

基于VMD-TPE-LSTM模型的月径流预测方法研究

卢名燊^{1,2}, 郑雅莲^{1,2}, 朱彦泽³, 刘森宇³, 刘攀^{1,2}, 程磊^{1,2*}

¹武汉大学水利水电学院, 湖北 武汉

²武汉大学水资源工程与调度全国重点实验室, 湖北 武汉

³国网新源集团有限公司富春江水力发电厂, 浙江 桐庐

收稿日期: 2023年5月8日; 录用日期: 2023年6月12日; 发布日期: 2023年6月30日

摘要

科学、准确、可靠的径流预测对防汛抗旱、水资源高效利用、水利设施综合效益的发挥至关重要。受到气候变化和人类活动的影响, 径流过程易呈现出高度的非线性、非平稳性特征, 给径流预测带来了更大的挑战。本文提出了一种基于变分模态分解(VMD)、剪枝优化算法(TPE)、长短期记忆网络(LSTM)等方法结合的月径流预测模型(VMD-TPE-LSTM), 采用受钱塘江上游新安江水库调控影响的富春江水库1969~2022年月径流序列对VMD-TPE-LSTM模型进行了训练、验证与测试, 月径流预测结果表明: VMD-TPE-LSTM模型的纳什效率系数达到了0.91, 能够对峰值流量实现较好的预测, 模型具有良好的泛化性能; 进一步开展了对照实验, 揭示了各因素在组合径流预测模型中对模型预测性能影响程度排序为: 预处理技术 > 基准模型 > 模型参数。因此, 耦合预处理技术和参数优化算法的径流预测方法能有效解决气候和人类活动影响的径流非平稳性问题, 从而提高月径流预测精度和能力。

关键词

入库流量预报, 变分模态分解, 剪枝优化算法, 长短期记忆网络

Research on Monthly Runoff Forecasting Method Based on VMD-TPE-LSTM Model

Mingshen Lu^{1,2}, Yalian Zheng^{1,2}, Yanze Zhu³, Shenyu Liu³, Pan Liu^{1,2}, Lei Cheng^{1,2*}

¹School of Water Resources and Hydropower Engineering, Wuhan University, Wuhan Hubei

²State Key Laboratory of Water Resources Engineering and Management, Wuhan University, Wuhan Hubei

³Fuchunjiang Hydropower Plant, State Grid Xinyuan Group Co., Ltd., Tonglu Zhejiang

Received: May 8th, 2023; accepted: Jun. 12th, 2023; published: Jun. 30th, 2023

作者简介: 卢名燊(1999-), 男, 硕士研究生, 主要研究方向为中长期水文预报, Email: mingshenlu@whu.edu.cn

*通讯作者 Email: lei.cheng@whu.edu.cn

文章引用: 卢名燊, 郑雅莲, 朱彦泽, 刘森宇, 刘攀, 程磊. 基于 VMD-TPE-LSTM 模型的月径流预测方法研究[J]. 水资源研究, 2023, 12(3): 213-225. DOI: 10.12677/jwrr.2023.123025

Abstract

Scientific, accurate, and reliable hydrological forecasting is crucial for flood control, drought resistance, efficient water resource utilization, and comprehensive water conservancy facility benefits. The runoff process is influenced by climate change and human activities, showing a high degree of non-linearity and non-smoothness, posing a greater challenge to runoff forecasting. In this paper, a monthly runoff forecasting model (VMD-TPE-LSTM) is proposed by coupling variational mode decomposition (VMD) with tree-structured parzen estimator algorithm (TPE) and long short-term memory network (LSTM). The model is trained, validated, and tested using the monthly runoff process of the Fuchun River Reservoir influenced by the upstream reservoir regulation from 1969 to 2022. The monthly runoff forecasting results show that the Nash efficiency coefficient of the VMD-TPE-LSTM model is 0.91 and achieve accurate forecast of peak flow, which has good generalization performance. Further controlled experiments reveal that the factors in the combined runoff forecasting model influence the model forecasting performance in the following order: pre-processing technique > baseline model > model parameters. It can be seen that the coupled pre-processing technique and parameter optimization algorithm can effectively solve the runoff non-smoothness problem influenced by climate change and human activities, thus improve the accuracy and capability of monthly runoff forecasting.

Keywords

Reservoir Inflow Forecasting, Variational Mode Decomposition, Tree-Structured Parzen Estimator Algorithm, Long Short-Term Memory Network

Copyright © 2023 by author(s) and Wuhan University.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

中长期径流预测是流域水资源分配和水库调度决策的基础, 预报的准确性直接影响到流域的防洪、抗旱、发电和水资源的优化配置[1]。径流通常受到多种因素的影响, 如降水、蒸发、太阳辐射、下垫面和大气环流等, 并呈现高度的时空变异性和非平稳性。由于气候变化和人类活动的影响, 径流的非平稳性和非一致性进一步加剧, 导致旱涝等极端事件频发, 对社会经济和居民人身安全造成了极大影响[2] [3]。径流预测精度的提高对流域水资源调控、水库防洪、发电等综合利用功能的实现具有重要意义。

中长期水文预报中常用的模型主要分为过程驱动模型(Process-driven Models)和数据驱动模型(Data-driven Models) [4] [5] [6] [7]。过程驱动模型从水文过程的物理成因出发, 将流域特征概化, 利用数学模型来模拟水文循环系统中的下渗、产汇流等过程。与数据驱动模型相比, 这类模型能更好地考虑流域内各种水文过程的相互作用和影响, 理论上可以更准确刻画实际水文循环过程, 但在实际应用中受到数据资料不足、模型不确定性大和计算复杂度高等方面的影响, 模型预测精度的提升和应用范围受到一定限制。数据驱动模型通常只在物理成因上考虑因子与径流的相关性, 而不考虑水文过程的物理机制, 通过直接构建预报因子与径流之间的映射关系实现径流预测。当研究区域观测资料不足、流域水文过程的物理机制未知或仅部分了解时, 运用数据驱动模型作为径流预测模型更为合适。目前, 以机器学习技术为主导的数据驱动模型在中长期预报领域应用广泛。徐莹等[8]提出一种基于遗传算法的支持向量机模型应用于解决月径流预测问题, 万育生等[9]将随机森林模型应用于丹江口水库的月径流预测研究, Yuan 等[10]结合长短期记忆网络模型(Long Short-Term Memory, LSTM)和蚁狮优

化算法(ALO)提出一种基于 LSTM-ALO 的月径流预测模型。以上研究所提出的模型均取得较好的径流预测结果,然而在水文气象资料缺失的地区,缺乏降水、蒸发等相关特征信息作为输入,只能依靠月径流时间序列展开预测,而单一的机器学习模型难以准确识别径流序列内部的变化规律,径流预测精度有限。

为了准确提取径流序列中趋势、变化规律等信息,一些学者将信号分解算法等预处理技术引入月径流预测过程中,对“分解-预测-重构”的预测模型开展了大量的研究[11] [12] [13]。钱晓燕等[14]将经验模态分解(Empirical Mode Decomposition, EMD)与 LS-SVM 模型相耦合,并与单独的 LS-SVM 及 BP 神经网络比较,研究结果表明该方法预报精度较高。Tan 等[15]基于集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)对月径流序列进行分解,以产生更清晰的信号作为人工神经网络(ANN)模型的输入,对不同信号分量进行预测并叠加得到月径流预测结果。上述研究结果表明,“分解-预测-重构”模型能够在月径流预测方面取得较好的应用效果。

然而在“分解”阶段,通过应用 EMD 和 EEMD 算法对径流分解得到的分量存在噪声和模态混叠等问题,对模型精度有较大的影响[16];而变分模态分解[17] (Variational Mode Decomposition, VMD)是一种完全非递归的变分模态分解,具有比 EMD 和 EEMD 更好的噪声鲁棒性,但其分解效率受到参数设置的影响,需对参数进行适当选择。在“预测”阶段,预测模型的性能与模型结构和参数密切相关,因此需要针对研究目标选择合适的机器学习模型以及相应的优化算法对模型参数进行合理率定。长短期记忆网络(LSTM)作为一种典型的深度学习模型,能够捕捉径流序列中的非线性关系和长期依赖关系,在径流预测方面具有较大的优势。剪枝优化算法(Tree-structured Parzen Estimator approach, TPE)是一种高效、灵活、鲁棒和可扩展的超参数优化算法,适用于大规模、复杂和噪声数据的超参数搜索问题。与网格搜索和随机搜索算法相比, TPE 算法具有更高的搜索效率和更灵活的搜索空间,在搭建基于机器学习的径流预测模型方面具有较大的优势,可以减少超参数搜索的时间和成本,提高模型的精度和效率。

鉴于此,为更好地提高径流预测准确性,本文提出了一种基于变分模态分解(VMD)、剪枝优化算法(TPE)、长短期记忆网络(LSTM)多种方法的 VMD-TPE-LSTM 月径流预测模型,将其应用于钱塘江流域富春江水库的月径流预测。该组合模型利用 VMD 方法结合排列熵,将月径流序列分解为不同时间尺度的本征模态函数(IMF),随后基于 LSTM 模型对不同尺度的分量进行预测,并由 TPE 算法对模型参数进行优化,最后将 LSTM 的各分量预测结果重构叠加得到月径流预测结果。

2. 研究方法

2.1. 变分模态分解

变分模态分解(VMD) [17]的基本思想是将一个信号分解成多个频带,每个频带内的信号用一个本征模态函数(Intrinsic Mode Function, IMF)表示[18]。为了实现这个目标, VMD 引入拉格朗日乘子,将分解问题构造为变分问题。通过求解这个变分问题,可以得到一组本征模态函数和对应的频带,从而完成信号分解。

VMD 构造的变分问题表示如下:

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum k \left\| \partial_t \left[\delta(t) + \frac{j}{\pi t} \right] * u_k(t) e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} & \sum k u_k(t) = f(t) \end{aligned} \quad (1)$$

式中: k 是 IMF 的个数, $f(t)$ 是原始序列, $\{u_k\}$ 和 $\{\omega_k\}$ 分别是本征模函数和中心频率。

利用拉格朗日乘子 λ 和二次惩罚项 α 将上述约束问题转化为下面的无约束问题:

$$L(\{u_k\}, \{\omega_k\}, \lambda): \alpha \sum k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum k u_k(t) \rangle \quad (2)$$

利用交替迭代更新本征模函数 $\{u_k\}$ 、中心频率 $\{\omega_k\}$ 和拉格朗日乘子 λ ，它们的迭代公式如下：

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i < k} \hat{u}_i^{n+1}(\omega) - \sum_{i > k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \tag{3}$$

$$\hat{\omega}_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_i^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_i^{n+1}(\omega)|^2 d\omega} \tag{4}$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \gamma \left(\hat{f}(\omega) - \sum_k \hat{u}_i^{n+1}(\omega) \right) \tag{5}$$

式中： γ 为噪声容忍度。

上述迭代满足迭代停止条件时停止，停止条件为：

$$\sum_{i=1}^K \left(\|\hat{u}_i^{n+1} - \hat{u}_i^n\|_2^2 / \|\hat{u}_i^n\|_2^2 \right) < \varepsilon \tag{6}$$

式中： ε 为判别精度。

2.2. 长短期记忆网络模型

长短期记忆网络模型(LSTM)是由 Hochreiter [19]提出的一种特殊的循环神经网络(Recurrent Neural Network, RNN)。它解决了传统 RNN 模型中随着迭代次数增加出现的梯度消失或梯度爆炸的问题，能够长时间记忆历史信息并将其传递到未来计算当中。LSTM 模型主要组成部分是 LSTM 单元(LSTM cell)，它由遗忘门、输入门、输出门和细胞状态组成，其具体的实现如下式所示：

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t * \tanh(C_t) \end{cases} \tag{7}$$

式中： f_t 、 i_t 、 o_t 分别为遗忘门、输入门和输出门参数； C_t 、 \tilde{C}_t 分别为记忆细胞单元状态和记忆细胞候选单元状态； W 和 b 分别表示对应的权值和偏差； σ 为 sigmoid 函数； \tanh 为双曲正切函数； x_t 为 t 时刻的输入向量； h_{t-1} 为 $t-1$ 时刻的隐藏层状态； h_t 为预测结果。

在 LSTM 模型中，细胞单元能够存储当前时刻入库流量与历史径流信息之间的长期依赖关系，能够更好地模拟入库径流，因此本文以 LSTM 模型为基准模型开展富春江水库月入库径流模拟。

2.3. Optuna 优化框架

Optuna 优化框架是 Akiba [20]提出的一套为深度学习设计的超参数调优框架。它包含 3 个核心概念，分别是目标函数、单次实验和研究。其中目标函数通常为应用模型的损失(Loss)或准确度(Accuracy)，单次实验为目标函数的单次调用，研究为一系列单次实验的集合，用于优化管理。Optuna 具有高效的采样机制和剪枝算法、便捷的可视化、高度兼容的通用架构等特征。Optuna 优化框架的具体流程如下：

步骤 1：确定优化目标、参数类型、参数取值范围和最大实验次数；

步骤 2：在定义的参数取值范围空间内进行搜索超参数组合；

步骤 3: 用修剪器根据修剪条件自动终止效果差的种群个体;

步骤 4: 确定未剪枝个体种群的目标函数值;

步骤 5: 重复步骤 2~4, 直到达到最大实验次数, 并输出最优解和最优目标函数值。

与网格搜索、随机搜索等其他优化方法相比, Optuna 优化框架以较低的计算成本提供了最优的超参数组合。因此, 本文基于 Optuna 框架采用剪枝优化算法对 LSTM 模型的参数进行调优。

2.4. VMD-TPE-LSTM 模型

VMD 算法基于严格的变分学理论通过自主选取模态分解个数使分解得到的 IMF 更具规律性, TPE 可实现预测中各个 IMF 的 LSTM 模型超参数调优, LSTM 相较于普通神经网络对于规律性强的数据信息具有更好的学习能力。VMD 分解得到的每个 IMF 均为单谐波, 序列复杂度和原始月径流时间序列相比极大地被降低, 因而能有效地适应 LSTM 的预测。基于此, 本研究将 VMD、TPE 以及 LSTM 相结合, 构建基于 VMD-TPE-LSTM 的月径流时间序列预测模型, 模型结构见图 1。

具体预测步骤如下:

步骤 1: 基于 VMD 对径流序列分解。基于 VMD 算法对月径流序列分解为若干个 IMF 和残差噪声 R, 使非平稳月径流序列变为相对平稳的子序列。由于 VMD 的分解效率受参数 k, γ, α 的影响[21], 其中 k 对算法的分解精度影响最大。本文引入排列熵(Permutation Entropy, PE)概念, 以子序列排列熵均值最小作为 Optuna 框架中的优化目标, 对 k 值进行优化, 以期获得熵值最小、模态复杂度最低的子序列;

步骤 2: 确定各子序列预测因子。利用偏自相关函数(PACF)来确定各 IMF 的 LSTM 模型的预测因子, 当大于某一滞时 L 后 PACF 基本落在 95%置信带内, 则选取预测时刻前 $t-1$ 时刻到 $t-L$ 时刻的月径流作为预测因子;

步骤 3: LSTM 模型超参数优化。将 PACF 得出的 IMF 预测因子分别输入 LSTM 模型中, 基于 Optuna 框架利用 TPE 算法对各个 IMF 的 LSTM 模型超参数进行调优, 本文训练的超参数主要有隐藏层的神经元数(n_hidden)、模型的时间步长(timesteps)、训练时每批次的样本数(batch_size)、训练轮次(epochs)和学习率(learning_rate);

步骤 4: 预报结果输出和评估。当模型优化达到最大迭代次数后, 对检验期各 IMF 进行预测得到各 IMF 的 t 时刻月径流预测结果, 将 IMF 预测结果进行叠加重构得到检验期月径流预测值, 然后根据评价指标对模型性能进行评估。

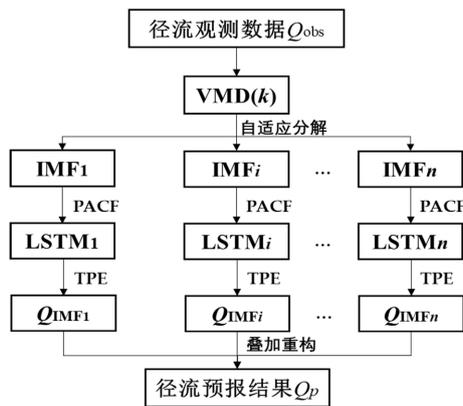


Figure 1. VMD-TPE-LSTM model structure diagram
图 1. VMD-TPE-LSTM 模型结构图

2.5. 模型评价指标

为了综合评价模型的性能, 本文选取了四项指标, 分别为纳什效率系数(NSE)、相关系数(r)、平均绝对误差(MAE)和均方根误差(RMSE)。NSE 能有效地评价模型预报结果的精度和稳定性, r 用于评价预报结果的线性相

关性，MAE 和 RMSE 用于度量模型预测值与观测值间的平均差异程度，其中 NSE 和 r 越接近于 1 或者 MAE 和 RMSE 越接近于 0 说明模型性能越好。四项指标计算公式如下所示：

$$NSE = 1 - \frac{\sum_{i=1}^N (y_{P,i} - y_{O,i})^2}{\sum_{i=1}^N (y_{O,i} - \bar{y}_{O,i})^2} \quad (8)$$

$$r = \frac{\sum_{i=1}^N (y_{P,i} - \bar{y}_{P,i})(y_{O,i} - \bar{y}_{O,i})}{\sqrt{\sum_{i=1}^N (y_{P,i} - \bar{y}_{P,i})^2 \sum_{i=1}^N (y_{O,i} - \bar{y}_{O,i})^2}} \quad (9)$$

$$MAE = \frac{1}{N} |y_{P,i} - \bar{y}_{O,i}| \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{P,i} - y_{O,i})^2} \quad (11)$$

式中： N 为数据长度； $y_{O,i}$ 是月径流实测值； $y_{P,i}$ 为月径流模拟值； $\bar{y}_{O,i}$ 为月径流实测值的平均值； $\bar{y}_{P,i}$ 为月径流模拟值的平均值。

3. 实例分析

3.1. 研究区域与数据

钱塘江流域地处浙江省，位于东经 117°~122°，北纬 28°~31°，全长 588.73 km，流域总面积约为 55,600 km²。钱塘江流域属于副热带湿润季风气候，濒临海洋，季风活动频繁，全年温暖多雨，流域年平均气温 17℃，年降

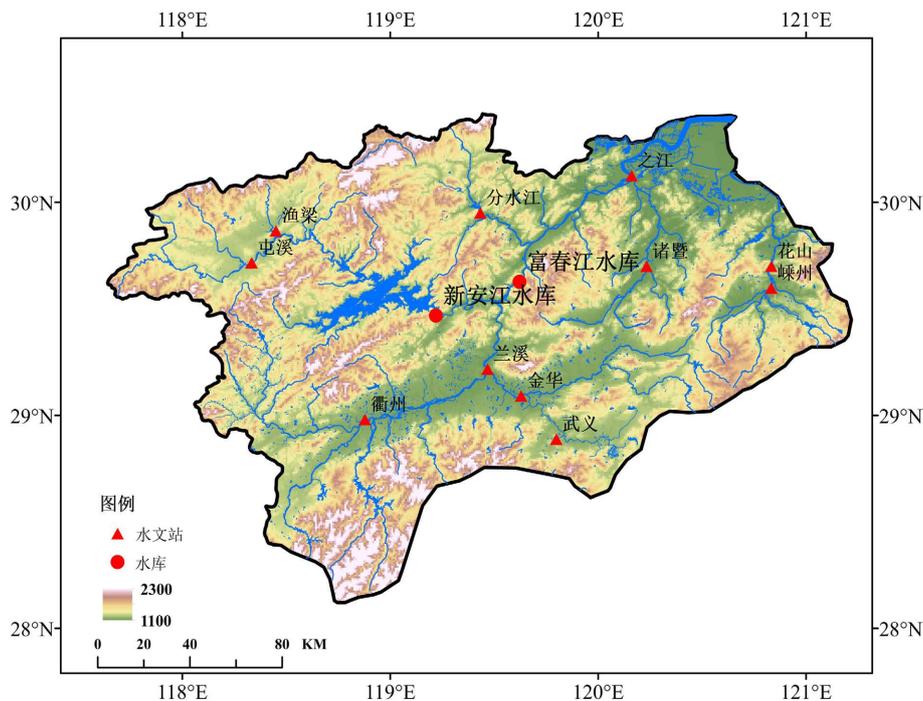


Figure 2. Water system map of the Qiantang River Basin
图 2. 钱塘江流域水系图

雨量为 1200~2200 mm。钱塘江流域多年平均径流量为 389 亿 m^3 ，径流量在年际和年内分布极不均匀，来水主要集中在 3~7 月，钱塘江流域如图 2 所示。

本文采用钱塘江流域内富春江水库 1969 年 1 月至 2022 年 12 月月尺度入库流量数据为样本(数据均来自于富春江水力发电厂)，根据 8:2 比例将样本划分为率定期和检验期，其中率定期 1969~2012 年(共 528 个月)的数据用作模型训练和验证，检验期 2013~2022 年(共 120 个月)的数据用作模型测试，其月径流过程线如图 3 所示。富春江水库受上游新安江水库调度的影响，其入库月径流序列波动性较大，最大、最小月径流分别为 $4730 \text{ m}^3/\text{s}$ 和 $63 \text{ m}^3/\text{s}$ ，最大与最小月径流之比高达 75.1，具有强非线性及非平稳性。

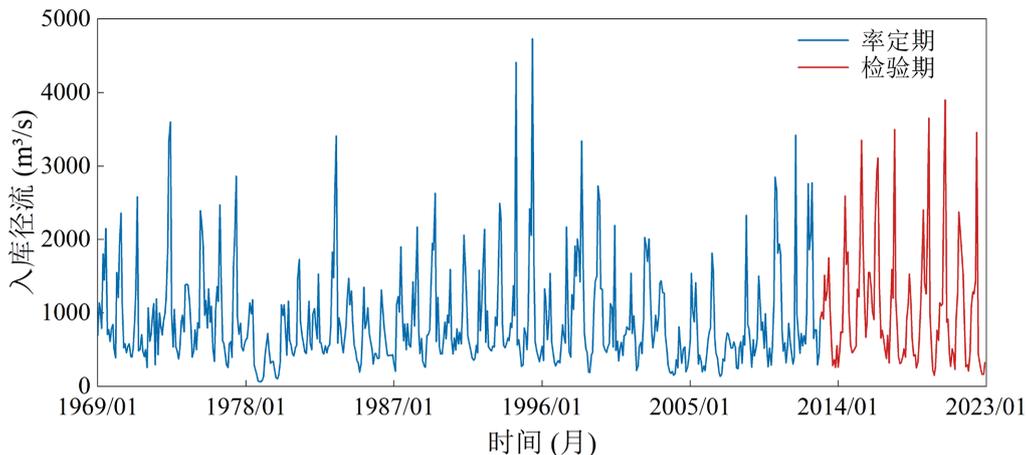


Figure 3. The original monthly inflow process of Fuchun River Reservoir

图 3. 富春江水库原始逐月入库流量过程线

3.2. 模型构建

3.2.1. 月径流序列分解

富春江水库入库月径流具有强非线性及非平稳性，为提取出径流中的趋势、噪声、变化规律等有效信息从而提高径流预测的准确性，本文利用 VMD 算法对富春江水库的月径流序列进行分解。率定期月径流序列，以子序列排列熵均值最小为优化目标，采用 TPE 优化算法对 VMD 算法中参数 k 进行优化，搜索范围设置为 [2] [15]，得到最优分解次数 k 为 8，月径流的分解结果如图 4 所示。由图 4 可知，VMD 算法将月径流序列分解为 8 个 IMF，其中 IMF1 的波形变化频率最为平缓，但频谱幅值变化最大，随着分解模态数量的增加，后续 IMF 的振幅逐渐稳定在 -600 到 600 之间，但变化频率逐渐增大。综上可知，相比于原始径流序列，经过 VMD 分解后各 IMF 的波动性降低，且具有一定的周期性，可见 VMD 是一种有效的序列分解方法。

通过 VMD 分解，将原始日径流序列分解为由低频到高频的周期性模态分量，揭示出月径流数据内的隐藏信息，即周期性震荡变化和趋势。这样不仅使模型能更好地理解径流序列周期性的信息，同时也有利于提高模型的训练效率和预测精度。

3.2.2. 预报因子筛选及模型参数设置

本研究采用 PACF 函数分析每个 IMF 序列中的数据相关性，并以此优选 LSTM 模型的预测因子，作为后续径流预测模型的输入变量。如图 5 所示，图中蓝色阴影为 95% 置信区间，当滞后项的 PACF 大于置信区间时说明该滞后项与目标变量之间存在显著的直接关系，当大于滞后 L 时，PACF 基本落在 95% 置信区间内，则选取预测时刻前 $t-1$ 时刻到 $t-L$ 时刻的月径流作为预测因子，输出变量为 t 时刻月径流，具体如表 1 所示。

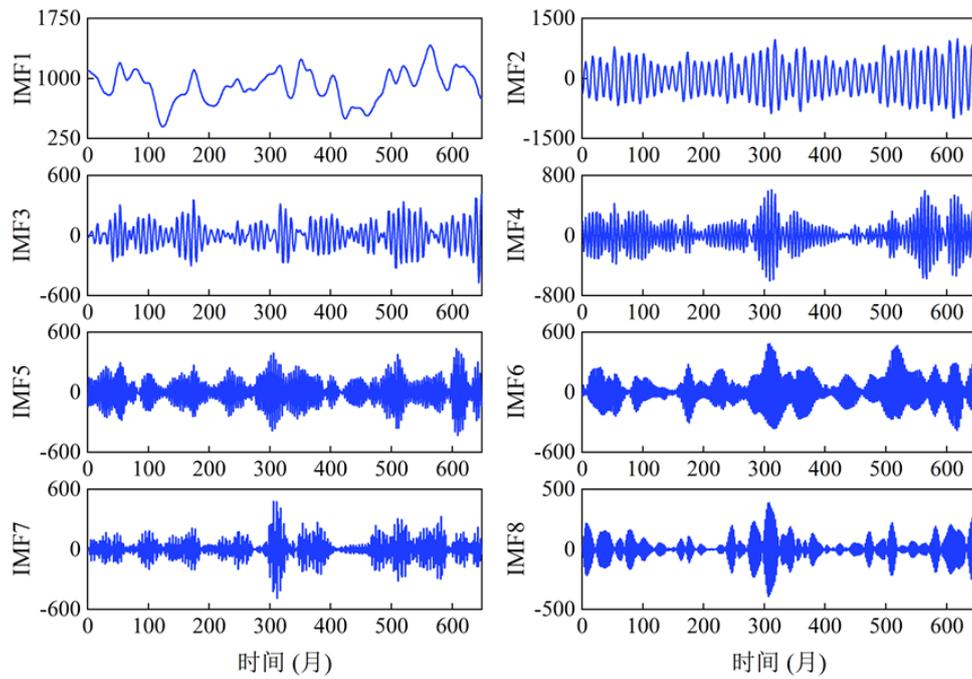


Figure 4. Decomposed sub-series process line for Fuchun River reservoir inflow process
图 4. 富春江水库入库流量分解子序列过程线

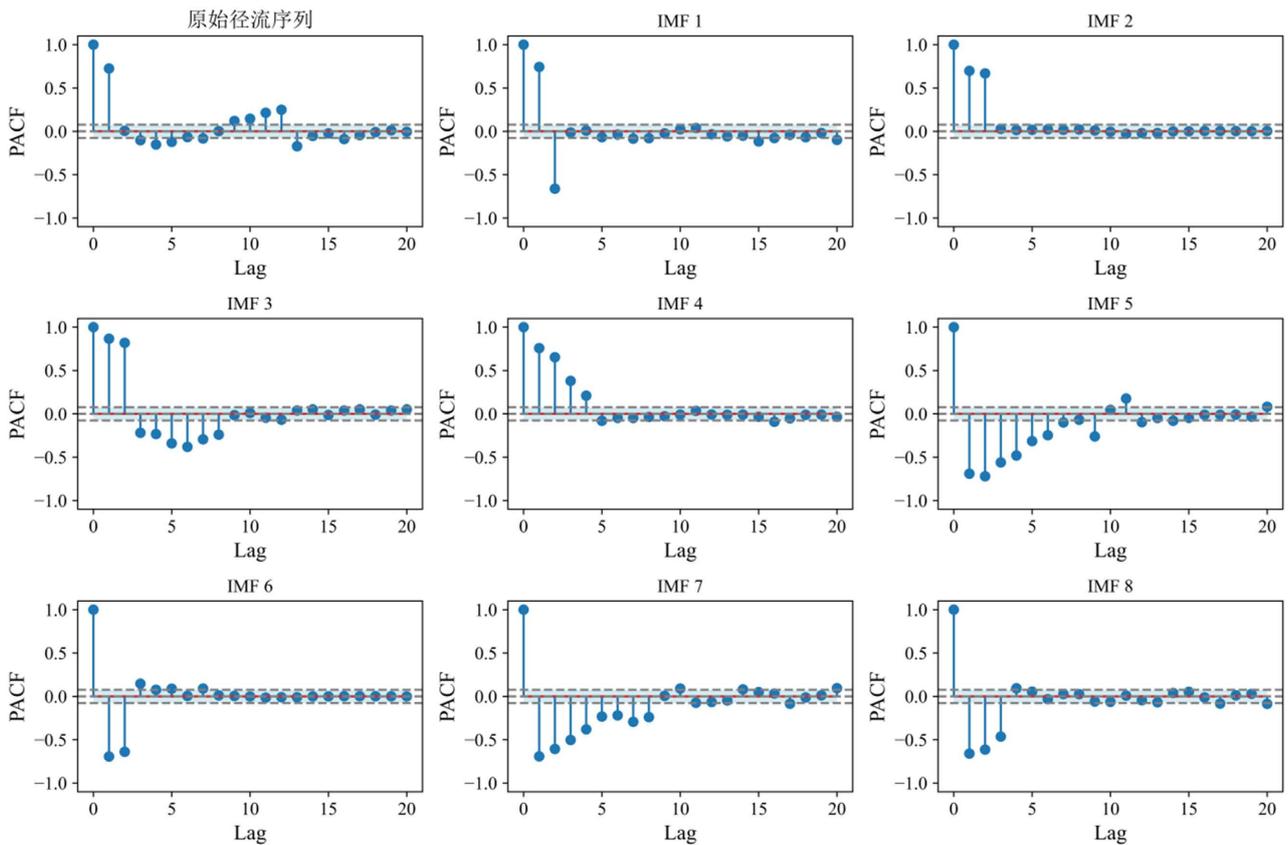


Figure 5. The PACFs of monthly runoff for the Fuchun River Reservoir
图 5. 富春江水库月径流系列的 PACF 值

Table 1. Input steps, input variables and out variables in LSTM models for each subseries of the Fuchun River Reservoir
表 1. 富春江水库各子序列的 LSTM 模型中的输入步长、输入变量和输出变量

序列	输入步长	输入变量	输出变量
原始径流序列	13	$x_{t-1}, x_{t-2}, x_{t-3}, x_{t-4}, x_{t-5}, x_{t-6}, x_{t-7}, x_{t-8}, x_{t-9}, x_{t-10}, x_{t-11}, x_{t-12}, x_{t-13}$	x_t
IMF1	2	x_{t-1}, x_{t-2}	x_t
IMF2	2	x_{t-1}, x_{t-2}	x_t
IMF3	8	$x_{t-1}, x_{t-2}, x_{t-3}, x_{t-4}, x_{t-5}, x_{t-6}, x_{t-7}, x_{t-8}$	x_t
IMF4	4	$x_{t-1}, x_{t-2}, x_{t-3}, x_{t-4}$	x_t
IMF5	12	$x_{t-1}, x_{t-2}, x_{t-3}, x_{t-4}, x_{t-5}, x_{t-6}, x_{t-7}, x_{t-8}, x_{t-9}, x_{t-10}, x_{t-11}, x_{t-12}$	x_t
IMF6	3	$x_{t-1}, x_{t-2}, x_{t-3}$	x_t
IMF7	8	$x_{t-1}, x_{t-2}, x_{t-3}, x_{t-4}, x_{t-5}, x_{t-6}, x_{t-7}, x_{t-8}$	x_t
IMF8	3	$x_{t-1}, x_{t-2}, x_{t-3}$	x_t

对上述每个序列建立 TPE-LSTM 模型，每个模型的隐藏层个数为 1，优化器为 Adam，主要训练的超参数有隐藏层节点数(n_hidden)、模型的时间步长(timesteps)、训练时每批次的样本数(batch_size)、训练轮次(epochs)和学习率(learning_rate)。设定的 LSTM 超参数搜索范围及搜索间隔如下：隐藏层神经元数为[32, 512]，间隔为 32；模型的时间步长为[1, 24]，间隔为 1；训练时每批次的样本数按照 2^n 次依次选取，其中 n 为 2~8；训练轮次为 10~2000，间隔为 10；学习率为 0.000001~0.01，间隔为 0.000001；超参数优化的目标函数为 MSE，最终得到各子序列的 LSTM 模型超参数率定结果如表 2 所示，其中默认值为后续单一 LSTM 模型采用超参数值。

Table 2. Hyperparameters of LSTM model
表 2. LSTM 模型超参数

模型参数	默认值	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8
隐藏层节点数	64	192	288	416	192	256	288	320	384
时间步长	1	21	10	6	8	7	4	5	15
训练批次样本数	4	64	64	32	128	64	16	64	32
训练轮次	100	940	640	620	620	740	880	840	880
学习率	0.001	0.00144	0.009663	0.001215	0.00104	0.00044	0.00013	0.000453	0.000368

3.3. 结果与讨论

基于 VMD-TPE-LSTM 模型对富春江水库进行月径流预测。为全面验证 VMD-TPE-LSTM 模型的预测效果，本文分别针对径流预测中 TPE 优化算法、VMD 预处理和 LSTM 模型，设计 3 组对照模型和 1 组基准模型：① 使用粒子群参数优化的 VMD-PSO-LSTM 模型；② 使用经验模态分解的 EMD-TPE-LSTM 模型；③ 耦合 TPE 参数优化和 VMD 预处理的随机森林模型(VMD-TPE-RF)；④ 单一的 LSTM 模型。对照模型和基准模型同时进行径流预测，以期分别揭示各要素对预测效果的贡献大小。这些模型在富春江水库的月径流预测过程结果如图 6 所示，各模型检验期预测流量和实测流量的散点图如图 7 所示，对应的检验期评价指标结果如表 3 所示。

从图 6 可以看出，VMD-TPE-LSTM 模型准确预测了富春江水库的整体月径流趋势，能够对高、中、低流量实现较好的预测。此外，由散点图 7 可知，VMD-TPE-LSTM 模型预测结果比其他 4 种模型更接近 $y = x$ 回归线，尤其是中高流量的预测，说明本文所提出的模型在峰值预测相较于其他模型具有显著的优势。由表 3 可知，VMD-TPE-LSTM 模型对富春江水库的月径流预测结果的 NSE 达到了 0.91， r 达到了 0.95，且 MAE 和 RMSE

显著低于其他 4 个模型，预测误差相对较小，预测精度达到了水文情报预报规范中的甲级标准。

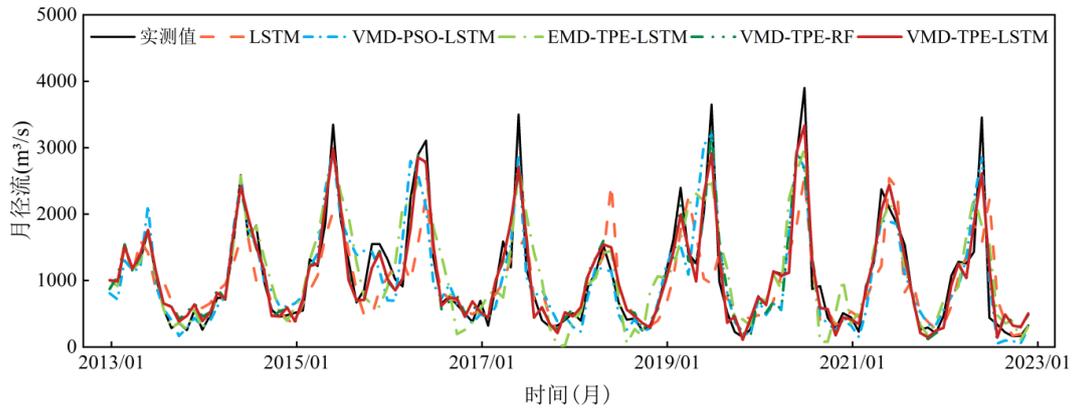


Figure 6. The prediction results of monthly runoff for each model during the testing period

图 6. 各模型在检验期的月径流预测结果

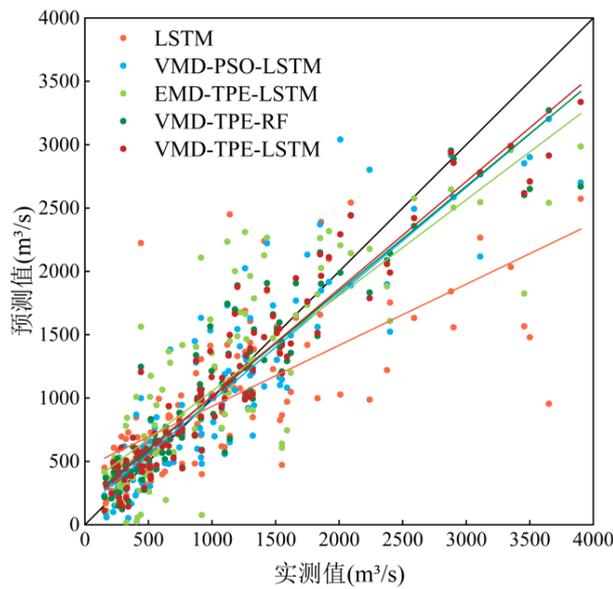


Figure 7. The scatter plot of monthly runoff prediction for each model during the testing period

图 7. 各模型在检验期的月径流预测散点图

Table 3. The evaluation indicators of each model for monthly runoff prediction results during the test period

表 3. 各模型在检验期的月径流预测结果的评价指标

模型	NSE	r	MAE	RMSE (m^3/s)
LSTM	0.50	0.72	373	582
VMD-PSO-LSTM	0.89	0.95	191	265
EMD-TPE-LSTM	0.72	0.83	314	454
VMD-TPE-RF	0.87	0.94	201	283
VMD-TPE-LSTM	0.91	0.95	180	251

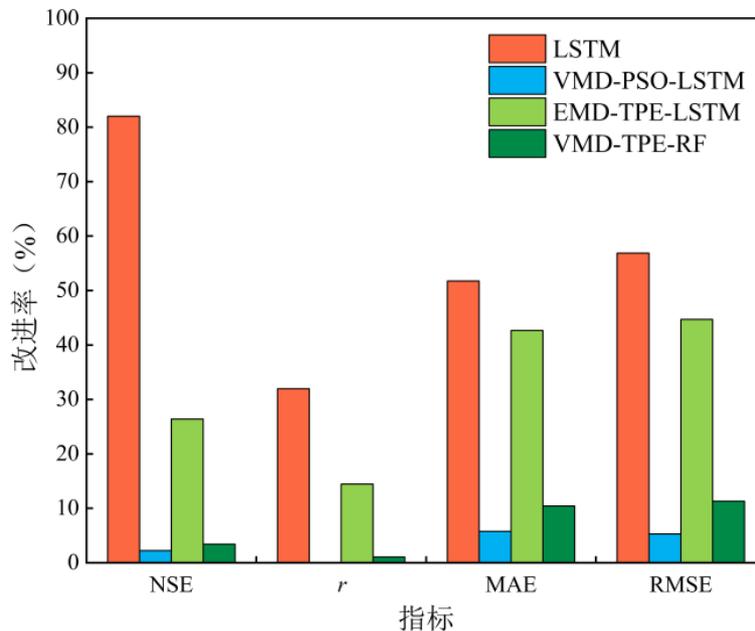


Figure 8. Improvement rate of the VMD-TPE-LSTM compared to each model in four evaluation indicators

图 8. VMD-TPE-LSTM 模型与各模型相比在四个评价指标的改进率

将 VMD-TPE-LSTM 模型与 4 个模型进行分析比较, VMD-TPE-LSTM 模型相对于各模型的改进率如图 8 所示。由图可知, 与 LSTM、VMD-PSO-LSTM、EMD-TPE-LSTM 和 VMD-TPE-RF 相比, VMD-TPE-LSTM 模型的各个指标均较对比模型有所改进, NSE 分别提高了 82%、2%、26%和 3%; r 分别提高了 32%、0%、15%和 1%; MAE 分别降低了 52%、6%、43%和 10%; RMSE 分别降低了 57%、5%、45%和 11%。在 3 个对照模型当中, VMD-TPE-LSTM 模型对于 EMD-TPE-LSTM 模型的改进率最高, 其次是 VMD-TPE-RF 模型和 VMD-PSO-LSTM 模型, 说明在径流预测模型当中径流预处理技术对模型预测效果的影响大于基准模型机理和参数优化算法。通过 VMD 预处理促使模型更好地捕捉径流时间序列的非平稳特征, 同时采用排列熵确定子序列个数, 解决了序列分解中存在的模态混叠和噪声的问题, 减少了子序列预测结果叠加产生的累积误差, 进一步提升了模型预测性能。此外, 采用先进的优化算法和基准模型, 提高模型参数搜索效率和模型非线性映射能力, 在一定程度上也能提高模型预测性能。

综上所述, 本文提出的耦合变分模态分解预处理方法、剪枝优化算法以及长短期记忆网络的组合模型具有较好的实用性, 与其他 4 个模型进行对比, 该模型在 NSE、 r 、MAE 和 RMSE 均取得了最佳表现。综合 4 种评价指标, 对模型性能进行综合排序, 结果为: VMD-TPE-LSTM > VMD-PSO-LSTM > VMD-TPE-RF > EMD-TPE-LSTM > LSTM。由此可见, 在径流预测中预处理技术、基准模型机理和模型参数优化对于模型预测性能提升具有不同重要程度。因此, 在进行径流预测模型搭建时, 对历史径流数据进行预处理是提升预测结果的重要一环, 其在一定意义上甚至高于预测模型本身和参数优化算法; 但选择合适的预测模型和参数优化算法也能对预测模型的性能有所提升。

4. 结论

为提高水库中长期月入库径流的预测效果, 提出了 VMD-TPE-LSTM 月径流预测模型, 并应用于钱塘江流域富春江水库月入库流量预测, 得到以下结论:

- 1) 本文利用排列熵来确定变分模态分解中固有模态分量的分解个数, 解决了序列分解中存在的模态混叠和

噪声的问题, 将非线性及非平稳的原始径流序列分解为不同频率尺度的子序列, 分离月径流序列内的周期性震荡变化和趋势, 使机器学习模型能更好地理解径流序列的周期性信息, 提高了模型的预测精度。

2) 本文设置了三组对照模型与提出的 VMD-TPE-LSTM 模型进行对比分析, 结果表明在径流预测中径流预处理技术、基准模型和模型参数对于模型预测性能提升具有不同重要程度, 性能提升贡献排序为: 预处理技术 > 基准模型 > 模型参数。

3) 本文提出的 VMD-TPE-LSTM 模型在月径流预测中展示出良好的预测精度和泛化能力, 尤其是对峰值流量的准确模拟, 是一种高效可靠的月径流预测模型, 可以为水资源的合理配置和优化运行提供有效的信息参考。

致 谢

感谢国网新源集团富春江水力发电厂为本研究提供基础数据与支持。

基金项目

科技部重点研发计划长江黄河等重点流域水资源与水环境综合治理项目(2022YFC3202804), 国家自然科学基金项目(41890822)。

参考文献

- [1] 杨大文, 徐宗学, 李哲, 等. 水文学研究进展与展望[J]. 地理科学进展, 2018, 37(1): 36-45.
YANG Dawen, XU Zongxue, LI Zhe, et al. Progress and prospect of hydrological sciences. Progress in Geography, 2018, 37(1): 36-45. (in Chinese)
- [2] ARNELL, N. W., GOSLING, S. N. The impacts of climate change on river flow regimes at the global scale. Journal of Hydrology, 2013, 486: 351-364. <https://doi.org/10.1016/j.jhydrol.2013.02.010>
- [3] SORG, A., BOLCH, T., STOFFEL, M., et al. Climate change impacts on glaciers and runoff in Tien Shan (Central Asia). Nature Climate Change, 2012, 2(10): 725-731. <https://doi.org/10.1038/nclimate1592>
- [4] 王文, 马骏. 若干水文预报方法综述[J]. 水利水电科技进展, 2005(1): 56-60.
WANG Wen, MA Jun. Review on some methods for hydrological forecasting. Advances in Science and Technology of Water Resources, 2005(1): 56-60. (in Chinese)
- [5] DEB, P., KIEM, A. S. and WILLGOOSE, G. A linked surface water-groundwater modelling approach to more realistically simulate rainfall-runoff non-stationarity in semi-arid regions. Journal of Hydrology, 2019, 575: 273-291.
<https://doi.org/10.1016/j.jhydrol.2019.05.039>
- [6] HSU, K., GUPTA, H. V. and SOROOSHIAN, S. Artificial neural network modeling of the rainfall-runoff process. Water Resources Research, 1995, 31(10): 2517-2530. <https://doi.org/10.1029/95WR01955>
- [7] SAJIKUMAR, N., THANDAVESWARA, B. S. A non-linear rainfall-runoff model using an artificial neural network. Journal of Hydrology, 1999, 216(1-2): 32-55. [https://doi.org/10.1016/S0022-1694\(98\)00273-X](https://doi.org/10.1016/S0022-1694(98)00273-X)
- [8] 徐莹, 王嘉阳, 苏华英. 基于遗传算法的支持向量机在径流中长期预报中的应用[J]. 水利与建筑工程学报, 2014, 12(5): 42-45+72.
XU Ying, WANG Jiayang and SU Huaying. Application of support vector machine based on genetic algorithm to mid-term and long-term run-off prediction. Journal of Water Resources and Architectural Engineering, 2014, 12(5): 42-45+72. (in Chinese)
- [9] 万育生, 王栋, 黄朝君. 丹江口水库来水情势分析与径流预测[J]. 南水北调与水利科技(中英文), 2021, 19(3): 417-426.
WAN Yusheng, WANG Dong and HUANG Chaojun. Water inflow regime analysis and runoff prediction of Danjiangkou reservoir. South-to-North Water Transfers and Water Science and Technology (Chinese and English), 2021, 19(3): 417-426. (in Chinese)
- [10] YUAN, X., CHEN, C., LEI, X., et al. Monthly runoff forecasting based on LSTM-ALO model. Stochastic Environmental Research and Risk Assessment, 2018, 32(8): 2199-2212.
- [11] MENG, E., HUANG, S., HUANG, Q., et al. A robust method for non-stationary streamflow prediction based on improved EMD-SVM model. Journal of Hydrology, 2019, 568: 462-478. <https://doi.org/10.1016/j.jhydrol.2018.11.015>
- [12] HE, X., LUO, J., ZUO, G., et al. Daily runoff forecasting using a hybrid model based on variational mode decomposition and deep neural networks. Water Resources Management, 2019, 33(4): 1571-1590. <https://doi.org/10.1007/s11269-019-2183-x>
- [13] FENG, Z., WANG, W., TANG, Z., et al. Monthly runoff time series prediction by variational mode decomposition and support

- vector machine based on quantum-behaved particle swarm optimization. *Journal of Hydrology*, 2020, 583: 124627. <https://doi.org/10.1016/j.jhydrol.2020.124627>
- [14] 钱晓燕, 邵骏, 袁鹏, 等. 基于 EMD 和 LS-SVM 的中长期径流预报[J]. *水电能源科学*, 2010, 28(4): 11-13.
QIAN Xiaoyan, SHAO Jun, YUAN Peng, et al. Mid-long term runoff forecasting base on EMD and LS-SVM. *Water Resources and Power*, 2010, 28(4): 11-13. (in Chinese)
- [15] TAN, Q., LEI, X., WANG, X., et al. An adaptive middle and long-term runoff forecast model using EEMD-ANN hybrid approach. *Journal of Hydrology*, 2018, 567: 767-780. <https://doi.org/10.1016/j.jhydrol.2018.01.015>
- [16] 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.
WANG Wenchuan, GAO Chang and XU Lei. Monthly runoff forecast based on TVF-EMD and LSTM neural network coupling. *China Rural Water and Hydropower*, 2022(2): 76-81+89. (in Chinese)
- [17] DRAGOMIRETSKIY, K., ZOSSO, D. Variational mode decomposition. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544. <https://doi.org/10.1109/TSP.2013.2288675>
- [18] JING, X., LUO, J., ZHANG, S., et al. Runoff forecasting model based on variational mode decomposition and artificial neural networks. *Mathematical Biosciences and Engineering*, 2021, 19(2): 1633-1648. <https://doi.org/10.3934/mbe.2022076>
- [19] HOCHREITER, S., SCHMIDHUBER, J. Long short-term memory. *Neural Computation*, 1997, 9(8): 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [20] AKIBA, T., SANO, S., YANASE, T., et al. Optuna: A next-generation hyperparameter optimization framework. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Anchorage: ACM, 2019: 2623-2631. <https://doi.org/10.1145/3292500.3330701>
- [21] ZUO, G., LUO, J., WANG, N., et al. Decomposition ensemble model based on variational mode decomposition and long short-term memory for streamflow forecasting. *Journal of Hydrology*, 2020, 585: 124776. <https://doi.org/10.1016/j.jhydrol.2020.124776>