

WPT – HPO – ELM 径流多步预报模型研究

许建伟¹, 崔东文²

(1. 云南省水利水电勘测设计研究院, 云南 昆明 650021; 2. 云南省文山州水务局, 云南 文山 663000)

摘要: 为提高径流时间序列多步预报精度, 建立了小波包变换(WPT) – 猎人猎物优化(HPO)算法 – 极限学习机(ELM)相融合的径流时间序列多步预报模型, 并应用于云南省南康河水文站月径流和日径流时间序列多步预报。引入 HPO 算法原理, 在不同维度条件下选取 6 个典型函数对 HPO 进行仿真验证; 利用 2 层 WPT 将径流时序数据分解为 4 个子序列分量, 达到降低径流序列数据复杂性和不平稳性的目的; 采用 HPO 优化 ELM 输入层权值和隐含层偏值, 建立 WPT – HPO – ELM 模型对实例月径流和日径流进行多步预报。结果表明: HPO 算法具有较好的寻优精度和全局搜索能力; WPT – HPO – ELM 模型对预见期为 1 ~ 3 个月的月径流具有理想的预报效果, 预报的平均绝对百分比误差 $\leq 2.43\%$, 合格率 $\geq 99.2\%$, 确定性系数 ≥ 0.999 ; 对预见期为 4 ~ 6 个月的月径流具有较好的预报效果, 预报的平均绝对百分比误差 $\leq 15.0\%$, 合格率 $\geq 73.3\%$, 确定性系数 ≥ 0.991 ; 当预见期 ≥ 7 个月时, 预报效果较差。对预见期为 1 ~ 3 d 的日径流具有理想的预报效果, 预报的平均绝对百分比误差 $\leq 1.23\%$, 合格率为 100%, 确定性系数 ≥ 0.999 ; 对预见期为 4 ~ 7 d 的日径流具有较好的预报效果, 预报的平均绝对百分比误差 $\leq 15.3\%$, 合格率 $\geq 73.0\%$, 确定性系数 ≥ 0.947 ; 当预见期 ≥ 8 d 时, 预报效果较差。WPT – HPO – ELM 模型能充分发挥 WPT、HPO 和 ELM 的优势, 表现出较高的预报精度和稳定性能, 预报误差随着预见期的增加而增大, 该模型及方法可为径流时间序列多步预报提供新途径。

关键词: 径流预报; 小波包变换; 猎人猎物优化算法; 极限学习机; 多步预报; 仿真测试

中图分类号: TV121⁺.4; P333

文献标识码: A

文章编号: 1672-643X(2022)06-0069-08

WPT – HPO – ELM multi-step runoff forecast model

XU Jianwei¹, CUI Dongwen²

(1. Yunnan Institute of Water & Hydropower Engineering Investigation, Design and Research, Kunming 650021, China;

2. Wenshan Prefecture Water Bureau of Yunnan Province, Wenshan 663000, China)

Abstract: To improve the multi-step forecast accuracy of runoff time series, a novel model was established combining wavelet packet transform (WPT), hunter – prey optimization (HPO) algorithm and extreme learning machine (ELM), which was then applied to the multi – step forecast of monthly and daily runoff time series of the Nankang River Hydrological Station in Yunnan Province. The principle of HPO algorithm is introduced, and 6 typical functions are selected to simulate and verify HPO under different dimensional conditions. Then the data of runoff time series is decomposed into 4 subsequence components using double-layer WPT, so as to reduce the complexity and instability of the runoff sequence data. The ELM input layer weights and hidden layer biases are optimized to establish a WPT – HPO – ELM model for the prediction of monthly and daily runoff in multiple steps. The results show that the HPO algorithm has good optimization accuracy and global search ability; the WPT – HPO – ELM model performs ideally at the forecast of 1 – 3 months monthly runoff, with the mean absolute percentage error $\leq 2.43\%$, the pass rate $\geq 99.2\%$, and the coefficient of certainty ≥ 0.999 ; it can also present a satisfactory result at the forecast of the monthly runoff with a forecast period of 4 – 6 months, with the mean absolute percent-

收稿日期: 2022-05-27; 修回日期: 2022-07-25

基金项目: 云南省创新团队建设专项(2018HC024); 云南重点研发计划项目(科技入滇专项); 国家澜湄合作基金项目(2018-1177-02)

作者简介: 许建伟(1984-), 男, 云南楚雄人, 高级工程师, 主要从事水利水电工程规划、建设征地移民安置等工作。

通讯作者: 崔东文(1978-), 男, 云南玉溪人, 教授级高级工程师, 主要从事水资源管理保护及智能算法在水文水资源系统中的应用研究等工作。

age error $\leq 15.0\%$, the pass rate $\geq 73.3\%$, and the coefficient of certainty ≥ 0.99 ; however, it performed poorly when the forecast period is ≥ 7 months. It has an ideal forecasting effect for the daily runoff with a forecast period of 1–3 d, with the mean absolute percentage error $\leq 1.23\%$, the pass rate = 100%, and the coefficient of certainty ≥ 0.999 ; it also performs satisfactorily when forecast period is 4–7 d, with the mean absolute percentage error $\leq 15.3\%$, the pass rate $\geq 73.0\%$, and the coefficient of certainty ≥ 0.94 ; whereas when the forecast period is ≥ 8 d, the forecast effect is poor. The WPT–HPO–ELM model can give full play to the advantages of WPT, HPO and ELM, showing high forecast accuracy and stability; however, the forecast error increases with the increase of the forecast period. The proposed model and method can provide a new approach for the multi-step forecasting of runoff time series.

Key words: runoff forecast; wavelet packet transform (WPT); hunter–prey optimization (HPO); extreme learning machine (ELM); multi-step forecast; simulation test

1 研究背景


径流时间序列预报,尤其是径流时间序列多步预报一直是水文预报研究的热点和难点。提高径流时间序列多步预报精度对于水文预报、水资源开发利用等具有重要意义。由于河川径流形成过程机理复杂,BP(back propagation)神经网络^[1]、支持向量机(support vector machines,SVM)^[2]、随机森林(random forest,RF)^[3]、长短时记忆神经网络(long short-term memory networks,LSTM)^[4]等传统预测方法难以获得满意的预报效果。目前,基于“分解–预测–集成”的智能预测混合方法被广泛应用于径流时间序列预测研究,如包苑村等^[5]基于变分模态分解(variational mode decomposition,VMD)方法和卷积–长短期记忆神经网络(convolutional neural network and long short-term memory networks,CNN–LSTM)建立 VMD–CNN–LSTM 模型,通过渭河流域张家山站和魏家堡站 1960–2005 年实测月径流数据对模型进行验证,结果表明 VMD–CNN–LSTM 模型具有更优的预测精度以及更小的误差;席东洁等^[6]基于经验模态分解(empirical mode decomposition,EMD)与 Elman 神经网络建立了 EMD–Elman 月径流组合预测模型,并将其应用于黄河上游唐乃亥水文站 1979–2009 年的月径流时间序列预测中;桑宇婷等^[7]建立了互补集合经验模态分解(complementary ensemble empirical mode decomposition,CEEMD)–BP 神经网络模型,并通过汾河月径流预测实例对模型进行了验证,证明了该组合模型预测效果较好;徐冬梅等^[8]基于完整集成经验模态分解(complete ensemble empirical mode decomposition with adaptive noise,CEEMDAN)和小波分解(wavelet decomposition,WD)组合的二次分解方法,提出 CEEMDAN–

WD–PSO–LSSVM 组合模型对洛河流域长水文站月径流进行了预测,结果表明该组合模型具有较高的预报精度;王丽丽等^[9]建立了奇异谱分析(singular spectrum analysis,SSA)–灰狼优化算法–支持向量机回归(support vector regression,SVR)模型,通过黑河正义峡月径流预测实例对模型进行了验证,结果表明该模型能够更深入地捕获水文径流的内在特性,具有更好的预测效果;孙望良等^[10]引入变分模态分解(VMD)、去趋势波动分析(detrended fluctuation analysis,DFA)和长短时记忆神经网络(LSTM)方法,提出 DFA–VMD–LSTM 日径流预报模型对三峡水库日径流进行了预报,取得较好预报效果;黄景光等^[11]基于小波分解方法和支持向量机(SVM)建立了组合日径流预报模型对宜昌站日径流进行预报,验证了该模型具有更好的预报稳定性;黄巧玲等^[12]将小波变换与支持向量机相结合,提出利用小波支持向量机回归模型对泾河流域张家山水文站日径流进行预报,结果显示该模型可有效模拟和预报日径流;任化准等^[13]融合小波分析方法、粒子群优化算法和支持向量机,构建了小波–粒子群–支持向量回归耦合日径流预报模型并对金沙江中游石鼓水文站日径流进行了预报,结果表明该模型在日径流预报中具有较强的适应性;张亚杰等^[14]建立了经验模态分解(EMD)–法务侦查(forensic-based investigation,FBI)算法–极限学习机(extreme learning machine,ELM)组合径流预测模型,并将该模型应用于云南省姑老河水文站年径流的预测,获得了较好的预测效果。

然而,上述模型或方法存在以下问题或不足:(1)大多数径流预报仅针对预见期为 1 个月或 1 d 的单步预报,而在实际应用中,单步预报往往无法满足月径流或日径流预报的实际需求,须根据需要依

据历史数据实现更多尺度的超前多步预报,即实现未来更为长远的径流时间点预报。(2)变分模态分解(VMD)和经验模态分解(EMD)等方法难以有效对原序列进行分解,如VMD的模态个数和惩罚因子难以确定,分解个数取值很大程度上影响了VMD的分解精度;EMD及其改进分解方法存在模态混叠、计算量大、复杂度高等问题。(3)预测模型中,Elman神经网络存在调节参数多、易陷入局部最优等缺点;SVR在处理大规模数据时预测精度不理想;LSTM网络预测性能较好,但存在计算量大、耗时长等不足。

为提高月径流或日径流时间序列多步预报精度,解决上述单步预测、分解方法和预测模型存在的问题,本文引入小波包变换(wavelet packet transform, WPT)、猎手猎物优化(hunter-prey optimization, HPO)算法和极限学习机(ELM),建立WPT-HPO-ELM组合径流时间序列多步预报模型,并通过云南省南康河水文站月径流和日径流时间序列多步



2 数据来源与研究方法

2.1 研究区概况与数据来源

南康河水文站位于云南省普洱市西盟县勐梭镇南康桥村,建于1981年,系怒江流域南康河干流控制站,控制径流面积902 km²,为云南省重要水文站和报讯站。南康河属云南省山区性水文站,河谷深切,洪水过程陡涨陡落,径流起伏变化十分剧烈。本文分别以南康河水文站1981年1月-2020年12月共480个月的月径流和2018年1月1日-2020年12月31日共1096 d的日径流为研究对象,月径流和日径流时序变化曲线见图1。由图1可以看出,南康河水文站最大月径流为161.0 m³/s,最小月径流为4.1 m³/s,比值为39.3;最大日径流为241.0 m³/s,最小日径流为4.3 m³/s,比值为55.7。可见南康河水文站月径流和日径流在时序上呈现出典型的多尺度、高度非线性特征,波动变化剧烈。




图1 南康河水文站逐月/逐日径流变化曲线

2.2 研究方法

2.2.1 小波包变换(WPT) 小波包变换(WPT)是一种特殊的小波变换(WT),相对于WT只解析信号低频部分,WPT还能对信号高频部分进行进一步分解,更适用于径流时间序列分解,已在水文时间序列预测研究中得到应用^[15-16]。

利用WPT对径流原始信号进行分解的公式^[17-19]为:

$$\begin{cases} d_l^{j,2n} = \sum_k h_{k-2l} d_k^{j-1,n} \\ d_l^{j,2n+1} = \sum_k g_{k-2l} d_k^{j-1,n} \end{cases} \quad (1)$$

重构算法为:

$$\bar{d}_l^{j,n} = \sum_k (\bar{h}_{l-2k} d_k^{j+1,2n} + \bar{g}_{l-2k} d_k^{j+1,2n+1}) \quad (2)$$

式中: $d_l^{j,2n}$ 、 $d_l^{j,2n+1}$ 为小波包系数; j 为尺度参数, $j \in \{i, i-1, \dots, 1\}$; l, k 为平移参数; n 为频率参数, $n = \{2^j - 1, 2^j - 2, \dots, 0\}$; h_{k-2l} 、 g_{k-2l} 分别为小波包

分解中的低通、高通滤波器组; $\bar{d}_l^{j,n}$ 为小波包重构后的小波包系数; $\bar{h}_{l-2k}$ 、 $\bar{g}_{l-2k}$ 分别为小波包重构的低通、高通滤波器组。

小波包变换的关键是小波基函数的选择,本文选择具有较好变换效果的 demy 小波基函数。

2.2.2 猎手猎物优化(HPO)算法 猎手猎物优化(HPO)算法是 Naruei 等^[20]于2021年提出的一种新型群体智能优化算法。该算法灵感来自于狮子、豹子、狼等“猎手”攻击远离群体的雄鹿、瞪羚等猎物的行为,“猎手”向远处的猎物调整自己的位置以获得最佳狩猎位置,而猎物则向安全的地方调整自己的位置以逃避攻击,猎物最安全位置即为待优化问题的最优解。HPO 算法设置参数少,寻优性能强,目前已在函数及工程优化中得到应用。

HPO 算法数学原理简述如下^[20]:

(1)初始化。HPO 算法利用公式(3)在搜索空间中随机生成初始种群个体位置,描述如下:

$$x_i = \text{rand}(1, d) \cdot (ub - lb) + lb \quad (3)$$

式中: x_i 为猎人或猎物位置; ub 、 lb 为搜索空间上、下限值; d 为问题维度。

(2) 猎人搜索策略。猎物通常成群结队, 猎人常选择远离群体的猎物作为狩猎目标。该策略类似于算法中的探索策略, 倾向于高度随机行为。猎人位置更新数学描述为:

$$x_{i,j}(t+1) = x_{i,j}(t) + 0.5[(2CZP_{pos(j)} - x_{i,j}(t)) + (2(1-C)Z\mu - x_{i,j}(t))] \quad (4)$$

式中: $x_{i,j}(t+1)$ 为第 i 个猎人第 j 维第 $t+1$ 次迭代位置; $x_{i,j}(t)$ 为第 i 个猎人第 j 维第 t 次迭代位置; $P_{pos(j)}$ 为猎物第 j 维位置; μ 为所有猎物平均位置, 描述为 $\mu = \frac{1}{n} \sum_{i=1}^n \vec{x}_i$, n 为种群规模; C 为探索和开发之间的平衡参数, 描述为 $C = 1 - 0.98t/T$, t 、 T 分别为当前迭代次数

和最大迭代次数; Z 为自适应参数。

(3) 猎物逃避策略。HPO 算法中, 猎物最安全位置即为全局最佳位置, 因为只有这样才能使猎物获得生存机会。猎物位置更新数学描述为:

$$x_{i,j}(t+1) = T_{pos(j)} + CZ\cos(2\pi R_1) \cdot (T_{pos(j)} - x_{i,j}(t)) \quad (5)$$

式中: T_{pos} 为全局最优位置; R_1 为 $[-1, 1]$ 范围内的随机数; 其他参数意义同上。

为验证 HPO 算法的寻优能力, 选取 Sphere 等 6 个典型测试函数在不同维度条件下进行仿真验证, 其寻优结果见表 1。基于 MATLAB 2018a M 语言实现 HPO 对 6 个典型测试函数的 20 次寻优, 利用 20 次寻优平均值对 HPO 寻优性能进行评估。设置猎人或猎物种群规模 $N = 50$, 最大迭代次数 $T = 100$, 其他采用算法默认值。

表 1 HPO 算法标准测试函数在不同维度条件下的寻优结果

函数	范围	最优值	10 维	30 维	50 维	100 维	300 维	500 维
Sphere/单峰函数	$[-100, 100]$	0	3.77×10^{-46}	3.03×10^{-43}	5.88×10^{-41}	5.46×10^{-38}	1.72×10^{-36}	1.94×10^{-35}
Schwefel 2.22/单峰函数	$[-10, 10]$	0	1.91×10^{-25}	1.48×10^{-22}	4.91×10^{-22}	3.14×10^{-21}	8.42×10^{-20}	1.19×10^{-19}
Schwefel 2.21/单峰函数	$[-100, 100]$	0	1.46×10^{-43}	1.83×10^{-38}	1.36×10^{-36}	8.72×10^{-33}	6.07×10^{-30}	1.08×10^{-26}
Griewank/多峰函数	$[-600, 600]$	0	0	0	0	0	0	0
Rastrigin/多峰函数	$[-5.12, 5.12]$	0	0	0	0	0	0	0
Ackley/多峰函数	$[-32, 32]$	8.88×10^{-16}	8.88×10^{-16}	8.88×10^{-16}	8.88×10^{-16}	8.88×10^{-16}	8.88×10^{-16}	8.88×10^{-16}

由表 1 可知, 对于单峰函数, HPO 算法在不同维度条件下的寻优精度均在 1.19×10^{-19} 以上; 对于多峰函数, HPO 算法在不同维度条件下寻优均获得了理论最优值, 表明具有较好的寻优精度和全局搜索能力。

2.2.3 极限学习机(ELM) ELM 是近年兴起的一种单隐层前馈神经网络(single-hidden layer feedforward networks, SLFNs)学习算法, 具有学习速度快、泛化性能好等优点。在实际应用中, 由于 ELM 随机给定的输入层权值和隐含层偏值易导致模型预测效果不佳, 目前用于 ELM 关键参数优化的群体智能算法有爬行动物搜索算法^[19]、灰狼优化算法^[21]、鲸鱼优化算法^[22]、黑猩猩优化算法^[23]等。

给定 M 个样本 $X_k = \{x_k, y_k\}$, $k = 1, 2, \dots, M$, 其中 x_k 为输入数据, y_k 为真实值, 设定 $f(\cdot)$ 为激活函数, 隐含层节点为 m 个, 则 ELM 输出可表示为^[14]:

$$o_j = \sum_{i=1}^m \lambda_i f(W_i \cdot X_k + b_i) \quad (k = 1, 2, \dots, M) \quad (6)$$

式中: o_j 为输出值; $W_i = \{w_{i1}, w_{i2}, \dots, w_{im}\}'$ 为第 i 个输入层节点与隐含层节点的连接权值; b_i 为第 i 个输入层节点和隐含层节点的偏值; λ_i 为第 i 个隐含层节点与输出层节点的连接权值。

2.2.4 模型建立的流程

步骤 1: 为兼顾模型预报精度和计算规模, 本文基于 demy 小波基函数, 采用 2 层 WPT 对南康河水文站 1981 年 1 月 - 2020 年 12 月月径流、2018 年 1 月 1 日 - 2020 年 12 月 31 日日径流时序数据进行 2 层小波包分解, 即将各径流时序数据分解为 4 个子序列分量 $[2, 1]$ 、 $[2, 2]$ 、 $[2, 3]$ 、 $[2, 4]$, 见图 2。由图 2 可以看出, 不同的子序列分量反映了径流的不同变化特征。直观上, $[2, 4]$ 分量的频率最低, 周期性明显, 反映出径流数据的整体变化趋势; $[2, 3]$ 分量波动性较为平缓, 且频率相对较低, 具有一定的周期性, 反映出径流数据的周期性规律; $[2, 2]$ 和 $[2, 1]$ 分量波动激烈且频率较大, 周期性不明显, 反映出径流数据的随机性。




图2 南康河水文站径流 WPT 分解 3D 效果图

步骤2:为便于各分量预测结果重构,在延迟时间为1的条件下,采用Cao方法确定各子序列分量 $[2,1] \sim [2,4]$ 的嵌入维数 k ,并利用前 k 月(日)的径流分量来预测当月(日)(即1个月或1d)、第2月(日)(即2个月或2d)、第3月(日)(即3个月或3d)……的径流分量。预测模型的输入、输出表示为:

$$X_{\text{input}} = \begin{bmatrix} X_1 & X_2 & \cdots & X_k \\ X_2 & X_3 & \cdots & X_{k+1} \\ \vdots & \vdots & \cdots & \vdots \\ X_{u-k} & X_{u-k+1} & \cdots & X_{u-1} \end{bmatrix}, Y_{\text{output}} = \begin{bmatrix} X_{k+c} \\ X_{k+c+1} \\ \vdots \\ X_{u+c-1} \end{bmatrix} \quad (7)$$

式中: X_{input} 和 Y_{output} 分别为月(日)径流预测输入值和输出值, m^3/s ; c 为超前步数; u 为月(日)径流序列长度; k 为嵌入维数或滞后数。

利用Cao方法确定月径流子序列分量 $[2,1] \sim [2,4]$ 的 k 值分别为13、16、24、20;确定日径流子序列分量 $[2,1] \sim [2,4]$ 的 k 值分别为13、12、24、15。选取2011年1月-2020年12月月径流(120个月)、2020年1月1日-2020年12月31日日径流(366d)作为预测样本,其余样本作为训练样本(参见图1)。

步骤3:利用训练样本均方误差(mean square error, MSE)构建HPO优化ELM输入层权值和隐含层偏值的适应度函数。

$$\begin{cases} \min f(W, b) = \frac{1}{l} \sum_{i=1}^l (Q'_i - Q_i)^2 \\ \text{s. t } W \in [W_{\min}, W_{\max}], b \in [b_{\min}, b_{\max}] \end{cases} \quad (8)$$

式中: Q'_i 为第 i 个径流实测值; Q_i 为第 i 个径流预报值; l 为训练样本数; 其他参数意义同上。

步骤4:设置HPO算法最大迭代次数 $T = 100$,种群规模 $N = 50$,其他采用算法默认值;ELM网络激活函数选择sigmoid,隐含层节点数为 $2k$ (k 为嵌入维数),输入层权值和隐含层偏值搜索空间设置为 $[-1, 1]$,径流时序数据采用 $[-1, 1]$ 进行归一化处理。

步骤5:基于公式(3)在搜索空间随机初始化猎人或猎物个体位置 x_i ;计算猎人或猎物个体适应度值,确定并保存最佳猎物位置 T_{pos} 。令 $t = 1$ 。

步骤6:在 $[0, 1]$ 范围内生成随机数 R_2 ,若 $R_2 < 0.2$,则基于公式(4)执行猎人搜索策略,更新猎人位置;否则基于公式(5)执行猎物逃避策略,更新猎物位置。

步骤7:基于猎人或猎物新位置计算适应度值,比较并保存当前最佳猎物位置 T_{pos} 。

步骤8:令 $t = t + 1$,判断是否满足终止条件,若不满足则转至步骤6。

步骤9:输出最佳猎物位置 T_{pos} , T_{pos} 即为ELM输入层权值和隐含层偏值最佳矩阵。利用最优ELM输入层权值和隐含层偏值矩阵建立HPO-ELM模型进行预测。

步骤10:利用平均绝对百分比误差(mean absolute percentage error, $MAPE$)、平均绝对误差(mean absolute error, MAE)、确定性系数(C_d)和合格率(P_r)对预报模型进行评估,该4个参数的计算方法见公式(9)~(12)。

$$MAPE = \frac{1}{R} \sum_{u=1}^R \left| \frac{Q'_u - Q_u}{Q'_u} \right| \times 100\% \quad (9)$$

$$MAE = \frac{1}{R} \sum_{u=1}^R |Q'_u - Q_u| \quad (10)$$

$$C_d = 1 - \frac{\sum_{u=1}^R (Q'_u - Q_u)^2}{\sum_{u=1}^R (Q'_u - Q''_u)^2} \quad (11)$$

$$P_r = \frac{p}{R} \times 100\% \quad (12)$$

式中: Q'_u 为第 u 个径流实测值, m^3/s ; Q_u 为第 u 个径流预报值, m^3/s ; R 为径流预报样本长度; Q''_u 为实测径流的平均值, m^3/s ; p 为绝对百分比误差 $\leq 20\%$ 的样本数量。

步骤11:当月径流或日径流预报值的平均绝对百分比误差 $MAPE > 30\%$ 时,停止WPT-HPO-

ELM 模型多步预报。

3 结果与分析

利用所构建的 WPT - HPO - ELM 模型对南康

河水文站月径流和日径流进行训练及多步预报,不同预报月数、日数的月径流、日径流多步预报结果误差对比分别见图 3、4,不同预报期的预报相对误差效果见图 5。




图3 不同预报月数月径流多步预报结果误差对比




图4 不同预报日数日径流多步预报结果误差对比




图5 不同预报期的月径流和日径流多步预报相对误差效果

分析图 3 ~ 5 可以得出:

(1) WPT - HPO - ELM 模型对预报期为 1 ~ 3 个月的月径流具有理想的预报效果, 预报结果的 $MAPE$ 、 MAE 、 C_d 、 P_r 分别在 0.33% ~ 2.43%、0.047 ~ 0.352 m³/s、1.000 0 ~ 0.999 7、100% ~ 99.2% 之间; 对预报期为 4 ~ 6 个月的月径流具有较

好的预报效果, 预报结果的 $MAPE$ 、 MAE 、 C_d 、 P_r 分别在 5.55% ~ 15.0%、0.796 ~ 2.107 m³/s、0.998 6 ~ 0.990 7、95.8% ~ 73.3% 之间; 当预报期为 7 个月时, 预报结果的 $MAPE$ 、 MAE 、 C_d 、 P_r 分别为 31.2%、4.688 m³/s、0.9475、57.5%, 预报效果较差, 已不能满足月径流预报精度要求。

(2) WPT-HPO-ELM 模型对预报期为 1~3 d 的日径流具有理想的预报效果,预报结果的 $MAPE$ 、 MAE 、 C_d 分别为 0.20%~1.23%、0.070~0.377 m^3/s 、1.000 0~0.999 6 之间, P_r 均为 100%;对预报期为 4~7 d 的日径流具有较好的预报效果,预报结果的 $MAPE$ 、 MAE 、 C_d 、 P_r 分别在 3.03%~15.30%、0.851~4.166 m^3/s 、0.997 9~0.947 0、99.5%~73.0% 之间;当预见期为 8~10 d 时,预报的 $MAPE \geq 21.1\%$ 、 $MAE \geq 6.236 m^3/s$ 、 $C_d \leq 0.898 3$ 、 $P_r \leq 58.2\%$,预报效果相对较差,已不能满足日径流预报精度要求。

(3) 图 3、4 表明, WPT-HPO-ELM 模型对月径流和日径流时间序列预报误差随着预报期的增加而增加。在月径流预报期为 1~6 个月、日径流预报期为 1~7 d 范围内, WPT-HPO-ELM 模型预报结果可靠性较强、精度较高,将其用于月径流或日径流时间序列多步预报是可行的。

(4) 图 5 表明, WPT-HPO-ELM 模型对南康河水文站预报期为 1~3 个月的月径流预报中, 86.7% 样本的相对误差在 -5%~5% 范围内波动;对预报期为 1~3 d 的日径流预报中, 97.5% 样本的相对误差在 -5%~5% 范围内波动,具有更小的预报误差和更高的预报精度。

4 讨论

时间序列预测方法较多,根据预测模型的不同可以分为传统预测方法、智能预测方法和智能混合预测方法 3 类。传统预测方法主要利用数学统计方法研究历史数据走势规律并建立回归模型来拟合未来数据,从而达到预测的目的,但对于非平稳时间序列的预测精度较差;智能预测方法主要融合优化算法与机器学习机,建立组合模型达到预测的目的,但对于高度非线性、多尺度时间序列难以获得满意的预测效果;智能混合预测方法主要通过多种算法、方法和模型相互组合优化,充分利用各算法的优点,达到提高模型预测精度的目的,如本文建立的 WPT-HPO-ELM 模型,其在实例月径流和日径流时间序列预报中获得较好的预报效果,主要得益于 WPT 方法、HPO 算法、ELM 网络三者的有机融合,模型及方法可在类似水文预报研究中进一步发展与推广。今后可在以下方面作进一步探索:

(1) 将 WPT 与其他变分模态分解、小波变换、奇异谱分析、经验模态分解、改进经验模态分解等方法的分解效果作对比验证。

(2) WPT 应用的关键是小波基函数的选择,目前小波基函数有 harr 小波、coifN 小波、dbN 小波、demy 小波、cgua 小波、mexh 小波、sym8 小波等。本文选择 demy 小波基函数,而基于其他小波基函数的 WPT 分解效果有待验证。

(3) 虽然 HPO 算法在标准函数与 ELM 输入层权值和隐含层偏值的优化中具有较好的应用效果,但与传统粒子群优化算法、遗传算法等的优化效果的对比有待验证。

(4) ELM 输入层权值、隐含层偏值与隐含层神经元节点数对 ELM 模型性能影响较大,本文利用 HPO 算法优化 ELM 输入层权值和隐含层偏值,但 ELM 隐含层神经元节点数的选取对月径流和日径流时间序列预报精度的影响有待进一步研究。

5 结论

径流时间序列多步预报是水文预报研究领域的热点和难点。为提高径流时间序列多步预报精度,基于 WPT 方法、HPO 算法和 ELM 网络,建立 WPT-HPO-ELM 径流时间序列多步预报模型,通过云南省南康河水文站月径流和日径流时间序列多步预报实例对 WPT-HPO-ELM 模型进行检验,得到如下结论:

(1) 在不同维数条件下, HPO 算法对 Sphere 等 6 个标准函数均具有较好的寻优精度,尤其是针对高维问题优化, HPO 算法表现出较好的寻优效果,将 HPO 用于 ELM 输入层权值和隐含层偏值优化是可行的。

(2) WPT-HPO-ELM 模型对预见期为 1~3 个月的月径流和 1~3 d 的日径流具有理想的预报效果;对预见期为 4~6 个月的月径流和 4~7 d 的日径流具有较好的预报效果;当预见期为 7 个月或 ≥ 8 d 时,预报效果较差,已不能满足月径流或日径流预报精度要求。

(3) 在月径流预报期为 1~6 个月、日径流预报期为 1~7 d 范围内, WPT-HPO-ELM 模型预报结果可靠性较强,实测月径流或日径流值相近,将 WPT-HPO-ELM 模型用于月径流或日径流时间序列多步预报是可行的,该模型及方法可为实现径流时间序列精准预报提供新的途径。

(4) WPT-HPO-ELM 模型能充分发挥 WPT 方法、HPO 算法和 ELM 网络的优势,表现出较好的多步预报精度和稳定性能,模型预报误差随着预见期的增加而增加。

参考文献:

- [1] 赵文刚, 刘晓群, 宋 雯, 等. 基于 PSO - BP 神经网络的西洞庭湖南咀站径流预测[J]. 人民长江, 2019, 50(3): 124 - 130.
- [2] 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.
- [3] 崔东文, 郭 荣. 基于随机漂移粒子群优化的随机森林预测模型及水文应用实例[J]. 三峡大学学报(自然科学版), 2019, 41(2): 6 - 10.
- [4] 胡顺强, 崔东文. 基于海洋捕食者算法优化的长短期记忆神经网络径流预测[J]. 中国农村水利水电, 2021(2): 78 - 82 + 90.
- [5] 包苑村, 解建仓, 罗军刚. 基于 VMD - CNN - LSTM 模型的渭河流域月径流预测[J]. 西安理工大学学报, 2021, 37(1): 1 - 8.
- [6] 席东洁, 赵雪花, 张永波, 等. 基于经验模态分解与 Elman 神经网络的月径流预测[J]. 中国农村水利水电, 2017(7): 112 - 115.
- [7] 桑宇婷, 赵雪花, 祝雪萍, 等. 基于 CEEMD - BP 模型的汾河上游月径流预测[J]. 人民黄河, 2019, 41(8): 1 - 5.
- [8] 徐冬梅, 庄文涛, 王文川. 基于 CEEMDAN - WD - PSO - LSSVM 模型的月径流预测研究[J]. 中国农村水利水电, 2021(8): 54 - 58 + 66.
- [9] 王丽丽, 李 新, 冉有华, 等. 基于奇异谱分析 - 灰狼优化 - 支持向量回归混合模型的黑河正义峡月径流预测[J]. 遥感技术与应用, 2020, 35(2): 355 - 364.
- [10] 孙望良, 周建中, 彭利鸿, 等. DFA_VMD_LSTM 组合日径流预测模型研究[J]. 水电能源科学, 2021, 39(3): 12 - 15.
- [11] 黄景光, 吴 巍, 程璐瑶, 等. 基于小波支持向量机特征分类的日径流组合预测——以宜昌三峡水库为例[J]. 中国农村水利水电, 2018(6): 33 - 39.
- [12] 黄巧玲, 粟晓玲, 杨家田. 基于小波分解的日径流支持向量机回归预测模型[J]. 西北农林科技大学学报(自然科学版), 2016, 44(4): 211 - 217.
- [13] 任化准, 陈 琼, 何有良, 等. WPSO - SVR 耦合日径流预测模型研究及应用[J]. 人民长江, 2017, 48(10): 40 - 43.
- [14] 张亚杰, 崔东文. 基于 EMD - FBI - ELM 模型的径流预测研究[J]. 人民珠江, 2022, 43(6): 94 - 100 + 107.
- [15] 徐冬梅, 张一多, 王文川. 基于小波包分解的 LS - SVM - ARIMA 组合降水预测[J]. 南水北调与水利科技(中英文), 2020, 18(6): 71 - 77.
- [16] 杨琼波, 崔东文. 基于小波包分解的 AIS - GMDH 月径流时间序列预测研究[J]. 水力发电, 2022, 48(6): 45 - 51.
- [17] 朱刘柱, 王绪利, 马 静, 等. 基于小波包分解与循环神经网络的综合能源系统短期负荷预测[J]. 电力建设, 2020, 41(12): 135 - 142.
- [18] 叶瑞丽, 郭志忠, 刘瑞叶, 等. 基于小波包分解和改进 Elman 神经网络的风电场风速和风电功率预测[J]. 电工技术学报, 2017, 32(21): 103 - 111.
- [19] 李新华, 崔东文. 基于 WPD - RSA - ELM 模型的水文时间序列多步预测[J/OL]. 水利水电技术(中英文). (2022-05-05) [2022-07-22]. <http://kns.cnki.net/kcms/detail/10.1746.TV.20220505.1017.004.html>.
- [20] NARUEI I, KEYNIA F, MOLAHOSSEINI A S. Hunter - prey optimization: Algorithm and applications[J]. Soft Computing, 2021, 26: 1279 - 1314.
- [21] 姚 芳, 姜 涛, 刘明宇, 等. 基于 GWO - ELM 的逆变器开路故障诊断[J]. 电源学报, 2020, 18(1): 45 - 53.
- [22] 王珂珂, 牛东晓, 甄 皓, 等. 基于 WOA - ELM 模型的中国碳排放预测研究[J]. 生态经济, 2020, 36(8): 20 - 27.
- [23] 程国森, 崔东文. 黑猩猩优化算法 - 极限学习机模型在富水性分级判定中的应用[J]. 人民黄河, 2021, 43(7): 62 - 66 + 103.
- [29] GIBSON J J, EDWARDS T W D, BURSEY G G, et al. Estimating evaporation using stable isotopes: Quantitative results and sensitivity analysis for two catchments in Northern Canada[J]. Hydrology Research, 1993, 24(2-3): 79 - 94.
- [30] KONG Yanlong, WANG Ke, LI Jie, et al. Stable isotopes of precipitation in China: A consideration of moisture sources[J]. Water, 2019, 11(6): 1239.
- [31] 代述勇, 雷加强, 赵景峰, 等. 策勒河出山径流特征及其趋势[J]. 干旱区地理, 2009, 32(2): 204 - 210.
- [32] HAN Yongxiang, FANG Xiaomin, SONG Lianchun, et al. A study of atmospheric circulation and dust storm causes of formation in the Tarim Basin—The restructured wind field by shapes of dune and observed prevailing wind[J]. Chinese Journal of Atmospheric Sciences, 2005, 29(4): 627 - 635.
- [33] CHEN Haiyan, CHEN Yaning, LI Weihong, et al. Identifying evaporation fractionation and streamflow components based on stable isotopes in the Kaidu River Basin with mountain - oasis system in north-west China[J]. Hydrological Processes, 2018, 32(15): 2423 - 2434.
- [34] 钱剑平, 赵建平, 桂东伟, 等. 策勒绿洲生态与灌溉用水对地下水埋深的影响[J]. 水土保持通报, 2018, 38(1): 96 - 102.
- [35] 刘 毅. 塔里木盆地南缘绿洲灌区地表水与地下水联合利用研究[D]. 乌鲁木齐: 新疆大学, 2019.
- [36] YIN Changjun, LIU Yunfei, GUI Dongwei, et al. A Study on evaporation calculations of agricultural reservoirs in hyper-arid areas[J]. Agriculture, 2022, 12(5): 612.
- [37] 韩兴胜. 新疆策勒县水资源现状及对策探析[J]. 地下水, 2017, 39(6): 184 - 185 + 194.
- [38] 陆 婷. 南北疆典型小流域遥感蒸散发及生态耗水对比研究[D]. 乌鲁木齐: 新疆大学, 2018.

(上接第 68 页)