a}$,多年平均径流量为 $49.2259 \text{ m}^3/\text{s}$,主要补给源为大气降水、冰川融水^[22]。

2.2 数据来源

选取 1944 年 1 月-2017 年 12 月莺落峡站 888 个月的实测月径流量数据资料(图 1)进行建模和模型验证。径流数据来源于《甘肃河西地区内陆河水文年鉴》(第 10 卷第 5 册)^[23]。

2.3 研究方法

2.3.1 相空间重构

(1) 延迟时间 τ 。用于计算参数 τ 的方法有很多,如自相关函数法、C-C 法等。而在处理非线性时间序列方面,互信息法^[24]具有更明显的优势。对于径流时间序列 $x(t) = \{x_1, x_2, \dots, x_n\}$,假设 $x(t)$ 在序列中出现的概率为 $P(x(t))$, $x(t+\tau)$ 在该序列中出现的概率为 $P(x(t+\tau))$ 。两者共同出现的概率为 $P(x(t), x(t+\tau))$,则互信息函数为:

$$I(\tau) = - \sum_{t=1}^n [P(x(t), x(t+\tau)) [\ln P(x(1)) \cdot \ln P(x(t+\tau)) - \ln P(x(1), x(t+\tau))]] \quad (1)$$

通过计算,当互信息函数曲线首次达到局部极小值时所对应的 τ ,即为最佳延迟时间 τ 。




图 1 1944 - 1917 年黑河上游莺落峡水文站月径流量

(2) 嵌入维数 m 。G - P 关联维法、FNN 法和 Cao 方法是确定嵌入维数的常用方法。而 Cao 方法^[25]具有主观参数少(仅有 1 个主观参数 τ)、信号区分能力强、计算效率高的优点。Cao 方法由公式(2)计算相空间中的点在不同嵌入维数下的最邻近点的距离变化 $\alpha(i, m)$;再经公式(3)计算 $\alpha(i, m)$ 的均值 $E(m)$,并通过公式(4)计算 $E_1(m)$ 的变化情况。最后,绘制出 $E_1(m) - m$ 曲线。当 $E_1(m)$ 的变化逐渐达到稳定时,则稳定处的 m 即为所求。

$$\alpha(i, m) = \frac{\| Y_{\eta(n)} - Y_n \|_{\infty}^{(m+1)}}{\| Y_{\eta(n)} - Y_n \|_{\infty}^m} \quad (2)$$

式中: $\alpha(i, m)$ 为不同嵌入维数下的最邻近点的距离; $\| \cdot \|_{\infty}^{(m+1)}$ 为 $m + 1$ 维空间 ∞ - 范数; Y_n 为距离 Y_{η} 最近的向量。

$$E(m) = \frac{1}{n - m\tau} \sum_{i=1}^{n-m\tau} \alpha(m, i) \quad (3)$$

$$E_1(m) = \frac{E(m)}{E(m + 1)} \quad (4)$$

式中: $E(m)$ 为 $\alpha(i, m)$ 的均值; $E_1(m)$ 为 $E(m)$ 的变化情况; τ 为延迟时间,根据时间序列的时间间隔而定,本文中 τ 的单位为月。

(3) 相空间重构。在参数 τ 和 m 确定后,进行径流量时间序列 $x(t) = \{x_1, x_2, \dots, x_n\}$ 的相空间重构^[26],得到 m 维的向量序列:

$$Y_i = \{x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}\} \quad (5)$$

式中: $i = 1, 2, \dots, M, M = n - (m - 1)\tau$ 。

2.3.2 最大 Lyapunov 指数 最大 Lyapunov 指数 λ_{\max} 是系统是否具有混沌特征的辨识参数(若 $\lambda_{\max} > 0$,则系统具有混沌特征),同时也可以确定重构序列的递补预测周期 $T(T = 1/\lambda_{\max})$ ^[27]。计算 λ_{\max} 的方法主要有小数据量法、Wolf 法、Jacobian 法、 p - 范数法等,其中 Wolf 法^[28]运算简单、应用更为广泛。本文采用 Wolf 法计算 λ_{\max} 。

2.3.3 BP 神经网络(back propagation neural net-

work, BPNN) BPNN 是由单个输入层、单个或多个隐含层和一个输出层组成的误差反向传播的前馈型神经网络^[18-19],网络模型中的每一层神经元都具有单向连接、双向传输交换信息的特征。通过 BPNN 的输出层可将输出值沿误差减小的方向,按梯度下降法逐层反向修正权值与阈值;并经多次训练迭代的向前传递与反向更新后形成达到期望的网络,最后代入测试数据进行预测验证。

2.3.4 混沌 - BPNN 模型 将混沌理论和 BPNN 结合,建立径流量的混沌 - BPNN 预测模型,具体步骤如下:

(1)相空间重构。计算径流量时间序列 $x(t) = \{x_1, x_2, \dots, x_n\}$ 的延迟时间 τ 、嵌入维数 m 和最大 Lyapunov 指数 λ_{\max} ,并在此基础上进行相空间重构。

(2) 确定 BPNN 输入层、隐含层。嵌入维数 m 可以被认为径流量影响因素的个数,将其作为混沌 - BPNN 模型的输入层神经元的个数;而输入神经元的取值由公式(5)确定。隐含层的节点数 n 可由经验公式和试凑法求得^[29-30]。

(3)构建混沌 - BPNN 模型。将重构好的向量序列分成训练数据和验证数据。基于 MATLAB 神经网络工具箱,将训练好的各层网络神经元相结合,构建混沌 - BPNN 模型,输出预测结果。混沌 - BPNN 预测模型结构见图 2。




图 2 混沌 - BPNN 预测模型结构

2.3.5 模型性能评价 为更好地评价预测模型的可靠性和准确性,本文选取水文预报中较为常用的

4种评价指标——平均绝对百分比误差 $MAPE$ 、预测精度 PP 、相对误差 RE 、合格率 QR 进行模型性能的评价^[31]。评价指标的具体计算公式如下：


$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{x}_i - x_i}{x_i} \right| \quad (6)$$

$$PP = (1 - MAPE) \times 100\% \quad (7)$$

$$RE = \left| \frac{(\hat{x}_i - x_i)}{x_i} \right| \times 100\% \quad (8)$$

$$QR = \frac{k}{N} \times 100\% \quad (9)$$

式中： \hat{x}_i 为预测值； x_i 为实测值； k 为验证期预报合格的个数； N 为验证期的总预报个数。



根据《水文情报预报规范 (GB/T 22482—2008)》中的规定,中长期径流预报的相对误差数值百分比小于 20% 时为合格^[32]。

3 结果与分析

3.1 黑河出山径流时间序列的相空间重构

以莺落峡 1944 - 2017 年径流量数据进行时间序列的相空间重构,由此确定径流量影响因素的个数及其取值。利用互信息法求得黑河出山径流量时间序列的延迟时间 $\tau = 5$ 月;利用 Cao 方法求得其嵌入维数 $m = 7$,时间延迟 τ 与嵌入维数 m 的确定如图 3 所示。




图 3 时间延迟 τ 与嵌入维数 m 的确定

对黑河出山径流量时间序列进行相空间重构,得到一个延迟时间为 5 个月的 7 维向量空间 Y :

$$Y = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_{789} \\ Y_{799} \\ \vdots \\ Y_{858} \end{pmatrix} = \begin{pmatrix} x_1 & x_6 & x_{11} & x_{16} & x_{21} & x_{26} & x_{31} \\ x_2 & x_7 & x_{12} & x_{17} & x_{22} & x_{27} & x_{32} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{798} & x_{803} & x_{808} & x_{813} & x_{818} & x_{823} & x_{828} \\ x_{799} & x_{804} & x_{809} & x_{814} & x_{819} & x_{824} & x_{829} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{858} & x_{863} & x_{868} & x_{873} & x_{878} & x_{883} & x_{888} \end{pmatrix} \quad (10)$$

3.2 月径流量的混沌 - BPNN 建模与验证

利用 Wolf 法计算得到最大 Lyapunov 指数 $\lambda_{\max} = 0.1542$ 。 $\lambda_{\max} > 0$, 表明黑河出山径流序列具有混沌特征,可进行混沌 - BPNN 预测模型的构建与训练。嵌入维数 $m = 7$,表示黑河出山径流量的影响因素为 7 个,其取值由公式(10)确定。以此确定混沌 - BPNN 模型的输入层神经元的个数为 7;同时,根据经验公式和试凑法计算出隐含层节点数也为 7。选择对 2013 年 1 月 - 2017 年 12 月(5 年)的径流量进行验证。假设公式(10)中 $(Y_{799}, Y_{800}, \dots, Y_{858})^T$ 未知;将 $(Y_1, Y_2, \dots, Y_{798})^T$ 作为 BPNN 的输入

层,导入进行训练建模;输出向量 $\hat{Y}_{799}, \hat{Y}_{800}, \dots, \hat{Y}_{858}$, 其最后一列数值 $\hat{x}_{829}, \hat{x}_{830}, \dots, \hat{x}_{888}$ 即为 $x_{829}, x_{830}, \dots, x_{888}$ 的验证值(图 4)。

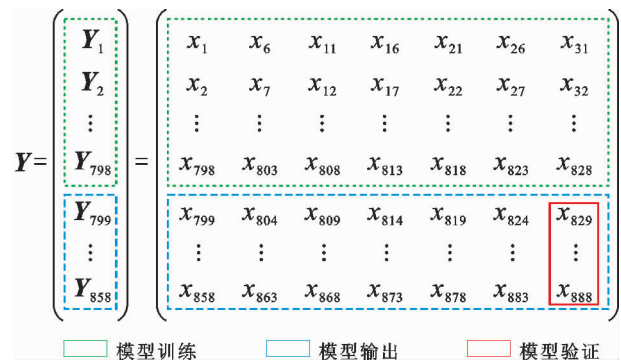


图 4 黑河出山径流混沌 - BPNN 预测模型结构

为评价所建立混沌理论与 BPNN 耦合模型的有效性,建立黑河出山径流的 BPNN 模型。单一的 BPNN 模型是将黑河上游 1944 年 1 月至 2012 年 12 月(828 个月)的径流量数据作为输入层变量进行建模训练。该模型只考虑单一时间序列,不进行相空间重构,因此 BPNN 的输入层神经元个数为 1(即影响因素为 1)。由经验公式法和试凑法求得隐含层节点数为 5。经过 BPNN 训练后的模型可对 2013 年

1 月至 2017 年 12 月的径流量进行预测验证。

绘制径流量实测值与两种模型验证值的散点图进行对比(图 5);利用公式(7)式计算得到径流量的预测精度分别为 83.57%、88.29%。结果表明,混沌-BPNN 模型对黑河出山径流的中长期预测精度优于单一的 BPNN 模型。




图 5 2013-01 - 2017-12 两种模型的预测结果与实测值的对比

4 讨论

4.1 混沌-BPNN 模型存在的主要问题

虽然混沌-BPNN 模型具有较高的预测精度,但还存在 2 个主要问题:(1)由于径流存在周期性,对未来径流量影响较大的应该是一个周期内的数据。而混沌-BPNN 模型在进行 BPNN 训练时,将 $(Y_1, Y_2, \dots, Y_{798})^T$ 全部作为的输入层(图 4),模型可能会因序列跨度太长(1944 - 2012 年),受个别极端值影响导致预测精度降低;(2)对 2013 年 1 月 - 2017 年 12 月的黑河出山径流量进行模型验证,即公式(10)中 $x_{829} \sim x_{888}$ 设定为未知(图 6 中灰色部分);而混沌-BPNN 模型将 $(Y_{799}, Y_{800}, \dots, Y_{858})^T$ 全部设为未知(图 4),则已知信息(图 6 中的白色部分)没有被充分利用。

4.2 混沌-BPNN 模型的改进

基于以上两点,对混沌-BPNN 模型进行改进。

(1)由最大 Lyapunov 指数可求得 $T = 1/\lambda_{\max} = 6.49 \approx 6$,即混沌-BPNN 模型的预测周期时长为 6 个月。因此,可选取 2012 年 8 月 - 2012 年 12 月(共 5 个月)径流量数据建模,即在公式中选择向量 $Y_{794} \sim Y_{798}$,5 个向量进行 BPNN 建模与训练。

(2)预测 x_{829} 输入 $Y_{794} \sim Y_{798}$ 进行样本训练,输出层输出:

$$\hat{Y}_{799} = (\hat{x}_{799} \quad \hat{x}_{804} \quad \hat{x}_{809} \quad \hat{x}_{814} \quad \hat{x}_{819} \quad \hat{x}_{824} \quad \hat{x}_{829}) \quad (11)$$

在(7)式中, \hat{x}_{829} 即为 x_{829} 的预测值。

(3)预测 x_{830} 。在公式(11)中,保留 \hat{x}_{829} ,其他值

用实测值代替预测值,记为: Y'_{799} :

$$Y'_{799} = (x_{799} \quad x_{804} \quad x_{809} \quad x_{814} \quad x_{819} \quad x_{824} \quad \hat{x}_{829}) \quad (12)$$

选取 $(Y_{795}, \dots, Y_{798}, Y'_{799})^T$ 共 5 个向量作为样本,进行训练,输出 \hat{Y}_{800} :

$$\hat{Y}_{800} = (\hat{x}_{800} \quad \hat{x}_{805} \quad \hat{x}_{810} \quad \hat{x}_{815} \quad \hat{x}_{820} \quad \hat{x}_{825} \quad \hat{x}_{830}) \quad (13)$$

在(9)式中,即 \hat{x}_{830} 为 x_{830} 的预测值。

(4)重复以上步骤,每次预测去掉第一个向量,补充新的向量,保持输入层为 5 个向量进行 BPNN 训练,可得 $x_{831}, x_{832}, \dots, x_{888}$ 的预测值。由改进模型的特点,可称之为径流中长期预测的混沌-BPNN 等维递补模型。

4.3 不同预测模型的性能评价

依照水文预报的规范,本文选取相对误差在 20% 以内的预测为合格。通过公式(8)对黑河上游 60 个月逐月预测的相对误差对比分析(图 7),混沌-BPNN 等维递补模型明显优于另外两种模型,其各月经流量的预报误差率基本小于 20%。

x_{799}	x_{804}	x_{809}	x_{814}	x_{819}	x_{824}	x_{829}
...
x_{804}	x_{809}	x_{814}	x_{819}	x_{824}	x_{829}	x_{834}
...
x_{809}	x_{814}	x_{819}	x_{824}	x_{829}	x_{834}	x_{839}
...
x_{814}	x_{819}	x_{824}	x_{829}	x_{834}	x_{839}	x_{844}
...
x_{819}	x_{824}	x_{829}	x_{834}	x_{839}	x_{844}	x_{849}
...
x_{824}	x_{829}	x_{834}	x_{839}	x_{844}	x_{849}	x_{854}
...
x_{829}	x_{834}	x_{839}	x_{844}	x_{849}	x_{854}	x_{859}
...
x_{858}	x_{863}	x_{868}	x_{873}	x_{878}	x_{883}	x_{888}

□ 已知信息 ■ 未知信息

图 6 混沌-BPNN 模型验证环节的已知信息和未知信息

根据公式(6)、(7)、(9)的计算结果(表 1),混沌-BPNN 等维递补模型的平均绝对百分比误差为 8.16%,低于另外两种预测模型;预测精度为 91.84%,高于 BPNN 和混沌-BPNN,达到了 90% 以上,实现了较高精度的中长期径流预测。此外,通过逐月比较各模型预测值与实测值的相对误差,可以看出混沌-BPNN 等维递补模型的合格率更高,为 88.33%。

(1)混沌理论与 BPNN 结合,弥补了两种方法各自的缺点,所以混沌-BPNN 和混沌-BPNN 等维

递补模型的预测精度明显高于单一 BPNN 模型的预测精度。混沌理论和 BPNN 耦合为解决复杂非线性系统的问题,提供了强有力的工具。

(2)在利用 BPNN 对相空间重构后的径流量时间序列进行训练建模时,若选用全部的历史重构序列建立预测模型,则可能会因径流时间序列跨度较长而受到某些随机跳跃性数据的扰动,导致模型精度降低;若所选序列太短,则可能缺少相应的建模信息,也是对历史观测数据的浪费。利用最大 Lyapunov 指数确定预测周期时长后,在一个周期内进行径流量预测,不仅降低了时间序列跨度的波动性、

减少了对历史水文观测资料的浪费,还可避免人为随意截选样本序列进行建模的主观性。所以,混沌 - BPNN 等维递补模型的预测精度又明显高于混沌 - BPNN 的预测精度。

表 1 3 种预测模型的综合性能评价

评价参数	BPNN	混沌 - BPNN	混沌 - BPNN 等维递补
MAPE / %	16.48	11.71	8.16
PP / %	83.57	88.29	91.84
QR / %	66.67	75.00	88.33




图 7 3 种模型的逐月相对误差对比(2013-01 - 2017-12)

5 结 论

(1)根据混沌理论和人工神经网络各自特有的优势,建立了径流量的混沌理论与 BPNN 耦合的径流预测的两种模型。耦合模型克服了单一 BPNN 模型对径流量影响因素考虑不够和难以量化的缺点,提高了河川径流量的中长期预测精度。

(2)混沌 - BPNN 等维递补模型在混沌 - BPNN 模型的基础上弱化了长序列数据的起伏振荡性,利用预测值动态递补对系统演变记忆逐渐消退的旧信息,使模型预测精度有所提高。对黑河出山径流建立了混沌 - BPNN 等维递补预测模型,精度达到了 91.84%;该模型比混沌 - BPNN 模型具有更好的预测精度。

参考文献:

[1] 陈益平,秦欢欢. 人类活动影响下内陆干旱区张掖盆地需水量预测[J]. 节水灌溉, 2020(2): 61 - 66.
 [2] 国俊宝,余钟波,杨传国,等. 基于物理成因的中长期径流预测模型研究[J]. 水电能源科学, 2020,38(5):35 - 37 + 34.
 [3] 李文武,石强,王凯,等. 基于变分模态分解和深度门控网络的径流预测[J]. 水力发电学报, 2020,39(3): 34 - 44.
 [4] 庄晓雯,尹成波,曹银妹,等. 基于逐步聚类分析法的开都河径流预测模型[J]. 人民黄河, 2019,41(2):1 - 4.

[5] TAN Qiaofeng, LEI Xiaohui, WANG Xu, et al. An adaptive middle and long-term runoff forecast model using EEMD - ANN hybrid approach [J]. Journal of Hydrology, 2018, 567: 767 - 780.
 [6] 梁浩,黄生志,孟二浩,等. 基于多种混合模型的径流预测研究[J]. 水利学报, 2020,51(1):112 - 125.
 [7] 王杰. 气候变化条件下黑河上游径流模拟及预测[D]. 北京:中国地质大学(北京),2019.
 [8] 赵奕,南卓铜,李祥飞,等. 分布式水文模型 DHSVM 在西北高寒山区流域的适用性研究[J]. 冰川冻土, 2019, 41(1):147 - 157.
 [9] 李建林,李志强,王心义,等. 河流年径流量的 GM(1,2) - Markov 中长期预测模型[J]. 干旱区地理, 2016, 39(2): 240 - 245.
 [10] 晋健,刘育,王琴慧,等. 基于小波去噪和 FA - SVM 的中长期径流预报[J]. 人民长江,2020,51(09):67 - 72.
 [11] 陈建龙,刘永峰,钱鞠,等. R/S 分析法与 GM(1,1) 灰色模型相结合的鸳鸯池水库入库径流量预测[J]. 水资源与水工程学报,2018,29(5):148 - 153 + 158.
 [12] 王佳,王旭,王浩,等. 基于 EEMD 与 ANN 混合方法的水库月径流预测[J]. 人民黄河,2019,41(5):43 - 46.
 [13] KALTEH A M. Improving forecasting accuracy of streamflow time series using least squares support vector machine coupled with data-preprocessing techniques [J]. Water Resources Management, 2016, 30(2): 747 - 766.
 [14] 周有荣,崔东文. 基于混合核 SHTS - SVM 的年径流预

- 测[J]. 水资源与水工程学报, 2019, 30(3): 66-72.
- [15] 吕金虎, 陆君安, 陈士华. 混沌时间序列分析及其应用[M]. 武汉: 武汉大学出版社, 2002.
- [16] 李彦彬. 河川径流的混沌特征和预测研究[D]. 西安: 西安理工大学, 2009.
- [17] 李永坤, 马旭, 潘兴瑶, 等. 基于芒种日分析的BP模型在中长期汛期降雨量预报中的应用[J]. 南水北调与水利科技, 2019, 17(3): 1-6+39.
- [18] 冯鑫伟, 黄领梅, 沈冰. 多元线性回归与BP神经网络模型在次洪量预测中的对比研究[J]. 水资源与水工程学报, 2017, 28(3): 123-126+133.
- [19] 王文川, 李文锦, 徐冬梅, 等. 基于马尔可夫链校正GM-BP模型的径流预测[J]. 南水北调与水利科技, 2019, 17(5): 44-49.
- [20] 姜锋, 丁志宏, 赵焱. 基于CEEMDAN的黑河莺落峡年径流量多时间尺度变化特征研究[J]. 中国农村水利水电, 2018(2): 64-67.
- [21] 李建林, 咎明军, 李宝玲. 基于R/S分析的黑河出山年径流量灰色预测[J]. 地域研究与开发, 2014, 33(5): 127-131.
- [22] 程建忠, 陆志翔, 邹松兵, 等. 黑河干流上中游径流变化及其原因分析[J]. 冰川冻土, 2017, 39(1): 123-129.
- [23] 甘肃省水利厅. 甘肃河西地区内陆河水文年鉴(第10卷)[M]. 兰州: 甘肃科学技术出版社, 2018.
- [24] 何自立, 陆梦可, 王正中, 等. 基于相空间重构小波神经网络径流式水电站发电量预测[J]. 中国农村水利水电, 2017(9): 178-180+190.
- [25] CAO Liangyue. Practical method for determining the minimum embedding dimension of a scalar time series[J]. Physica D: Nonlinear Phenomena, 1997, 110(1-2): 43-50.
- [26] 周建中, 彭甜. 长江上游径流混沌动力特性及其集成预测研究[J]. 长江科学院院报, 2018, 35(10): 1-9.
- [27] 汪伟, 罗周全, 王益伟, 等. 基于混沌理论的矿井涌水量预测研究[J]. 中国安全科学学报, 2013, 23(4): 51-56.
- [28] 周长让, 陈元芳, 顾圣华, 等. 日径流序列混沌识别中合理长度的确定[J]. 南水北调与水利科技, 2017, 15(1): 55-59+101.
- [29] 张以文, 郭海帅, 涂辉, 等. 基于随机隐含层权值神经网络的瓦斯浓度预测[J]. 计算机工程与科学, 2019, 41(4): 699-707.
- [30] 王义民, 张珏. 基于混沌神经网络的径流预测模型[J]. 西北农林科技大学学报(自然科学版), 2010, 38(6): 200-204.
- [31] 岳兆新, 艾萍, 熊传圣, 等. 基于改进深度信念网络模型的中长期径流预测[J]. 水力发电学报, 2020, 39(10): 33-46.
- [32] 中华人民共和国国家质量监督检验检疫总局, 中国国家标准化管理委员会. GB/T 22482—2008 水文情报预报规范[S]. 北京: 中国标准出版社, 2009.

(上接第72页)

- [17] 国家气候中心. 气象干旱等级: GB/T 20481—2017[S]. 北京: 中国标准出版社, 2017.
- [18] 鲁凤, 钱鹏, 胡秀芳, 等. 基于小波分析与Mann-Kendall法的上海市近12年空气质量变化[J]. 长江流域资源与环境, 2013, 22(12): 1614-1620.
- [19] 王泉轩, 左小清, 杨泽楠, 等. 基于Mann-Kendall检验和信息熵的成都市1980-2016年降水时空变化[J]. 中国水土保持科学, 2019, 17(4): 26-33.
- [20] 周晓宇, 赵春雨, 张新宜, 等. 1961-2009年辽宁省气温、降水变化特征及突变分析[J]. 干旱区资源与环境, 2013, 27(10): 87-93.
- [21] 邓岳川, 周亮广. 地形起伏度与GPS多路径误差的相关性分析[J]. 测绘科学, 2019, 44(10): 21-28.
- [22] 赵志成, 熊康宁, 陈浒, 等. 干旱对贵州喀斯特石漠化生态治理区土壤动物的影响[J]. 西南农业学报, 2011, 24(3): 1167-1172.
- [23] 冯禹, 崔宁博, 徐燕梅, 等. 贵州省干旱时空分布特征研究[J]. 干旱区资源与环境, 2015, 29(8): 82-86.
- [24] 白淑英, 莫婷, 史建桥, 等. 近50年贵州不同强度降水日数时空变化分析[J]. 南水北调与水利科技, 2015, 13(2): 220-224.
- [25] 贵州省气象局. 贵州省干旱标准: DB 52/T 1030—2015[S]. 贵州省质量技术监督局, 2015.
- [26] 罗宁. 中国气象灾害大典: 贵州卷[M]. 气象出版社, 2006.
- [27] 汪攀, 刘毅敏. Sen's斜率估计与Mann-Kendall法在设备运行趋势分析中的应用[J]. 武汉科技大学学报, 2014, 37(6): 454-457+472.
- [28] 马士彬, 张勇荣, 安裕伦. 山区城市土地利用动态空间分布特征——以贵州省六盘水市为例[J]. 自然资源学报, 2012, 27(3): 489-496.
- [29] 汤国安, 那嘉明, 程维明. 我国区域地貌数字地形分析研究进展[J]. 测绘学报, 2017, 46(10): 1570-1591.
- [30] 陈学凯, 雷宏军, 徐建新, 等. 气候变化背景下贵州省农作物生长期干旱时空变化规律[J]. 自然资源学报, 2015, 30(10): 1735-1749.
- [31] 李月, 白晓永, 周运超, 等. 基于SPEI的贵州省近60年干旱时空特征分析[J]. 中国水土保持, 2015(7): 57-60.