

DOI:10.11705/j.issn.1672-643X.2023.04.10

基于 ASWPD - BO - GRU 的月径流量预测模型

唐铭泽, 杨银科, 张菁雯

(长安大学 水利与环境学院 旱区地下水文与生态效应教育部重点实验室, 陕西 西安 710054)

摘要: 为提高月径流量预测精度,并针对传统分解集成径流预测模型错误使用未来数据的问题,提出并建立了基于自适应小波包分解(ASWPD)和贝叶斯优化(BO)的门控循环单元(GRU)月径流量预测模型(ASWPD-BO-GRU)。首先,利用ASWPD对原始月径流量时间序列进行分解,在不使用未来数据的前提下得到4个相对规律的分解子序列,以降低预测难度;然后,利用BO优选分解后的子序列对应的GRU模型超参数;最终,对每个子序列进行预测,将预测结果相加重组得出月径流量预测结果。将提出并建立的模型应用于黑河流域莺落峡水文站月径流量预测中,并与GRU、BO-GRU、WPD-BO-GRU模型(基于传统分解思想对原始月径流量时间序列整体进行分解的预测模型)的预测结果进行对比。结果表明:ASWPD-BO-GRU模型的纳什效率系数(NSE)为0.89,在实例应用中预测精度最高,说明ASWPD-BO-GRU模型在正确分解的前提下具有较高的预测精度和更强的泛化能力。

关键词: 月径流量预测; 自适应动态分解策略; 小波包分解; 贝叶斯优化; 门控循环单元

中图分类号:TV121⁺4; P338⁺.2 文献标识码:A 文章编号:1672-643X(2023)04-0084-08

Monthly runoff prediction model based on ASWPD - BO - GRU

TANG Mingze, YANG Yinke, ZHANG Jingwen

(Key Laboratory of Subsurface Hydrology and Ecological Effects in Arid Region, School of Water and Environment, Chang'an University, Xi'an 710054, China)

Abstract: To improve the accuracy of monthly runoff prediction and to address the problem that the conventional decomposition integrated runoff prediction models incorrectly uses future data, a gated recurrent unit (GRU) monthly runoff prediction model (ASWPD-BO-GRU) based on self-adaptation strategy wavelet packet decomposition (ASWPD) and Bayesian optimization (BO) is proposed and developed. First, in order to reduce the prediction difficulty the original monthly runoff time series is decomposed using ASWPD, by which four relatively regular decomposed subseries are obtained without using future data. Then, the hyperparameters of the GRU model corresponding to the decomposed subseries are optimized using BO. Finally, the monthly runoff prediction results are obtained by predicting each subseries and summing and reorganizing the prediction results. The proposed and established model is applied to the prediction of monthly runoff at Yingluoxia Hydrological Station in the Heihe River Basin, and the prediction results are compared with those of GRU, BO-GRU, and WPD-BO-GRU models (models based on the conventional decomposition idea which decomposes the original monthly runoff time series as a whole). The results show that the Nash-Sutcliffe efficiency coefficient (NSE) of ASWPD-BO-GRU model is 0.89, which has the highest prediction accuracy in the example application, indicating that the ASWPD-BO-GRU model has higher prediction accuracy and stronger generalization ability with correct decomposition.

Key words: monthly runoff prediction; self-adaptation decomposition strategy (AS); wavelet packet decomposition (WPD); Bayesian optimization (BO); gated recurrent unit (GRU)

收稿日期:2023-03-01; 修回日期:2023-04-05

基金项目:长安大学中央高校基本科研业务费专项资金项目(300102292903);中国科学院黄土与第四纪地质国家重点实验室开放基金项目(SKLLQG1933);陕西省自然科学基金基础研究计划项目(2017JM4018、2021SF497)

作者简介:唐铭泽(1998—),男,陕西西安人,硕士研究生,主要从事水文水资源方面的研究。

通讯作者:杨银科(1977—),男,陕西宝鸡人,博士,副教授,主要从事水文水资源方面的研究。

1 研究背景

准确有效的径流预测对区域水资源水量安全评价、水资源的科学配置以及防洪减灾决策等均具有重要的意义。然而,受全球气候变化及高强度人类活动等因素的综合影响,径流时间序列呈现出复杂的非线性、非平稳性特征,使径流预测难度加大^[1]。因此,探索高精度且可靠的径流预测模型成为现阶段径流预测领域亟需解决的现实问题。

目前常用的径流预测模型有过程驱动模型、数理统计模型和神经网络模型等。相比于过程驱动模型和数理统计模型,神经网络模型因其具有良好的非线性映射能力^[2]、无需考虑水文过程的物理机制且能适应复杂时间序列数据,在解决径流预测方面有独到的优势^[3-4]。

门控循环单元(gated recurrent unit, GRU)为神经网络中深度学习的代表技术之一,其对长短期记忆神经网络(long short-term memory, LSTM)模型的结构进行了改进,在保证预测精度的同时还拥有了更快的收敛速度^[5-6]。然而,GRU 的性能在很大程度上受模型超参数设置的影响,且由于原始径流时间序列具有一定的趋势性、周期性和随机性特征^[7],使用单一模型进行径流预测会导致 GRU 的性能不能充分发挥和无法充分捕捉原始径流时间序列中的重要信息,在许多领域中对时间序列进行预测时也都面临着此类问题。在以往的研究中,通常有两种方法来提高 GRU 的预测精度:(1)使用优化算法优化模型超参数。如:使用粒子群算法、黏菌算法、布谷鸟搜索算法、麻雀优化算法、贝叶斯优化等优化算法确定模型的最优超参数^[8-12]。其中贝叶斯优化(Bayesian optimization, BO)作为一种新兴的超参数优化方法,能够以较少的迭代次数获得满意的优化结果,比网格搜索和随机搜索方法更有效^[13]; (2)使用数据分解技术与 GRU 构建分解集成模型。常用的数据分解技术有小波分解、经验模态分解、总体经验模态分解和小波包分解等^[14-16]。这些技术可以将具有多种规律特征的原始时间序列分解为一组相对平稳且简单的子序列,从而降低模型的预测难度。其中小波包分解(wavelet packet decomposition, WPD)具有可以人为选择分解层数和分解使用的小波函数等优点,并且能够同时对信号的低频和低频部分进行分解^[17-18],进而提升了预测模型的精度。

正确建立分解集成模型是进行径流预测的前

提,目前很多研究直接对原始径流时间序列整体使用数据分解技术,这种分解策略会导致分解子序列中每一个时间节点上的数据都包含了来自未来不可获取的数据信息^[19-21],从而产生数据泄露问题。所以直接对整个原始径流时间序列使用数据分解技术是不现实的,难以满足实际预测需求。为了解决这一问题,熊怡等^[22]设计了一种自适应动态分解策略(self-adaptation decomposition strategy, AS),这种策略是利用观测数据来更新历史样本,在数据分解中避免了引入未来信息,并提升了径流预测的精度。

综上所述,基于目前径流预测中存在的问题,本文首先采用 AS 策略对原始月径流量时间序列进行 WPD 分解,称为自适应小波包分解(self-adaptation strategy wavelet packet decomposition, ASWPD)。在不使用未来数据的前提下,充分提取原始月径流量时间序列中的数据特征,以降低预测难度。然后使用 BO 对 GRU 进行超参数优化,提出并建立了基于 ASWPD-BO-GRU 的月径流量预测模型。以黑河流域莺落峡水文站月径流量预测为实例(预见期为 1 个月)进行模型应用研究,以期对月径流量预测提供一条新思路。

2 数据来源与研究方法

2.1 研究区概况

莺落峡水文站位于甘肃省张掖市甘州区龙渠乡,集水面积为 10 009 km²,多年平均径流量为 49.225 9 m³/s,径流年内分配十分不均^[23]。莺落峡水文站作为黑河上游祁连山出山径流的主控水文站,其径流量的多少直接影响着黑河流域经济社会的发展和生态环境的保护。

2.2 数据来源

本文的月径流量数据来源于国家冰川冻土沙漠科学数据中心(<http://www.ncdc.ac.cn>)提供的黑河流域莺落峡水文站逐月逐年径流资料数据集^[24]。从中选取莺落峡水文站 1964 年 1 月—2016 年 12 月(共 636 个月)的月径流量数据作为研究对象,将 1964 年 1 月—2006 年 12 月(共 516 个月)的月径流量数据划分为模型训练集,将 2007 年 1 月—2016 年 12 月(共 120 个月)的月径流量数据划分为模型测试集。

2.3 研究方法

2.3.1 小波包分解(WPD) WPD 是在小波分解(wavelet decomposition, WD)的基础上产生并得以发展的,与 WD 不同的是,WPD 在分解信号低频部分

的同时,也对高频部分继续分解,并且能够根据信号特征和分析需求,自适应选取对应的频带来匹配信号的频谱,从而具有更广泛的应用价值。WPD 算法公式如下^[17,25-26]:

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

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, $n \in \{2^j - 1, 2^j - 2, \dots, 0\}$; h_{k-2l} 、 g_{k-2l} 分别为小波包分解中的低通、高通滤波器组。

重建算法为:

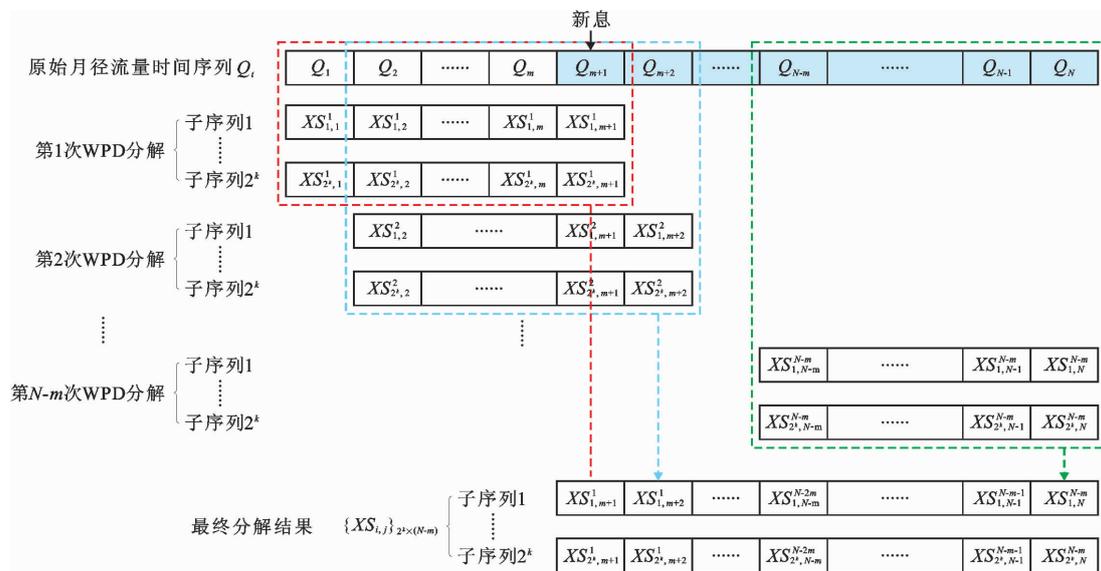


图1 自适应小波包分解(ASWPD)的分解步骤示意图

设原始月径流量时间序列为 $Q_t, t = 1, 2, \dots, N$ 。

Step 1: 对小波包分解算法的分解层数 k 和母小波函数进行设定;

Step 2: 对分解序列的起始长度 m 进行设定, 随着新息的依次添加, 待分解序列始终以 $m+1$ 个长度滚动分解;

Step 3: 将 Q_m 后的数据按顺序作为新息添加到待分解序列的末端, 同时将待分解序列的首个数据移出, 保持待分解序列长度为 $m+1$ 并进行 WPD 分解。具体为, 第 1 次分解时, Q_{m+1} 作为新息加入待分解序列末端, 对 $m+1$ 个数据 Q_1, Q_2, \dots, Q_{m+1} 进行 k 层 WPD 分解, 分解为 2^k 个子序列 $\{XS_{i,j}^1\}_{2^k \times (m+1)}$, 将 $\{XS_{i,j}^1\}_{2^k \times (m+1)}$ 的最后一列元素 $\{XS_{i,m+1}^1\}_{2^k}$ 作为 Q_{m+1} 的分解分量; 随后加入新息 Q_{m+2} , 同时将 Q_1 移出待分解序列, 将序列 Q_2, Q_3, \dots, Q_{m+2} 分解为 2^k 个子序列 $\{XS_{i,j}^2\}_{2^k \times (m+1)}$, 将 $\{XS_{i,j}^2\}_{2^k \times (m+1)}$ 的最后一列元素

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

式中: $\bar{d}_l^{j,n}$ 为小波包重建后小波包系数; \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。

2.3.2 自适应小波包分解(ASWPD) 本文提出的自适应小波包分解(ASWPD)的机理是利用 AS 策略对原始月径流量时间序列进行 WPD 分解。其中, AS 在分解过程中避免了引入未来信息, 只要增加新息, 分解进程就会自适应调整。AS 的具体操作细节见参考文献[22]。因此, ASWPD 能在不引入未来信息的前提下发挥小波包分解提取信号中有效信息的能力。ASWPD 的具体分解步骤如图 1 所示。

$\{XS_{i,m+2}^2\}_{2^k}$ 作为 Q_{m+2} 的分解分量; 重复此过程直至得到最后一个数据 Q_N 的分解分量;

Step 4: 经过不断的滚动分解, 最终得到 2^k 个子序列, 记作 $\{XS_{i,j}^l\}_{2^k \times (N-m)}$, 用该组子序列进行 GRU 预测并重构。

2.3.3 贝叶斯优化(BO) BO 是一种全局优化算法, 适合解决多维、未知的复杂优化问题, 能够有效地对神经网络超参数进行寻优处理, 从而提高时间序列的预测精度。与随机搜索及网格搜索相比较, BO 能更加有效地解决优化问题^[13]。BO 的具体计算公式和细节见参考文献[27]。另外, 本文选用高斯过程和期望改进(EI)函数作为概率代理模型和采集函数。

2.3.4 门控循环单元(GRU) GRU 是 LSTM 的变体, 由更新门和重置门两个门结构组成。相比于 LSTM, GRU 简化了模型结构, 训练速度更快, 且保

持了 LSTM 的预测效果。GRU 的一个单元结构如图 2 所示。GRU 的具体计算公式和细节见参考文献[12]。

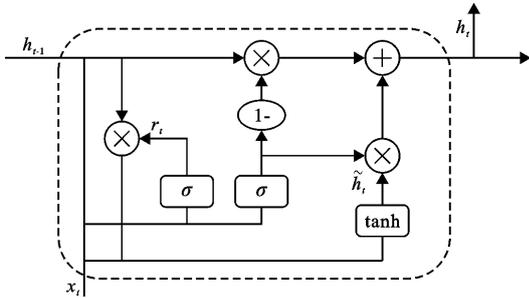


图2 门控循环单元(GRU)结构

2.3.5 预测模型构建流程

Step 1: 利用 ASWPD 进行原始月径流量时间序列分解。首先设置 WPD 的分解层数 k 和母小波函数以及待分解序列起始长度 m , 然后对原始月径流量时间序列进行 ASWPD 分解。得到 2^k 个分解子序列, 再将各个分解子序列进行训练期、测试期划分, 用于模型建模和测试;

Step 2: 数据预处理。为了提升模型的收敛速度, 需要对分解子序列数据进行标准化处理。计算公式为:

$$x_{\text{norm}} = \frac{x - \mu_{\text{tr}}}{\sigma_{\text{tr}}} \quad (3)$$

式中: x_{norm} 为标准化后的数据; μ_{tr} 为分解子序列中训练期数据的均值, 10^8 m^3 ; σ_{tr} 为分解子序列中训练期数据的标准差, 10^8 m^3 。

Step 3: 确定每个分解子序列 GRU 模型的输入、输出变量。对各分解子序列训练期数据使用偏自相关函数 (partial autocorrelation function, PACF) 确定 GRU 模型的输入变量, 输入变量的选取准则为^[28]: (1) 选择超出置信区间的 PACF 值对应的滞时变量作为输入; (2) 如果存在每个滞时变量对应的 PACF 值均在置信区间以外的情况, 则选择几个滞时小的变量作为输入。当确定了输入变量, 若 x_{i-i} 为输入变量, 则 x_i 即为输出变量。

Step 4: 利用 BO 确定各个分解子序列 GRU 模型的超参数。GRU 模型对超参数的选择非常敏感, 选择不当会在很大程度上影响 GRU 的性能, 甚至会引入模型过拟合问题; 如, GRU 隐藏层的层数和每层神经元的数量决定了 GRU 模型的结构; 学习率体现了每次参数更新的幅度大小; L2 正则化参数决定了模型的抗过拟合能力; 最大训练回合表征模型是否学习充分。因此, 设置 BO 的最大迭代次数, 并设

置目标函数为训练完成的 GRU 在训练集上的均方误差, 对各个分解子序列的 GRU 模型采用 BO 对上述 5 个超参数进行寻优。利用目标函数构建的优化问题如下:

$$\begin{cases} \min f(a, b, c, d, e) = \frac{1}{l} \sum_{i=1}^l (\hat{Y}_i - Y_i)^2 \\ \text{s. t } a \in [a_{\min}, a_{\max}], b \in [b_{\min}, b_{\max}], \\ c \in [c_{\min}, c_{\max}], d \in [d_{\min}, d_{\max}], \\ e \in [e_{\min}, e_{\max}] \end{cases} \quad (4)$$

式中: Y_i 为第 i 个月径流量预测值, 10^8 m^3 ; \hat{Y}_i 为与 Y_i 对应的第 i 个月径流量真实值, 10^8 m^3 ; l 为训练样本数量; a 为 GRU 隐藏层层数; b 为每层神经元个数; c 为学习率; d 为 L2 正则化参数; e 为最大训练回合数。

Step 5: 对各个分解子序列进行预测并叠加重构得到月径流量预测结果。采用筛选得到的各分解子序列的输入、输出变量和 GRU 模型超参数分别构建预测模型进行预测, 将预测结果反标准化后进行叠加重构得到最终月径流量预测结果。反标准化计算公式为:

$$x_{\text{denorm}} = x \sigma_{\text{tr}} + \mu_{\text{tr}} \quad (5)$$

式中: x_{denorm} 为反标准化后的数据, 10^8 m^3 ; μ_{tr} 为分解子序列中训练期数据的均值, 10^8 m^3 ; σ_{tr} 为分解子序列中训练期数据的标准差, 10^8 m^3 。

Step 6: 模型评价。选取纳什效率系数 (NSE)、平均绝对百分比误差 (MAPE)、平均绝对误差 (MAE)、均方根误差 (RMSE) 对模型预测结果进行评价。具体计算公式见文献[29]、[30]。

3 结果与分析

3.1 月径流量序列分解结果

对莺落峡水文站 1964 年 1 月—2016 年 12 月的径流量数据采用 ASWPD 进行分解, 根据模型训练期预测结果, 设置 ASWPD 中待分解序列起始长度 m 为 24, 分解层数 k 为 2, 母小波函数为 db4 小波基函数, 将原始月径流量时间序列分解为 M_1 、 M_2 、 M_3 、 M_4 共 4 个子序列。分解结果如图 3 所示。

3.2 模型输入变量选择

对分解子序列 M_1 、 M_2 、 M_3 、 M_4 的训练期数据依次使用 PACF 并遵循上述提到的准则进行 GRU 模型输入、输出变量的确定。各分解子序列的 PACF 值如图 4 所示, 最终各分解子序列 GRU 模型的输入、输出变量选择见表 1。

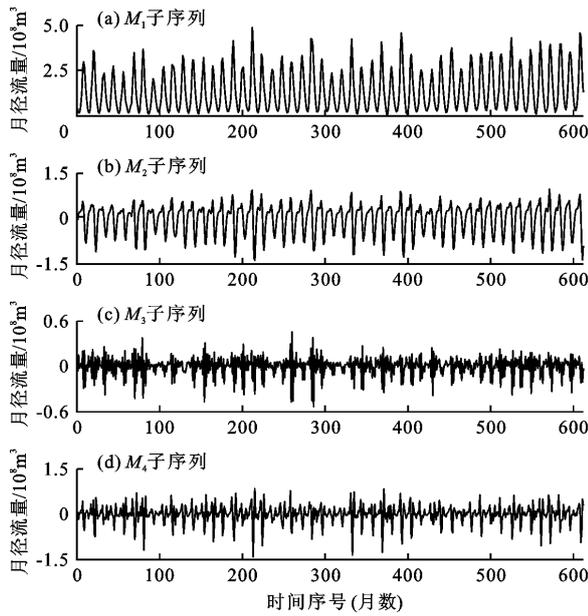


图3 原始月径流量时间序列 ASWPD 分解图 (1964-01—2016-12)

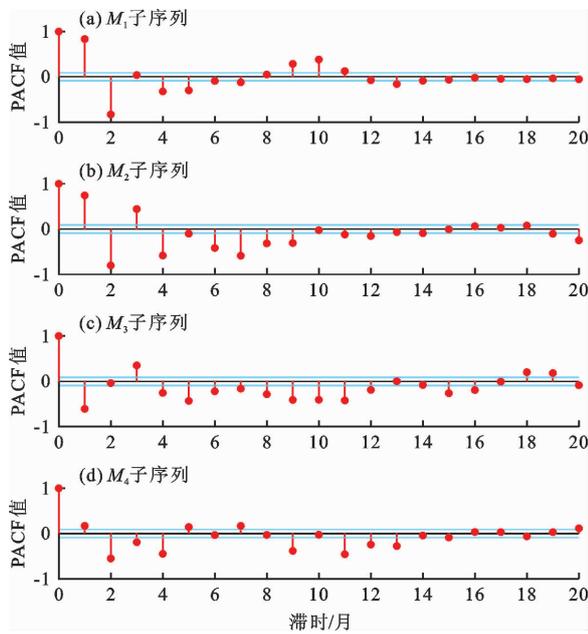


图4 各分解子序列 PACF 值

表1 各子序列输入、输出变量

子序列	输入变量	输出变量
M_1	$x_{t-1}, x_{t-2}, x_{t-4}, x_{t-5}, x_{t-7}, x_{t-9}, x_{t-10}, x_{t-11}$	x_t
M_2	$x_{t-1}, x_{t-2}, x_{t-3}, x_{t-4}, x_{t-5}, x_{t-6}, x_{t-7}, x_{t-8}, x_{t-9}, x_{t-11}, x_{t-12}$	x_t
M_3	$x_{t-1}, x_{t-3}, x_{t-4}, x_{t-5}, x_{t-6}, x_{t-7}, x_{t-8}, x_{t-9}, x_{t-10}, x_{t-11}, x_{t-12}$	x_t
M_4	$x_{t-1}, x_{t-2}, x_{t-3}, x_{t-4}, x_{t-5}, x_{t-7}, x_{t-9}, x_{t-11}, x_{t-12}$	x_t

3.3 模型参数设置

GRU 模型在对各分解子序列的训练过程中,优化器选择 Adam 算法;设置 batchsize 为 32;设置 Dropout 为 0.5,用于改善模型过拟合问题;设置 BO 的最大迭代次数为 100;设置 BO 优化 GRU 模型超参数时隐藏层层数、每层神经元数量、学习率、L2 正则化参数、最大训练回合数的寻优范围分别为 $[1, 4]$ 、 $[1, 200]$ 、 $[10^{-2}, 1]$ 、 $[10^{-10}, 10^{-2}]$ 、 $[1, 150]$,各分解子序列经 BO 寻优得到的超参数如表 2 所示。

表2 各子序列 GRU 模型最优超参数

子序列	隐藏层 层数	每层神经 元数量	学习率	L2 正则化参数	最大训练 回合数
M_1	1	70	0.0161	1.1662×10^{-5}	144
M_2	1	199	0.0232	1.4669×10^{-8}	148
M_3	1	200	0.0101	9.2942×10^{-10}	88
M_4	2	197	0.0103	2.7086×10^{-10}	149

3.4 预测结果及分析

为验证本文提出并建立的 ASWPD - BO - GRU 模型的预测效果,同时建立了 GRU 模型、BO - GRU 模型、WPD - BO - GRU 模型(基于传统分解思想对原始月径流量时间序列整体进行分解的预测模型)共 3 种对比模型,通过前文 2.3.5 节选取的 4 个评价指标对各模型预测结果进行评价。为在相同条件下进行对比验证,对 3 种对比模型均使用标准化处理数据并用 PACF 确定模型的输入、输出变量。对 GRU 模型通过人工经验确定模型的超参数;对 BO - GRU 模型设置 BO 算法的最大迭代次数为 100,由于 ASWPD - BO - GRU 模型中 BO 算法对超参数的寻优范围已足够广泛,所以对 BO - GRU 模型 5 个超参数寻优范围的设置与 ASWPD - BO - GRU 模型相同;对 WPD - BO - GRU 模型进行 3 层 WPD 分解,母小波函数为 db4 小波基函数,保证原始月径流量时间序列特征能被充分提取,BO 参数设置同上。

不同模型在测试期(2007 年 1 月—2016 年 12 月)对莺落峡水文站月径流量的预测结果见图 5,各评价指标的计算结果见表 3。

由图 5 可以看出,在测试期 GRU、BO - GRU、ASWPD - BO - GRU、WPD - BO - GRU 4 种模型对原始月径流量时间序列的拟合效果依次逐渐提高。其中,单一 GRU 模型的拟合效果最差,特别在原始月径流量时间序列的峰值和谷值处误差极大,预测效果不佳;BO - GRU 模型与原始月径流量时间序列

的波动趋势基本接近,相比于单一GRU模型,大幅减小了预测的峰值、谷值误差;ASWPD-BO-GRU模型相比于BO-GRU模型,对原始月径流量时间序列波动趋势的接近程度更好,尤其减少了预测的

峰值误差,有效提升了拟合精度;WPD-BO-GRU模型相比于其他3种模型,与原始月径流量时间序列的波动趋势最为接近,预测的峰值、谷值误差也最小,对原始月径流量时间序列的拟合精度最高。

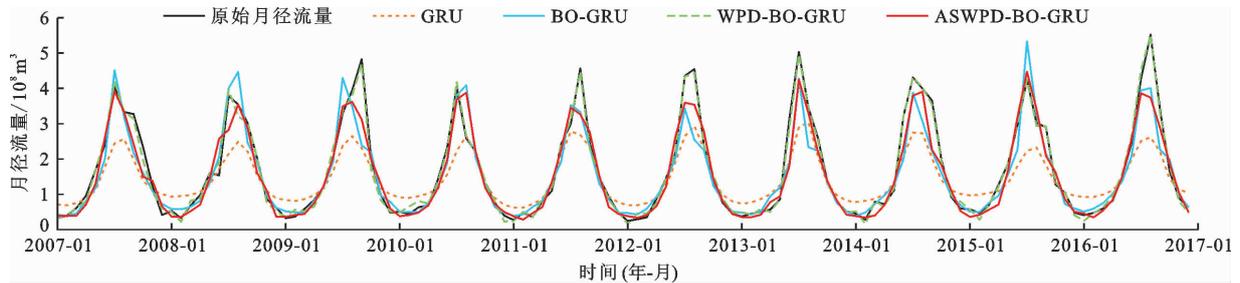


图5 莺落峡水文站测试期不同模型月径流量预测结果

表3 莺落峡水文站月径流量不同预测模型评价指标计算结果

模型	阶段	NSE	MAPE / MAE / RMSE /		
			%	10^8 m^3	10^8 m^3
ASWPD-BO-GRU	训练期	0.89	16.73	0.23	0.37
	测试期	0.89	18.37	0.28	0.45
WPD-BO-GRU	训练期	0.99	11.65	0.08	0.11
	测试期	0.99	10.25	0.09	0.12
BO-GRU	训练期	0.87	20.16	0.25	0.41
	测试期	0.83	22.41	0.35	0.56
GRU	训练期	0.77	34.95	0.37	0.56
	测试期	0.65	46.51	0.56	0.80

分析表3可以得出:GRU模型测试期的MAPE、MAE、RMSE分别为46.51%、 $0.56 \times 10^8 \text{ m}^3$ 、 $0.80 \times 10^8 \text{ m}^3$,相比于训练期分别增加了33.08%、51.35%、42.86%,GRU模型测试期的NSE为0.65,相比于训练期减少了15.58%,说明GRU模型出现了一定程度的过拟合问题;BO-GRU模型测试期的MAPE、MAE、RMSE相比于GRU模型分别减少了51.82%、37.50%、30.00%,NSE相比于GRU模型提升了27.69%,与GRU模型相比,BO-GRU模型4个评价指标的训练期与测试期差距也大幅减小;ASWPD-BO-GRU模型测试期的MAPE、MAE、RMSE相比于BO-GRU模型分别减少了18.03%、20.00%、19.64%,NSE相比于BO-GRU模型提升了7.23%;WPD-BO-GRU模型测试期的MAPE、MAE、RMSE相比于ASWPD-BO-GRU模型分别减少了44.2%、67.5%、73.33%,NSE相比于ASWPD-BO-GRU模型提升了11.24%。

上述预测结果与分析表明,BO-GRU模型的预测精度要远高于GRU模型,并且还在一定程度上抑

制了单一GRU模型的过拟合问题,提升了泛化能力和预测性能。ASWPD-BO-GRU模型的预测精度要远高于BO-GRU模型,说明ASWPD在数据分解过程中虽然没有使用未来数据信息,但仍能提升模型的预测精度。WPD-BO-GRU模型的预测精度最高,但由于WPD-BO-GRU模型在对原始月径流量时间序列分解时引入了未来数据信息,发生了数据泄露问题,所以才产生了虚高的预测结果,因而无法在实际中应用。而本文提出的ASWPD-BO-GRU模型是在正确分解的基础上建立的,不会发生数据泄露问题,并且NSE接近0.9,说明该模型具有较高的预测精度,相比于其他3个预测模型能更好地应用于实际中。

4 讨论

本文对莺落峡水文站月径流量的预测结果表明,ASWPD-BO-GRU模型与原始月径流量时间序列的拟合程度较好,在预测精度或实际应用方面优于其他3个对比模型。主要的原因有:

(1)本文利用BO对L2正则化参数进行了寻优,保证了GRU在训练集上的均方根误差尽量小的同时防止了模型复杂度过高,在一定程度上抑制了过拟合问题,提升了模型泛化能力;

(2)GRU模型的最优超参数有时不在人工经验选择超参数的范围之内,因而无法通过人工经验进行最优的超参数选择。应用具有良好的全局搜索能力的BO来优化GRU模型的超参数能在一定程度上打破人工经验选择超参数的局限性,从而更准确地对模型超参数进行选择,BO优秀的寻优能力在其他学者的相关研究中也得到了印证^[12,31];

(3)对原始月径流量时间序列整体使用WPD分

解技术的传统方法虽然能大幅降低原始月径流量时间序列的非线性和预测难度,提升预测的精度,但该方法在分解过程中使用了未来数据,所以无法在实际中使用。应用 ASWPD 分解技术能够在不使用未来数据的前提下还能有效地提取原始月径流量时间序列中复杂的有效信息,从而降低预测难度并提升预测精度。因此,本文提出的 ASWPD-BO-GRU 模型在实际应用中相比于其他 3 种对比模型的泛化能力更强,具有较高的预测精度和稳定性,能够很大程度弥补单一模型的缺点,并且解决了传统分解集成模型错误使用未来数据的问题,所以可将 ASWPD-BO-GRU 模型应用于实际月径流量的预测。

此外,由于 ASWPD 中待分解序列起始长度、分解层数和母小波函数的选择对 ASWPD 的分解效果影响很大,而本文是通过模型训练期预测结果进行试错确定的,因此可在下一步研究中考考虑通过优化算法对上述参数进行寻优以进一步提高分解效果和预测精度。

5 结 论

本文构建了基于 ASWPD-BO-GRU 的月径流量预测模型,通过对莺落峡水文站月径流量预测的实例分析,得出以下主要结论:

(1) 利用 BO 优化 GRU 模型的超参数(隐藏层数、每层神经元数量、学习率、L2 正则化参数、最大训练回合数),能在一定程度上打破人工经验选择超参数的局限性和抑制单一 GRU 模型的过拟合问题,从而能更准确地对模型超参数进行选择并提升模型的泛化能力。

(2) ASWPD 能在不使用未来数据的前提下将原始月径流量时间序列分解为相对规律的子序列,可以减弱各种外界因素对月径流量时间序列的影响,降低径流预测的难度。

(3) 基于传统分解集成模型思想的 WPD-BO-GRU 模型会造成“虚假”的高精度预测结果,无法在现实中应用。ASWPD-BO-GRU 模型可解决传统分解集成模型错误使用未来数据的问题,并且在实例应用中纳什效率系数(NSE)接近 0.9,各项评价指标也优于 BO-GRU 模型和 GRU 模型,具有较高的预测精度,说明将 ASWPD-BO-GRU 模型用于月径流量预测是可行的。

参考文献:

[1] 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.

- [2] 王万良,张兆娟,高楠,等. 基于人工智能技术的大数据分析方法研究进展[J]. 计算机集成制造系统,2019,25(3):529-547.
- [3] 李继清,王爽,段志鹏,等. 基于 ESMD-BP 神经网络组合模型的中长期径流预报[J]. 应用基础与工程科学学报,2020,28(4):817-832.
- [4] 张森,颜志俊,徐春晓,等. 基于 MPGA-LSTM 月径流预测模型及应用[J]. 水电能源科学,2020,38(5):38-41+75.
- [5] 刘明宇,吴建平,王钰博,等. 基于深度学习的交通流量预测[J]. 系统仿真学报,2018,30(11):4100-4105+4114.
- [6] 陈海文,王守相,王绍敏,等. 基于门控循环单元网络与模型融合的负荷聚合体预测方法[J]. 电力系统自动化,2019,43(1):65-72.
- [7] 邵骏,袁鹏,张文江,等. 基于贝叶斯框架的 LS-SVM 中长期径流预报模型研究[J]. 水力发电学报,2010,29(5):178-182+189.
- [8] 刘芊彤,邢远秀. 基于 VMD-PSO-GRU 模型的锂离子电池剩余寿命预测[J]. 储能科学与技术,2023,12(1):236-246.
- [9] 徐冬梅,夏王萍,王文川. 基于黏菌算法优化 VMD-CNN-GRU 模型的年径流预测[J]. 南水北调与水利科技(中英文),2022,20(3):429-439.
- [10] 杨海柱,江昭阳,李梦龙,等. 基于 CS-GRU 模型的短期负荷预测方法研究[J]. 传感器与微系统,2022,41(9):54-57.
- [11] 陈臣鹏,赵鑫,毕贵红,等. 基于多模式分解和麻雀优化残差网络的短期风速预测模型[J]. 电网技术,2022,46(8):2975-2985.
- [12] 李其峰,杨杰,程琳,等. 基于 BO-GRU 的混凝土坝变形预测模型[J]. 水资源与水工程学报,2021,32(4):180-184+193.
- [13] YANG Li, SHAMI A. On hyperparameter optimization of machine learning algorithms: theory and practice[J]. Neurocomputing, 2020, 415: 295-316.
- [14] 邢子轩,张凡,武明虎,等. 基于 WD-GRU 的锂离子电池剩余寿命预测[J]. 电源技术,2022,46(8):867-871.
- [15] 贺琪,胡泽煜,徐慧芳,等. 基于经验模态分解-门控循环模型的海表温度预测方法[J]. 激光与光电子学进展,2021,58(24):342-350.
- [16] 孟安波,许炫淙,陈嘉铭,等. 基于强化学习和组合式深度学习模型的超短期光伏功率预测[J]. 电网技术,2021,45(12):4721-4728.
- [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):131-138.
- [18] 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.
- [19] ZHANG Xiaoli, PENG Yong, ZHANG Chi, et al. Are hybrid models integrated with data preprocessing techniques suitable for monthly streamflow prediction? Some experiment evidences [J]. Journal of Hydrology, 2015, 530: 137-152.
- [20] TAN Qiaofeng, LEI Xiaohui, WANG Xu, et al. An adaptive middle and long-term runoff prediction model using EEMD-ANN hybrid approach [J]. Journal of Hydrology, 2018, 567: 767-780.
- [21] ZUO Ganggang, LUO Jungang, WANG Ni, et al. Decomposition ensemble model based on variational mode decomposition and long short-term memory for streamflow forecasting [J]. Journal of Hydrology, 2020, 585: 124776.
- [22] 熊怡, 周建中, 孙娜, 等. 基于自适应变分模态分解和长短期记忆网络的月径流预报 [J]. 水利学报, 2023, 54(2): 172-183+198.
- [23] 邹悦, 张勃. 黑河流域莺落峡站河道内生态需水研究 [J]. 地理科学进展, 2012, 31(5): 625-631.
- [24] 鱼腾飞. 黑河流域莺落峡水文站逐月逐年径流资料数据集(1944—2016年) [EB/OL]. 国家冰川冻土沙漠科学数据中心 (<http://www.ncdc.ac.cn>) (2021-11-03) [2023-06-06]. <https://doi.org/10.12072/ncdc.XBSAQ.db2298>. 2022.
- [25] 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.
- [26] 章竹耀, 肖欣, 郭晓丽, 等. 基于储能电池的光伏功率波动平抑策略 [J]. 电力建设, 2016, 37(8): 90-95.
- [27] 丁常松, 郭士杰, 孙磊, 等. 基于贝叶斯优化算法的柔性外骨骼助力参数自适应优化 [J]. 制造业自动化, 2023, 45(2): 78-84.
- [28] FENG Zhongkai, NIU Wenjing, TANG Zhengyang, 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.
- [29] 崔东文. 基于 WPD-MRFO-ESN 模型的水库来水量时间序列预测 [J]. 华北水利水电大学学报(自然科学版), 2022, 43(6): 10-17.
- [30] 王秀杰, 张帅, 田福昌, 等. 基于 TVF-EMD-PSO-GRU 的月径流模型与应用研究 [J]. 天津大学学报(自然科学与工程技术版), 2022, 55(8): 802-810.
- [31] 陆秋贤, 马刚, 涂孟夫. 基于 IEWT-FE-BO-LSTM 模型的超短期风功率预测 [J]. 水电能源科学, 2023, 41(1): 217-220.

(上接第 83 页)

- [20] LI Min, ZHENG Tianyuan, ZHANG Jian, et al. A new risk assessment system based on set pair analysis- variable fuzzy sets for underground reservoirs [J]. Water Resources Management, 2019, 33(1): 4997-5014.
- [21] 隋帅, 方运海, 李敏, 等. 地下水库运行效果评价体系构建与应用研究 [J]. 中国海洋大学学报(自然科学版), 2020, 50(6): 126-133.
- [22] 李璇, 束龙仓, 鲁程鹏, 等. 石川河地下水库建库条件分析及地下水位动态预测 [J]. 水资源保护, 2017, 33(3): 13-18.
- [23] 王从荣, 尤爱菊, 束龙仓. 地下水库研究的现状及展望 [J]. 浙江水利科技, 2018, 46(5): 68-71.
- [24] 罗浩, 周维博, 白洁芳, 等. 基于 GC-TOPSIS 模型的水资源管理绩效评价及障碍度分析 [J]. 水资源与水工程学报, 2019, 30(4): 26-31.
- [25] 李云, 张紫瑶, 周维博. 西安市 2010—2018 年水生态承载力评价 [J]. 水资源与水工程学报, 2021, 32(6): 65-70.
- [26] 刘丽耘. 老年失眠中医 PRO 量表的研制及科学性考评 [D]. 成都: 成都中医药大学, 2020.
- [27] 刘亦平. 富平县水资源承载能力监测预警机制 [R]. 西安: 西安博思节能环保科技有限公司, 2018.
- [28] 张紫瑶, 王继玲, 周维博, 等. 不同回灌补源模式下石川河富平地下水数值模拟 [J]. 水资源与水工程学报, 2022, 33(2): 54-60.
- [29] 石文凯, 温忠辉, 李璇, 等. 基于人工调蓄的石川河河谷疏干含水层恢复效果分析 [J]. 水电能源科学, 2017, 35(3): 138-141+112.