

DOI: 10.19797/j.cnki.1000-0852.20210314

WPD-COA-ELM模型在汛期月降水量时间 序列预测中的应用研究

杨琼波¹, 崔东文^{1,2}

(1.云南省水文水资源局 红河分局,云南 红河 661100; 2.云南省文山州水务局,云南 文山 663000)

摘要:针对月降水量时间序列多尺度非平稳性特点,提出小波包分解(WPD)-白骨顶鸟优化算法(COA)-极限学习机(ELM)相融合的降水量预测模型。首先,利用WPD将非平稳月降水量时间序列分解为若干子序列分量;然后在不同维度条件下利用6个典型函数对COA进行仿真测试;利用COA优化ELM输入层权值和隐含层偏值,对每一个子序列分量分别建立COA-ELM模型进行预测,将预测结果叠加重构后即最终预测结果;最后,以云南省龙潭站汛期和主汛期月降水量数据为例进行实验,并与WPD-COA-BP、WPD-ELM、WPD-BP预测模型进行比较。结果表明:COA在不同维度条件下均具有较好的寻优精度和全局搜索能力。WPD-COA-ELM模型对实例汛期、主汛期月降水量时间序列预测的平均绝对百分比误差分别为3.91%、3.59%,预测精度优于WPD-COA-BP模型,远优于WPD-ELM、WPD-BP模型。WPD能科学降低月降水时间序列数据的复杂性,提高预测效果;COA能有效优化ELM输入层权值和隐含层偏值,提高ELM网络性能。

关键词:降水量预测;小波包分解;白骨顶鸟优化算法;极限学习机;仿真测试

中图分类号:P457.6

文献标识码:A

文章编号:1000-0852(2023)01-0017-07

0 引言

降水量预测是水资源合理开发利用的重要基础,同时是缓解区域水资源供需矛盾、提高防洪抗旱应急能力、保障区域水生态安全的重要支撑。长期以来,国内外学者对如何提高降水量预测精度进行了有益探索,主要预测方法有成因预测与统计分析^[1]。然而,由于降水受地理位置、地形条件、大气环流、人类活动等诸多因素影响,往往表现出较强的非线性、非平稳性和多尺度等特征^[2],传统成因预测方法难以获得理想的预测效果。近年来,人工智能方法在降水量预测研究中得到广泛应用,如人工神经网络^[2-4]、支持向量回归机(SVM)^[5-6]、随机森林(RF)^[7]、长短期记忆网络(LSTM)^[8]等均被成功地应用于降水量预测中;众多时

间序列处理方法也在降水量时间序列数据处理中得到应用,如总体经验模态分解(EEMD)^[9]、互补集合经验模态分解(CEEMD)^[10]、小波包分解(WPD)^[9]、奇异谱分解(SSA)^[10]等在分解复杂降水量时间序列中发挥重要作用。

结合月降水量时间序列多尺度非平稳性特点,为进一步提高月降水量时间序列预测精度,本研究提出小波包分解(WPD)-白骨顶鸟优化算法(COA)-极限学习机(ELM)月降水量时间序列融合预测模型。

1 研究方法

利用WPD将降水量时间序列数据分解为若干子序列分量,利用白骨顶鸟优化算法COA优化ELM输入

收稿日期:2021-08-03

网络首发地址:https://kns.cnki.net/kcms/detail/11.1814.p.20221212.1748.001.html

作者简介:杨琼波(1977—),女,云南石屏人,本科,高级工程师,主要从事水文水资源分析研究和水资源管理保护方面的工作。

E-mail:yqb2021edw@163.com

通信作者: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方面的工作。

E-mail:cdwgr@163.com

网络首发日期:2022-12-13

层权值和隐含层偏置,针对每一个子序列分量分别建立 COA-ELM 模型进行预测,将预测结果叠加重构后即最终预测结果,并与 WPD-ELM 模型及基于 BP 神经网络建立的 WPD-COA-BP、WPD-BP 模型作对比分析。

1.1 小波包分解(WPD)

WPD 源于小波分解,它在分解信号低频子集同时,对高频子集继续分解,具有数学释意明确、使用简洁、能够自行设定分解层数和分解使用的小波函数等优点,已在降水量时间序列预测研究中得到应用^[9]。理论上信号被小波包分解为 3 层就能够提取信号中的有效信息,逼近任意非线性函数^[11-12]。连续小波转换数学描述见式(1)。

$$CWT(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

式中: $x(t)$ 为原始信号; ψ^* 为母小波函数; a 为比例因子; b 为转换参数; t 为原始信号对应时间点。

1.2 白骨顶鸟优化算法(COA)

COA 是 Iraj Naruei 等人于 2021 年受白骨顶鸟水上觅食行为启发而提出的一种新型元启发式优化算法^[13],具有实现简单、寻优效果好等优点。

1.2.1 COA 算法数学描述

COA 主要通过模拟白骨顶鸟水上随机移动、链式运动、领导者位置调整和更新达到求解问题的目的^[13]。COA 数学描述如下:

(1)初始化。COA 利用式(2)对白骨顶鸟种群进行初始化:

$$CootPos(i) = rand(1,d) \times (ub - lb) + lb \quad (2)$$

式中: $CootPos(i)$ 为白骨顶鸟位置; d 为问题维度; ub 、 lb 为搜索空间上、下限。

(2)随机移动。为实现这种移动,COA 在搜索空间中随机确定一位置,并使白骨顶鸟向这个随机位置移动。白骨顶鸟的这种移动有效探索了搜索空间的不同区域,若算法陷入局部极值,则这种移动将克服算法逃逸局部最优。白骨顶鸟利用式(3)更新位置:

$$CootPos(i) = CootPos(i) + A \times R_2 \times (Q - CootPos(i)) \quad (3)$$

式中: R_2 为 $[0,1]$ 范围内的随机数; A 为随机移动控制参数, $A = 1 - L/Iter$, L 、 $Iter$ 分别为当前迭代次数和最大迭代次数; Q 为搜索空间中的随机位置, $Q = rand(1,d) \times (ub - lb) + lb$ 。

(3)链式运动。COA 中,两只白骨顶鸟的平均位置可用于实现链式运动。COA 利用式(4)实现链式运动及白骨顶鸟的位置更新:

$$CootPos(i) = 0.5 \times (CootPos(i-1)) + CootPos(i) \quad (4)$$

式中: $CootPos(i-1)$ 为第二只白骨顶鸟位置

(4)领导者位置调整。COA 将组群中领头的白骨顶鸟定义为领导者,其他白骨顶鸟根据领导者平均位置调整自己的位置并向他们移动。COA 利用式(5)来更新其他白骨顶鸟的位置。

$$CootPos(i) = LeaderPos(k) + 2 \times R_1 \times \cos(2R\pi) \times (LeaderPos(k) - CootPos(i)) \quad (5)$$

式中: $LeaderPos(k)$ 为选定的领导者位置; R_1 为 $[0,1]$ 范围内的随机数; R 为 $[-1,1]$ 范围内的随机数。

(5)领导者位置更新。白骨顶鸟群始终朝向一个目标(最佳区域)移动,领导者同样需要朝该目标更新他们的位置。COA 利用式(6)更新领导者位置:

$$LeaderPos(i) = \left\{ \begin{aligned} & [B \times R_3 \times \cos(2R\pi) \times (gBest - LeaderPos(i)) + gBest, R_4 < 0.5] \\ & [B \times R_3 \times \cos(2R\pi) \times (gBest - LeaderPos(i)) - gBest, R_4 \geq 0.5] \end{aligned} \right\} \quad (6)$$

式中: $gBest$ 为找到的最佳位置; R_3 、 R_4 为 $[0,1]$ 范围内的随机数; B 为领导者移动控制参数, $B = 2 - L/Iter$ 。

1.2.2 COA 仿真验证

选取 Sphere 等 6 个单、多峰目标函数在不同维度条件下对 COA 进行仿真测试。采用 20 次寻优平均值对 COA 的寻优性能进行评估,见表 1。设置白骨顶鸟种群规模 $N=100$,最大迭代次数 $Iter = 3000$,领导者百分比 $N_l=10\%$,其他采用算法默认值。

对于单峰函数,COA 在不同维度条件下 20 次寻优均值均在 $1.41E-85$ 以上,具有较好的寻优精度;对于多峰函数 Griewank、Rastrigin,COA 在不同维度条件下 20 次寻优均获得了理论最优值 0;对于连续旋转不可分多峰函数 Ackley,COA 在不同维度条件下 20 次寻优均值在 $1.22E-14$ 以上,具有较好的全局搜索能力。

可见,对于上述 6 个测评函数,COA 在不同维条件下均具有较好的寻优精度和全局搜索能力,其寻优精度基本不受维度的影响。

1.3 极限学习机(ELM)

ELM 是近年兴起的一种隐层前馈神经网络(SLF-Ns)学习算法,具有学习速度快、泛化性能好、调节参

表1 函数优化对比结果

Table1 Function optimization comparison results

函数	取值范围	理论最优值	维度					
			10维	30维	50维	100维	300维	500维
Sphere/单峰函数	[-100,100]	0	3.16E-197	5.77E-173	6.64E-167	1.67E-165	1.64E-98	9.00E-93
Schwefel2.22/单峰函数	[-10,10]	0	2.57E-91	1.92E-89	6.06E-91	5.60E-95	2.27E-93	1.41E-85
Schwefel12/单峰函数	[-100,100]	0	3.40E-190	1.78E-194	2.77E-188	1.01E-157	3.23E-171	3.69E-215
Griewank/多峰函数	[-600,600]	0	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Rastrigin/多峰函数	[-5.12,5.12]	0	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
Ackley/多峰函数	[-600,600]	0	9.41E-15	3.02E-15	1.22E-14	2.31E-15	3.731E-15	1.01E-14

数少等优点^[14-15]。在实际应用中,由于ELM随机给定的输入层权值和隐含层偏置易导致模型预测效果不佳,目前灰狼优化(GWO)算法^[14]、鲸鱼优化算法(WOA)^[15]、黑猩猩优化算法(ChOA)^[16]等新型群体智能仿生算法尝试用于ELM输入层权值和隐含层偏置优化,并取得较好的优化效果。

给定 M 个样本 $X_k = \{x_k, y_k\}, k = 1, 2, L, M$,其中 x_k 为输入数据, y_k 为真实值, $f(\cdot)$ 为激活函数,隐层节点为 m 个,ELM输出可表示为^[16-18]

$$o_j = \sum_{i=1}^m \lambda_i f(W_i \cdot X_k + b_i), k = 1, 2, \dots, M \quad (7)$$

式中: o_j 为输出值; $W_i = \{w_{i1}, w_{i2}, L, w_{im}\}$ 为输入层节点与第 i 个隐含层节点的连接权值; b_i 为第 i 个输入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节点的连接权值。

1.4 WPD-COA-ELM建模流程

WPD-COA-ELM建模步骤如下,流程见图1。

步骤一:利用WPD将实例月降水量时间序列分解为8子序列分量[3,0]—[3,7],见图2。采用自相关函数法(AFM)确定各子序列分量的输入、输出向量,划分训练样本和预测样本。

步骤二:针对每一个子序列分量,利用训练样本均方误差构建目标函数:

$$\min(w, b) = \frac{1}{l} \sum_{i=1}^l (\hat{Y}_i - Y_i)^2 \quad (8)$$

s.t. $w \in [w_{\min}, w_{\max}], b \in [b_{\min}, b_{\max}]$

式中: \hat{Y}_i 为第 i 个月降水量实测值; Y_i 为第 i 个训练样本预测值; l 为训练样本数; w 为ELM输入层权值; b 为隐含层偏值。

步骤三:设置种群规模 N ,最大迭代次数 $Iter$,领导者百分比 N_l ,随机初始化白骨顶鸟种群位置 $CootPos(i)$,随机选择白骨顶鸟领导者;令当前迭代次数 $L=1$ 。

步骤四:计算所有白骨顶鸟适应度值,比较并确定最佳白骨顶鸟位置 $gBest$ 。

步骤五:分别利用式(3)~(6)执行随机移动、链式运动、领导者位置调整和领导者位置更新操作。

步骤六:计算更新后白骨顶鸟适应度,比较并确定最佳白骨顶鸟位置 $gBest$ 。

步骤七:令 $L=L+1$ 。判断是否 $L=Iter$,若是,输出 $gBest$,算法结束;否则返回步骤五。

步骤八:输出 $gBest$,并构建COA-ELM模型对分量[3,0]—[3,7]进行预测,预测结果叠加重构后即最终预测结果。

步骤九:利用平均绝对百分比误差(MAPE)、平均绝对误差(MAE)、均方根误差(RMSE)对各模型进行评估,见式(9)。

$$MAPE = \frac{1}{R} \sum_{u=1}^R \left| \frac{\hat{Y}_u - Y_u}{\hat{Y}_u} \right| \times 100\%$$

$$MAE = \frac{1}{R} \sum_{u=1}^R |\hat{Y}_u - Y_u| \quad (9)$$

$$RMSE = \sqrt{\frac{1}{R} \sum_{u=1}^R (\hat{Y}_u - Y_u)^2}$$

式中: \hat{Y}_u 为第 u 个样本实测值; Y_u 为第 u 个样本预测值; R 为样本数量。

2 实例应用

以云南省龙潭站为例,选取1952—2005年月降水量时间序列数据。龙潭站位于文山市城区上游,设立于1951年4月,系红河流域泸江水系盘龙河干流国家基本水文站,控制径流面积3128 km²。盘龙河流域属低纬度高原季风气候,流域多年平均(1952—2005年)降雨量1004 mm,多年平均降水总量73.92亿m³,雨量充沛,但降雨时空分布不均,年际变化悬殊。流域干湿季分明,5—10月为雨季,降雨量约占全年的80%,尤

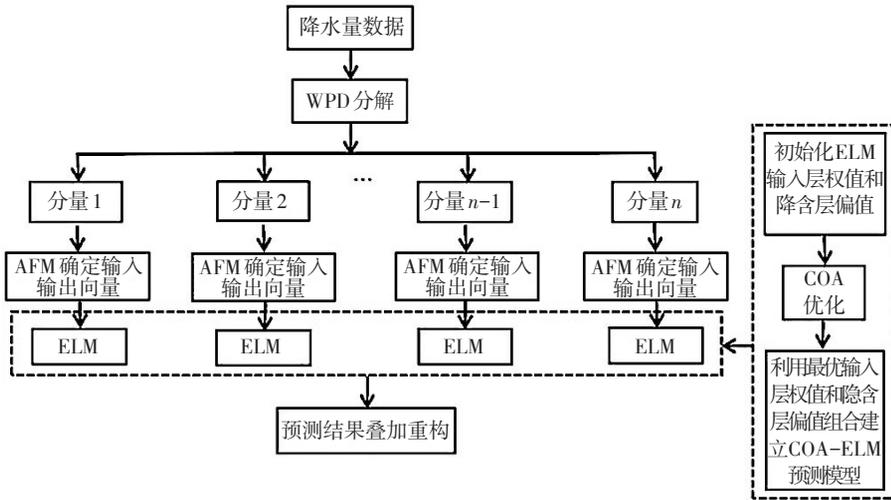


图1 建模流程图
Fig.1 Forecast flow chart

以7、8、9月份最为集中,降水量约占全年的60%,降水易产生洪涝灾害。

2.1 小波包分解时序数据

利用 db4 小波将龙潭站 1952—2005 年实测汛期(5—10月,共 324 组)和主汛期(7、8、9月,共 162 组)月降水量数据进行 3 层小波包分解,分别得到 8 个分解空间的子序列分量数据,见图 2~3。

2.2 时间序列建模

采用自相关函数法 (AFM) 确定各分量的输入、输出向量。确定原则:通过 SPSS 软件计算各

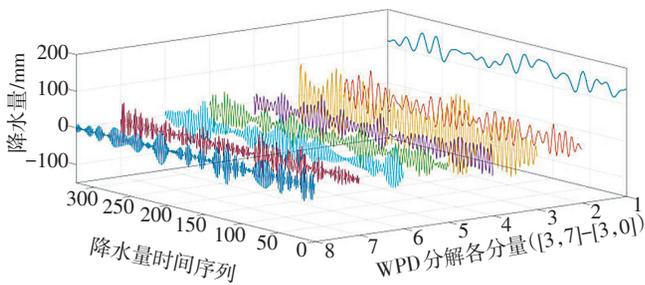


图2 汛期降水序列分解
Fig.2 Decomposition of Precipitation Series in Flood Season

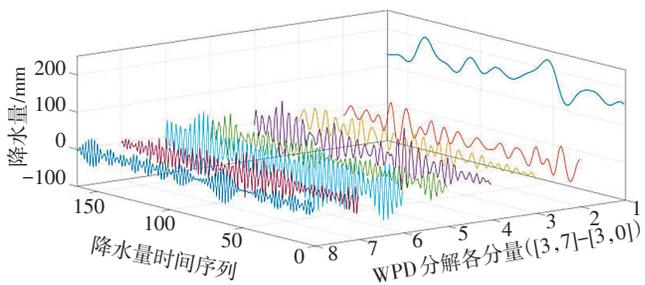


图3 主汛期降水序列分解
Fig.3 Decomposition of Precipitation Series in Main Flood Season

分量的自相关系数,在滞后数 $H \geq 4$ 情况下,将自相关系数最大时所对应的滞后数 H 作为各分量最优嵌入维数,即将预测月前 H 个月降水量数据作为输入向量,预测月作为输出向量,见表 2。本文利用汛期前 257~260 个月降水量数据作为训练样本,后 60 个月作为预测样本;利用主汛期前 126~128 个月降水量数据作为训练样本,后 30 个月作为预测样本。

2.3 参数设置及预测分析

2.3.1 参数设置

(1) WPD-COA-ELM、WPD-ELM 模型:设置 WPD-ELM 模型各分量隐含层神经元数为输入维数的 2 倍-1,激活函数选择 sigmoid 函数。为在公平条件下对比验证 WPD-COA-ELM 模型,设置 ELM 参数同 WPD-ELM 模型;设置 COA 种群规模 $N=50$,最大迭代次数 $Iter=100$,领导者百分比 $N_L=10\%$,输入层权值和隐含层偏值搜索空间 $\in [-1, 1]$,数据均采用 $[-1, 1]$ 进行归一化处理。

(2) WPD-COA-BP、WPD-BP 模型:设置 WPD-BP 模型各分量隐含层神经元数为输入维数的 2 倍-1,隐含层传递函数、输出层传递函数、训练函数分别采用 $tansig$ 、 $purelin$ 、 $traingdx$,设定期望误差为 0.0001,最大训练轮回均设置为 1000 次。为在公平条件下对比验证 WPD-COA-BP 模型,设置 BP 参数同 WPD-BP 模型;COA 参数设置及数据处理同上。

2.3.2 预测结果分析

利用 WPD-COA-ELM 等 4 种模型对各分量进行预测,将各分量预测结果叠加重构后即得到实例汛期和主汛期降水量最终预测结果。并利用上述 $MAPE$ (%)、 MAE (mm)、 $RMSE$ (mm) 进行评估,结果见表 3;预测效果见图 4~7。分析可知:

(1) WPD-COA-ELM 模型对汛期月降水量预测的 $MAPE$ 、 MAE 、 $RMSE$ 分别为 3.91%、2.28 mm、2.77 mm,较 WPD-COA-BP、WPD-ELM、WPD-BP 模型在 $MAPE$ 上分别降低 42.4%、65.1%、72.3%, MAE 降低 48.8%、74.6%、81.8%, $RMSE$ 降低 47.2%、75.5%、82.5%;对主汛期月降水量预测的 $MAPE$ 、 MAE 、 $RMSE$ 分别为 3.59%、4.32mm、5.50mm,较 WPD-COA-BP、WPD-

表2 各分量自相关系数、嵌入维数及序列长度

Table2 Autocorrelation coefficient of each component, embedding dimension and sequence length

实例	分量	自相关系数	输入维数	序列长度 长度	实例	分量	自相关系数	输入维数	序列长度 长度
汛期	[3,0]	0.629	4	320	主汛期	[3,0]	0.716	4	158
	[3,1]	-0.822	5	319		[3,1]	-0.758	5	157
	[3,2]	0.919	6	318		[3,2]	-0.742	4	158
	[3,3]	-0.607	7	317		[3,3]	0.754	5	157
	[3,4]	0.715	4	320		[3,4]	0.687	4	158
	[3,5]	0.686	6	318		[3,5]	0.890	6	156
	[3,6]	0.666	5	319		[3,6]	-0.803	6	156
	[3,7]	0.680	4	320		[3,7]	0.640	4	158

表3 月降水预测结果对比

Table3 Comparison of monthly precipitation forecast results

实例	模型	样本	MAPE/%	MAE/mm	RMSE/mm	实例	模型	样本	MAPE/%	MAE/mm	RMSE/mm
汛期	WPD-COA-ELM	训练	1.59	1.45	1.84	主汛期	WPD-COA-ELM	训练	1.51	1.99	2.51
		预测	3.91	2.28	2.77			预测	3.59	4.32	5.50
	WPD-COA-BP	训练	3.65	3.26	3.99		WPD-COA-BP	训练	1.97	2.67	3.37
		预测	6.79	4.45	5.25			预测	6.80	6.81	8.17
	WPD-ELM	训练	6.33	5.73	7.48		WPD-ELM	训练	2.71	3.75	4.71
		预测	11.2	8.99	11.3			预测	9.64	8.19	10.4
	WPD-BP	训练	9.06	7.89	9.72		WPD-BP	训练	5.14	6.68	9.19
		预测	14.1	12.5	15.8			预测	13.5	12.8	17.6

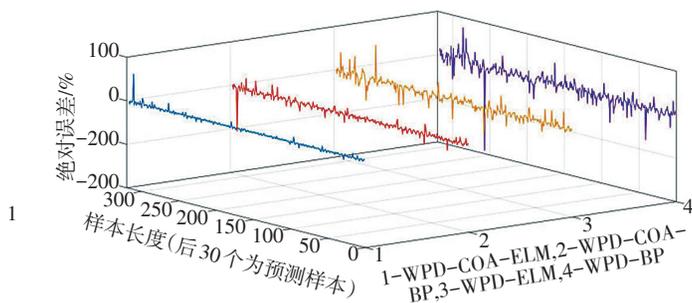


图4 汛期拟合-预测相对误差

Fig.4 Flood season fitting-prediction relative error

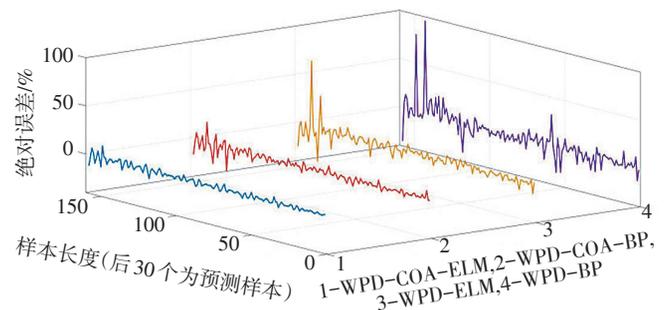


图5 主汛期拟合-预测相对误差

Fig.5 Main flood season fitting-prediction relative error

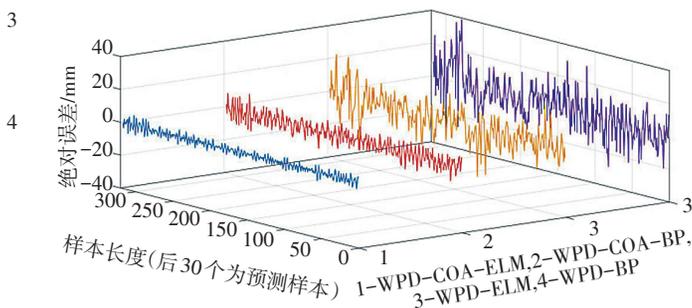


图6 汛期拟合-预测绝对误差

Fig.6 Flood season fitting-prediction absolute error

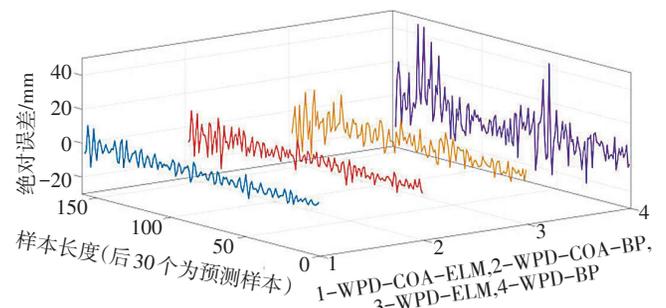


图7 主汛期拟合-预测绝对误差

Fig.7 Main flood season fitting-prediction absolute error

ELM、WPD-BP模型在MAPE上分别降低47.2%、62.8%、73.4%，MAE降低36.6%、47.3%、66.3%，RMSE降低32.7%、47.1%、68.8%，WPD-COA-ELM模型具有更高的预测精度，将其用于月降水量时间序列预测是可行和可靠的。

(2)基于COA优化的ELM、BP模型的预测精度要远高于未经优化的ELM、BP模型，说明COA能有效优化ELM输入层权值、隐含层偏值及BP网络权值、阈值。

(3)WPD-COA-ELM模型对汛期、主汛期月降水量的预测效果优于WPD-COA-BP模型，表明ELM在大容量样本预测问题上具有优势。ELM人为设置参数少、泛化能力好；而BP神经网络由于人为设置参数较多，制约了BP神经网络预测精度的提高。

(4)通过WPD对汛期、主汛期月降水量时序数据进行分解，可以有效弱化复杂气候环境对降水时间序列的影响，降低预测复杂度，提高预测精度。

(5)WPD-COA-ELM模型对汛期、主汛期降水量拟合-预测效果最好，WPD-COA-BP模型次之，WPD-ELM、WPD-BP模型较差。就相对误差而言，汛期84.2%、主汛期81.7%样本的拟合-预测相对误差在-3%~3%之间，具有更好的预测效果。

3 结论

(1)通过6个标准测试函数在不同维度条件下对COA进行仿真验证，验证了COA具有较好的寻优精度和全局搜索能力，仿真结果基本不受维度的影响。

(2)WPD-COA-ELM模型对汛期、主汛期月降水量的拟合、预测精度优于WPD-COA-BP模型，远优于WPD-ELM、WPD-BP模型，具有更好的预测精度，将WPD-COA-ELM模型用于月降水量时间序列预测是可行的。模型及方法可为相关时间序列预测研究提供新途径。

(3)WPD能将汛期、主汛期月降水量时序数据分解为更具规律的子序列分量，有效弱化复杂环境对降水时间序列的影响，降低预测复杂度，大大提高模型的预测精度；利用COA优化ELM输入层权

值和隐含层偏值，有利于提高ELM预测精度和智能化水平。

参考文献:

- [1] 李栋,薛惠锋,张燕.基于经验模态分解的降水量组合预测模型[J].计算机仿真,2019,36(3):458-463.
- [2] 张先起,胡登奎,刘斐.基于CEEMD-Elman耦合模型的年降水量预测[J].华北水利水电大学学报(自然科学版),2019,40(4):32-39.
- [3] 董淑华,邢贞相,娄丹,等.基于改进径向基函数的降雨量短期预测研究[J].沈阳农业大学学报,2017,48(3):367-372.
- [4] 胡虎,杨侃,朱大伟,等.基于EEMD-GRNN的降水量预测分析[J].水电能源科学,2017,35(4):10-14.
- [5] 谢昊伶,彭国华,郭满才,等.基于改进的SVR模型在年降水量预测中的应用[J].数学的实践与认识,2017,47(18):154-161.
- [6] 贺玉琪,王栋,王远坤.BRR-SVR月降水量预测优化模型[J].水利学报,2019,50(12):1529-1536.
- [7] 甄亿位,郝敏,陆宝宏,等.基于随机森林的中长期降水量预测模型研究[J].水电能源科学,2015,33(6):6-10.
- [8] 刘新,赵宁,郭金运,等.基于LSTM神经网络的青藏高原月降水量预测[J].地球信息科学学报,2020,22(8):1617-1629.
- [9] 徐冬梅,张一多,王文川.基于小波包分解的IS-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.
- [10] 张以晨,欧阳琦,邵杰.奇异谱分析-支持向量回归机耦合模型在月降水量预测中的应用[J].水电能源科学,2017,35(10):18-22.
- [11] 王同亮,马绍休,高扬,等.小波包分解与多个机器学习模型耦合在风速预报中的对比[J].中国沙漠,2021,41(2):38-50.
- [12] 陈洁,詹仲强.高阶统计量与小波包分解在风氢混合储能系统中的应用[J].太阳能学报,2018,39(11):3286-3294.
- [13] ABDOLLAHZADEH B, GHAREHCHOPOGH F S, MIRJALILI S. African Vultures Optimization Algorithm: A New Nature-Inspired Metaheuristic Algorithm for Global Optimization Problems[J]. Computers & Industrial Engineering, 2021(158).
- [14] 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.
- [15] 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(8):20-27.
- [16] 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.
- [17] 陈艳茹.基于遗传算法和极限学习机的智能算法在基坑变形预测中的应用[J].隧道建设(中英文),2018,38(6):71-77.
- [18] 殷豪,董朕,孟安波.基于结合混沌纵横交叉的粒子群算法优化极限学习机的短期负荷预测[J].计算机应用研究,2018,35(7):174-177.

Application of WPD-COA-ELM Model in the Prediction of Time Series of Monthly Precipitation in Flood Season

YANG Qiongbo¹, CUI Dongwen^{1,2}

(1. Yunnan Provincial Hydrology and Water Resources Bureau, Honghe Branch, Honghe 661100, China;

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

Abstract: According to the multi-scale non-stationary characteristics of monthly precipitation time series, a precipitation prediction model integrating wavelet packet decomposition (WPD), coot optimization algorithms (COA) and extreme learning machine (ELM) is proposed. Firstly, the non-stationary monthly precipitation time series is decomposed into several subsequence components by WPD; Secondly, the principle of coa is briefly introduced, and six typical functions are used to simulate and test COA under different dimensions; The COA is used to optimize the elm input layer weight and hidden layer bias, and the COA-ELM model is established for each subsequence component for prediction. The final prediction result is the superposition and reconstruction of the prediction results; Finally, taking the monthly precipitation data of flood season and main flood season of Longtan station in Yunnan Province as an example, the experiment is compared with wpd-coa-bp, wpd-elm and wpd-bp prediction models. The results show that COA has good optimization accuracy and global search ability under different dimensions. The average absolute error of WPD-COA-ELM model in predicting the time series of monthly precipitation in case flood season and main flood season is only 3.91% and 3.59% respectively. The predicted value closely follows the change trend of monthly precipitation, and the prediction accuracy is better than WPD-COA-BP model, far better than WPD-ELM and WPD-BP model. WPD can scientifically reduce the complexity of monthly precipitation time series data and improve the prediction effect; COA can effectively optimize elm input layer weight and hidden layer bias, and improve elm network performance.

Keywords: precipitation forecast; wavelet packet decomposition; coot optimization algorithms; extreme learning machine; simulation test

=====

(上接第5页)

- | | |
|--|---|
| [7] 刘杰,孙龙,杨春生,等.国家地下水监测综合成果分析应用系统建设成果[J].水利信息化,2020(4):9-11. | [10] 杨春生,英爱文.国家地下水监测工程自动监测仪器的质量控制和运行维护[J].地下水,2020,42(6):51-53. |
| [8] 英爱文,章树安,于钊,等.国家地下水监测工程(水利部分)项目建设与管理[M].郑州:黄河水利出版社,2021. | [11] 章雨乾,章树安.对地下水监测有关问题分析与思考[J].地下水,2021,43(1):53-56. |
| [9] 章树安,刘庆涛,杨桂莲,等.国家地下水监测工程(水利部分)项目技术与应用[M].郑州:黄河水利出版社,2022. | [12] 中华人民共和国国务院.地下水管理条例(国务院令第748号)[Z].2021. |

Understanding and Research on the National Standard

“Technical Standard for Groundwater Monitoring”

ZHANG Shu'an^{1,2}, LU Hongjian^{1,2}, SUN Long^{1,2}

(1. Information Center, MWR, Beijing 100053, China;

2. National Groundwater Monitoring Center, MWR, Beijing 100053, China)

Abstract: This paper briefly introduced background of the revised national standard “Technical standard for groundwater monitoring”, and put forward the understanding of the main contents of the standard, such as the construction of monitoring stations and automatic monitoring systems, information monitoring and data processing, information service system construction and monitoring system operation and maintenance. The technical problems involved in the compiling of the standard, such as the full coverage of the groundwater monitoring station network in the county-level administrative region, the setting of measuring point, the error accuracy of manual and automatic monitoring, and the treatment method of groundwater fluctuating level, were discussed and explored. After the implementation of this standard, it will further improve the technical level of groundwater station network layout, well design and construction, automatic information monitoring, data processing, information service and operation and maintenance in China, and provide important technical supports for the implementation of the second phase of national groundwater monitoring engineering and the high-quality development of water conservancy.

Keywords: groundwater; monitoring engineering; technical standard; understanding and research