

径流序列相空间重构的水文学含义及应用

李建林^{1,2}, 贺奇¹, 王树威³, 王心义^{1,2}, 张杰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. 中化地质矿山总局浙江地质勘察院, 浙江 杭州 310002)

摘要:为确定径流序列相空间重构后的水文学含义并提高径流中长期预测精度,基于混沌理论进行径流序列相空间重构,并对径流影响因素与重构后相空间列向量进行相关性分析。在此基础上建立了混沌理论与人工神经网络耦合(Chaos-BPNN)的径流预测模型,并应用于黑河上游莺落峡水文站和正义峡水文站。结果表明:径流序列重构后相空间列向量具有明确的水文学含义;Chaos-BPNN径流预测模型仅需径流序列数据就可进行建模和预测,规避了径流预测过程中主控因素难以确定和不易量化的问题;黑河上游降水量、输沙量、水位和气温分别与重构后相空间的第1、3、6、7列具有较高的相关性,风速与任何一列都不相关,推测雪线高程、植被覆盖率以及土地利用类型等因素与第2、4、5列存在相关性;构建的Chaos-BPNN径流预测模型在黑河上游莺落峡水文站和正义峡水文站的径流预测精度均在86%以上。

关键词:径流序列;相空间重构;混沌特征;径流影响因素;Chaos-BPNN径流预测模型

中图分类号:TV122 **文献标志码:**A **文章编号:**1004-6933(2024)03-0090-08

Hydrological meaning and application of phase space reconstruction of runoff series//LI Jianlin^{1,2}, HE Qi¹, WANG Shuwei³, WANG Xinyi^{1,2}, ZHANG Jie¹ (1. School of Resources & Environment, Henan Polytechnic University, Jiaozuo 454000, China; 2. State Collaborative Innovation Center of Coal Work Safety and Clean-Efficiency Utilization, Jiaozuo 454000, China; 3. Zhejiang Geological Prospecting Institute of China Chemical Geology and Mine Bureau, Hangzhou 310002, China)

Abstract: To determine the hydrological meaning of the reconstructed phase space of the runoff series and improve the accuracy of mid- to long-term runoff prediction, the phase space of the runoff series was reconstructed based on chaos theory, and correlation analysis was conducted between the influencing factors of runoff and the reconstructed phase space column vectors. On this basis, a runoff prediction model coupled with Chaos theory and artificial neural network (Chaos-BPNN) was established, and applied to the Yingluoxia and Zhengyixia hydrological stations in the upper reaches of the Heihe River. The results indicate that the reconstructed phase space column vectors of the runoff series have clear hydrological meaning. The Chaos-BPNN runoff prediction model only requires runoff sequence data for modeling and prediction, avoiding the problems of difficult determination and quantification of main control factors in the runoff prediction process. The precipitation, sediment transport, water level, and temperature in the upper reaches of the Heihe River are highly correlated with the reconstructed phase space columns 1, 3, 6, and 7, respectively. Wind speed is not correlated with any column, and it is speculated that factors such as snow line elevation, vegetation coverage, and land use type are correlated with columns 2, 4, and 5. The Chaos-BPNN runoff prediction model constructed has a runoff prediction accuracy of over 86% at the Yingluoxia and Zhengyixia hydrological stations in the upper reaches of the Heihe River.

Key words: runoff series; phase space reconstruction; chaotic characteristics; influencing factors of runoff; Chaos-BPNN runoff prediction model

径流过程受降水、蒸发、太阳辐射和人类活动等多种复杂因素的影响^[1],表现出一定的非线性、非平稳性和混沌性^[2],所以径流的中长期预测一直是径流研究中的热点和难点^[3]。目前,径流预测主要

采用物理过程驱动模型和数据驱动模型^[4-5]。由于数据驱动模型需要的数据少,而且可以从长期径流时间序列中提取非线性水流特征,产生比物理过程驱动模型更令人满意的预测效果,因此数据驱动模

型在径流预测中的应用越来越广泛^[6]。多数学者基于模糊理论^[7]、混沌理论^[8]、神经网络^[9]、小波分析^[10]、支持向量机^[11]等方法建立数据驱动的径流预测模型。此外,学者们还采用对模型改进的方式进行中长期径流预测^[12-15]。

混沌理论创立以来,逐渐成了研究复杂性系统的有效工具之一^[16]。利用混沌理论进行径流特征分析与预测的研究始于20世纪末,目前得到的主要结论有:径流过程具备了产生混沌的条件;重构后的相空间的列数(嵌入维数)等于引起径流变化的主控因素的个数;利用混沌理论可以对径流序列进行短期的预测。但整体而言,混沌理论在水文学领域的研究进展较为缓慢,除了混沌理论本身的理论基础不够完善外,没有厘清径流动力学机制,即相空间重构后高维空间向量的水文学含义是一个重要原因,即重构后的相空间每一列的数值是否能代表某一主控因素的变化,或者与某一主控因素的变化存在较强的相关性呢?目前还未见到相关的研究成果。因此,厘清相空间重构后径流序列的水文学含义不仅可以推动混沌理论在水文领域的发展,也可以实现中长期径流的高效预测。

鉴于此,本文拟进行径流序列相空间重构后水文学含义的探讨,并建立径流混沌-BP人工神经网络(Chaos-BPANN)径流预测模型,并应用于我国第二大内陆河——黑河上游径流,以期为提高径流中长期预报的精度提供参考。

1 研究方法与步骤

1.1 径流序列相空间重构

重构的非线性系统相空间可能被延拓到维度较高的空间中去,通过延迟坐标进行相空间重构,可以挖掘出时间序列中蕴含的丰富信息。针对径流序列,确定了延迟时间 τ 和嵌入维数 m ,就可以得到重构的相空间。

a. 延迟时间 τ 。目前有很多方法可以计算延迟时间,比如互信息法、自相关函数法、C-C法^[17-18]等。在解决非线性时间序列问题上,互信息法具有较高的优势^[19],故本文采用互信息法计算 τ 。具体方法为:对于径流序列 $X = \{x_1, x_2, \dots, x_n\}$,假设 x_i 和 $x_{i+\tau}$ 在序列中出现的概率分别为 $P(x_i)$ 和 $P(x_{i+\tau})$,两者共同出现的概率为 $P(x_i, x_{i+\tau})$,则互信息函数为

$$I(\tau) = - \sum_{i=1}^{n-\tau} P(x_i, x_{i+\tau}) \left[\ln P(x_i) \ln P(x_{i+\tau}) - \ln P(x_i, x_{i+\tau}) \right] \quad (1)$$

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。

b. 嵌入维数 m 。常用的计算方法有G-P关联维数法、假邻近法(false nearest neighbors, FNN)和Cao方法^[20]。Cao方法具有主观参数少(仅有1个主观参数 τ)、区分信号能力强、计算效率高的优点。Cao方法是在延迟时间确定的情况下对最小嵌入维数进行求取的方法(FNN方法的改进)。Cao方法的计算步骤为:

步骤1 计算相空间中的点在各嵌入维数条件下的最近邻点的距离变化值,公式为

$$\alpha(i, m) = \frac{\|Y_i(m+1) - Y_{n(i, m)}(m+1)\|}{\|Y_i(m) - Y_{n(i, m)}(m)\|} \quad (2)$$

式中: $\|\bullet\|$ 为 ∞ -范数; $Y_i(m+1)$ 为第 i 个相空间重构向量,嵌入维数为 $m+1$; $Y_{n(i, m)}(m+1)$ 为距离 $Y_i(m+1)$ 最近的向量,其中 $n(i, m) \in \{1, 2, \dots, N-m\tau\}$ 。

步骤2 计算相同维数下距离变化均值:

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

式中 $E(m)$ 为所有 $\alpha(i, m)$ 的均值。

步骤3 根据式(4)观察 $E_1(m)$ 的变化情况:

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

当 $E_1(m)$ 在 m_0 处达到平稳,或在此之后变化幅度较小时,则认为此时的 m 为最小嵌入维数。

c. 相空间重构。延迟时间 τ 和嵌入维数 m 确定后,将径流序列重构为 m 维的向量序列:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_{i+N} \end{bmatrix} = \begin{bmatrix} x_1 & x_{1+\tau} & x_{1+2\tau} & \cdots & x_{1+(m-1)\tau} \\ x_2 & x_{2+\tau} & x_{2+2\tau} & \cdots & x_{2+(m-1)\tau} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{i+N} & x_{i+N+\tau} & x_{i+N+2\tau} & \cdots & x_{i+N+(m-1)\tau} \end{bmatrix} \quad (5)$$

1.2 最大 Lyapunov 指数

最大 Lyapunov 指数 $\lambda_{\max}$ 的正负可以作为判断系统是否具有混沌特征的依据, $\lambda_{\max} > 0$ 意味着系统具有混沌特征。计算 $\lambda_{\max}$ 的方法主要有小数据量法、Wolf法、Jacobian法等。其中Wolf法运算简单,应用最为广泛^[21],因此本文采用Wolf法进行计算,其步骤如下:

对于混沌时间序列 $\{x_1, x_2, \dots, x_n\}$,设其嵌入维数为 m ,延迟时间为 τ ,则重构相空间得到 $Y_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau})$ ($i = 1, 2, \dots, N$)。取初始 Y_0 ,设其与最近邻点 Y'_0 的距离为 L_0 ,追踪这两点的时间演化,直到下一时刻,其间距超过某规定值 $\varepsilon > 0$, $L'_0 = |Y_1 - Y'_0| > \varepsilon$,保留 Y_1 ,并在 Y_1 附近寻找另外一个点 Y'_1 ,使得 $L_1 = |Y_1 - Y'_1| < \varepsilon$,并且与之夹角尽可能小。继续上述过程,直至 Y 达到时间序列的终点,这时

追踪演化过程总的迭代次数为 M , 则最大 Lyapunov 指数为

$$\lambda_{\max} = \frac{1}{M} \sum_{i=0}^M \ln \frac{L'_i}{L_i} \tag{6}$$

1.3 相关性分析

利用决定系数 R^2 以及皮尔逊相关系数 ρ_{xy} 判别径流影响因素与重构后相空间某一列元素的相关程度^[22], 即明确重构后相空间列向量的水文学含义。

1.4 Chaos-BPNN 径流预测模型

人工神经网络 (artificial neural network, ANN) 是通过模仿人脑神经元网络连接结构、模拟人脑中生物神经元对信息存储和加工的处理机制, 来解决复杂实际问题的智能化信息处理工具。BPNN (back propagation neural network) 是一种误差反向传播的前馈神经网络, 由输入层、单个或多个隐含层和一个输出层^[23] 组成, 能较好地解决非线性问题。因此, 本文采用 BPNN 建立径流预测模型。

a. Chaos-BPNN 径流预测模型的构建。 首先, 利用嵌入维数 m 确定径流主控因素的个数; 其次, 径流主控因素与重构后相空间某一列元素的相关程度确定后, 将列向量作为 BPNN 的输入层进行学习; 然后, 基于 Matlab 神经网络工具箱, 结合各层训练好的神经网络构建 Chaos-BPNN 径流预测模型; 最后, 输出预测结果。

b. 模型预测性能评估。 为更好地评价径流预测模型的可靠性和准确性, 选取 4 种较为常用的评

价指标, 分别为平均绝对百分比误差 E_M 、模型精度 P_P 、合格率 Q_R 以及纳什效率系数 NSE。NSE 取值为 $(-\infty, 1]$, NSE 值接近 1, 表示模式质量好, 模型可信度高; NSE 值接近 0, 表示模拟结果接近观测值的平均值水平, 即总体结果可信, 但过程模拟误差大; NSE 值远小于 0, 则模型是不可信的。指标计算公式为

$$E_M = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{x}_i - x_i}{x_i} \right| \times 100\% \tag{7}$$

$$P_P = 1 - E_M \tag{8}$$

$$Q_R = \frac{k}{n} \times 100\% \tag{9}$$

式中: $\hat{x}_i$ 为预测值; x_i 为实测值; n 为验证期的总预报个数; k 为相对误差小于 10% 的预测集样本个数。

1.5 研究步骤

围绕相空间重构后径流序列水文学含义的确定和 Chaos-ANN 径流预测模型的建立展开研究。首先, 利用相关分析法寻找相空间每一列与哪个径流相关因素具有较高的相关性, 以确定其水文学含义; 其次, 将列元素作为输入层导入确定的 ANN 进行学习、训练; 最后, 进行径流中长期预测与模型验证。具体步骤如图 1 所示。

2 实例应用

2.1 研究区概况

黑河流域位于我国西北地区, 面积约




图 1 研究步骤示意图

Fig. 1 Schematic diagram of research steps

14.3 万 km², 年平均降水量 150 mm, 年平均潜在蒸发量超过 1 000 mm。黑河上游建有两处气象站(野牛沟(YNG)和祁连(QL))和 3 处水文站(莺落峡(YLX)、祁连和札马什克);其中, 莺落峡水文站(38°48'N, 100°11'E, 海拔 1 710 m, 建于 1944 年)是黑河上游径流的控制站(图 2), 集水区面积 10 009 km², 年均流量 15.524 亿 m³, 年平均流量 49.226 m³, 径流模数 4.918 L/(s · km²)。黑河径流补给来源主要为大气降水、冰雪融水^[24], 年内径流分布不均。利用上游气象和径流数据建立径流预测模型, 为了验证模型的普适性, 在正义峡水文站进行了验证。正义峡水文站(40°40'N, 100°9'E, 建于 1943 年)作为黑河干流中游最后一个基础水文站, 是黑河中下游的分界段, 距河源 517 km。




图 2 黑河上游及气象站、水文站位置

Fig. 2 Heihe River upstream and locations of meteorological and hydrologic stations

2.2 数据来源

莺落峡水文站 1944—2017 年和正义峡水文站 1954—2017 年的月径流量数据以及莺落峡站 1990—2000 年水位、输沙量、降水量、气温和风速数据来自《甘肃河西地区内陆河水文年鉴》(第 10 卷第 5 册)。祁连站和野牛沟站 1990—2000 年的月平均气温及月降水量资料来源于中国气象局气象中心。

2.3 结果与分析

2.3.1 数据处理

图 3 为莺落峡水文站 1944—2017 年和正义峡水文站 1954—2017 年的月径流情况。对莺落峡水文站的水位、输沙量、降水量、气温、风速时间序列进行均值计算, 结果分别为 0.9159 m、0.8765 kg/m³、15.134 1 mm、9.341 7℃、0.707 6 m/s。其中, 降水量基于上游多个雨量站的资料采用泰森多边形法计算得到。

2.3.2 径流序列混沌特征

对 1944 年 1 月至 2010 年 12 月径流观测数据进行时间序列的相空间重构, 利用互信息法求得径




图 3 莺落峡和正义峡水文站月径流情况

Fig. 3 Monthly runoff situation of Yingluoxia Hydrological Station and Zhengyixia Hydrological Station

流序列的延迟时间 $\tau=5$ 月; 利用 Cao 方法求得嵌入维数 $m=7$, 说明黑河上游径流主控影响因素有 7 个。因此, 通过重构径流时间序列的相空间, 得到延迟时间为 5 月的 7 维相空间 Y :

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_{594} \\ Y_{595} \\ \vdots \\ Y_{654} \\ \vdots \\ Y_{774} \end{bmatrix} = \begin{bmatrix} x_1 & x_6 & x_{11} & x_{16} & x_{21} & x_{26} & x_{31} \\ x_2 & x_7 & x_{12} & x_{17} & x_{22} & x_{27} & x_{32} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{594} & x_{599} & x_{604} & x_{609} & x_{614} & x_{619} & x_{624} \\ x_{595} & x_{600} & x_{605} & x_{610} & x_{615} & x_{620} & x_{625} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{654} & x_{659} & x_{664} & x_{669} & x_{674} & x_{679} & x_{684} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{774} & x_{779} & x_{784} & x_{789} & x_{794} & x_{799} & x_{804} \end{bmatrix} \quad (10)$$

2.3.3 重构后相空间列向量的水文学含义

进行相空间列向量与影响因素的相关性分析, 需要在同一时间段上进行。径流序列相空间重构后, 每一列分别为不同时间段上的径流序列。首先确定重构后相空间列向量对应的时间, 结果见表 1。

表 1 重构后相空间列向量对应的时间

Table 1 Time period corresponding to column vectors						
1993-07 至 1998-06	1993-12 至 1998-11	1994-05 至 1999-04	1994-10 至 1999-09	1995-03 至 2000-02	1995-08 至 2000-07	1996-01 至 2000-12
x_{595}	x_{600}	x_{605}	x_{610}	x_{615}	x_{620}	x_{625}
x_{596}	x_{601}	x_{606}	x_{611}	x_{616}	x_{621}	x_{626}
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
x_{654}	x_{659}	x_{664}	x_{669}	x_{674}	x_{679}	x_{684}

选取径流的 5 个影响因素(降水量、输沙量、水位、气温和风速)进行相空间列向量(式(10)红框内的相点)与相关因素的相关性分析。将相空间每一列径流相点元素作为因变量 y , 分别与同时期的水位、输沙量、降水量、气温、风速作线性回归和皮尔逊相关性分析, 其中第 1、3、6、7 列径流与相关因素具

有较显著的相关性,结果见图 4。由图 4 可见,不同时期的径流与降水量、输沙量、水位、气温的 R^2 分别为 0.6284、0.5377、0.7847 和 0.5964, ρ_{xy} 分别为 0.7930、0.6460、0.8860 和 0.7720。风速与任何一系列相点元素都不相关,说明风速不是径流的主要相关因素。第 2、4、5 列相点元素可能与其他因素有关,如雪线高程、植被覆盖率以及土地利用类型等因素。相关性分析结果说明通过将一维的径流时间序列重构并展开至高维的相空间,能充分挖掘每一维径流序列所蕴含的信息,相空间重构后的列向量具有明显的水文学含义,即每一列径流相点序列近似等效为一个径流的相关因素。

2.3.4 Chaos-BPNN 径流预测模型的预测过程

计算得到最大 Lyapunov 指数为 0.1398,表明黑河上游径流序列具有混沌特征,可以构建 Chaos-BPNN 径流预测模型。由于重构后的相空间每一列元素代表径流某一影响因素的取值,所以列向量可




图 4 第 1、3、6、7 列径流与相关因素相关分析结果

Fig. 4 Results of correlation analysis between runoff and related factors in columns 1, 3, 6, and 7

的径流进行 Chaos-BPNN 模型训练,假设此期间的径流量未知,即 x_{565} 、 x_{566} 、 $\cdots$ 、 x_{804} 未知。因此,训练相点 Y_1 、 Y_2 、 $\cdots$ 、 Y_{533} 和径流量 x_{32} 、 x_{33} 、 $\cdots$ 、 x_{564} ,如表 2 所示。训练好 Chaos-BPNN 模型后,利用 $Y_{534} = (x_{534}, x_{539}, \cdots, x_{564})$ 对径流 x_{565} 的预测值 $\hat{x}_{565}$ 进行预测,预测过程采用梯度预测,训练过程如图 5 所示。在得到 $\hat{x}_{565}$ 之后,将其实测值替换为预测值,然后训练相点 Y_2 、 Y_3 、 $\cdots$ 、 Y_{535} 和径流量 x_{33} 、 x_{34} 、 $\cdots$ 、 $\hat{x}_{565}$,通过输入相点 Y_{535} 预测 $\hat{x}_{566}$ 。如此梯式下降、循环往复,直至预测出 $\hat{x}_{804}$,预测过程如图 6 所示。

表 2 Chaos-BPNN 预测模型网络训练情况

Table 2 Chaos-BPNN prediction model network training

训练输入							训练输出
降水量	雪线高程	输沙量	植被覆盖率	土地利用类型	水位	气温	径流量
x_1	x_6	x_{11}	x_{16}	x_{21}	x_{26}	x_{31}	x_{32}
x_2	x_7	x_{12}	x_{17}	x_{22}	x_{27}	x_{32}	x_{33}
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
x_{533}	x_{538}	x_{543}	x_{548}	x_{553}	x_{558}	x_{563}	x_{564}




图 5 梯式下降训练过程示意图

Fig. 5 Schematic diagram of ladder descent training process



--->梯度填补

--->测试输出

图 6 梯式下降预测过程示意图

Fig. 6 Schematic diagram of ladder descent prediction process

2.3.5 Chaos-BPNN 径流预测模型预测结果

经计算 Chaos-BPNN 径流预测模型在黑河上游的预测精度为 91.66%,表明建立的 Chaos-BPNN 径流预测模型具有较好的预测效果。将 Chaos-BPNN 径流预测模型应用于正义峡水文站,预测 1954—2017 年的径流,以1997 年11 月至2017 年10 月的径流数据作为测试集,其余作为训练集,结果如图 7 所示。评价结果表明,预测结果的平均绝对百分比误差为 13.16%,模型精度为 86.84%,合格率为 55.83%,纳什效率系数为 0.898 3。




图 7 正义峡水文站径流的预测值与实测值对比

Fig. 7 Comparison between predicted and measured values of runoff in Zhengyixia Station

将 Chaos-BPNN 径流预测模型应用于莺落峡水文站 2023—2042 年的径流预测,结果见图 8。预测结果表明 2023—2042 年,黑河上游年径流量表现为平、丰交替的状态,径流最大值发生在 2031 年 7 月,为 3.91 亿 m³,月径流平均值为 1.58 亿 m³,与 1993—2023 年平均值 (1.47 亿 m³) 相比增加了 6.96%,与 Li 等^[4,10]的研究结论一致,说明该模型的构建及运算合理。




图 8 莺落峡水文站 2023—2042 年径流预测值

Fig. 8 Predicted values of runoff in Yingluoxia Station from 2023 to 2042

3 讨 论

3.1 重构后相空间列向量的水文学含义

- a. 重构后相空间列向量特征。径流序列重构后,相空间列向量为不同时段径流量序列。黑河上游流域研究时段径流重构后第 1、3、6、7 列分别与同时段的降水量、气温、水位和输沙量具有较高的相关性,所以可以认为重构后相空间的第 1、3、6、7 列向量代表了降水量、气温、水位和输沙量随时间的变化。
- b. 径流相关因素特征。径流的主要影响因素为气候和人类活动,其中气候因素包括降水、蒸发、气温等;人类活动体现为土地利用类型和植被覆盖率等。由于重构后相空间列向量为不同时间段的径流量序列,为了验证其是否具有明显的水文学特征,应选取随时间变化明显的影响因素与列向量进行相关性分析。气候因素易于表达为时间序列,而人类活动不易用时间序列来表达。黑河发源于祁连山北麓中段,季节性融雪和降水是径流的主要影响因素,

但限于资料的限制,未收集到雪线高程的资料;另外,气象因素中,蒸发和气温具有很强的相关性,所以只选取气温序列与相空间的列向量进行了相关性分析。黑河径流序列嵌入维数 $m=7$,即黑河径流的相关因素为 7 个;4 个影响因素(降水量、气温、水位和输沙量)与相空间列向量有很强的相关性。那么,推测剩下的那 3 列向量应该分别为雪线高程、土地利用类型和植被覆盖率等因素的综合体现。对不同径流,相空间列向量的水文学含义会有所不同,但都应该代表某一径流相关因素随时间的变化。不易用时间序列描述的径流相关因素(如土地利用类型)如何与相空间列向量进行对应分析,将在以后的研究中作进一步探讨。

3.2 Chaos-BPNN 径流预测模型与单一 BPNN 模型预测结果对比

选取 1990—2000 年的径流序列及其同时间段的降水量、输沙量、水位、气温的实测值驱动单一 BPNN 模型进行径流预测。利用 1990 年 1 月至 1995 年 12 月的数据进行 BPNN 网络结构模型的训练。对训练好的 BPNN 模型,利用 1996 年 1 月至 2000 年 12 月的数据对径流进行测试验证。将 Chaos-BPNN 模型和单一 BPNN 模型的预测结果与实测径流量进行对比,如图 9 所示。对 Chaos-BPNN 径流预测模型与单一 BPNN 径流预测模型的径流预测结果进行性能评价,结果显示 Chaos-BPNN 径流预测模型与单一 BPNN 模型都可以实现对径流较好的预测,平均绝对百分比误差分别为 8.34% 和 16.94%,模型精度分别为 91.66% 和 83.06%,合格率分别为 74.58% 和 65%,纳什效率系数分别为 0.9477 和 0.8287。但单一 BPNN 模型需要降水量、输沙量、水位和气温长序列的实测数据,而 Chaos-BPNN 径流预测模型仅需要径流序列数据即可。单一 BPNN 模型的预测精度低于 Chaos-BPNN 径流预测模型,原因在于建模过程中单一 BPNN 模型仅选择了 4 个径流的影响因素作为输入层进行训练,并




图 9 Chaos-BPNN 模型和 BPNN 模型径流预测值与实测值对比

Fig. 9 Comparison of runoff predicted by Chaos-BPNN model and BPNN model with measured runoff values

且这 4 个因素的取值都与时间有关;而 Chaos-BPNN 模型中重构的相空间代表了 7 个径流影响因素。

4 结 论

- a. 径流序列重构后相空间列向量具有明确的水文学含义。相空间的嵌入维数代表了径流相关因素的个数;相空间每一列元素与径流某一影响因素线性相关。对不同径流,相空间列向量的水文学含义会有所不同,但都代表了一个径流的影响因素。
- b. 构建的 Chaos-BPNN 径流预测模型仅需要径流序列数据就可进行预测,规避了径流影响因素难以确定和不易量化的难题。
- c. 对于应用区域黑河上游,重构后的相空间 7 个列向量分别反映了降水量、输沙量、水位、气温、雪线高程、植被覆盖率以及土地利用类型随时间的变化;构建的 Chaos-BPNN 径流预测模型在不同水文站的预测精度均在 86% 以上,高于单一 BPNN 模型的预测精度;Chaos-BPNN 径流预测模型的预测结果显示,2023—2042 年黑河上游月平均径流值与 1993—2023 年平均值相比将增加 6.96%。

参考文献:

[1] 张金萍,王宇昊. 郑州市降雨-径流关系不确定性分析[J]. 水资源保护,2021,37(6):1-6. (ZHANG Jinping, WANG Yuhao. Uncertainty analysis of rainfall-runoff relationship in Zhengzhou City [J]. Water Resources Protection,2021,37(6):1-6. (in Chinese))

[2] 李建林,王树威,王心义,等. 递归图理论在不同时间尺度下的径流混沌特征分析[J]. 应用基础与工程科学学报,2023,31(3):569-583. (LI Jianlin, WANG Shuwei, WANG Xinyi, et al. Analysis on runoff characteristics of recurrence plot theory under different time scales [J]. Journal of Basic Science and Engineering,2023,31(3):569-583. (in Chinese))

[3] 岳兆新,艾萍,熊传圣,等. 基于信息熵与改进极限学习机的中长期径流预测[J]. 水利水电科技进展,2021,41(4):7-14. (YUE Zhaoxin, AI Ping, XIONG Chuansheng, et al. Medium-long term runoff forecasting based on information entropy and improved extreme learning machine [J]. Advances in Science and Technology of Water Resources,2021,41(4):7-14. (in Chinese))

[4] LI Z L, LI Q J, WANG J, et al. Impacts of projected climate change on runoff in upper reach of Heihe River basin using climate elasticity method and GCMs [J]. Science of the Total Environment,2020,716:137072.

[5] 李镇洋,李国芳,高倩雨,等. 变化环境下嫩江富拉尔基站径流响应[J]. 水利水电科技进展,2022,42(2):

- 35-40. (LI Zhenyang, LI Guofang, GAO Qianyu, et al. Runoff response of Fulaerji station in Nenjiang River under changing environment [J]. Advances in Science and Technology of Water Resources, 2022, 42 (2): 35-40. (in Chinese))
- [6] 孙周亮,刘艳丽,张建云,等. 中长期径流预报研究进展与展望[J]. 水资源保护, 2023, 39 (2): 136-144. (SUN Zhouliang, LIU Yanli, ZHANG Jianyun, et al. Research progress and prospect of mid-long term runoff prediction [J]. Water Resources Protection, 2023, 39 (2): 136-144. (in Chinese))
- [7] 马盼盼,白涛,武连洲,等. 黄河源区河川径流短期预测的 ANFIS 模型[J]. 西北农林科技大学学报(自然科学版), 2018, 46 (6): 145-154. (MA Panpan, BAI Tao, WU Lianzhou, et al. Short-term runoff prediction by ANFIS model in source region of the Yellow River [J]. Journal of Northwest A & F University (Natural Science Edition), 2018, 46 (6): 145-154. (in Chinese))
- [8] 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. (ZHOU Jianzhong, PENG Tian. Chaotic dynamic characteristics and integrated prediction of runoff in the upper reaches of Yangtze River [J]. Journal of Changjiang River Scientific Research Institute, 2018, 35 (10): 1-9. (in Chinese))
- [9] 田烨,谭伟丽,王国庆,等. LSTM 变体模型在径流预测中的性能及其可解释性[J]. 水资源保护, 2023, 39 (3): 188-194. (TIAN Ye, TAN Weili, WANG Guoqing, et al. Performance of variant LSTM models in runoff prediction and their interpretability [J]. Water Resources Protection, 2023, 39 (3): 188-194. (in Chinese))
- [10] 陈子豪,李莹莹,李凯,等. 基于 M-K、小波和 R/S 方法的黑河上游来水预测[J]. 人民黄河, 2021, 43 (12): 29-34. (CHEN Zihao, LI Yingying, LI Kai, et al. Trend prediction of incoming water process in the upper reaches of Heihe River based on M-K, wavelet and R/S method [J]. Yellow River, 2021, 43 (12): 29-34. (in Chinese))
- [11] 于国荣,夏自强. 混沌时间序列支持向量机模型及其在径流预测中应用[J]. 水科学进展, 2008 (1): 116-122. (YU Guorong, XIA Ziqiang. Prediction model of chaotic time series based on support vector machine and its application to runoff [J]. Advances in Water Science, 2008 (1): 116-122. (in Chinese))
- [12] 荣艳淑,胡玉恒,冯瑞瑞,等. 广义相加模型在乌江夏季径流预报中的应用[J]. 河海大学学报(自然科学版), 2021, 49 (2): 121-126. (RONG Yanshu, HU Yuheng, FENG Ruirui, et al. Application of generalized additive model in summer runoff forecasting of Wujiang Basin [J]. Journal of Hohai University (Natural Sciences), 2021, 49 (2): 121-126. (in Chinese))
- [13] 江善虎,任明明,章二子,等. 基于非平稳 GEV 模型的黄河源区枯季径流演变特征分析[J]. 河海大学学报(自然科学版), 2023, 51 (2): 1-7, 63. (JIANG Shanhu, REN Mingming, ZHANG Erzi, et al. Study on evolution characteristics of dry season runoff using a non-stationary GEV model in source region of the Yellow River [J]. Journal of Hohai University (Natural Sciences), 2023, 51 (2): 1-7, 63. (in Chinese))
- [14] 康艳,程潇,陈沛如,等. 基于集成学习模型的非平稳月径流预报[J]. 水资源保护, 2023, 39 (2): 125-135, 179. (KANG Yan, CHENG Xiao, CHEN Peiru, et al. Non-stationary monthly runoff forecast based on ensemble learning model [J]. Water Resources Protection, 2023, 39 (2): 125-135, 179. (in Chinese))
- [15] 贾玉雪,张奇,曾冰茹,等. 湘江流域多源降水与气温产品组合的径流极值模拟精度评价[J]. 河海大学学报(自然科学版), 2023, 51 (2): 8-16, 163. (JIA Yuxue, ZHANG Qi, ZENG Bingru, et al. Accuracy evaluation of runoff extremum simulation for the product combination of multi-source precipitation and temperature in the Xiangjiang River Basin [J]. Journal of Hohai University (Natural Sciences), 2023, 51 (2): 8-16, 163. (in Chinese))
- [16] 李建林,高培强,王心义,等. 基于混沌-广义回归神经网络的矿井涌水量预测[J]. 煤炭科学技术, 2022, 50 (4): 149-155. (LI Jianlin, GAO Peiqiang, WANG Xinyi, et al. Prediction of mine water inflow based on chaos-generalized regression neural network [J]. Coal Science and Technology, 2022, 50 (4): 149-155. (in Chinese))
- [17] HONG M, WANG D, WANG Y, et al. Mid-and long-term runoff predictions by an improved phase-space reconstruction model [J]. Environmental Research, 2016, 148: 560-573.
- [18] HUANG F, YIN K, ZHANG G, et al. Landslide displacement prediction using discrete wavelet transform and extreme learning machine based on chaos theory [J]. Environmental Earth Sciences, 2016, 75 (20): 1-18.
- [19] KARUNASINGHA D S K, LIONG S Y. Enhancement of chaotic hydrological time series prediction with real-time noise reduction using extended Kalman filter [J]. Journal of Hydrology, 2018, 565: 737-746.
- [20] CAO L Y. Practical method for determining the minimum embedding dimension of a scalar time series [J]. Physica D: Nonlinear Phenomena, 1997, 110 (1/2): 43-50.

(下转第 148 页)

[37] BAHREMAND A, SMEDT F D. Distributed hydrological modeling and sensitivity analysis in Torysa Watershed, Slovakia[J]. Water Resources Management, 2008, 22 (3):393-408.

[38] JIANG Sanyuan. Hydrological water quality modelling of nested meso scale catchments [D]. Braunschweig : Technical University Carolo-Wilhelmina,2014.

[39] HAMILTON A, MOORE R. Quantifying uncertainty in streamflow records [J]. Canadian Water Resources Journal,2012,37(1):3-21.

[40] 向鑫,敖天其,肖钦太. 基于 SWAT 模型的小流域非点源污染负荷分布模拟研究[J]. 水电能源科学,2022,40

(6): 41-44. (XIANG Xin, AO Tianqi, XIAO Quintai. Simulation of non-point source pollution load distribution in small watershed based on SWAT model [J]. Water Resources and Power, 2022, 40 (6): 41-44. (in Chinese))

[41] 赵串串,冯倩,侯文涛,等. 基于 AnnAGNPS 模型的澜河流域非点源污染模拟研究[J]. 环境污染与防治, 2019, 41 (3): 317-322. (ZHAO Chuanchuan, FENG Qian,HOU Wentao,et al. Simulation of non-point source pollution based on AnnAGNPS model in Bahe River Basin [J]. Environmental Pollution & Control,2019 41 (3): 317-322). (in Chinese))

(收稿日期:2023 -08 -09 编辑:王芳)

(上接第 97 页)

[21] 王树威,李建林,崔延华,等. 混沌理论与 BPNN 耦合的径流中长期预测模型[J]. 水资源与水工程学报,2021, 32(3):73-79. (WANG Shuwei, LI Jianlin, CUI Yanhua, et al. Medium and long term runoff prediction model coupled with chaos theory and BPNN[J]. Journal of Water Resources and Water Engineering, 2021, 32 (3): 73-79. (in Chinese))

[22] 张相,丁鸣鸣,林杰,等. 水蚀作用下红壤丘陵区土壤特性的空间分异特征[J]. 南京林业大学学报(自然科学版), 2023, 47 (6): 77-84. (ZHANG Xiang, DING Mingming, LIN Jie, et al. Spatial differentiation of soil properties in hilly red soil region under water erosion[J]. Journal of Nanjing Forestry University (Natural Science Edition),2023,47(6): 77-84. (in Chinese))

[23] 滕文龙,丛炳虎,商云坤,等. 基于 MEA-BP 神经网络的

建筑能耗预测模型[J]. 吉林大学学报(工学版), 2021, 51 (5): 1857-1865. (TENG Wenlong, CONG Binghu, SHANG Yunkun, et al. Modeling of building energy consumption prediction based on MEA-BP neural network[J]. Journal of Jilin University(Engineering and Technology Edition), 2021, 51 (5): 1857-1865. (in Chinese))

[24] 连运涛,王昱,郑健,等. 黑河流域上游水沙输移趋势及其成因分析[J]. 干旱区资源与环境,2019,33(3): 98-104. (LIAN Yuntao, WANG Yu, ZHENG Jian, et al. The trend of runoff and sediment transport in the upper reaches of Heihe basin and its cause analysis[J]. Journal of Arid Land Resources and Environment, 2019, 33(3): 98-104. (in Chinese))

(收稿日期:2023 -08 -07 编辑:王芳)

(上接第 139 页)

[21] 李佳,谢文霞,姜智绘,等. 海绵城市地块汇水区颗粒污染物的传输[J]. 环境科学,2020,41(9):4113-4123. (LI Jia, XIE Wenxia, JIANG Zhihui, et al. Transition of particulate pollutant in the parcel-based catchment of sponge city [J]. Environmental Science, 2020, 41 (9): 4113-4123. (in Chinese))

[22] ALMAMOON A, JAHAN S, HE X, et al. First flush analysis using a rainfall simulator on a micro catchment in an arid climate [J]. Science of the Total Environment, Elsevier,2019,693:133552.

[23] 张香丽,赵志杰,秦华鹏,等. 常州市不同下垫面污染物冲刷特征[J]. 北京大学学报(自然科学版), 2018, 54 (3): 644-654. (ZHANG Xiangli, ZHAO Zhijie, QIN Huapeng, et al. Characteristics of pollutants flush on different types of underlying surface in Changzhou [J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2018,54(3):644-654. (in Chinese))

[24] HOSSAIN I, IMTEAZ M, GATO-TRINIDAD S, et al. Development of a catchment water quality model for continuous simulations of pollutants build-up and wash-off [J]. International Journal of Environmental and Ecological Engineering,2010,4(1):11-18.

(收稿日期:2023 -02 -09 编辑:王芳)

