

DOI:10.11705/j.issn.1672-643X.2022.04.02

基于WD-COA-LSTM模型的月降水量预测

王文川, 杨静欣, 臧红飞

(华北水利水电大学 水资源学院, 河南 郑州 450046)

摘要: 为进一步提高月降水量预测精度,提出了基于小波分解(WD)和郊狼优化(COA)算法的长短期记忆神经网络(LSTM)降水量预测模型(WD-COA-LSTM)。首先用小波分解对时间序列进行预处理,消除序列的非平稳性,得到1个低频率序列和3个高频率序列;然后通过郊狼优化算法对神经网络(LSTM)模型进行参数优化;最后将各子序列预测值叠加得到月降水量预测值。将提出的模型应用于洛阳市栾川县白土镇和洛宁县故县镇两个雨量站的月降水量预测中,并与LSTM、COA-LSTM、WD-LSTM模型预测结果进行对比。结果表明:提出的WD-COA-LSTM模型的预测精度最高,说明小波分解和郊狼优化算法能有效加强LSTM模型预测的精度和泛化能力,为月降水量的预测提供了一种新的途径。

关键词: 月降水量预测;小波分解;郊狼优化算法;长短期记忆神经网络

中图分类号:TV125

文献标识码:A

文章编号:1672-643X(2022)04-0008-06

Monthly precipitation prediction based on WD-COA-LSTM model

WANG Wenchuan, YANG Jingxin, ZANG Hongfei

(College of Water Resources, North China University of Water Resources and Electric Power, Zhengzhou 450046, China)

Abstract: In order to improve the prediction precision of monthly precipitation, the precipitation prediction model of WD-COA-LSTM is proposed based on wavelet decomposition (WD), coyote optimization algorithm (COA) and long short-term memory (LSTM) neural network. Firstly, the time series is pre-processed by WD to eliminate its non-stationarity, and a low-frequency sequence and three high-frequency sequences are obtained as the result. Then the parameters of the LSTM model are optimized by COA. Finally, the predicted monthly precipitation is obtained by superimposing the predicted values of each subsequence. The proposed model was applied to the monthly precipitation prediction of Baitu Town in Luanchuan County and Guxian Town in Luoning County, Luoyang City, and the results were then compared with those of the LSTM, COA-LSTM and WD-LSTM models. It is found that the proposed WD-COA-LSTM model produced the highest prediction accuracy, indicating that WD and COA can improve the precision and generalization ability of LSTM model. This model provides a new approach for the prediction of monthly precipitation.

Key words: monthly precipitation prediction; wavelet decomposition (WD); coyote optimization algorithm (COA); long short-term memory (LSTM) neural network

1 研究背景

降水预测是水文预报领域的一项重要研究内容,降水量异常是诱发旱灾、洪涝灾害的直接因素之一,因此,对其准确预测具有重要意义。近年来许多专家学者对降水量预测进行了大量探索,主要的研究方法有自回归模型^[1-2]、支持向量机^[3-5]、神经网络

^[6-8]等。其中长短期记忆(long short-term memory, LSTM)神经网络模型能精准地预测时间序列,有效解决了一些神经网络中出现的梯度爆炸问题,成为近年来的研究热点。如Kumar等^[9]采用递归神经网络(recurrent neural networks, RNN)模型和长短期记忆(LSTM)神经网络模型对印度不同区域降水量进行了预测,结果表明LSTM模型比RNN模型预

收稿日期:2021-11-09; 修回日期:2022-04-29

基金项目:河南省重点研发与推广专项(202102310259、202102310588);河南省高校科技创新团队(18IRTSTHN009)

作者简介:王文川(1976-),男,河南鹿邑人,博士,教授,博士生导师,研究方向为水文学及水资源。

测精度更高;殷兆凯等^[10]通过对比分析新安江模型与 LSTM 模型在不同预见期下对锦江高安雨量站日降水量的预测结果,发现 LSTM 模型在不同预见期下的日降水量预测精度均优于新安江模型;刘新等^[11]利用 LSTM 等 5 种神经网络模型分别进行中长期降水对比预测,发现 LSTM 模型预测精度整体优于其他几个神经网络模型。

虽然 LSTM 模型在时间序列预测方面表现出了良好的适用性,但由于降水时间序列的非平稳性,以及预测模型参数确定困难,使得数据驱动模型推广应用受到限制,因此仍需进一步改进以提高预报精度。在以往的研究中,通常有两种策略来提高预测精度:一是数据预处理技术,通过数据预处理可以减少时间序列数据的非平稳特征,提取隐藏在数据中的有效信息^[12];二是采用优化算法对模型的超参数进行优化^[13]。因此,近年来许多学者在时序预处理和模型参数优选方面进行了大量探索。小波分解(wavelet decomposition, WD)作为一种数据预处理技术,已在水文预报中得到广泛应用, Kim 等^[14]采用小波分解算法对区域和分类降水量数据进行分解,并通过与单一的数据驱动模型对比,发现经小波分解后的时间序列对于雨量的预测准确度更高;赵然杭等^[15]采用基于时间序列分解的神经网络模型,首先对时序数据进行预处理,然后选取随机率定的神经网络参数对降水数据进行挖掘和预测,预测结果达到了精度要求。另外许多研究通过优化算法来优化 LSTM 模型的超参数,如 Kala 等^[16]使用人工藻类算法(artificial algae algorithm, AAA)对 LSTM 模型进行参数寻优,提高了 LSTM 模型的预测精度;胡玉杰等^[17]采用经粒子群优化算法(particle swarm optimization, PSO)参数率定后的 AdaBoost-C4.5 模型按降水等级对时序数据建立模型,在一定程度上提高了降水量预测的泛化能力。但上述研究只注重时间序列的分解或模型参数的优化,均属于单一的研究方法。

基于以上分析,本文将时间序列预处理与模型

参数优化相结合,首先利用小波分解(WD)方法,将径流数据分解为不同频率的时间序列,在降低序列非平稳性的同时达到提高数据预测精度的目的,然后运用郊狼优化算法(coyote optimization algorithm, COA)筛选出 LSTM 模型最优的超参数,最后,建立 WD-COA-LSTM 耦合模型。采用 LSTM、COA-LSTM、WD-LSTM 3 个降水预测模型对河南省洛阳市栾川县白土镇和洛宁县故县镇两个雨量站进行预测和对比,验证了 WD-COA-LSTM 预测模型的可靠性。

2 数据来源与研究方法

2.1 研究区域概况

河南省洛阳市栾川县白土镇和洛宁县故县镇的两个雨量站点均位于洛河流域的中上游,该流域起源于龙潭泉^[18],流域覆盖面积近 2 000 km²,两个雨量站点所处地区四季分明,年均降水量为 600 mm。

2.2 数据来源

分别选取白土镇雨量站和故县镇雨量站 1966-2016 年的月降水实测数据作为研究对象,训练样本均采用前 36 a 的月降水数据,验证样本均采用后 15 a 的月降水数据。LSTM 作为数据驱动模型,其时间滞时的选择对于时间序列的预测精度具有重要影响,因此运用自相关系数法^[19]来选取合适的滞时。图 1 和图 2 分别为白土镇和故县镇原始月降水序列的自相关函数(autocorrelation function, ACF)图和偏相关函数(partial autocorrelation function, PACF)图,由图 1、2 可以看出,白土镇雨量站降水数据的 ACF 值在 11~14 时达到极值,且在 14 以后 PACF 的预测值落在 95% 置信带内;故县镇雨量站降水数据的 ACF 值在 11~13 时达到极值,且在 13 以后 PACF 的预测值落在 95% 置信带内。通过综合考虑气候、水文环境、地理位置等因素的影响,分别选用 14 和 13 作为白土镇和故县镇的时间滞时来对两个雨量站的降水量进行滚动预测。

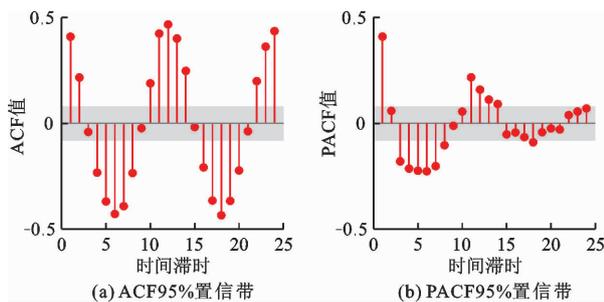


图1 白土镇月降水序列的 ACF 与 PACF 图

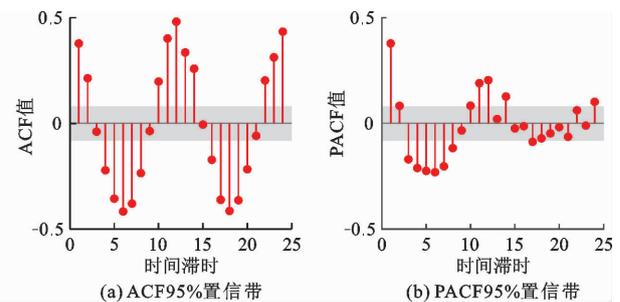


图2 故县镇月降水序列的 ACF 与 PACF 图

2.3 研究方法

2.3.1 小波分解(WD) 小波分解是通过提取原始数据内的不同信息,将其分解得到高频、低频序列两部分,以此类推,通过多级分解后有效提高了频率的分辨率^[20]。

原始序列与各子序列关系式为:

$$x(t) = a_k(t) + \sum_{i=1}^k d_i(t) \quad (1)$$

式中: a_k 为低频序列; d_i 为高频序列; k 为分解层数。

2.3.2 郊狼优化算法(COA) 郊狼优化算法(COA)^[21]是一种基于种群的算法,其灵感来自于郊狼这一犬种^[22]。与许多其他 MHS (MinHash)^[23]方法不同的是,在 COA 中,狼被分为子群体并组成总群体,每个狼群由一定数量的郊狼和一个 alpha 个体组成。alpha 狼代表狼群中最优秀的郊狼。此外,COA 算法关注郊狼的社会结构和行为的共享。在第 n 个时刻,第 n 个狼群中的第 c 只狼的社会状况用向量 $\mathit{soc}_c^{p,t} = (x_1, x_2, \dots, x_{Dimension})$ 表示。COA 优化算法步骤如下:

步骤 1: 计算郊狼的适应能力。某个郊狼对环境的适应能力表现为 $\mathit{fit}_c^{p,t} \in R$ (优化过程中目标函数的值),与其他智能算法一样,初始社会条件是在郊狼种群中随机设定的。COA 根据来自郊狼的信息计算狼群的文化倾向,假设每个郊狼都为狼群的生存做出贡献。第 p 组狼的文化倾向($\mathit{cult}_j^{p,t}$) 计算公式为:

$$\mathit{cult}_j^{p,t} = \begin{cases} O_{\frac{(N_c+1)}{2},j}^{p,t} & (N_c \text{ is odd}) \\ \frac{O_{\frac{N_c}{2},j}^{p,t} + O_{\frac{(N_c+1)}{2},j}^{p,t}}{2} & (\text{otherwise}) \end{cases} \quad (2)$$

式中: $O^{p,t}$ 为第 t 瞬间第 p 组狼的社会适应能力排名情况。根据公式(2),狼群的文化倾向是由狼群中狼的社会状况来表示的。

步骤 2: 选择狼群中的 alpha 郊狼。

$$\mathit{alpha}^{p,t} = \{ \mathit{soc}_c^{p,t} \mid \arg_{c=\{1,2,\dots,N_c\}} \min f(\mathit{soc}_c^{p,t}) \} \quad (3)$$

步骤 3: 更新狼群的社会状况。在 COA 算法中,族群间的文化相互作用用 δ_1 和 δ_2 表示。 δ_1 和 δ_2 分别为 alpha 效应和 pack 效应:

$$\delta_1 = \mathit{alpha}^{p,t} - \mathit{soc}_{cr_1}^{p,t} \quad (4)$$

$$\delta_2 = \mathit{cult}_j^{p,t} - \mathit{soc}_{cr_2}^{p,t} \quad (5)$$

式中: cr_1 和 cr_2 代表随机选择的郊狼。利用 δ_1 和 δ_2 更新新的郊狼社会状况公式为:

$$\mathit{new_soc}_c^{p,t} = \mathit{soc}_c^{p,t} + r_1 \cdot \delta_1 + r_2 \cdot \delta_2 \quad (6)$$

式中: $\mathit{new_soc}_c^{p,t}$ 为郊狼新的社会地位(适应度值); r_1 和 r_2 为 $[0,1]$ 范围内随机生成的权重系数,分别表示 alpha 和 pack 效应。

如公式(7)所示,如果郊狼新的社会地位比以前更好,它将被狼群接受;否则,将被拒绝。

$$\mathit{soc}_c^{p,t+1} = \begin{cases} \mathit{new_soc}_c^{p,t} & (\mathit{new_fit}_c^{p,t} < \mathit{fit}_c^{p,t}) \\ \mathit{soc}_c^{p,t} & (\text{otherwise}) \end{cases} \quad (7)$$

步骤 4: 郊狼的诞生和死亡过程。新郊狼的出生是父母与社会环境的结合,是随机选择的。在这个过程中,环境影响也被考虑在内。新郊狼的出生模型计算公式为:

$$\mathit{pup}_j^{p,j} = \begin{cases} \mathit{soc}_{cw_1}^{p,t} & (\mathit{rnd}_j < P_s \text{ or } j = j_1) \\ \mathit{soc}_{cw_2}^{p,t} & (\mathit{rnd}_j > P_s + P_a \text{ or } j = j_1) \\ R_j & (\text{otherwise}) \end{cases} \quad (8)$$

式中: w_1 和 w_2 为随机选择的郊狼; j_1 和 j_2 为随机选择的郊狼基因; P_s 和 P_a 为分散和关联的可能性,建立以支持郊狼文化多样性: $P_s = 1/Dimension$ 和 $P_a = (1 - p)/2$ 。

步骤 5: 更新狼群的年龄。

2.3.3 长短期记忆神经网络 长短期记忆(LSTM)神经网络是由 Hochreiter 等^[24]提出的,弥补了传统神经网络在处理长时依赖时的不足,解决了长期时间序列中的梯度消失问题,并且对于时间序列当中间隔或者延迟很久的关键性事件能够快速预测。LSTM 记忆单元结构如图 3 所示。

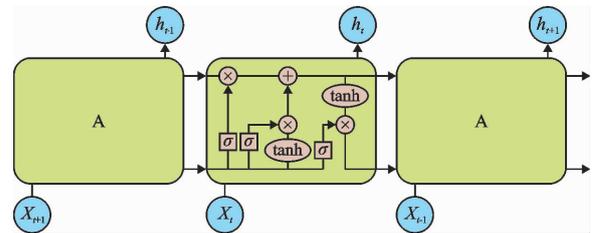


图 3 LSTM 记忆单元结构示意图

输入数据通过 LSTM 记忆单元的具体过程如下:

步骤 1: 通过遗忘门筛选出有效信息,剔除无效信息。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_i) \quad (9)$$

步骤 2: 经输入门选择需要储存在单元中的新信息。

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (10)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (11)$$

步骤 3: 通过输出门处理更新后的参数。

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (12)$$

$$o_i = \sigma(W_o \cdot [h_{i-1}, x_i] + b_o) \quad (13)$$

$$h_i = o_i \cdot \tanh(C_i) \quad (14)$$

式中: h_{i-1} 为上一时刻数据输出; x_i 为当前数据输入; f_i, i_i, o_i 分别为经过 3 个门层的输出; c_i 为隐藏层状态变量; h_i 为 o_i 与 c_i 结合后得到的最终输出; \tanh, σ 分别为双曲正切函数和 Sigmoid 函数。

2.3.4 预测实现步骤 WD - COA - LSTM 模型建立流程如图 4 所示,具体步骤如下:

步骤 1:利用小波分解将本文研究的降水序列分解后得到 1 个低频子序列 a_3 和 3 个高频子序列 d_1, d_2, d_3 。

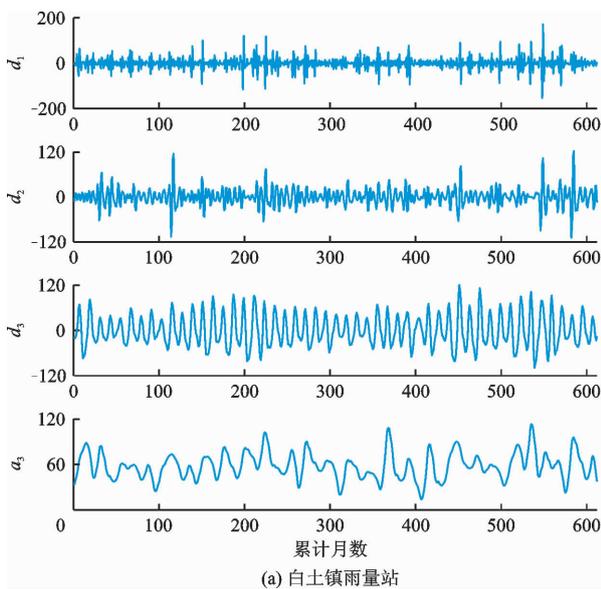
步骤 2:将 4 个子序列分别用 COA - LSTM 模型进行预测,得到 4 组预测值 A_3, D_1, D_2, D_3 。

步骤 3:将 4 组预测值叠加得到最终的预测结果。

3 结果与分析

利用小波分解中 db4 小波基函数^[25]对降水量数据进行分解,根据本文实际研究序列的变化规律将降水时间序列分解为 a_3, d_1, d_2, d_3 4 个子序列,两个雨量站分解结果如图 5 所示。

在 WD - COA - LSTM 模型中,COA 优化算法中



的种群规模、最大迭代次数分别设为 100、400;COA 优化 LSTM 参数时隐藏层数 H 、最大循环次数 E 以及学习率 η 的寻优范围分别为 $[0, 400]$ 、 $[200, 400]$ 和 $[0.001, 0.1]$ 。

为检验 WD - COA - LSTM 模型的预测效果,建立 LSTM、COA - LSTM、WD - LSTM 模型作为对照试验,并选取 4 个评价指标:均方根误差 $RMSE$ 、平均绝对误差 MAE 、纳什系数 NSE 、相关系数 R 对预测结果进行评价,具体计算公式见文献[26]。

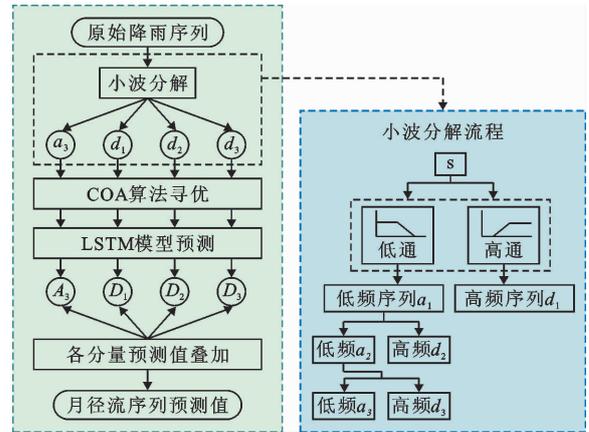


图 4 WD - COA - LSTM 模型构建流程图

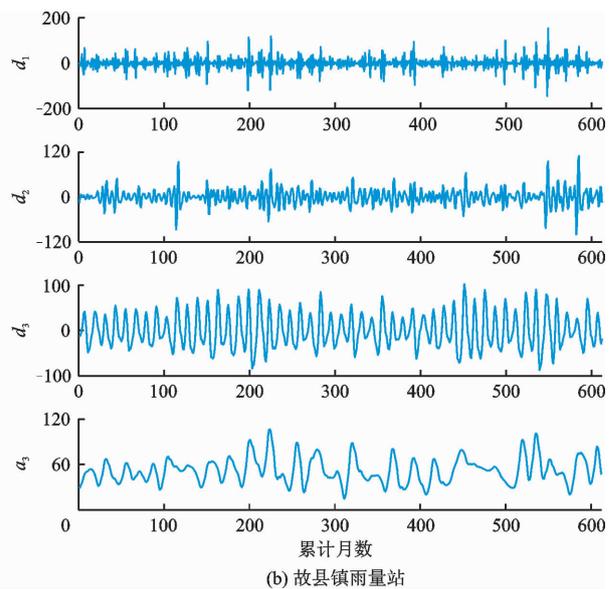


图 5 1966 - 2016 年白土镇和故县镇雨量站月降水量小波分解图

两个雨量站 2002 - 2016 年验证期不同模型月降水量预测结果对比如图 6 所示,各模型评价指标结果如表 1、2 所示。

由图 6 可以看出,在验证期 LSTM、COA - LSTM、WD - LSTM、WD - COA - LSTM 4 个模型与实测降水序列的拟合精度依次逐渐提高。单一的 LSTM 模型的预测值与实测降水序列相比,离散程

度最大,在极值点的预测值总体大于实测值,预测效果不佳;经 COA 优化后的 LSTM 模型有效提高了实测降水序列的拟合度,且其预测的峰值误差远小于单独 LSTM 模型预测的峰值误差,可见经 COA 算法优化后的 LSTM 模型预测精度得到了一定程度的提升;经 WD 分解后的 LSTM 模型与实测降水序列的波动趋势较为接近,由此可以看出 WD 分解能精确

捕捉降水时间序列的变化趋势,提取时序数据的有 效信息,从而提升模型预测精度。

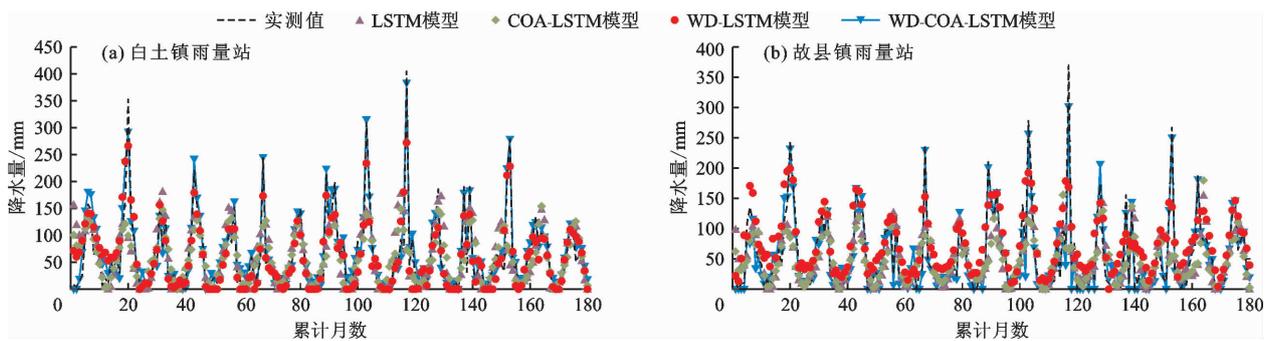


图6 白土镇和故县镇雨量站2002-2016年验证期不同模型月降水量预测结果对比

表1 白土镇雨量站降水量预测模型评价指标结果

模型	训练期				验证期			
	<i>RMSE</i> /mm	<i>MAE</i> /mm	<i>NSE</i>	<i>R</i>	<i>RMSE</i> /mm	<i>MAE</i> /mm	<i>NSE</i>	<i>R</i>
LSTM	43.6490	31.3562	0.3708	0.6497	60.1168	39.8712	0.2321	0.5639
COA-LSTM	39.9711	26.9364	0.4734	0.6839	54.5720	33.1808	0.3672	0.6104
WD-LSTM	27.2157	20.4503	0.7559	0.8962	34.3586	26.0005	0.7492	0.8696
WD-COA-LSTM	17.2619	13.2818	0.9078	0.9574	20.8231	15.7074	0.9079	0.9578

表2 故县镇雨量站降水量预测模型评价指标结果

模型	训练期				验证期			
	<i>RMSE</i> /mm	<i>MAE</i> /mm	<i>NSE</i>	<i>R</i>	<i>RMSE</i> /mm	<i>MAE</i> /mm	<i>NSE</i>	<i>R</i>
LSTM	38.3306	26.4092	0.4634	0.6828	51.6477	32.7588	0.3059	0.5652
COA-LSTM	37.1390	25.1679	0.4762	0.7103	51.3364	31.9096	0.3142	0.5711
WD-LSTM	37.2976	29.9011	0.4919	0.7983	42.7862	30.7186	0.5236	0.7940
WD-COA-LSTM	8.5022	6.5604	0.9736	0.9877	16.8913	12.2686	0.9258	0.9629

分析表1、2可以得出:白土镇雨量站COA-LSTM模型验证期的*RMSE*、*MAE*、*NSE*和*R*值较LSTM模型的误差分别减少了9.22%、16.78%、58.21%和8.25%;WD-LSTM模型验证期的*RMSE*、*MAE*、*NSE*和*R*值较COA-LSTM模型的误差分别减少了37.04%、21.64%、104.03%和42.46%;WD-COA-LSTM模型验证期的*RMSE*、*MAE*、*NSE*和*R*值较WD-LSTM模型的误差分别减少了39.39%、39.59%、21.18%和10.14%。故县镇雨量站COA-LSTM模型验证期的*RMSE*、*MAE*、*NSE*和*R*值较LSTM模型的误差分别减少了0.60%、2.59%、2.71%和1.04%;WD-LSTM模型验证期的*RMSE*、*MAE*、*NSE*和*R*值较COA-LSTM模型的误差分别减少了16.66%、3.73%、66.65%和39.03%;WD-COA-LSTM模型验证期的*RMSE*、*MAE*、*NSE*和*R*值较WD-LSTM模型的误差

分别减少了60.52%、60.06%、76.81%和21.27%。

上述预测结果与分析表明,WD-COA-LSTM模型对于洛河流域月降水量趋势的拟合程度明显高于其他几个单一模型,说明WD-COA-LSTM模型相比于单一的预测模型具有更好的预测精度。

4 讨论

本文对洛河流域月降水量的预测结果表明,WD-COA-LSTM模型与原始降水序列的拟合程度最高,与实测值的波动趋势大体一致,WD-COA-LSTM模型整体优于与其相比较的其他3个模型。主要原因在于:首先LSTM作为深度学习模型可以克服传统RNN模型面临的梯度消失和梯度爆炸问题,其次降水时间序列表现出高度非线性,起伏变化较大,应用WD分解技术能够提取时间序列中隐含的复杂有效信息,从而降低序列的非线性和

降水时间序列预测的难度,提升预测的精度。另外,选择适当 LSTM 模型的超参数可有效提高模型的预测精度,郊狼优化(COA)算法具有良好的全局搜索能力,应用郊狼算法优化 LSTM 模型参数能够打破人为参数选择的局限性,提升模型参数选择的效率和准确性。因此,经过分解技术与参数优化技术相结合的 WD-COA-LSTM 模型,首先经过 WD 分解将月降水时间序列分解为几个子序列,并消除月降水时间序列中潜在的多尺度现象。然后每个子序列由 LSTM 模拟,经 COA 进行超参数优化,克服了人为确定参数的不足。本文提出的 WD-COA-LSTM 模型相比于前人所采用的单一组合模型泛化能力更加突出,具有更高的预测精度和稳定性,能够在很大程度上弥补单一模型的缺陷。

5 结 论

(1)本文提出了 WD-COA-LSTM 月降水量预测模型,其针对月降水数据的复杂性和非线性特征,采用小波分解方法进行数据预处理,提取实测降水序列中隐含的有效信息,分出低频和高频序列,提高了时间序列的平稳性,能够更加全面地捕捉到降序时序数据的变化趋势。并通过运用具有较强全局探索能力和局部开发能力的 COA 优化算法平衡搜索性能,从而提高了 LSTM 模型参数优选的效率。

(2)在洛河流域两个不同雨量站的降水量预测中,单一的 LSTM 神经网络模型的预测值与实测值之间均存在较大误差,经 COA 算法优化后的 LSTM 模型的预测精度虽有所提高,但经时间序列预处理和参数优化后的 WD-COA-LSTM 模型的预测结果在几个预测模型中具有更明显的优势,拟合效果最佳,能够最大程度降低降水序列的复杂性,提高模型精度。

(3)本文所提出的 WD-COA-LSTM 预测模型,在月降水量预测中表现出了良好的准确性和有效性,为月降水量预测提供了一种新的思路。虽然 COA 优化算法相比其他传统优化算法具有较强的全局探索能力,但有时也会陷入局部最优,因此未来可尝试将 COA 优化算法进行改进后用于径流预报的研究。

参考文献:

[1] 李智强,邹红霞,齐斌,等.基于 EEMD-ARIMA 的年降水量预测拟合模型研究[J].计算机应用与软件,2020,37(11):46-50+78.
[2] 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.

- [3] 孙傲涵,李建柱,冯平. RF-SVR 降尺度模型在滦河流域的适用性分析[J].水资源与水工程学报,2021,32(2):31-37.
[4] 刘易文,李家科,丁强,等.汉江流域安康段降雨径流特征分析及预测[J].人民珠江,2021,42(6):59-69.
[5] 罗芳琼,吴春梅,黄鸿柳,等.优化支持向量机在降水预报中的应用[J].数学的实践与认识,2017,47(24):172-177.
[6] 疏杏胜,王子茹,李福威,等.基于机器学习模型的短期降雨多模式集成预报[J].南水北调与水利科技,2020,18(1):42-50.
[7] 张梦,赵靓芳,全星. PSO-ESN 在城市内涝点降雨积水预测中的应用[J].中国农村水利水电,2019(6):56-59+65.
[8] 王汉涛,张潇潇.仿生算法优化 BP 神经网络在降雨空间插值中的应用[J].水资源与水工程学报,2019,30(3):106-112.
[9] KUMAR D, SINGH A, SAMUI P, et al. Forecasting monthly precipitation using sequential modelling[J]. Hydrological Sciences Journal, 2019, 64(6): 690-700.
[10] 殷兆凯,廖卫红,王若佳,等.基于长短时记忆神经网络(LSTM)的降雨径流模拟及预报[J].南水北调与水利科技(中英文),2019,17(6):1-9+27.
[11] 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.
[12] NI Lingling, WANG Dong, SINGH V P, et al. Streamflow and rainfall forecasting by two long short-term memory-based models[J]. Journal of Hydrology, 2020, 583: 124296.
[13] YUAN Xiaohui, CHEN Chong, LEI Xiaohui, et al. Monthly runoff forecasting based on LSTM-ALO model[J]. Stochastic Environmental Research and Risk Assessment, 2018, 32: 2199-2212.
[14] KIM S, KISI O, SEO Y, et al. Assessment of rainfall aggregation and disaggregation using data-driven models and wavelet decomposition[J]. Hydrology Research, 2017, 48(1): 99-116.
[15] 赵然杭,甘甜,逢晓腾,等.基于时间序列分解的降雨数据挖掘与预测[J].中国农村水利水电,2021(11):116-122.
[16] KALA A, VAIDYANATHAN S G. Forecasting monthly rainfall using bio-inspired artificial algae deep learning network[J]. Fluctuation and Noise Letters, 2022, 21(2): 2250018.
[17] 胡玉杰,杜景林,董亚,等.基于改进 AdaBoost-C4.5 算法的降雨预测[J].现代电子技术,2021,44(14):6-10.

(下转第 23 页)

- [35] ARIKEN M, ZHANG Fei, CHAN N W, et al. Coupling coordination analysis and spatio-temporal heterogeneity between urbanization and eco-environment along the Silk Road Economic Belt in China [J]. *Ecological Indicators*, 2021, 121: 107014.
- [36] 李茜,胡昊,李名升,等. 中国生态文明综合评价及环境、经济与社会协调发展研究[J]. *资源科学*, 2015, 37(7): 1444 - 1454.
- [37] 孟斌,王劲峰,张文忠,等. 基于空间分析方法的中国区域差异研究[J]. *地理科学*, 2005, 25(4): 393 - 400.
- [38] 王少剑,崔子恬,林靖杰,等. 珠三角地区城镇化与生态韧性的耦合协调研究[J]. *地理学报*, 2021, 76(4): 973 - 991.
- [39] LI Yangfan, LI Yi, ZHOU Yan, et al. Investigation of a coupling model of coordination between urbanization and the environment [J]. *Journal of Environmental Management*, 2012, 98: 127 - 133.
- [40] 郭付友,佟连军,仇方道,等. 黄河流域生态经济走廊绿色发展时空分异特征与影响因素识别[J]. *地理学报*, 2021, 76(3): 726 - 739.
- [41] 徐辉,王亿文,张宗艳,等. 黄河流域水-能源-粮食耦合机理及协调发展时空演变[J]. *资源科学*, 2021, 43(12): 2526 - 2537.
- [42] 王慧亮,申言霞,李卓成,等. 基于能值理论的黄河流域水资源生态经济系统可持续性评价[J]. *水资源保护*, 2020, 36(6): 12 - 17.
- [43] 孟钰,杜琼英,管新建,等. 黄河流域水资源利用效率评估及空间分异研究[J]. *中国农村水利水电*, 2020(10): 12 - 16.

(上接第13页)

- [18] 赫晓慧,孟军令,郭恒亮,等. 土地利用与气候变化对洛河流域径流的影响[J]. *水电能源科学*, 2021, 39(10): 31 - 34.
- [19] 王文川,高畅,徐雷. 基于TVF-EMD与LSTM神经网络耦合的月径流预测研究[J]. *中国农村水利水电*, 2022(2): 76 - 81 + 89.
- [20] 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.
- [21] DUMAN S, KAHRAMAN H T, GUVENC U, et al. Development of a Lévy flight and FDB-based coyote optimization algorithm for global optimization and real-world ACOPT problems [J]. *Soft Computing*, 2021, 25(12): 6577 - 6617.
- [22] 张新明,付子豪,陈海燕,等. 全局引导和相互作用的郊狼优化算法及其应用[J]. *计算机应用研究*, 2020, 37(9): 2711 - 2717.
- [23] 邱宁佳,王宪勇,王鹏,等. 融合MHS与AIM-RT的谱聚类优化推荐算法[J]. *计算机应用研究*, 2020, 37(11): 3292 - 3296.
- [24] HOCHREITER S, SCHMISHUBER J. Long short-term memory [J]. *Neural Computation*, 1997, 9(8): 1735 - 1780.
- [25] 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.
- [26] WANG Wenchuan, CHAU K W, XU Dongmei, et al. Improving forecasting accuracy of annual runoff time series using ARIMA based on EEMD decomposition [J]. *Water Resources Management*, 2015, 29: 2655 - 2675.