文章编号:1000-7601(2022)06-0258-10

doi:10.7606/j.issn.1000-7601.2022.06.28

VMD-LSTM 模型对不同预见期 月径流的预测研究

祁继霞¹,粟晓玲^{1,2},张更喜²,张 特²

(1.西北农林科技大学水利与建筑工程学院,陕西杨凌 712100;2.西北农林科技大学旱区农业水土工程教育部重点实验室,陕西杨凌 712100)

摘 要:为减小径流时间序列的非线性及非平稳性带来的预测误差,提高多种预见期下的月径流预测精度,将 变模态分解(VMD)和长短期记忆神经网络(LSTM)模型相结合,建立了VMD-LSTM组合预测模型,并将大气环流因 子作为模型输入的增加项,预测未来1~3个月的月径流。将模型应用于黄河流域上游唐乃亥、民和、享堂、红旗及折 桥站的月径流预测以验证模型的适用性,并与VMD-BP(BP神经网络)、VMD-SVR(支持向量回归)及单一LSTM模 型相比较。结果表明:VMD-LSTM组合模型的预测误差最小、精度最高,相比单一LSTM模型,其纳什效率系数 (NSE)约从0.6~0.7提高到0.9以上;融合大气环流因子后VMD-LSTM模型预测精度进一步提高,NSE保持在0.91 ~0.96之间;随着预见期的增长,VMD-LSTM模型预测精度衰减较VMD-BP和VMD-SVR模型明显变缓,在3个月 预见期时NSE仍能保持在0.84~0.95之间。VMD-LSTM模型是月径流预测的一种有效方法,结果可为研究区月径 流预测提供参考。

关键词:月径流预测;变模态分解;长短期记忆神经网络;大气环流;预见期 中图分类号:S273.29;P338⁺.2 文献标志码:A

Research on monthly runoff prediction of VMD-LSTM model in different forecast periods

QI Jixia¹, SU Xiaoling^{1,2}, ZHANG Gengxi², ZHANG Te²

(1. College of Water Resources and Architectural Engineering, Northwest A&F University,

Yangling, Shaanxi 712100, China; 2. Key Laboratory of Arid Area Agricultural Water and Soil Engineering,

Ministry of Education, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: In this study, Variational Mode Decomposition (VMD) and Long Short-Term Memory (LSTM) neural network were integrated to establish a hybrid prediction model. The named VMD-LSTM model was to reduce the prediction error caused by the nonlinearity and non-stationarity of the runoff series and improve the accuracy of monthly runoff prediction results under various forecast periods. Some highly correlated atmospheric circulation factors were selected as the additional term of the model input to predict the monthly runoff for $1 \sim 3$ lead months. The performance of VMD-LSTM in predicting monthly runoff at the Tangnaihai, Minhe, Xiangtang, Hongqi and Zheqiao stations at the upper reaches of the Yellow River Basin was verified. The VMD-LSTM model was compared with VMD-BP (BP neural network), VMD-SVR (support vector regression) and the single LSTM model for evaluating its applicability. The results showed that the VMD-LSTM model exhibited the best forecasting performance, compared with the single LSTM model, and its Nash efficiency coefficient (*NSE*) was substantially improved from 0.6~0.7 to above 0.9. When putting atmospheric circulation factors, the accuracy of VMD-LSTM model was further improved, with *NSE* remaining at 0.91~0.96. With the increase of lead time, the precision attenuation of VMD-LSTM model became slower than VMD-BP and VMD-SVR model, and its *NSE* still remained at 0.84~0.95 when

基金项目:国家自然科学基金项目(51879222,52079111)

作者简介:祁继霞(1995-),女,青海海东人,硕士研究生,研究方向为流域水文模拟及预报。E-mail:1531903401@qq.com

通信作者:粟晓玲(1968-),女,四川开江人,教授,主要从事水资源优化配置、流域水文模拟及预报研究。E-mail:xiaolingsu@nwafu.edu.cn

收稿日期:2021-12-15 修回日期:2022-05-04

the forecast period was 3 months. The VMD-LSTM model is an effective method for monthly runoff prediction, and the results can provide guidance for monthly runoff prediction in the study area.

Keywords: monthly runoff prediction; variable modal decomposition; long short-term memory neural network; atmospheric circulation; forecast period

径流预测是水资源管理、配置和有效利用的基础,精确的径流预测可为区域防洪抗旱、水库优化 调度及水利工程规划设计等提供有效的科学支 持^[1]。尤其在干旱地区,水资源短缺一直是限制农 业和经济发展的最大问题,准确可靠的径流预测结 果可为水资源高效利用提供重要参考,缓解旱区水 资源短缺、供需矛盾等问题。径流的形成极易受气 候变化及人类活动等的影响,径流序列常表现出高 度的非线性、非稳定性与复杂性^[2]。因此,获得高 精度的径流预测结果仍面临挑战,如何提高径流预 测精度仍需进一步研究。

当前用于径流预测的模型主要分为过程驱动 模型和数据驱动模型两类^[3]。过程驱动模型主要 通过分析和模拟水文循环过程来实现[4-5],虽然能 较好地揭示径流形成的物理机制,但建模需要大量 准确可靠的水文过程资料,普遍存在模型参数难以 确定及模型通用性较差等缺陷^[6]。数据驱动模型 无需考虑径流形成的物理过程,所需数据量少且建 模简单,因而被广泛使用。数据驱动模型通常分为 时间序列统计模型和机器学习模型,时间序列统计 模型一般适用于平稳或线性的数据序列[7-8],难以 获得隐藏在径流时间序列中的非线性特征,因而预 测效果普遍不理想:传统的机器学习模型包括人工 神经网络(ANN)、支持向量机(SVM)、自适应模糊 推理系统(ANFIS)及小波变换(WT)等^[9-11],这类模 型因具有较强的非线性映射能力[12],可以捕获径流 时间序列中的非线性及非平稳特性,在径流预测中 取得了较好的效果^[13]。

上述机器学习模型虽然具有较强的数据处理 能力,但 ANN 易陷入局部最小值收敛及过拟合^[14], SVM 需要谨慎选择核函数, ANFIS 难以处理噪声 等,导致模型的预测精度受到影响。随着深度学习 技术的快速发展,研究者提出了基于循环神经网络 的长短期记忆神经网络(LSTM),以解决径流的长 期依赖问题^[15-16],从而获得更高精度的径流预测结 果。LSTM 的优点在于能够处理较长时间信息的序 列,实现时间序列的长期传递和记忆^[17-18]。已有研 究表明 LSTM 模型是一种更有效的径流预测模型, 如胡庆芳等^[19]采用 LSTM 模型对汉江安康站的日 径流进行预测,发现 LSTM 模型可以有效避免过拟 合问题;Gao 等^[20]讨论了 LSTM、ANN、门控递归单 元(GRU)模型在径流预测中的效果,发现 LSTM 和 GRU 模型的性能优于 ANN 模型。Yuan 等^[21]利用 蚁狮优化算法(ALO)对 LSTM 模型的参数进行优 化,并与 BP 神经网络、最小支持向量机、径向基神 经网络进行比较,结果证明所构建的 LSTM-ALO 模 型用于月径流预测时显著优于其他三类模型。

由于径流是具有周期性、随机性及趋势性的非 平稳成分,直接使用上述模型预测的精度受限。信 号分解技术可以将径流序列分解为多个相对稳定 的分量,同时达到降噪的目的,使模型可以更好地 捕捉径流序列变化特征,提高预测精度。近年来基 于分解技术与机器学习的混合模型广泛应用于径 流预测中,如梁浩等^[22]在优选多元线性回归 (MLR)、ANN、SVM模型的基础上,构建了基于经验 模态分解(EMD)、集合经验模态分解(EEMD)、小 波分解(WD)的混合模型,结果发现混合模型的预 测精度均高于单一模型。Wang等^[23]、黄巧玲等^[24] 也将分解技术和机器学习模型相耦合用于月径流 的预测,表明耦合模型具有更高的预测精度。

基于分解技术的机器学习模型从挖掘数据序 列自身的变化规律出发可用于径流的模拟及预测, 但这类模型未考虑径流形成的物理成因,因而预测 精度受限。考虑到大气环流是气候和天气变化的 主导因子,同时也是水循环的主要驱动要素,对径 流的变化有一定的影响,将大气环流因子作为机器 学习模型的输入不仅考虑了径流形成的物理因素, 也可改善模型的预测效果。如梁浩等^[22]、孟二浩 等^[25]在常规预报因子的基础上增加了大气环流因 子后预测精度得到了进一步的提高;李福兴等^[26]通 过平均值法筛选大气环流因子作为神经网络的输 入,发现预测误差明显减小。

然而,当前基于 LSTM 模型的径流预测研究大 多只考虑了单一预见期及单一站点,分解技术能否 提高 LSTM 模型在多预见期下的效用尚不明确,且 大气环流因子对较长预见期径流预测结果的影响 尚无明确结论,故有待进一步评估混合模型融合大 气环流因子后在多种预见期及多个站点上的适用 性。基于此,本文选取了黄河流域上游 5 个水文站 的月径流数据,在对月径流进行变模态分解的基础 上,采用LSTM 模型预测了各水文站未来1~3个月 的径流量,并融合了大气环流信息,以期进一步提 高月径流在多种预见期下的预测精度。

研究方法 1

1.1 变模态分解

变模态分解(Variational Mode Decomposition, VMD)是一种自适应、完全非递归的模态变分和信 号处理方法^[27],可根据实际情况确定序列的分解个 数,在克服传统经验模态分解存在的端点效应和模 态混叠问题的同时,实现固有模态分量的有效分 离,分解获得包含多个频率尺度且相对平稳的子序 列。VMD 的核心是构建和求解变分问题,假设原始 信号 f 被分解为 K 个具有中心频率的有限宽度的模 态分量,同时各模态的估计宽带之和最小,约束条 件为所有模态之和与原始信号相等,则相应约束变 分表达式为.

$$\min_{\{u_k\},\{\omega_k\}} \left\{ \sum_{k=1}^{\kappa} \| \partial_t \left[(\delta(t) + j/\pi t) * u_k(t) \right] e^{-jw_k t} \|_2^2 \right\}$$
(1)

$$s.t\sum_{k=1}^{n} u_k = f \tag{2}$$

式中,K为分解的模态个数, $\{u_k\}$, $\{\omega_k\}$ 分别对应分 解后的第k个模态分量和中心频率, $\delta(t)$ 为狄拉克 函数,* 为卷积运算符,f为原始时间序列。详细求 解过程参见文献[27-28]。

1.2 长短期记忆神经网络

长短期记忆神经网络(Long Short-Term Memory, LSTM) 是一种特殊的循环神经网络 (RNN),其优势在于解决 RNN 的梯度消失和梯度 爆炸问题,广泛应用于序列处理与预测。与普通 RNN 不同.LSTM 的核心概念在于细胞状态及"门" 结构,细胞状态保证了信息能在序列中传递下去, 而"门"结构则在训练过程中决定了该保存或遗忘 哪些信息。特殊的网络结构使得 LSTM 在学习当前 信息的同时,还能捕获时间序列中长期的依赖关 系,从而更适合处理和预测时间序列中间隔和延迟 较长的事件^[18, 29-30]。LSTM 的结构如图 1 所示,单 个 LSTM 主要由以下 4 个部分构成:

(1)遗忘门:决定应丢弃或保存哪些信息。

$$f_{t} = \sigma(W_{f} \cdot [h_{t-1}, x_{t}] + b_{f})$$
(3)
(2) 输入门, 决定更新哪些细胞状态

$$i_i = \sigma(W_i. [h_{i-1}, x_i] + b_i)$$
 (4)

$$C_{t} = \tanh(W_{C} \cdot [h_{t-1}, x_{t}] + b_{C})$$
(5)



图 1 LSTM 结构图



式如下:

$$C_{t} = f_{t} * C_{t-1} + i_{t} * \tilde{C}_{t}$$

$$\tag{6}$$

(4) 输出门:决定下一个隐藏状态应携带哪些 信息。

$$O_{t} = \sigma(W_{0}[h_{t-1}, x_{t}] + b_{0})$$

$$(7)$$

$$h_t = O_t * \tanh(C_t) \tag{8}$$

式中, W_t , W_i , W_e , W_o 为权重矩阵; b_t , b_i , b_e , b_o 为偏 置向量;h,-1,h,分别为上一时刻的输入和当前时刻 的输出;C₁₋₁,C₁分别为前一时刻和当前时刻的细胞 状态; \tilde{C} 为通过输入门的信息状态; σ 为 sigmoid 函数。

本文的 LSTM 模型通过 Python3.9 构建,参数通 过试错法确定,通过反复调整,最终确定 LSTM 模型 的网络结构为双隐层,每层的神经元个数为50;为 防止过拟合,加入舍弃层,并设定其随机取舍率为 50%;采用 Adam 优化器并设置其学习率为 0.05。

1.3 VMD-LSTM 预测模型

本文所提出的 VMD-LSTM 组合模型的建立主 要包含以下三个步骤:

(1)利用 VMD 方法对径流序列进行分解,得到 多个平稳的固有模态分量(IMFi(i=1=n))和一个趋势 分量(r);

(2)将分解得到的多个分量进行归一化处理:

(3) 确定 LSTM 模型的输入与输出:

采用前L个月的各固有模态分量(IMF1(1-1-1), *IMF2*_(*t*-*L*,*t*)....*IMFn*_(*t*-*L*,*t*))和趋势分量(*r*_(*t*-*L*,*t*))作为预 报因子,预测各水文站未来3个月的径流(R₄₁, R_{μ_2}, R_{μ_3})。其中 L 在 LSTM 模型中表示其滑动窗 口长度,根据月径流的周期变化规律,单一LSTM 模 型的 L 可直接设置为 12 个月, 但序列经 VMD 分解 后其径流年际变化规律已发生改变,故不能直接将 VMD-LSTM 混合模型的 L 值设为 12, 需要反复调试 确定L的最优值。

1.4 模型评价标准

采用均方根误差(RMSE)和纳什效率系数

(NSE)对模型预测结果进行精度评价,其中 RMSE 用来衡量预测值与实测值之间的偏差,其值越小越 好;NSE 取值范围为(-∞,1],越接近1表示模型 预测精度越高, RMSE 和 NSE 的具体计算公式 如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^{n} (y_i - y_0)^2}$$
(9)

$$NSE = 1 - \frac{\sum_{i=1}^{n} (y_0 - y_i)^2}{\sum_{i=1}^{n} (y_0 - \bar{y}_0)^2}$$
(10)

式中,*n* 表示序列长度, y_i 表示*i*时刻的预测值, y_0 表示*i*时刻的实测值, $\overline{y_0}$ 表示*i*时刻的实测值, $\overline{y_0}$ 表示实测径流的均值。

2 研究区概况

本文以黄河流域上游部分河流的月径流为研 究对象,收集了唐乃亥、民和、享堂、红旗和折桥共5 个水文站的月径流资料。其中,唐乃亥站是黄河源 区的门户站,也是龙羊峡水库的入库站,距离省会 西宁约300 km;民和站是黄河一级支流湟水的主要

Table 1

控制站,控制着湟水民和以上水量、沙量及水质的 变化;享堂站位于为黄河的二级支流、湟水的一级 支流大通河的主要控制站,直接为八盘峡水库的运 行调度、下游防汛、水源保护等提供水文依据及水 情信息^[23];红旗站位于黄河一级支流洮河,距离下 游刘家峡水库 27 km;折桥站位于大夏河下游,是刘 家峡水库的入库控制站,同时也是大夏河的重要水 沙控制站。以上五个水文站分属不同的子流域,水 文情势各异,具有较好的代表性,且径流数据资料 完整性良好,适用于水文数据的研究与预测,对其 进行月径流模拟预测可为水库的调度管理、水资源 的管理配置等提供科学有效的依据。各水文站基 本资料见表1,流域及水文站位置见图2。

本文所采用的径流数据来自黄河流域水文年鉴,88项大气环流因子的月尺度数据来自国家气候中心气候系统诊断预测室(https://cmdp.ncc-cma.net/cn/download.htm)。模型的输入项为前期的径流数据,大气环流因子为输入项增加项。依据表1所示各站径流资料,各序列前80%的数据用于模型训练,后20%的数据用于模型验证。

表1 各水文站径流资料基本信息

Basic information of streamflow data for selected stations

水文站 Hydrological station	径流资料起止年份 Runoff data length	序列长度/月 Sequence length/month	所在水系 Watershed	集水面 Catchment area/km ²	年均径流 Average annual runoff /(m ³ ・s ⁻¹)
唐乃亥 Tangnaihai	1956-2016	732	黄河 Yellow River	121972	633
民和 Minhe	1951-2016	792	湟水 Huangshui River	15342	53
享堂 Xiangtang	1951-2016	792	大通河 Datong River	15126	88
红旗 Hongqi	1957-2016	718	洮河 Taohe River	24973	143
折桥 Zheqiao	1963-2016	648	大夏河 Daxiahe River	6843	27



3 数据预处理

3.1 月径流 VMD 分解

VMD 的分解效果在很大程度上受模态分解个数 *K* 影响,*K* 值偏大或偏小均会影响后续预测效果。由于各模态的主要区别在于中心频率的不同,所以可通过不同模态下中心频率的分布情况选取合适的 *K* 值,具体求解方法参见文献[31],最终求得享堂站的 *K* 值为 7,其他各站均为 8。

以唐乃亥站为例,其月径流经 VMD 分解后的 结果见图 3,原始的月径流序列被分解成从高频到 低频的 7 个平稳分量(IMF)和表示趋势的残差项, 在数据量增加的同时,不仅减少了噪声,而且找出 了径流序列隐藏的周期性振荡变化趋势,有助于模





型更好地识别数据序列的内在变换规律,改善预测 效果。

3.2 大气环流因子筛选

目前,如何筛选机器学习模型的输入要素尚无具体可供遵循的原则,以往研究多采用相关系数法且结果相对较优。鉴于此,本文计算了所选5个站点的月径流与88项大气环流因子间的Person相关系数,考虑到机器学习模型的输入因子过多会造成过拟合现象,且为了尽可能选择与月径流相关性较强的环流因子,故从通过0.01显著性检验的环流因子中选取相关系数(正相关)最高的4项作为模型输入因子的增加项。经计算,与所选5个站的月径流相关系数最高的4项大气环流因子具有一致性,分别是北半球极涡中心强度指数(*NHPVCII*)、东亚槽强度指数(*EATII*)、西藏高原-1指数(*TPRI*)及西藏高原-2指数(*TPR2*),这4项指数与各站月径流的相关系数如表2所示。

4 结果与分析

4.1 VMD 分解对 LSTM 模型预测结果的影响

为了探究 VMD 分解技术对 LSTM 模型预测结 果的影响,使用单一预测模型 LSTM 和组合预测模

表 2 与月径流显著相关的大气环流因子及相关系数

Table 2Atmospheric circulation factors significantly correlatedwith monthly runoff and the corresponding correlation coefficients

水文站 Hydrological station	NHPVCII	EATH	TPR1	TPR2
唐乃亥站 Tangnaihai	0.672 * *	0.737 * *	0.701 * *	0.710 * *
民和站 Minhe	0.474 * *	0.578 * *	0.546 * *	0.547 * *
享堂站 Xiangtang	0.753 * *	0.814 * *	0.742 * *	0.764 * *
红旗站 Hongqi	0.509 * *	0.587 * *	0.555 * *	0.558 * *
折桥站 Zheqiao	0.421 * *	0.501 * *	0.482 * *	0.482 * *

注:**表示通过0.01显著水平的双尾检验。

Note: * * Means passed a two-tailed test at the 0.01 significance level.

型 VMD-LSTM 分别对 5 个水文站的月径流进行预测,各水文站不同预见期的预测结果见表 3。因篇幅限制,本文仅展示唐乃亥站不同预见期的单一模型和组合模型的效果(图 4)。在相同预见期下,两种模型均能有效预测低流量,但组合模型对高流量的预测效果显著优于单一模型,即 VMD-LSTM 组合模型能提高单一 LSTM 模型在峰值的预测精度。同时,相同预见期下组合模型的预测值与实测值的拟合程度要高于单一模型,且随着预见期的增长,组合模型的拟合程度没有发生明显的变化,预测效果

较为稳定。

从表3看出,与单一LSTM模型相比,VMD分 解技术能显著提高LSTM模型的预测精度。如在1 个月预见期时,唐乃亥、民和、享堂及折桥站的NSE 从0.7左右提高到了0.91以上,尤其是红旗站的 NSE 从0.598显著提升至0.898,可见组合模型在各 个站的预测精度都要高于单一模型。随着预见期 的增加,单一模型的预测精度逐渐降低,而组合模 型的预测精度下降幅度较小;相较于单一预测模 型,VMD-LSTM组合模型在较长预见期情况下依然 具有较高的预测精度,其中红旗站尤为明显,当预 见期由1个月增加到3个月时,采用单一模型时, NSE降幅为28.1%,而在组合模型下,NSE降幅仅为 8.5%。此外,在唐乃亥站及享堂站,采用 VMD-LSTM 组合模型时,当预见期由2个月增加到3个月 时,其NSE分别保持在0.910和0.940,无明显变化, 而 RMSE 仅减小了2%左右。可见组合模型在较长 的预见期下其预测精度显著高于单一模型,即 VMD 分解技术不仅提高了 LSTM 模型的预测精度,且延 长了预见期。



图 4 单一模型和组合模型验证期预测值与实测值对比(唐乃亥站) Fig.4 Comparison of measured and predicted monthly runoffs with LSTM and VMD-LSTM model during validation (Tangnaihai Station)

表 3	单一模型和组合	合模型在各7	卜文站验证期	期预测效果对	ťŁ

Table 3	Comparison	of	prediction	performances	between	LSTM	and	VMD-	-LSTM	model
			P	F						

of each	hydrological	station	during	the	validation	period
or cach	nyurongicar	station	uunng	unc	vanuation	periou

预见期	模型	误差指标	唐乃亥站	民和站	享堂站	红旗站	折桥站
Forecast period	Model	Error indicator	Tangnaihai	Minhe	Xiangtang	Hongqi	Zheqiao
	терм	$RMSE/(10^8 \text{ m}^3)$	6.411	14.793	32.533	52.382	9.919
1 month	LSTM	NSE	0.748	0.720	0.738	0.598	0.682
1-month	VMD ISTM	$RMSE/(10^8 m^3)$	3.531	8.016	14.095	25.843	4.971
	V WID-LSTW	NSE	0.922	0.918	0.949	0.898	0.919
	терм	$RMSE/(10^8 m^3)$	7.567	16.678	35.667	63.554	11.290
2_month	LSIM	NSE	0.650	0.646	0.689	0.404	0.589
2-month	VMD ISTM	$RMSE/(10^8 m^3)$	3.795	8.835	15.354	28.370	5.369
	VMD-LSIM	NSE	0.910	0.899	0.940	0.878	0.906
3-month	терм	$RMSE/(10^8 m^3)$	7.779	17.014	36.734	68.021	11.371
	LSTM	NSE	0.637	0.634	0.665	0.317	0.586
	VMD ISTM	$RMSE/(10^8 m^3)$	3.807	11.811	15.376	35.208	5.803
	VMD-LS1M	NSE	0.910	0.821	0.940	0.813	0.890

4.2 融合大气环流前后组合模型预测效果对比

ł

上述研究表明,VMD-LSTM 组合模型相较于单 一 LSTM 模型能更准确的预测未来 1~3 个月的径 流。为了进一步提高模型预测精度,将所筛选的 4 项大气环流因子作为 VMD-LSTM 模型输入项的增 加项,对 5 个水文站进行 1~3 个月预见期的月径流 预测。鉴于 BP 神经网络和支持向量回归(SVR)模 型在径流预测方面的优势^[14-15,23-26],分别构建基于 VMD 分解的 VMD-BP 和 VMD-SVR 组合模型作为 对比模型,以进一步评价 VMD-LSTM 模型在融合大 气环流因子前后的预测性能。

3种组合模型融合大气环流因子前后验证期的 预测结果如表4所示。由表4可以看出:(1)融合 大气环流前,VMD-LSTM模型在各水文站的预测效 果均明显优于 VMD-BP 和 VMD-SVR模型,且 VMD-SVR模型的预测效果略优于 VMD-BP模型, 并且随着预见期的增加, VMD-LSTM 模型预测精度 呈缓慢下降趋势,而 VMD-BP 和 VMD-SVR 模型预 测精度迅速下降。这可能是因为 BP 和 SVR 模型无 法准确获取时间序列的波动特性,因此前一刻的数 据信息只能反映在当前时刻,而 LSTM 模型既能获 得近期也能捕捉到早期的径流特性,能较为准确的 获取到径流时间序列的波动特性,可有效延长模型 的预见期。(2)3种模型融合大气环流后预测精度 均得到不同程度的提高,且相较于 LSTM 模型, BP 和 SVR 模型在融合大气环流后预测精度提升幅度 更大,尤其是在增加预见期后,大气环流对这两种 模型预测精度的提高尤为明显。特别是在民和站, 当预见期为3个月时,VMD-SVR和VMD-BP模型 在融合大气环流前其 NSE 仅为-0.035 和-0.014.融 合大气环流后两模型的 NSE 均提高到 0.7 以上,且 RMSE 减少了近 50%。这可能是因为大气环流对某 一区域气候的影响持续时间较长,所以前一时期的 大气环流因子对今后很长一段时间的气候均有影 响,进而通过水循环过程对径流产生影响。所以在 预见期增加的情况下,前期历史径流对后面几个月 的径流影响减小,模型预测精度逐渐降低,而大气环 流因子对后面几个月的径流仍然具有一定的影响,所 以在融合大气环流因子后,预见期越长其预测精度提 高越明显。(3)融合大气环流因子前后,3种模型在 唐乃亥站和享堂站的预测效果均优于其他水文站,且 在唐乃亥站的预测效果要略优于享堂站,这可能与站 点所处地理位置有关,唐乃亥站和享堂站分别位于黄 河源区和大通河流域下游,所在地区无较大引用水设 施,受人类活动扰动小,所以模型能较好的识别出径 流序列的规律特性,进而得到较高的预测精度。

尽管大气环流因子能显著提高 VMD-BP 和 VMD-SVR 模型的预测精度,而对 VMD-LSTM 模型 预测效果的改善没有其他两种模型明显,但最终的 预测结果表明,融合大气环流前后,VMD-LSTM 模 型在各水文站及各预见期情况下的预测精度均明 显高于其他两类模型。

Table 4 Predicted results of each model before and after integrating atmospheric circulation factors

水文站 Hydrological station	预见期 Forecast period	误差指标 Error indicator	VMD-LSTM	VMD-SVR	VMD-BP
		$RMSE/(10^8 \text{ m}^3)$	3.531→2.665	7.094→5.465	7.537→5.517
	1-month	NSE	0.922→0.956	0.682→0.811	0.641→0.808
唐乃亥站		$RMSE/(10^8 \text{ m}^3)$	3.795→3.276	10.179→6.581	10.340→7.076
Tangnaihai	2-month	NSE	0.910→0.933	0.349→0.728	0.329→0.685
	a 1	$RMSE/(10^8 \text{ m}^3)$	3.807→3.457	11.845→7.575	11.953→8.289
	3-month	NSE	0.910→0.926	0.124→0.642	0.109→0.571
		$RMSE/(10^8 m^3)$	8.016→6.572	18.660→11.660	19.101→11.965
	1-month	NSE	0.918→0.945	0.556→0.826	0.534→0.817
民和站	0	$RMSE/(10^8 \text{ m}^3)$	8.835→9.607	26.040→12.952	24.518→13.476
Minhe	2-month	NSE	0.899→0.881	0.130→0.785	0.228→0.767
	2	$RMSE/(10^8 \text{ m}^3)$	11.811→9.804	28.296→14.312	27.997→14.836
	3-month	NSE	0.821→0.877	-0.035→0.735	-0.014→0.715
	1-month	$RMSE/(10^8 \mathrm{m}^3)$	14.095→13.530	40.568→30.757	40.325→34.246
		NSE	0.949→0.953	0.627→0.786	0.632→0.734
享堂站	2-month 3-month	$RMSE/(10^8 \mathrm{m}^3)$	15.354→14.220	47.928→34.918	49.743→40.071
Xiangtang		NSE	0.940→0.948	0.441→0.703	0.398→0.610
		$RMSE/(10^8 \mathrm{m^3})$	15.376→14.598	49.068→34.337	51.312→40.358
		NSE	0.940→0.946	0.384→0.698	0.326→0.583
	1-month	$RMSE/(10^8 \text{ m}^3)$	25.843→24.199	51.271→45.139	52.413→45.288
		NSE	0.898→0.911	0.602→0.692	0.584→0.689
红旗站	2 month	$RMSE/(10^8 \text{ m}^3)$	28.370→27.908	63.543→46.164	66.494→53.120
Hongqi	2-month	NSE	0.878→0.882	0.385→0.675	0.327→0.570
	3-month	$RMSE/(10^8 m^3)$	35.208→32.428	68.736→51.726	71.756→55.575
	5-month	NSE	0.813→0.842	0.282→0.593	0.217→0.531
折桥站	1_month	$RMSE/(10^8 \mathrm{m^3})$	4.971→4.243	10.752→8.163	11.157→8.782
	1-month	NSE	0.919→0.941	0.618→0.780	0.588→0.745
	2_month	$RMSE/(10^8 m^3)$	5.369→4.789	13.431→7.981	13.794→9.424
Zheqiao	2-monu	NSE	0.906→0.926	0.406→0.790	0.373→0.708
	3-month	$RMSE/(10^8 \text{ m}^3)$	5.803→5.281	14.989→8.422	15.385→7.389
		NSE	0.890→0.909	0.265→0.768	0.226→0.629

注:箭头左侧和右侧分别表示融合大气环流因子前、后的预测结果。

Note: The data on the left and right of the arrow represent the predicted results before and after integrating the atmospheric circulation factors, respectively.

为了更直观地展示 3 种组合模型的预测效果, 以唐乃亥站为例,融合大气环流因子后各模型在验 证期的预测结果如图 5 所示。从图 5 看出,当预见 期为 1 个月时,3 种模型均能较好地预测出径流的 未来变化趋势,其中 VMD-LSTM 模型的预测效果最 佳,其他两种模型在峰值和谷值的预测效果明显不 如 VMD-LSTM 模型。随着预见期的增加,VMD-LSTM 模型的预测值与实测值之间依然保持高度的 吻合,而 VMD-BP 和 VMD-SVR 模型在 2、3 个月预 见期时模型的预测值明显偏离了实测值,具体表现 为图像的平移错位,即存在延迟问题。由此可见, VMD-LSTM 模型相较于其他两种模型不仅具有更 高的预测精度而目能有效避免预测延迟问题。

以上结果进一步表明 VMD-LSTM 模型的预测 性能优于 VMD-BP 和 VMD-SVR 模型,且融合大气 环流因子后模型的预测效果有了进一步的改善,可 为该区月径流预测提供准确可靠的理论参考。

5 结 论

(1) VMD 分解技术能显著提高 LSTM 模型的预测精度,且相较于单一的 LSTM 模型, VMD-LSTM 组合模型不仅能改善峰值的预测效果,同时能使模型在较长预见期下仍能保持较高的预测精度。

(2)在基于 VMD 分解技术的混合模型中,3 种 混合模型的预测精度由高到低依次为 VMD-LSTM> VMD-SVR>VMD-BP。

(3) 在 3 种混合模型的预报因子中增加筛选后 的大气环流因子,各站点及各模型的预测精度均得 到了不同程度的提高,尤其是 VMD-BP 和 VMD-SVR 模型提高的最为明显,说明有效的大气环流因 子可以显著提高月径流预测精度,且 3 种模型在受 人类活动干扰较小的唐乃亥站及享堂站的预测效 果更优。





(4)本研究提出的 VMD-LSTM 模型在融合大 气环流前后均优于 VMD-SVR 和 VMD-BP 模型,其 突出优点表现在预见期增加的情况下模型的预测 精度并没有发生明显的减小,避免了 VMD-BP 和 VMD-SVR 在预见期增加时存在的延迟问题,在提 高月径流预测精度的同时延长了预见期。

鉴于 VMD-LSTM 模型良好的径流预测性能,也 可将该模型应用于填补数据缺失的径流时间序列 中,插补或延长数据序列。为进一步提高月径流的 预测精度,可在模型的输入因子中加入其他气象数 据,同时采用优化算法来寻求 LSTM 模型的最优 参数。

参考文献:

FENG R, FAN G W, LIN J Y, et al. Enhanced long Short-Term memory model for runoff prediction [J]. Journal of Hydrologic Engineering, 2021, 26(2): 04020063.

[2] 李红波,夏潮军,王淑英.中长期径流预报研究进展及发展趋势[J]. 人民黄河,2012,34(8):36-38,40.
LI H B, XIA C J, WANG S Y. Research progress and development trend of medium-long term runoff forecasting[J]. Yellow River, 2012, 34(8): 36-38, 40.

[3] 郝丽娜,粟晓玲,黄巧玲.基于小波广义回归神经网络耦合模型的月径流预测[J].水力发电学报,2016,35(5):47-54.
 HAO L N, SU X L, HUANG Q L. Monthly runoff prediction using wavelet transform and generalized regression neural network model[J].

Journal of Hydroelectric Engineering, 2016, 35(5): 47-54.

[4] 陆旻皎.新安江模型研究的回顾和展望[J].水利学报,2021,52(4): 432-441.

LU M J. Recent and future studies of the Xinanjiang Model[J]. Journal of Hydraulic Engineering, 2021, 52(4): 432-441.

[5] 刘睿翀,霍艾迪,CHEN X H,等.基于 SUFI-2 算法的 SWAT 模型在 陕西黑河流域径流模拟中的应用[J].干旱地区农业研究,2014,32 (5):213-217,222.

LIU R C, HUO A D, CHEN X H, et al. Application of the SWAT model into the runoff simulation based on SUFI-2 Algorithm in Heihe river basin of Shaanxi Province[J]. Agricultural Research in the Arid Areas, 2014, 32(5): 213-217, 222.

- [6] DANIEL E B, CAMP J V, LEBOEUF E J, et al. Watershed modeling and its applications: a state-of-the-art review [J]. The Open Hydrology Journal, 2011, 5(1): 26-50.
- [7] 廖明,詹总谦,呙维,等.动态数据驱动模式下的湖泊流域降雨径流 模拟[J].遥感学报,2019,23(5):911-923.
 LIAO M, ZHAN Z Q, GUO W, et al. Study on rainfall-runoff simula-

tion and prediction in lake basin based on dynamic data-driven deep recurrent network [J]. Journal of Remote Sensing, 2019, 23(5): 911-923.

[8] FENG Z K, NIU W J, TANG Z Y, et al. Monthly runoff time series prediction by variational mode decomposition and support vector machine based on quantum-behaved particle swarm optimization [J]. Journal of Hydrology, 2020, 583: 124627.

[9] 李彦彬,黄强,徐建新,等.河川径流中长期预测的支持向量机模型

[J].水力发电学报,2008,(5):28-32.

LI Y B, HUANG Q, XU J X, et al. Support vector machine model of mid-long-term prediction of runoff in stream [J]. Journal of Hydroelectric Engineering, 2008, (5): 28-32.

- [10] LIU Z N, LI Q F, ZHOU J N, et al. Runoff prediction using a novel hybrid ANFIS model based on variable screening [J]. Water Resources Management, 2021, 35(9): 2921-2940.
- [11] 覃光华,宋克超,周泽江,等.基于 WA-GRNN 模型的年径流预测
 [J].四川大学学报(工程科学版),2013,45(6):39-46.
 QIN G H, SONG K C, ZHOU Z J, et al. Research on annual runoff prediction based on WA-GRNN Model[J]. Journal of SichuanUniversity (Engineering Science Edition), 2013, 45(6): 39-46.
- [12] 孙娜,周建中.基于正则极限学习机的非平稳径流组合预测[J].水 力发电学报,2018,37(8);20-28.
 SUN N, ZHOU J Z. Hybrid forecasting model for non-stationary runoff based on regularized extreme learning machine[J]. Journal of Hydroelectric Engineering, 2018, 37(8); 20-28.
- [13] LIN J Y, CHENG C T, CHAU K W. Using support vector machines for long-term discharge prediction[J]. Hydrological Sciences Journal, 2006, 51(4): 599-612.
- [14] 王广宇, 解建仓, 张建龙.GA-BP 组合预测方法在北洛河年径流量 预测中的应用[J].干旱地区农业研究, 2014, 32(1):203-207.
 WANG G Y, XIE J C, ZHANG J L. Application of GA-BP combination forecasting method into the annual runoff prediction of Beiluo River[J]. Agricultural Research in the Arid Areas, 2014, 32(1): 203-207.
- [15] LI Z H, KANG L, ZHOU L W, et al. Deep learning framework with time series analysis methods for runoff prediction [J]. Water, 2021, 13(4):575.
- [16] 陶思铭,梁忠民,陈在妮,等.长短期记忆网络在中长期径流预报中的应用[J].武汉大学学报(工学版),2021,54(1):21-27.
 TAO S M, LIANG Z M, CHEN Z N, et al. Application of long-short term memory network in medium-long term runoff forecast[J]. Engineering Journal of Wuhan University, 2021, 54(1): 21-27.
- [17] YUAN R F, CAI S Y, LIAO W H, et al. Daily runoff forecasting using ensemble empirical mode decomposition and long short-term memory[J]. Frontiers in Earth Science, 2021, 9: 621780.
- [18] 蔡文静,陈伏龙,何朝飞,等.基于时频分析的 LSTM 组合模型径流 预测[J].干旱区地理,2021,44(6):1696-1706.
 CAI W J, CHEN F L, HE C F, et al. Runoff prediction with LSTMbased combination model on time-frequency analysis[J]. Arid Land Geography, 2021, 44(6): 1696-1706.
- [19] 胡庆芳,曹士圯,杨辉斌,等.汉江流域安康站日径流预测的 LSTM 模型初步研究[J].地理科学进展,2020,39(4):636-642.
 HU Q F, CAO S Y, YANG H B, et al. Daily runoff predication using LSTM at the Ankang Station, Hanjing River[J]. Progress in Geography,2020, 39(4): 636-642.
- [20] GAO S, HUANG Y F, ZHANG S, et al. Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation [J]. Journal of Hydrology, 2020, 589: 125188.
- [21] YUAN X H, CHEN C, LEI X H, et al. Monthly runoff forecasting based on LSTM - ALO model [J]. Stochastic Environmental Research and Risk Assessment, 2018,32(8): 2199-2212.

- [22] 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.
 LIANG H, HUANG S Z, MENG E H, et al. Runoff prediction based on multiple hybrid models [J]. Journal of Hydraulic Engineering, 2020, 51(1): 112-125.
- [23] WANG W C, CHAU K W, QIU L, et al. Improving forecasting accuracy of medium and long-term runoff using artificial neural network based on EEMD decomposition [J]. Environmental Research, 2015, 139: 46-54.
- [24] 黄巧玲,粟晓玲.基于小波支持向量机耦合的月径流预测方法[J].
 水力发电学报,2015,34(3):1-7,20.
 HUANG Q L, SU X L. Wavelet support vector machine-coupling method for monthly runoff forecasting [J]. Journal of Hydroelectric Engineering, 2015, 34(3): 1-7, 20.
- [25] 孟二浩,黄生志,黄强,等.融合大气环流异常因子的径流预报研究
 [J].水力发电学报,2017,36(8):34-42.
 MENG E H, HUANG S Z, HUANG Q, et al. Runoff prediction incorporating anomalous atmospheric circulation factors[J]. Journal of Hydroelectric Engineering, 2017, 36(8): 34-42.
- [26] 李福兴,陈伏龙,蔡文静,等.基于 EMD 组合模型的径流多尺度预测[J].地学前缘,2021,28(1):428-437.
 LI F X, CHEN F L, CAI W J, et al. Multi-scale prediction of runoff based on EMD combined model[J]. Earth Science Frontiers, 2021,

(上接第250页)

- [22] 张蕾,侯英雨,郑昌玲,等.作物长势评估指数的设计与应用[J].应用气象学报,2019,30(5):543-554.
 ZHANG L, HOU Y Y, ZHENG C L, et al. The construction and application of assessing index to crop growing condition[J]. Journal of Applied Meteorological Science, 2019, 30(5):543-554.
- [23] 毛留喜,魏丽.大宗作物气象服务手册[M].北京:气象出版社, 2015:4-5.
 MAO L X, WEI L. Bulk crop meteorological service manual [M].

Beijing: China Meteorological Press, 2015: 4-5.

- [24] 刘维, 王冬妮, 侯英雨, 等. 基于吉林省观测土壤水分的 WOFOST 模型模拟研究[J]. 气象, 2018, 44(10): 1352-1359.
 LIU W, WANG D N, HOU Y Y, et al. Simulation research of WO-FOST model based on observed soil moisture data in Jilin Province
 [J]. Meteorological Monthly, 2018, 44(10): 1352-1359.
- [25] 郑昌玲,侯英雨,吴门新,等.基于 WOFOST 模型的华北冬小麦 动态长势评估指标构建[J].麦类作物学报,2020,40(6):746-753. ZHENG C L, HOU Y Y, WU M X, et al. Dynamic evaluation index of winter wheat growth in North China Plain based on WOFOST Model[J]. Journal of Triticeae Crops. 2020, 40(6): 746-753.
- [26] SUIPIT I, HOOJER A A, DIEPEN C A V. System description of the WOFOST 6.0 crop simulation model implemented in CGMS. Volume 1: theory and algorithms [M]. Luxembourg: Office for the Official Publications of the European Communities, 1994.
- [27] 杨妍辰,王建林,宋迎波. WOFOST 作物模型机理及使用介绍
 [J]. 气象科技进展,2013,3(5):29-35.
 YANG Y C, WANG J L, SONG Y B. Introduction of WOFOST crop

28(1): 428-437.

- [27] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [28] 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.
 LI W W, SHI Q, WANG K, et al. Runoff prediction based on variational mode decomposition and deep gated network[J]. Journal of Hydroelectric Engineering, 2020, 39(3): 34-44.
- [29] 吴娟,朱跃龙,金松,等.三种机器学习模型在太湖藻华面积预测中的应用[J].河海大学学报(自然科学版),2020,48(6):542-551.
 WU J, ZHU Y L, JIN S, et al. Area prediction of cyanobacterial blooms based on three machine learning methods in Taihu Lake[J]. Journal of Hohai University (Natural Sciences), 2020, 48(6): 542-551.
- [30] GAUCH M, KRATZERT F, KLOTZ D, et al. Rainfall-runoff prediction at multiple timescales with a single Long Short-Term Memory network[J]. Hydrology and Earth System Sciences, 2021, 25(4): 2045-2062.
- [31] 陶凯,吴定会.基于 VMD-JAYA-LSSVM 的短期风电功率预测[J]. 控制工程,2021,28(6):1143-1149.
 TAO K, WU D H. Application of VMD-SWT joint algorithm in fault traveling wave detection[J]. Control Engineering of China, 2021, 28 (6): 1143-1149.

growth simulation model mechanism and its use[J]. Advances in Meteorological Science and Technology, 2013, 3(5): 29-35.

[28] 何亮,侯英雨,赵刚,等. 基于全局敏感性分析和贝叶斯方法的
 WOFOST 作物模型参数优化[J]. 农业工程学报, 2016, 32(2):
 169-179.
 HE L, HOU Y Y, ZHAO G, et al. Parameters optimization of WO-

FOST model by integration of global sensitivity analysis and Bayesian calibration method [J]. Transactions of the Chinese Society of Agricultural Engineering, 2016, 32(2): 169-179.

[29] 黄健熙, 贾世灵, 马鸿元, 等. 基于 WOFOST 模型的中国主产区 冬小麦生长过程动态模拟[J]. 农业工程学报, 2017, 33(10): 222-228.

HUANG J X, JIA S L, MA H Y, et al. Dynamic simulation of growth process of winter wheat in main production areas of China based on WOFOST model[J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 33(10): 222-228.

- [30] 李颖,赵国强,陈怀亮,等.基于冬小麦农业气候分区的 WOFOST 模型参数标定[J].应用气象学报,2021,32(1):38-51.
 LI Y, ZHAO G Q, CHEN H L, et al. WOFOST model parameter calibration based on agro-climatic division of winter wheat[J]. Journal of Applied Meteorological Science, 2021, 32(1):38-51.
- [31] 刘维, 孟翠丽, 宋迎波. 冬小麦观测产量与统计产量的差异性分析[J]. 中国农业气象, 2021, 42(2): 123-133.
 LIU W, MENG C L, SONG Y B. Studies on the difference of observed yield and statistical yield of winter wheat [J]. Chinese Journal of Agrometeorology, 2021, 42(2): 123-133.