

张楚,何金宇,陈湘萍,等. 基于 VMD-SSA-LSSVM 混合径流预测模型及应用[J]. 智能计算机与应用,2025,15(6):108-113. DOI:10.20169/j.issn.2095-2163.250616

基于 VMD-SSA-LSSVM 混合径流预测模型及应用

张楚¹, 何金宇¹, 陈湘萍², 蔡永翔³

(1 贵州大学 电气工程学院, 贵阳 550025; 2 贵州大学 北阿拉巴马国际工程技术学院, 贵阳 550025;

3 贵州电网有限责任公司 电力科学研究院, 贵阳 550025)

摘要: 本文创建了一个以变分模态分解 (Variational Mode Decomposition, VMD)、麻雀搜索算法 (Sparrow Search Algorithm, SSA) 和最小二乘支持向量机 (Least Squares Support Vector Machine, LSSVM) 结合的水电站径流预测模型 (VMD-SSA-LSSVM), 旨在提升径流预测准确性。首先, 该模型运用 VMD 对含有大量复杂频率的径流数据进行分离, 从而获得包含各种频率成分的本征模函数 (Intrinsic Mode Functions, IMF)。随后, 通过使用 SSA 对传统的最小二乘支持向量机参数进行优化, 解决了原先 LSSVM 在参数选取上的盲区问题。最后, 在上述基础上搭建 VMD-SSA-LSSVM 混合模型, 并采用中国贵州省北盘江流域的某水电站 2022 年 4 月~2023 年 3 月数据集进行验证。实验结果表明, 本文所提预测模型的预测精度均有明显的提高, 这对于水电站入库径流预测方法和理论研究均具有很好的应用价值。

关键词: 入库径流预测; 变分模态分解; 最小二乘支持向量机; 麻雀搜索算法

中图分类号: TP183

文献标志码: A

文章编号: 2095-2163(2025)06-0108-06

Mixed runoff prediction model based on VMD-SSA-LSSVM and its application

ZHANG Chu¹, HE Jinyu¹, CHEN Xiangping², CAI Yongxiang³

(1 School of Electrical Engineering, Guizhou University, Guiyang 550025, China;

2 North Alabama International College of Engineering and Technology, Guizhou University, Guiyang 550025, China;

3 Power Science Research Institute of Guizhou Power Grid Co., Ltd., Guiyang 550025, China)

Abstract: This paper creates a the runoff prediction model of hydropower station (VMD-SSA-LSSVM), which combines Variational Mode Decomposition (VMD), Sparrow Search Algorithm (SSA) and Least Squares Support Vector Machine (LSSVM), aims to improve the accuracy of runoff prediction. Firstly, the model uses VMD to separate runoff data with a large number of complex frequencies to obtain Intrinsic Mode Functions (IMF) containing various frequency components. Then, by using SSA to optimize the parameters of traditional least square support vector machine, the blind spot problem in parameter selection of LSSVM is solved. Finally, the VMD-SSA-LSSVM hybrid model is built on the basis of the aboved, and the data set of a hydropower station in Beipanjiang River Basin, Guizhou Province, China from April 2022 to March 2023 is used for verification. The experimental results show that the prediction accuracy of the proposed prediction model is obviously improved, which has a good application value for the prediction method and theoretical research of the inflow runoff of hydropower station.

Key words: inflow runoff prediction; Variational Mode Decomposition; Least Squares Support Vector Machine; Sparrow Search Algorithm

0 引言

水电站入库径流的准确预测对于合理调配水资源、最大化水电站发电效益以及提升整体运营效益具有至关重要的意义^[1]。水力发电站水库入库流

量的影响要素包括降水量、蒸腾损失、来自上游的水利调配及从下游来的水利调配等多种自然条件约束, 这些元素之间的关联极为复杂并呈非线性特征, 同时其在时间和空间上的表现也有一定的无序性, 因此, 入库流量可视为一种难以预知的多变性数值。

基金项目: 国家自然科学基金 (51867007)。

作者简介: 张楚 (1997—), 男, 硕士研究生, 主要研究方向: 混合储能优化配置; 何金宇 (2001—), 男, 硕士研究生, 主要研究方向: 控制工程。

通信作者: 陈湘萍 (1977—), 女, 教授, 主要研究方向: 多源互补分布式供能控制技术。Email: ee.xpchen@gzu.edu.cn。

收稿日期: 2023-10-30

哈尔滨工业大学主办 ◆ 系统开发与应用

然而,若能够精确地把握到这种流量的变化轨迹,则对制定水电站的发电策略和合理分配水资源具备实际价值,从而实现更稳定电力输出,满足防洪与发电的需求^[2]。目前,预测径流的方法可以分为2类:直接预测法(统计法)和间接预测法(物理法)。

间接预测法、即物理法,主要依赖于基于物理机制的预测模型。这种模型要求深入分析径流的成因,但模型的构建相当复杂,需要大量的水文资料作为输入。同时,该过程还涉及复杂的水文认识,使得模型中的参数率设定变得尤为困难。由于这些参数的变动,预测结果也会相应产生变化,因此具有很高的不确定性^[3-6]。而使用直接预测法、即统计法可以通过分析历史水文气候因素间的统计关联以完成预估,这有助于深入理解各个元素之间相互影响的关系并仅需引入相对较少的天气气候数据^[7]。直接预测方法主要使用神经网络、时间序列算法、分类回归算法和灰色理论来进行预测。例如:谢梓彬^[8]就提出了一种可用来估计水电站水库水位的计算方法,采用了封闭式预测和开放式预测这2类多元预测手段对水库储水量进行了预测。黄景光等学者^[9]则借助自回归-移动平均模型(ARMA)和BP神经网络模式实现了对径流量的预测。高永华^[10]创建了一个基于LSTM的径流量预测模型,该模型能为其它地区的径流量模拟提供参考依据。尽管这些方法在某些程度上减少了预测错误,并提高了径流预测的精准性,但是不能忽视这些方法依旧存在局限性和不足,神经网络的预测模型存在过拟合、收敛慢以及容易陷入局部最优解等问题。

陈良等学者^[11]通过融合经验模态分解(EMD)方法、注意机制和BiLSTM神经网络等方法,用插值技术来进一步改进原始数据,并提升径流预测效果。朱非林等学者^[12]提出了一种结合变分模态分解(VMD)方法和长短期记忆(LSTM)神经网络的中长期径流预测模型。称为VMD-LSTM预测模型。实验结果验证了该预测模型能够有效提高预测精度。但对于EMD存在的模态混叠问题,VMD方法却能有效避免模态混叠现象的发生^[13]。

基于上述研究,本文利用VMD技术的原理对流量信息进行了拆解;同时考虑到LSSVM的表现主要受到诸如核心公式与处罚系数等关键因素的影响,其调试过程不仅繁复且耗费时间,而随着科技进步及现代化的推进,新型智能化优选策略不断涌现出来。在此背景下,例如麻雀搜索算法(SSA)作为一种构造简易但具备强大区域搜寻能力的工具被大

量用于设定最佳值以达到理想的效果。综上分析后,本文的主要工作是采用VMD策略对过去的径流数据进行分析,然后通过SSA-LSSVM模型对处理后的子序列进行预测,并得到递推输出。

1 研究区域及数据来源

本文的研究区域位于流经云贵两省的北盘江流域,所采用的数据由位于北盘江中段的一个梯级水电站所提供,该站的主要任务是发电,其次也服务于航运。坝址以上控制流域面积为16 068 km²。水库正常蓄水位585 m,相应库容为1.365×10⁸ m³,总库容1.695×10⁸ m³,调节库容0.731×10⁸ m³,属日调节水库;水电站配备了总功率为558 MW(3×180 MW+18 MW)的发电机组,年发电量平均达到15.61×10⁸ kW·h。本文所使用的的数据包括日尺度的径流数据,选取了2022年4月~2023年3月的数据。

2 算法模型原理

2.1 最小二乘支持向量机模型

最小二乘支持向量机(LSSVM)是对支持向量机(SVM)的一种改进。在LSSVM中,其损失函数被设计为最小二乘函数,以优化预测误差的平方和。同时,为了简化计算和提高效率,LSSVM将SVM中的不等式约束条件转化为等式约束条件。这样,LSSVM在保持SVM分类和回归能力的同时,提高了求解的效率和稳定性。LSSVM的目标优化函数定义如下:

$$\begin{cases} \min J(w, \xi) = \frac{1}{2}w^T w + \frac{1}{2}\gamma \sum_{i=1}^N \xi_i^2 \\ y_i = w^T \varphi(x_i) + b + \xi_i \end{cases} \quad (1)$$

其中, $x_i \in R_n$ 表示系统的输入; $y_i \in R$ 表示输出,这里 $i = 1, 2, 3, \dots, N$; γ 表示正则化参数; ξ_i 表示误差变量; w 表示权重; b 表示偏置量; $\varphi(x_i)$ 表示一个非线性映射函数,具有能把 x_i 从基础空间投射到高阶特性空间的非线性投射功能。通过引入拉格朗日算子,依据KKT条件,最终得到的回归函数公式如下:

$$y = w^T \varphi(x_i) + b = \sum_{i=1}^N a_i K(x, x_i) + b \quad (2)$$

其中, a_i 表示拉格朗日乘子, $K(x, x_i)$ 表示核函数,而本文采用的是径向基函数RBF。

2.2 变分模态分解

变分模态分解(VMD)是一种适应性的准正交信号分解方法,可以将实数输入信号 f 拆分成离散

的子信号(模态) u_k ,每个模态 u_k 都聚集在频率中心 w_k 附近,且总体较为紧凑。可以将VMD概括为一个受约束的变分问题:

$$\begin{cases} \min_{\{u_k\}, \{w_k\}} \left\{ \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) \times u_k(t) \right] e^{-jw_k t} \right\|_2^2 \right\} \\ \text{s.t.} \quad \sum_k u_k = f \end{cases} \quad (3)$$

其中, u_k 表示第 k 个模态分量; w_k 表示第 k 个模态所对应的频率核心位置; $\delta(t)$ 表示单位脉冲函数。引入二次惩罚因子 α 和拉格朗日乘数 λ ,可以将有限制的变分问题转化为无限制的问题。对此方法可表示为:

$$\begin{aligned} L(\{u_k\}, \{w_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[(\delta(t) + \frac{j}{\pi t}) \times u_k(t) e^{-jw_k t} \right] \right\|_2^2 + \\ & \left\| f(t) - \sum_k u_k(t) \right\|^2 + \\ & (\lambda(t), f(t) - \sum_k u_k(t)) \end{aligned} \quad (4)$$

2.3 麻雀优化算法

麻雀搜索算法(Sparrow Search Algorithm, SSA)的基本步骤是初始化变分模态分解 n 只麻雀的群体,利用评估函数来计算和排序每只麻雀的位置,并增加了检测和预警机制。根据麻雀的自然行为,可以将鸟类分为发现者、跟随者和警报者。以下是SSA搜索算法的发现者、跟随者和警报者的位置更新公式:

(1)发现者。位置更新公式为:

$$\mathbf{X}_{i,j}^{t+1} = \begin{cases} \mathbf{X}_{i,j}^t \cdot \exp\left(-\frac{i}{\alpha \cdot \text{item}_{\max}}\right), & R_2 < ST \\ \mathbf{X}_{i,j}^t + Q \cdot \mathbf{L}, & R_2 \geq ST \end{cases} \quad (5)$$

其中, t 表示循环次数; $j = 1, 2, 3, \dots, d$; $\text{item}_{\max}$ 表示最大的迭代次数; $\mathbf{X}_{i,j}$ 表示第 i 个麻雀在第 j 维中的位置信息; $\alpha \in (0, 1]$ 是一个随机数; Q 表示服从正态分布的随机数; $\mathbf{L}$ 表示一个 $1 \times d$ 的矩阵,该矩阵内每个元素全部为1; R_2 ($R_2 \in [0, 1]$)和 ST ($ST \in [0.5, 1]$)分别表示预警值和安全值。 $R_2 < ST$ 意味着周围捕食者接近,这2个值赋予发现者更宽广的搜索空间。相反, $R_2 \geq ST$ 意味着一些麻雀探测到有捕食者逼近,为确保安全,所有麻雀必须立即撤至更为安全的区域。

(2)跟随者。位置更新公式为:

$$\mathbf{X}_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{\mathbf{X}_{\text{worst}} - \mathbf{X}_{i,j}^t}{i^2}\right), & i > \frac{n}{2} \\ \mathbf{X}_p^{t+1} + |\mathbf{X}_{i,j}^t - \mathbf{X}_p^{t+1}| \cdot \mathbf{A}^T (\mathbf{A} \mathbf{A}^T)^{-1} \cdot \mathbf{L}, & \text{其他} \end{cases} \quad (6)$$

其中, $\mathbf{X}_p$ 表示当前发现者所处的最优位置; $\mathbf{X}_{\text{worst}}$ 表示现阶段搜索空间中最差的位置; $\mathbf{A}$ 表示 $1 \times d$ 的矩阵,矩阵中的每一个元素都会随机地被设定为1或-1;若 $i > n/2$ 时,则表明第 i 个个体对环境变化反应迟钝且尚未觅得食源,显示出了严重的营养不良状态,因此必须到其他地方找东西吃来补充体能。

(3)警报者。位置更新公式为:

$$\mathbf{X}_{i,j}^{t+1} = \begin{cases} \mathbf{X}_{\text{best}}^t + \beta \cdot |\mathbf{X}_{i,j}^t - \mathbf{X}_{\text{best}}^t|, & f_i > f_g \\ \mathbf{X}_{i,j}^t + K \cdot \left(\frac{|\mathbf{X}_{i,j}^t - \mathbf{X}_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon} \right), & f_i = f_g \end{cases} \quad (7)$$

其中, β 用作步长控制,是一个服从正态分布的随机数,其平均值为0,方差为1; K 为在 $[-1, 1]$ 范围内的一个随机数,不仅表示麻雀的移动方向,同时也参与步长的控制; f 表示优化问题的适应度函数,这里 f_i 、 f_g 和 f_w 分别对应麻雀个体的当前适应度值、全局最佳适应度值和最差适应度值; ε 表示一个极小的常量。当 $f_i > f_g$ 时,意味着当前的麻雀位于种群的边缘位置,因此更容易受到捕食者的攻击。当 $f_i = f_g$ 时,可理解为麻雀在种群的中心,感到了危险,因此需要与其他麻雀靠近,以减小被猎食的危险。

3 VMD-SSA-LSSVM 模型

基于VMD-SSA-LSSVM混合模型的径流预测的实现步骤如下:

步骤1 进行数据的清理、填补数据缺失的部分以及剔除不符合规定的数据,通过使用皮尔逊相关系数(Pearson)来筛选出具有较高相关性的特征。

步骤2 构建VMD模拟模型,设定初始相关参数,将数据拆解为 k 个子序列和剩余序列。

步骤3 根据各种特征的量纲等级差异,对特征参数和功率分解的不同模态进行统一化处理。

步骤4 对SSA参数进行初始化,包括SSA的最大迭代次数 M 、种群规模 N 和发现者比例 P 。

步骤5 对每只麻雀的适应水平进行估测,并且推算出整个麻雀群体中的最优个体,同时将其与曾经的最优个体进行评优。然后判断是否已经找到最好的解决措施或是达到了最高的重复操作次数。当达成标准时,重复的过程就会停止,否则,优化的过程会持续迭代。

步骤6 将最佳参数传入LSSVM模型,并对其进行优化。利用经过优化的LSSVM模型进行数据集的训练和预测,并对所有数据集的预测结果进行反向归一化处理和序列重构,以获取最终的预测

数值。

步骤 7 采用平均绝对百分比误差 (*MAPE*)、均方根误差 (*RMSE*) 和平均绝对误差 (Mean Absolute Error, *MAE*) 来评价模型的预测性能。

接下来,还将对实现步骤中涉及的重点研究内容给出阐释分述如下。

(1)相关性分析。存在一种线性关系,可用皮尔逊相关系数来衡量不同气象特征和径流之间的关系,该系数是介于 -1 到 1 之间的一个数,计算方法是度量 2 组数据 X 、 Y 之间的线性关系。数学公式如下:

$$\rho = \frac{cov(X,Y)}{\sigma_X \sigma_Y} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)} \sqrt{E(Y^2) - E^2(Y)}} \quad (8)$$

其中, $cov(X,Y)$ 表示变量 X 、 Y 的协方差, σ_X 、 σ_Y 分别表示变量 X 、 Y 的标准差。当 ρ 值接近 1 时,表示 2 组数据之间的正相关性增强,反之,当 ρ 值接近 -1 时,则表示 2 组数据的负相关性更密切。

(2)数据归一化。各种特性之间的量纲等级是不同的,因此在模型训练前必须对其进行一致化处理。本文采用最大和最小一致化方法,公式如下:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (9)$$

其中, x 表示原始值, $x_{\max}$ 和 $x_{\min}$ 分别表示极大值和极小值。

(3)模型评估指标。为了验证该算法的预测效果精确程度,本节选用了 3 个特定的评判指标来衡量其效果,即平均绝对误差 (Mean Absolute Error, *MAE*)、均方根误差 (Root Mean Square Error, *RMSE*) 和平均绝对百分比误差 (*MAPE*)。计算公式分别如下:

$$L_{MAE} = \frac{1}{n} \sum_i^n |\hat{y}_i - y_i| \quad (10)$$

$$L_{RMSE} = \sqrt{\frac{1}{n} \sum_i^n (\hat{y}_i - y_i)^2} \quad (11)$$

$$L_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (12)$$

其中, n 表示预测点个数,在测试集中, $\hat{y}_i$ 和 y_i 分别表示第 i 个径流的预测数据和真实数据。

4 算例分析

4.1 基于 VMD 的原始数据分解

针对输入数据, VMD 方法被运用在 2022 年 4

月至 2023 年 3 月间的 365 条月径流数据上进行分解。在运用 VMD 方法对原始月径流数据进行分解时,模态个数 k 的设定对分解效果具有显著影响。若设定的分解个数过多,可能会引发混频现象;反之,若分解个数过少,则可能使得原始信号中的信息无法得到充分保留,导致信息流失。当 k 值提升到能将各主要频率段的数据分配到不同的 *IMF* 分量中,且没有产生虚假信息时, k 值就是较为适宜的。在 k 值为 4 的情况下,对应的中心频率更加分散,并且没有出现虚假信息,因此 k 值选择为 4。惩罚系数决定着 *IMF* 分量的带宽。当惩罚系数减小时,各个 *IMF* 部分的带宽会扩大。对于过宽的带宽,有可能导致一些部分内含其他部分的信号;若值增大, *IMF* 部分的带宽则会变窄,过窄的带宽会导致在被拆分的信号中有部分信号失落。一般情况下,此系数的取值区间是 1 000 至 3 000,将研究中的值设定为 2 000。在完成分解后,径流数据被分为 1 个原始部分、4 个 *IMF* 部分以及 1 个残差部分,分解结果如图 1 所示。




图 1 VMD 分解结果

Fig. 1 VMD decomposition results

利用 VMD 分解得到的 4 个 *IMF* 分量,选取前 262 项作为训练集数据,而后 103 项则作为测试集数据。接着,运用 SSA-LSSVM 模型对测试集中的分量进行预测。通过训练前 262 项数据,优化了模型参数,并将优化后的模型应用于后 103 项的测试。最后,将预测结果与实际的测量数据进行对比,以评估模型的性能。

4.2 预测结果及分析

以下用 4 种模型来验证本文组合模型的有效

性。分别建立 LSSVM、SSA-LSSVM、VMD-LSSVM、VMD-SSA-LSSVM 四种模型,并通过式 (10) ~ 式 (12) 进行误差评价,评估结果见表 1。测试数据为 262 天,预测数据为 103 天。模型的预测结果及对比如图 2~图 6 所示。




图 2 LSSVM 模型预测结果

Fig. 2 Prediction results of LSSVM model




图 3 SSA-LSSVM 模型预测结果

Fig. 3 Prediction results of SSA-LSSVM model




图 4 VMD-LSSVM 模型预测结果

Fig. 4 Prediction results of VMD-LSSVM model




图 5 VMD-SSA-LSSVM 模型预测结果

Fig. 5 Prediction results of VMD-SSA-LSSVM model




图 6 各模型预测效果对比

Fig. 6 Comparison of prediction effect of each model

表 1 模型对比评估

Table 1 Model comparison evaluation

模型	MAE	RMSE	MAPE/ %
LSSVM	52.492 0	66.257 0	49.925 3
SSA-LSSVM	49.163 0	64.996 0	51.374 9
VMD-LSSVM	6.732 4	8.476 1	7.793 3
VMD-SSA-LSSVM	2.760 9	3.653 9	3.301 0

由图 5 可以看出,LSSVM 模型的预测数值落后于实际数值,其精确度也不高。然而,VMD-LSSVM 模型成功解决了这一问题,使其不再出现延迟现象。虽然 SSA-LSSVM 模型部分提升了 LSSVM 模型的预测精准度,但结果表现仍未达到预期标准。而 VMD-SSA-LSSVM 则是在 SSA-LSSVM 模型基础上应用 VMD 技术来拆解初始序列,从而降低了初始数据的复杂性和非稳定性对于预测精度的负面影响。这种方式巧妙融合了 SSA-LSSVM 和 VMD-LSSVM 的优势,显著提高了解决径流水文预测问题的能力。从表 1 的数据中可以看到,当使用相同的检测条件时,VMD-SSA-LSSVM 相较于 LSSVM、

SSA-LSSVM、VMD-LSSVM 等模型, *MAE* 分别下降了 49.731 1、46.402 1、3.971 5; *RMSE* 分别下调了 62.603 1、61.342 1、4.822 2; *MAPE* 也相应减小了 46.624 3%、48.073 9%、4.492 3%。这证明了本节所提出的方法比其他方法更具优越性能,极大地改进了各项指标的表现。

5 结束语

本文提出了一种基于北盘江流域某水电站逐日径流预测方法。实验结果表明,本文所提模型的预测结果均有明显的提高,现将本文工作总结如下:

(1)对于包含许多高频成分且频率组成复杂的径流数据,VMD 被用来将其拆分为各种频率组件,并且寻找数据中蕴含的复杂但有用的信息,以降低数据原始复杂性和非稳定性对预测准确度的干扰。

(2)由于径流易受到环境、降雨量、上下游电站水力调度等多方面因素影响,采用单一时间序列模型预测精度有限,甚至预测结果不能满足实际需求;使用 SSA 算法对 LSSVM 进行优化,改善了整个模型的预测性能。

(3)建立了一个结合了 VMD-SSA-LSSVM 的复合模型,且并入了皮尔逊相关系数以便对模型的初始数据进行降维度处理,同时还采用了平均绝对误差 (*MAE*)、均方根误差 (*RMSE*) 和平均绝对百分比误差 (*MAPE*) 的指标来对模型进行评估。

(4)为了验证所提出的径流预测方法的预测能力,对北盘江流域该电站收集的数据进行了验证。通过结果差异的深度分析可知,相较于 LSSVM、SSA-LSSVM 和 VMD-SSA 模型,本文研究中的 VMD-SSA-LSSVM 模型在预测精度上具有显著的优势,表明本文提出算法为径流预测提供了有效的方法。

(5)根据该水电站整年逐日径流数据,可看出其径流变化存在不规律性,而根据预测结果表明,在 4 月后径流量受到气候各方面影响呈上升态势。

(6)麻雀优化算法算法在解决优化问题中有一定的局限性。在某些情况下,由于全局搜索和局部搜索的不平衡,使得该算法会遇到全局搜索能力弱或容易陷入局部最优等现象,这可能导致不适当的结果和缓慢的收敛,因此后续研究中可对此部分进行优化改进。

参考文献

[1] 张冲,王千凤,齐新虎,等. 基于 EEMD-NGO-LSTM 神经网络耦合的月径流预测模型及应用[J]. 水力发电, 2024, 50(1): 1-7.

[2] 后永胜. 水力发电站入库径流预测模型与贝叶斯超参数优化[D]. 天津: 天津大学, 2021.

[3] 刘扬,王立虎. 基于改进 EMD-LSTM 的洪水预测方法研究[J]. 水利水电技术(中英文), 2022, 53(1): 35-44.

[4] DEHGHANI M, HUBALOVSKY S, TROJOVSKY P. Northern Goshawk Optimization: A new swarm-based algorithm for solving optimization problems[J]. IEEE Access, 2021, 9: 162059-16208.

[5] 孙国梁,李保健,徐冬梅,等. 基于 VMD-SSA-LSTM 的月径流预测模型及应用[J]. 水电能源科学, 2022, 40(5): 18-21.

[6] 贺圣平,王会军,李华,等. 机器学习的原理及其在气候预测中的潜在应用[J]. 大气科学学报, 2021, 44(1): 26-38.

[7] 郝增超,侯爱中,张璇,等. 干旱监测与预报研究进展与展望[J]. 水利水电技术, 2020, 51(11): 30-40.

[8] 谢梓彬. 基于神经网络对水电站径流量及水库水位的预测研究[J]. 水利科学与寒区工程, 2022, 5(11): 35-39.

[9] 黄景光,吴巍,程璐瑶,等. 基于小波支持向量机特征分类的日径流组合预测:以宜昌三峡水库为例[J]. 中国农村水利水电, 2018(6): 33-39.

[10] 高永华. 基于 LSTM 的河北省径流量预测研究[J]. 水利技术监督, 2023(9): 15-17.

[11] 陈良,毕晓英,周新志. 基于 EMD-ATT-BiLSTM 的径流量预测模型研究[J]. 现代计算机, 2022, 28(1): 18-24.

[12] 朱非林,侯添甜,梁一帆,等. 基于 VMD-LSTM 的水库中长期径流预测模型[J]. 水力发电, 2023, 49(9): 16-22.

[13] YU Yunluo, LI Wei, SHENG Deren, et al. A hybrid short-term load forecasting method based on improved ensemble empirical mode decomposition and back propagation neural network[J]. Journal of Zhejiang University - Science A (Applied Physics & Engineering), 2016, 17(2): 101-114.

[14] 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.