

# 基于 SSA-VMD-LSTM 的架空输电线路 动态载流量预测方法\*

王 帅 申杰文 徐 彬 朱振东  
(三峡大学电气与新能源学院 宜昌 443002)

**摘 要:** 准确预测架空输电线路动态载流量是保障线路安全增容的关键。针对传统预测模型因依赖人工经验选择模型超参数,难以有效降低线路动态载流量波动性而导致的预测精度不佳问题,本研究创新性提出一种基于 SSA-VMD-LSTM 的预测方法。该方法深度融合了 SSA 的全局优化能力、VMD 的多尺度数据分解特性以及 LSTM 的时序建模优势,构建了一个层次化的人工智能预测模型。首先,利用 SSA 的强大搜索能力对 VMD 超参数进行迭代寻优,获取最优超参数;随后,采用 VMD 对线路动态载流量进行多尺度分解,得到一系列中心频率不同但局部平稳的分量;在此基础上,对多个分量分别建立 LSTM 进行预测;最后,将分量预测结果叠加得到最终预测结果。实验结果表明,与多个传统预测模型相比,所提方法的预测精度至少提升 4.78%,充分验证了该方法在动态载流量预测中的有效性和优越性。

**关键词:** 架空输电线路;动态载流量;SSA;VMD;超参数寻优

**中图分类号:** TM751;TN06 **文献标识码:** A **国家标准学科分类代码:** 470.40

## Accurate prediction of dynamic line rating for overhead transmission lines based on SSA-VMD-LSTM

Wang Shuai Shen Jiewen Xu Bin Zhu Zhendong

(College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China)

**Abstract:** Accurately predicting the Dynamic Line Rating of overhead transmission lines is crucial for ensuring safe line capacity expansion. Traditional prediction models, which rely on manual experience for selecting hyperparameters, often struggle to effectively reduce the volatility of DLR, leading to suboptimal prediction accuracy. To address this issue, this study innovatively proposes an SSA-VMD-LSTM-based prediction method. This approach deeply integrates the global optimization capability of the Sparrow Search Algorithm, the multi-scale data decomposition characteristics of Variational Mode Decomposition, and the temporal modeling advantages of Long Short-Term Memory networks, constructing a hierarchical artificial intelligence prediction model. First, the powerful search ability of SSA is employed to iteratively optimize the hyperparameters of VMD, obtaining the optimal hyperparameters. Subsequently, VMD is used to decompose the DLR data into multiple scales, yielding a series of components with different central frequencies but local stationarity. On this basis, separate LSTM models are established to predict each component. Finally, the prediction results of all components are aggregated to produce the final prediction. Experimental results demonstrate that, compared to several traditional prediction models, the proposed method achieves at least a 4.78% improvement in prediction accuracy, fully validating its effectiveness and superiority in DLR prediction.

**Keywords:** overhead transmission lines;dynamic line rating;SSA;VMD;hyperparameter optimization

## 0 引 言

随着社会用电需求的急剧增长,架空输电线路的输电

能力面临巨大挑战<sup>[1-2]</sup>。为应对这一挑战,通常采用新建输电线路或实施动态增容技术以提升线路的电能输送容量<sup>[3]</sup>。然而,新建输电线路不仅投资巨大,且建设周期较



长,难以在短期内满足日益增长的用电需求。相比之下,动态增容技术<sup>[4]</sup>能够在不改变现有线路架构的前提下,通过实时监测线路周围的气象条件,充分挖掘线路的潜在输电能力,从而实现电能输送容量的提升。

现有研究表明,动态增容技术的核心在于准确预测线路的动态载流量<sup>[5]</sup>(dynamic line rating,DLR),以避免因线路温度越限而引发的安全隐患。然而,DLR 受风、环境温度和日照辐射等多种气象因素耦合影响,其数据具有显著的波动性特征,导致现有模型难以实现准确预测。因此,亟需对现有预测模型进行改进,以充分处理 DLR 数据的波动性特征,确保线路动态增容技术的安全应用。

为了准确预测 DLR 数据,国内外学者展开了大量研究。早期 DLR 数据预测研究通常采用统计学模型<sup>[6-8]</sup>。然而,统计学模型常使用线性叠加函数作为 DLR 数据的预测函数,导致数据的非线性特征易被忽略,造成模型预测精度不佳。随着计算机技术的快速发展,人工智能模型在 DLR 数据预测领域得到了广泛应用。为了更好表征数据的非线性特征,有研究尝试采用埃尔曼神经网络<sup>[9]</sup>、卡尔曼滤波网络<sup>[10]</sup>等模型预测 DLR 数据。但是,上述模型不属于时序类预测模型,难以充分捕捉 DLR 数据的长期时序关系,导致数据预测精度不足。为了解决该问题,后续研究逐渐采用时序类模型中的长短时记忆网络模型<sup>[11]</sup>(long short term memory, LSTM)、互信息法(mutual information, MI)-LSTM 模型<sup>[12]</sup>、门控循环单元模型<sup>[13]</sup>(gate recurrent unit, GRU)预测 DLR 数据。虽然上述模型能够捕捉 DLR 数据的长期时序关系,但其对于数据的波动性特征处理能力不足,导致预测精度提升依然有限。为此,后续研究考虑将 LSTM 时序模型结合经验模态分解<sup>[14]</sup>(empirical mode decomposition, EMD)等数据分解技术预测线路 DLR,以降低数据波动性。然而,EMD 算法在分解包含多种频率成分的 DLR 数据时,可能会因提取分量时的频率交错而造成分量混叠问题。因此,还需引入其他先进的数据分解算法对 DLR 数据的波动性进行处理。

实际上,在其他预测领域也存在类似于因数据波动性特征突出导致的预测精度不佳问题。例如,文献[15]在预测风电功率时曾考虑采用变分模态分解算法(variational mode decomposition, VMD)将波动性特征突出的风电功率数据进行分解,再对各分量预测。此外,文献[16]也曾使用 VMD 算法分解负荷数据,试图降低其波动性,从而提高预测精度。但这些研究并未注意到 VMD 的分解效果受算法中超参数影响严重,传统人工经验所确定的超参数缺乏理论依据,难以保证 VMD 有效分解数据。

因此,本文在 LSTM 模型的基础上,为了降低 DLR 数据的波动性,首先引入 VMD 算法分解 DLR 数据;其次采用麻雀搜索算法(sparrow search algorithm, SSA)寻优 VMD 超参数,确保 VMD 能够有效分解 DLR 数据;最后,利用 LSTM 模型的时序建模优势对各分量分别建立

LSTM 模型进行数据预测,由此提出一种基于 SSA-VMD-LSTM 模型的架空输电线路 DLR 数据预测方法。通过多组实验验证,本文所提模型的预测精度较传统模型提升显著,为架空输电线路的安全增容提供更为可靠的理论支撑。

## 1 架空输电线路 DLR 及现有数据预测方法

### 1.1 架空输电线路 DLR

架空输电线路 DLR 是指在多种气象因素的影响下,导线能够持续承载而不致使其温度超过限值的最大电流。根据 IEEE738 标准可知,架空输电线路 DLR 与多种气象因素之间的关系可由热平衡方程<sup>[17]</sup>进行表示。DLR 的热平衡方程如下:

$$Q_c(T_a, T_c, V, \theta) + Q_r(T_a, T_c) = Q_s(J) + I^2 R(T_c) \quad (1)$$

式中: $Q_c$ 、 $Q_r$  和  $Q_s$  分别为导线对流散热、辐射散热和日照吸热,计算公式如文献[3]; $T_a$  为环境温度; $T_c$  为线路温度; $V$  为风速; $\theta$  为风向角; $J$  为日照辐射强度; $I$  为线路电流; $R(T_c)$  为线路温度为  $T_c$  时的交流电阻值。

当线路温度达到极限  $T_{cmax}$  时,推导得到线路 DLR 的计算公式如下:

$$I_{max} = \sqrt{\frac{Q_c(T_a, T_{cmax}, V, \theta) + Q_r(T_a, T_{cmax}) - Q_s(J)}{R(T_{cmax})}} \quad (2)$$

根据上述分析,架空输电线路 DLR 与多种气象因素之间的影响关系如图 1 所示。

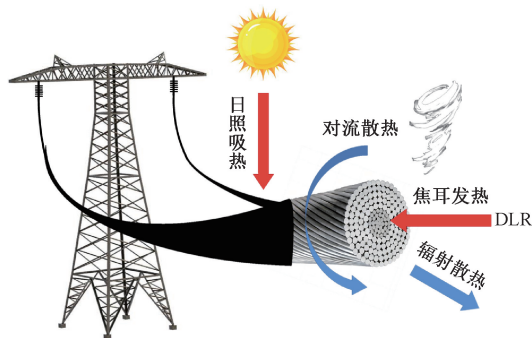


图 1 DLR

Fig. 1 Dynamic line rating

结合图 1 从气象因素的角度分析式(2)知,风速、环境温度、日照辐射强度和风向角这 4 种气象因素是影响 DLR 数据的主要因素。而这 4 种气象因素均具有较强的波动性且对 DLR 数据的影响程度并不相同,导致 DLR 数据也存在明显的波动性特征,预测难度较大。因此,欲准确预测 DLR 数据,需充分考虑数据的波动性特征,并以此为依据对现有数据预测方法进行改进。

### 1.2 现有数据预测方法的不足和改进思路

为了处理 DLR 数据的波动性,可借鉴其他预测领域所使用的方法,即采用 VMD 算法将 DLR 数据分解为一系列



中心频率不同但局部平稳的分量。考虑到 DLR 数据受多种气象因素耦合影响,其波动性特征非常显著,而 VMD 算法的分解效果又极易受算法中分解分量  $k$  和惩罚因子  $\alpha$  超参数的影响。故必须确保 VMD 超参数的最佳选取,进而保证 DLR 数据能够被 VMD 算法有效分解,最终提高预测精度。从现有研究进展来看,对于 VMD 算法中超参数的选取多依赖人工经验<sup>[18]</sup>,理论依据缺乏,导致某一领域所确定的超参数具有很强的局限性,难以沿用至其他领域,甚至难以沿用至相同领域的不同数据环境中。同时,人工经验也无法量化超参数对 DLR 数据分解效果的影响,导致 DLR 数据的分解效果难以得到保证。

基于此,为了保证 VMD 算法在分解 DLR 数据时不受超参数人工选择的不利影响,本文考虑根据 DLR 数据的分解特性构造出能够量化超参数影响 DLR 数据分解效果的目标函数,通过该目标函数建立超参数优化空间与分解效果之间的数学映射关系,从而将 VMD 算法中的超参数经验选取问题转换为可以量化的优化问题进行求解。随后,利用 SSA 算法的强大搜索能力,在超参数寻优空间内对 VMD 算法的超参数迭代寻优。最后,通过比较不同超参数的目标函数数值得到最佳超参数。本文创新提出的基于数据驱动的 VMD 超参数优化方法不仅可以量化不同超参数对 DLR 数据分解效果的影响程度;其次还可以避免传统方法中人工经验选参的主观性,以确保在不同数据环境中挑选出最佳超参数,有效保证 VMD 算法的分解效果,最终提高预测精度。

## 2 算法原理介绍

### 2.1 VMD 算法

VMD 能将 DLR 分解为多个中心频率不同但相对平稳的分量,从而实现降低数据波动性的目的。为避免各 DLR 分量发生混叠现象,需构建以各分量带宽之和最小为目标的约束方程,如式(3)所示。

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

式中:  $\min\{A\}$ , s. t. B 为满足条件 B 时使 A 达到最小;  $h_t$  为偏导运算符;  $\delta(t)$  为狄拉克函数;  $j$  为虚数单位;  $\pi$  为圆周率;  $*$  表示卷积运算符;  $u_k(t)$  为 DLR 数据分解产生的第  $k$  个分量;  $\omega_k(t)$  为第  $k$  个分量所对应的频率;  $f(t)$  为未分解的 DLR 数据。

为简化求解式(3),考虑将该约束变分方程转化成更易于求解的非约束变分方程,如式(4)所示。

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

式中:  $\alpha$  为惩罚因子;  $k$  为 DLR 数据的分解个数;  $\lambda$  为拉格朗日乘法算子。

随后,采用交替方向乘子法<sup>[19]</sup>迭代更新  $u_k$ 、 $\omega_k$ ,寻找式(4)的“鞍点”,即该约束变分方程的最优解,从而完成 DLR 数据分解。限于文章篇幅,具体求解过程详见文献[19]。

### 2.2 SSA 算法

SSA 是一种基于自然界麻雀觅食行为的群体智能优化算法<sup>[20]</sup>,具有优越的超参数寻优性能。采用 SSA 算法寻优 VMD 超参数时,首先需要选取恰当的适应度函数,以评估 SSA 寻优结果的质量。

考虑到经 VMD 分解后的 DLR 数据分量波动性会减弱,进而影响数据包络熵的改变。因此,可以选取包络熵作为 SSA 寻优 VMD 超参数的适应度函数,用于评估 SSA 寻优结果的质量。包络熵的数学表达式如下:

$$\begin{cases} E_p = - \sum_{j=1}^m p_j \lg p_j \\ p_j = a_j / \sum_{j=1}^m a_j \\ a_j = \sqrt{[x(j)]^2 + \{H[x(j)]\}^2} \end{cases} \quad (5)$$

式中:  $a_j$  为 DLR 数据分量通过 Hilbert 调解所得包络序列;  $H[\cdot]$  代表 Hilbert 变换;  $P_j$  代表  $a_j$  归一化后的形式;  $E_p$  代表 DLR 数据分量的包络熵。

在 SSA 迭代计算过程中,麻雀群体的搜索者位置更新公式如下:

$$\mathbf{X}_{i,j}^{t+1} = \begin{cases} \mathbf{X}_{i,j}^t \exp(-\frac{i}{sT_{\max}}), & R_2 < S_T \\ \mathbf{X}_{i,j}^t + \mathbf{QL}, & R_2 \geq S_T \end{cases} \quad (6)$$

式中:  $\mathbf{X}_{i,j}^{t+1}$  为搜索者更新后的位置;  $t$  为迭代次数;  $\mathbf{X}_{i,j}^t$  为搜索者更新前的位置;  $s$  为随机数;  $T_{\max}$  为最大迭代次数;  $\mathbf{L}$  为元素全为 1 的 1 行  $k$  列矩阵;  $\mathbf{Q}$  为服从正态分布的随机数;  $R_2$  为预警数值;  $S_T$  为非预警数值。

追随者注意到搜索者发现更高适应度的资源时,会从当前位置出发前往更有利的位置争夺资源。追随者位置更新公式如下:

$$\mathbf{X}_{y,j}^{t+1} = \begin{cases} U \exp(\frac{\mathbf{X}_w - \mathbf{X}_{y,j}^t}{\alpha T_{\max}}), & y > n/2 \\ \mathbf{X}_p^{t+1} + |\mathbf{X}_{y,j} - \mathbf{X}_p^{t+1}| \mathbf{LA}, & \text{其他} \end{cases} \quad (7)$$

式中:  $\mathbf{X}_{y,j}^{t+1}$  为追随者的更新位置,  $U$  为服从正态分布的随机数,  $\mathbf{A}$  为 1 行  $n$  列的矩阵;  $\mathbf{X}_w$  为麻雀群体中位置最恶劣的麻雀,  $\mathbf{X}_p$  为麻雀群体中位置最优的麻雀。

最后,麻雀群体中的警戒者位置更新公式如下:

$$\mathbf{X}_{E,j}^{t+1} = \begin{cases} \mathbf{X}_{\text{best}} + \beta |\mathbf{X}_{E,j} - \mathbf{X}_{\text{best}}| f_E > f_g \\ \mathbf{X}_{E,j}^t + K \left[ \frac{|\mathbf{X}_{E,j}^t - \mathbf{X}_{\text{worst}}^t|}{(f_E - f_w) + \epsilon} \right] f_E \Leftarrow f_g \end{cases} \quad (8)$$

式中:  $\mathbf{X}_{\text{best}}^t$  为  $t$  次迭代后麻雀群体中警戒者所能找到的最优位置;  $\beta$  为服从正态分布的步长控制参数,  $K$  为麻雀飞行轨迹,取值位于  $[-1, 1]$ ,  $\epsilon$  为趋近于 0 的随机常数,  $f_E$  为  $t$



次迭代后麻雀群体中某只麻雀的适应度,  $f_g$  为最优位置麻雀的适应度,  $f_w$  为最差位置麻雀的适应度。

### 2.3 LSTM 模型

LSTM 在传统循环神经网络的基础上,通过引入三个门控单元和一个记忆细胞,实现信息的准确存储与遗忘,从而有效捕捉 DLR 时序数据中的长期依赖关系<sup>[21]</sup>。因此, LSTM 非常适用于 DLR 时序数据预测。LSTM 的网络结构如图 2 所示。

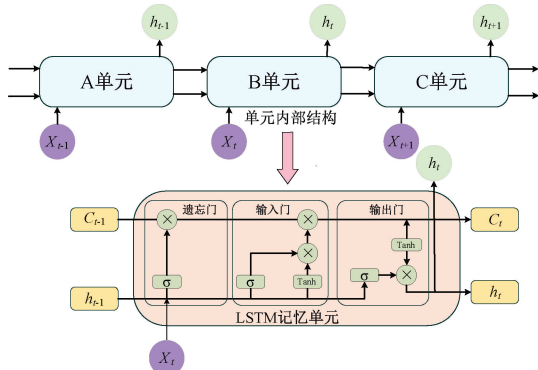


图 2 LSTM 模型

Fig. 2 LSTM model

LSTM 模型的内部更新过程可以表示为:

$$\begin{cases} f_t = \sigma(W_f[h_{t-1}, X_t] + b_f) \\ I_t = \sigma(W_I[h_{t-1}, X_t] + b_I) \\ \tilde{C}_t = \tanh(W_C[h_{t-1}, X_t] + b_C) \\ C_t = f_t * C_{t-1} + I_t * \tilde{C}_t \\ O_t = \sigma(W_O[h_{t-1}, X_t] + b_O) \\ h_t = O_t * \tanh(C_t) \end{cases} \quad (9)$$

式中:  $\sigma$  为 Sigmoid 激活函数;  $W_f, W_I, W_C, W_O$  和  $b_f, b_I, b_C, b_O$  分别为遗忘门  $f_t$ 、输入门  $I_t$ 、记忆细胞  $C_t$  和输出门  $O_t$  的权重矩阵和偏置项;  $X_t$  为当前时刻输入;  $h_{t-1}$  为前一时刻隐藏状态;  $\sigma$  为 Sigmoid 激活函数;  $\tanh$  为激活函数;  $\tilde{C}_t$  为记忆细胞候选状态;  $*$  为哈达码乘。

### 3 预测框架

基于 SSA-VMD-LSTM 的架空输电线路 DLR 预测框架如图 3 所示。

- 1) 随机初始化一定数量的 VMD 超参数  $k$  和  $\alpha$ , 并代入式(5)计算适应度值。
- 2) 根据式(6)~(8)更新 SSA 算法中不同身份麻雀的位置, 以寻找更小适应度值的超参数。
- 3) 达到迭代终止条件后输出最优超参数  $k$  和  $\alpha$ 。
- 4) 对 DLR 数据进行预处理, 主要包括填补缺失数据并删除异常数据。随后, 将数据划分为训练集和验证集。
- 5) 利用 VMD 算法将 DLR 数据分解为  $n$  个中心频率不同但局部平稳的分量。

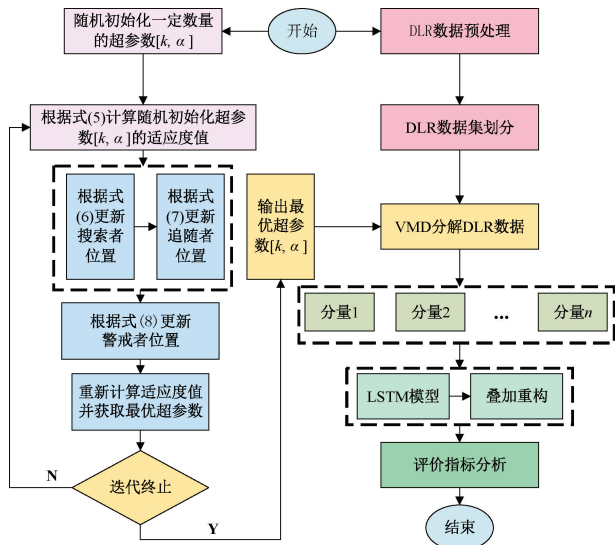


图 3 DLR 数据预测流程图

Fig. 3 DLR data prediction flowchart

6) 依次将  $n$  个分量送入 LSTM 模型进行预测, 得到分量预测值。

7) 对  $n$  个分量的预测值叠加重构, 并采用多个评价指标分析误差。

### 4 实验验证与分析

#### 4.1 数据说明

首先, 以中国广东省广州市某 110 kV 架空输电线路为研究对象, 收集该线路周围临近气象站的风速、环境温度、日照辐射强度和风向角气象数据, 收集间隔为 15 min, 收集时长为 2022 年 1 月~2023 年 3 月。随后, 选取 2022 年数据作为训练集, 对本文所提出的预测模型进行训练。最后, 为了验证训练完成的模型具有良好预测性能, 将 2023 年 3 月数据作为验证集, 用于检验预测模型的预测性能。此外, 需要特别说明的是, 该线路导线型号为 LGJ-300/40, 导线外径为 23.94 mm, 导线直流电阻与最大允许温度分别为 0.961 4  $\Omega/\text{km}$  与 70 $^{\circ}\text{C}$ 。

#### 4.2 数据预处理与评价指标选取

由于数据采集设备的长期户外工作特点极易造成 DLR 数据产生缺失和异常问题。因此, 本文考虑采用 3 次样条插值法<sup>[22]</sup>补全数据缺失部分, 再删除异常数据。为消除不同特征数据间的量纲影响, 最后对数据做最大-最小归一化处理。限于篇幅, 归一化方程详见文献<sup>[23]</sup>。

为了全面体现本文方法的突出预测性能, 考虑选取预测领域中常见的均方根误差(RMSE)、平均绝对百分比误差(MAPE)、平均绝对误差(MAE)和决定系数( $R^2$ )共 4 种评价指标对模型的预测性能进行评价。4 种评价指标详见文献<sup>[24]</sup>。

#### 4.3 VMD 超参数寻优结果分析

为了体现 SSA 算法寻优 VMD 超参数的优越性能, 本文考虑将 SSA 算法与参数优化领域经常使用的粒子群算



法 (particle swarm ptimization, PSO)、遗传算法 (genetic algorithm, GA) 以及 鲸 鱼 算 法 (whale optimization algorithm, WOA) 进行比较分析。同时,为了保证 SSA 等寻优算法的性能比较公平,各算法参数均设置如表 1 所示,且运行环境均为 13th Gen Intel (R) Core (TM) i5-13500HX 2.50 GHz 的 Windows11 64 位操作系统。

表 1 寻优算法参数设置

Table 1 Parameter settings for optimization algorithms			
$\alpha$ 寻优范围	$k$ 寻优范围	最大迭代数	种群数
[100 2 500]	[2 20]	20	30

SSA 等寻优算法的寻优结果如图 4 所示。

分析图 4 可知,SSA、GA、PSO 和 WOA 算法的迭代终止次数均为 20 次,但它们分别在第 6、11、8 和 9 次迭代时适应度函数值已趋于稳定,表明此时均已达到收敛状态。值得注意的是,SSA 算法在 VMD 超参数优化过程中展现出显著的性能优势:其收敛速度最快,仅需 6 次迭代即可达到稳定状态,这主要得益于 SSA 算法在搜索空间中独特的探索与开发平衡机制。此外,从收敛结果来看,SSA 算法获得的最优适应度函数值为 7.083,显著低于其他算法,表明其在 VMD 超参数  $k$  和  $\alpha$  的优化上具有更强的寻优能力,这有助于 VMD 更有效地分解 DLR 数据。




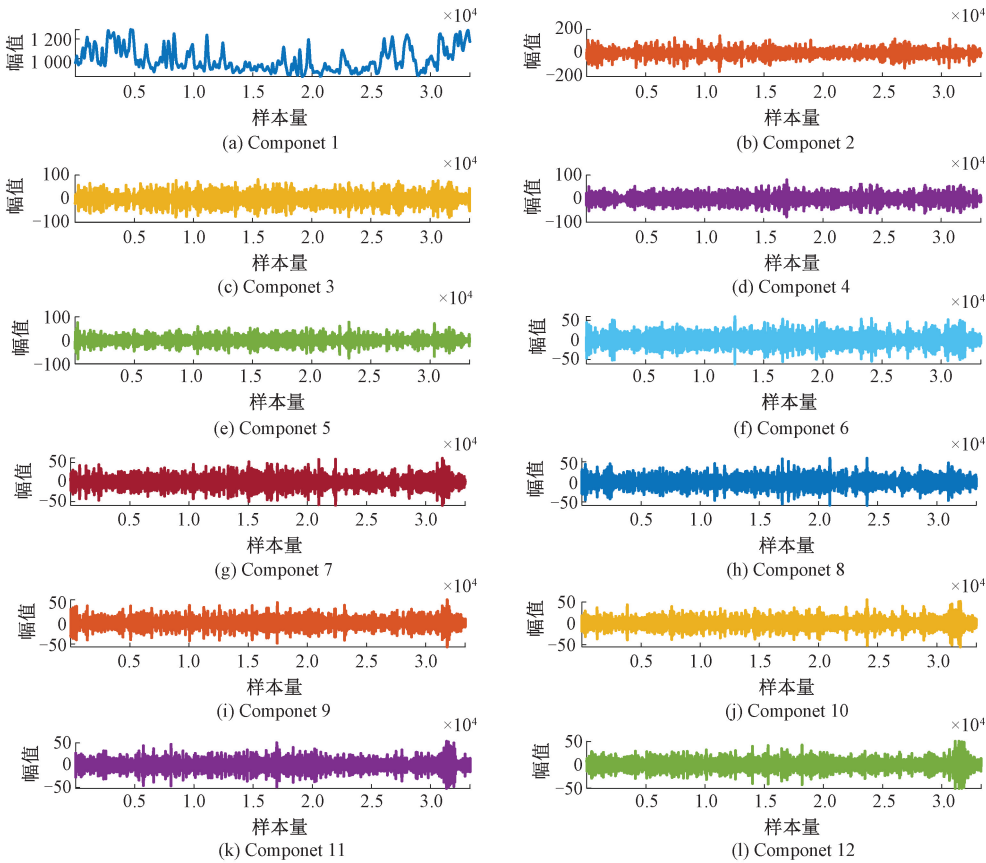
图 4 寻优性能对比

Fig. 4 Comparison of optimization performance

综上所述,与 GA、PSO 和 WOA 等算法相比,SSA 算法在收敛速度和优化质量上均表现出明显优势。因此,在利用 VMD 分解 DLR 数据时,采用 SSA 算法优化 VMD 超参数是一种更为理想的选择。

4.4 VMD 分解 DLR 数据

由于 DLR 数据具有强波动性,故使用超参数优化后的 VMD 算法对其进行分解,分解结果如图 5 所示。





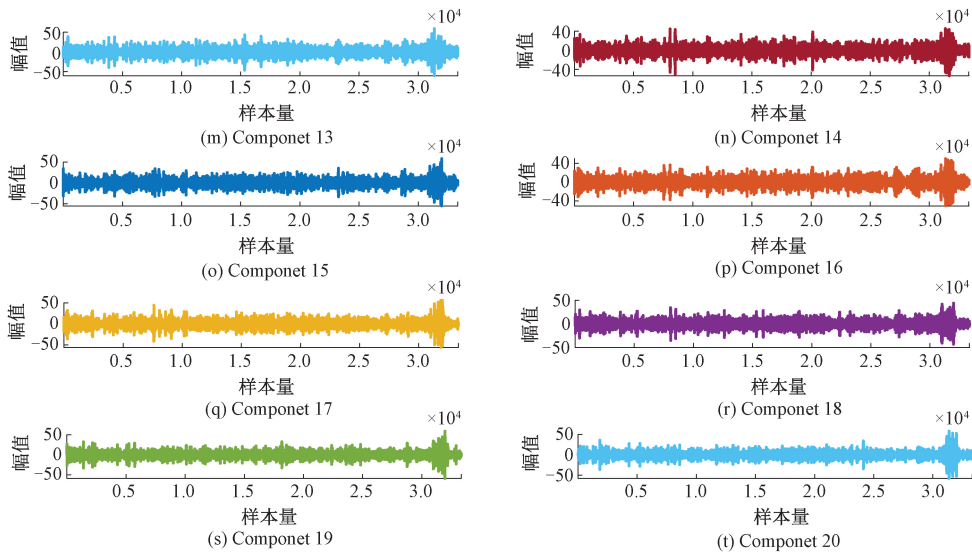


图 5 分解结果

Fig. 5 Decomposition result

分量 1 可捕捉原始 DLR 数据的长期变化趋势,其幅值变化较为平缓,反映 DLR 数据的整体规律。分量 2~10 则反映了 DLR 数据的中期波动,可能与各气象因素突变相关,其幅值变化规律性相对较差,但仍比原始数据更加平滑,且这些分量的局部变化较平稳和清晰。而分量 11~20 的变化规律相对不够明显,但其变化幅值较小,对整体预测结果的不利影响有限。

综上,VMD 通过将原始 DLR 数据分解为多个平稳分量,显著降低数据波动性,为 LSTM 模型提供更清晰和规

律的特征输入,以提高预测精度。

4.5 对比实验 1

为突出本文模型的优异预测性能,将 5 种在 DLR 预测领域应用较为广泛的预测模型作为本实验的对比模型。各模型预测结果如图 6 所示,评价指标如图 7 所示。由于文章篇幅有限,并且为了方便直观比较本文模型与其他对比模型的预测性能差异,考虑在此仅展示 2023 年 3 月数据验证集中存在较大波动性区域的预测结果和评价指标,分别如图 6 和 7 所示。

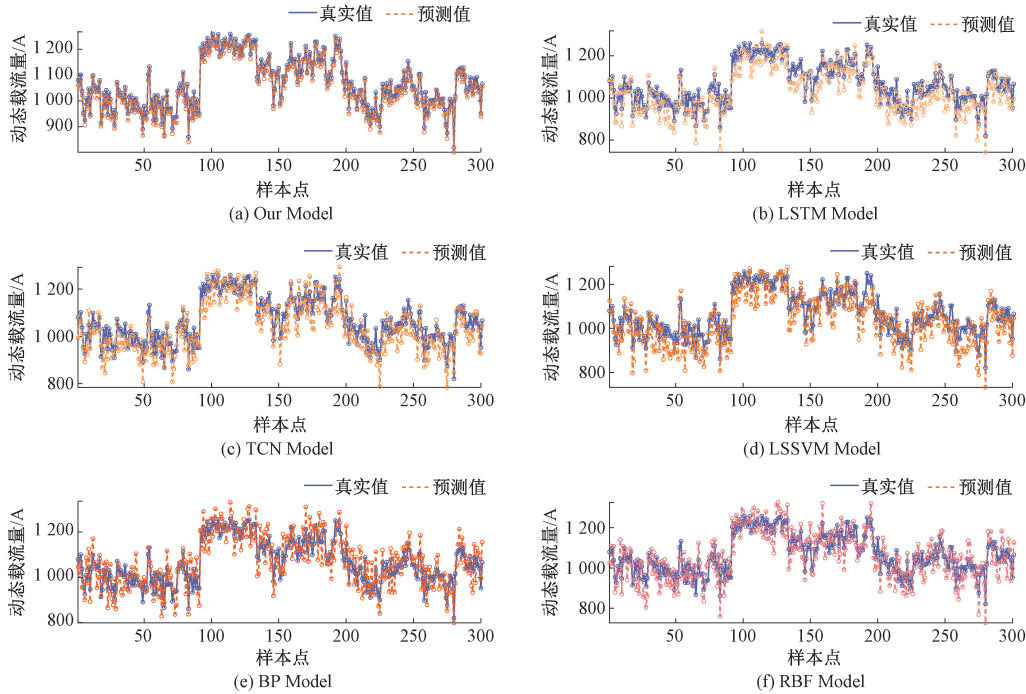


图 6 预测结果

Fig. 6 Prediction results



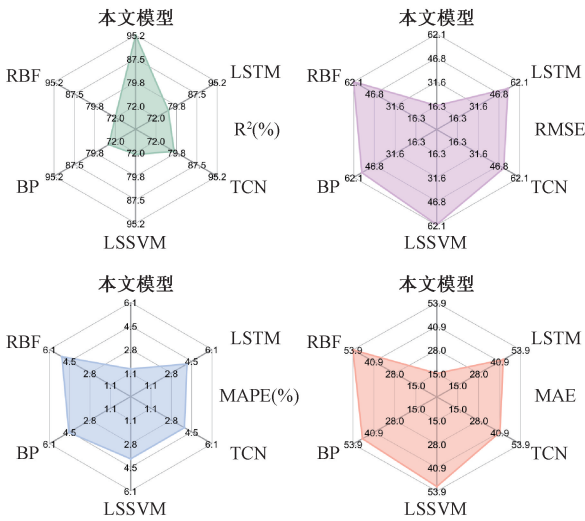


图 7 评价指标

Fig. 7 Evaluation metrics

与 LSTM 等模型相比,本文模型预测曲线与真实值曲线更加贴合。为明确其原因,需结合数据特点和模型原理分析。DLR 数据按时间收集,具有显著时序特征,即先前多个时刻的数据会影响后续时刻数据变化。若需准确预测 DLR 数据,则要求模型能捕捉数据的时序变化。但最小二乘支持向量机(least squares support vector machine, LSSVM)、反向传播神经网络(back propagation neural network, BP)和径向基神经网络(radial basis function, RBF)通过最小化损失函数不断调整模型参数,实现数据预测。因此,上述模型难以充分捕捉数据时序变化,在多个样本点出现较大误差。3 种模型的  $R^2$  均不超过 75%,

预测精度低于 LSTM 和时间卷积网络模型(temporal convolutional network, TCN)。

LSTM 和 TCN 模型内部存在专用于捕捉时序数据长期依赖关系的结构。如 LSTM 通过门控机制来控制数据的流入和流出,从而捕捉数据的长时序关系;TCN 通过因果卷积增加感受野,从而捕捉数据的时序关系。因此, LSTM 和 TCN 的  $R^2$  均超过 75%,预测精度高于另外 3 种模型。

虽然 LSTM 和 TCN 能捕捉数据的长期时序关系,但对于 DLR 数据瞬时的波动变化处理不够充分,导致在多个波动大的样本点存在误差,影响预测精度。本文模型利用 VMD 分解 DLR 数据,降低数据波动性从而提高预测精度。同时保证 VMD 分解有效性,利用 SSA 对 VMD 超参数进行寻优。结合图 7 更直观体现本文模型的优异预测性能,本文模型的  $R^2$  最高,比其他 5 种模型分别提升 18.56%、16.34%、22.63%、20.78%和 23.21%;RMSE 分别降低 37.18、34.11、45.43、39.80 和 45.81;MAPE 分别降低 2.66%、2.45%、2.45%、3.11%和 3.68%;MAE 分别降低 28.13、25.96、36.28、32.92 和 38.82。

#### 4.6 对比实验 2

为进一步突出本文方法的优越预测性能,考虑将文献中的 3 种先进方法作为本实验的对比。3 种先进方法所使用的预测模型分别为 MI-LSTM<sup>[12]</sup>、CNN-GRU-Attention<sup>[13]</sup>以及 EMD-DBO-BiLSTM<sup>[14]</sup>。由于文章篇幅有限,并且为了方便直观比较本文模型与其他先进模型的预测性能差异,考虑在此仅展示 2023 年 3 月数据验证集中存在较大波动性区域的预测结果和评价指标,分别如图 8 和表 2 所示。




图 8 预测结果

Fig. 8 Prediction results



表 2 不同方法的预测评价指标结果

Table 2 The results of prediction evaluation metrics for different methods

方法	RMSE	MAE	MAPE/%	R <sup>2</sup> /%
文献[14]方法	28.596 7	24.679 1	1.99	92.47
文献[13]方法	46.400 1	39.894 6	3.78	79.79
文献[12]方法	51.146 4	44.246 3	4.19	78.63
本文方法	16.299 5	15.045 3	1.42	97.25

实验结果表明,本文模型在 DLR 预测中具有显著优势。本文模型 R<sup>2</sup> 达到 97.25%,较 EMD-DBO-BiLSTM (92.47%)、CNN-GRU-Attention (79.79%) 和 MI-LSTM (78.63%) 分别提升 4.78%、17.46% 和 18.62%。其余指标方面,即使对比次优模型(EMD-DBO-BiLSTM),本文模型依旧性能突出, RMSE、MAE 和 MAPE 指标较次优模型分别降低 43.00%、39.04% 和 28.64%。

结合模型原理分析数据结果可知,MI-LSTM 仅利用 MI 算法加强 LSTM 对 DLR 数据时序特征的提取,而忽略

数据波动性处理,导致预测性能不佳;而 CNN-GRU-Attention 同样采用多种时序特征提取算法与时序模型结合,以更好处理 DLR 数据的时序特征,同样忽略数据波动特征导致预测精度不佳;最后,EMD-DBO-BiLSTM 模型利用 EMD 算法在一定程度上降低了 DLR 数据波动性,但 EMD 的固有缺陷限制了模型精度的进一步提升。而本文模型通过引入基于变分问题构造与求解的 VMD 算法有效避免了 EMD 分解时的频率混叠问题,更有效降低 DLR 数据波动性。在此基础上,本文模型还引入搜索能力强大的 SSA 算法寻优 VMD 超参数,以保证 VMD 分解性能。

4.7 消融实验

为了评估本文模型中各算法的有效性,考虑以本文模型为基础,构建去除 SSA 算法的 VMD-LSTM 消融模型以及同时去除 SSA 算法和 VMD 算法的 LSTM 消融模型,并将两种消融模型与本文模型进行预测性能对比。限于文献篇幅,仅展示 2023 年 3 月数据验证集中波动性较大区域的预测结果和评价指标。各模型预测结果如图 9 所示,评价指标如表 3 所示。




图 9 预测结果

Fig. 9 Prediction results

表 3 不同方法的预测评价指标结果

Table 3 The results of prediction evaluation metrics for different methods

方法	RMSE	MAE	MAPE/%	R <sup>2</sup> /%
VMD-LSTM	34.572 6	30.171 6	2.85	88.93
LSTM	53.482 5	43.183 1	4.08	76.69
本文方法	16.299 5	15.045 3	1.42	97.25

本文方法的 MAE、MAPE、RMSE 和 R<sup>2</sup> 均为 3 种模型中最优,分别为 15.045 3、1.42%、16.299 5 和 97.25%;而 VMD-LSTM 的 4 种指标分别为 30.171 6、2.85%、34.572 6 和 88.93%;LSTM 的 4 种指标分别为 43.183 1、4.08%、53.482 5 和 76.69%。

其次,相比于 VMD-LSTM,本文方法的 MAE、MAPE 和 RMSE 分别降低 15.126 3、1.43% 和 18.273 1, R<sup>2</sup> 提升 8.32%。结合模型原理分析可知,VMD-LSTM 仅依靠经



验选择 VMD 超参数,导致 VMD 算法在分解 DLR 数据时丢弃包含重要中心频率成分的分量数据,造成预测结果不佳。而本文方法采用 SSA 算法寻优 VMD 超参数,并且在寻优过程中以包络熵为适应度函数持续迭代,保证 VMD 有效分解 DLR 数据,从而提高模型的预测精度。

最后,相比 LSTM 模型,本文模型的 MAE、MAPE 和 RMSE 分别降低 28.137 8、2.66%、37.183,而  $R^2$  提升 20.56%。LSTM 模型直接对 DLR 数据进行预测,容易忽略数据的波动性,导致在波动性较大的样本点存在较大预测误差。而本文模型引入 VMD 算法将数据分解为一系列中心频率不同且局部平稳的分量,同时采用 SSA 算法保证 VMD 分解的有效性,极大程度上提高预测精度。

## 5 结 论

本文提出一种基于 SSA-VMD-LSTM 的架空输电线路 DLR 数据预测方法。以广州市某 110 kV 输电线路为例,进行 DLR 数据的预测,得到结论如下:

首先,采用 VMD 分解 DLR 数据时,可利用 SSA 的强大搜索能力对 VMD 超参数迭代寻优。寻优结果表明,SSA 的收敛速度和收敛精度均优于 PSO、GA 和 WOA 等传统寻优算法,验证了 SSA 优化 VMD 超参数的有效性。

其次,采用 SSA 优化后的 VMD 算法分解 DLR 数据,可将波动性强的原始数据分解为多个中心频率不同但局部平稳的分量,更有利于模型学习 DLR 数据的本质规律,从而提高模型预测精度。消融实验结果表明,本文模型的 DLR 数据预测精度均优于 LSTM 模型和 VMD-LSTM 模型,验证了本文模型中各算法的必要性。

最后,收集中国广州市某 110 kV 线路周围真实气象数据进行实验。实验结果表明,本文方法预测精度优于 DLR 预测领域多种传统单一模型与先进组合模型,验证了本文方法的优越预测性能,为架空输电线路安全增容提供更可靠的理论支撑。

## 参考文献

- [1] 侯宇,王伟,韦微,等. 输电线路动态增容技术研究及应用[J]. 电力系统自动化, 2021, 45(17): 189-198.  
HOU Y, WANG W, WEI ZH, et al. Research and application of dynamic rating technology of transmission lines[J]. Automation of Electric Power Systems, 2021, 45(17): 189-198.
- [2] 徐彬,刘任,刘焱,等. 计及线路载流不确定性风险的电力系统环境经济调度[J/OL]. 电网技术, 1-13 [2025-03-30]. <https://doi.org/10.13335/j.1000-3673.pst.2024.0870>.  
XU B, LIU R, LIU Y, et al. Environmental and economic dispatch for power systems considering

uncertainty risk of line ampacity[J/OL]. Power System Technology, 1-13[2025-03-30]. <https://doi.org/10.13335/j.1000-3673.pst.2024.0870>.

- [3] 周海松,陈哲,张健,等. 应用气象数值预报技术提高输电线路动态载流量能力[J]. 电网技术, 2016, 40(7): 2175-2180.  
ZHOU H S, CHEN ZH, ZHANG J, et al. Application of meteorological numerical forecast technology for improving transmission line capability[J]. Power System Technology, 2016, 40(7): 2175-2180.
- [4] 徐彬,刘任,唐波,等. 基于多误差特性融合的架空线路载流量概率预测[J/OL]. 电力系统自动化, 1-21 [2025-03-30]. <http://kns.cnki.net/kcms/detail/32.1180.tp.20250320.1453.006.html>.  
XU B, LIU R, TANG B, et al. Probabilistic ampacity prediction for overhead transmission lines integrating multiple mirror characteristics[J/OL]. Automation of Electric Power Systems, 1-21[2025-03-30]. <http://kns.cnki.net/kcms/detail/32.1180.tp.20250320.1453.006.html>.
- [5] 高正男,胡姝博,金田,等. 考虑传输线动态增容风险的电力系统日前调度模型[J]. 高电压技术, 2023, 49(8): 3215-3226.  
GAO ZH N, HU SH B, JIN T, et al. Day-ahead power system scheduling model considering transmission line dynamic capacity expansion risk[J]. High Voltage Engineering, 2023, 49(8): 3215-3226.
- [6] JIANG J A, YANG Y C, WANG C H, et al. Impact assessment of various wind speeds on dynamic thermal rating of the terrain-located EHV power grids. A Case of Valley in Taiwan[J]. IEEE ACCESS, 2018, (6): 48311-48323.
- [7] MADADI S, MOHAMMADI-IVATLOO B, TOHIDI S. Dynamic line rating forecasting based on integrated factorized Ornstein-Uhlenbeck processes[J]. IEEE Transactions on Power Delivery, 2020, 35(2): 851-860.
- [8] JIANG J A, LIANG Y T, CHEN C P, et al. On dispatching line ampacities of power grids using weather-based conductor temperature forecasts[J]. IEEE Transactions on Smart Grid, 2018, 9(1): 406-415.
- [9] 于宗超,刘绚,严康,等. 考虑 DLR 和风电预测不确定性的机会约束机组组合模型[J]. 高电压技术, 2021, 47(4): 1204-1214.



- YU Z CH, LIU X, YAN K, et al. Combination model of chance-constrained security constraint unit with considering the forecast uncertainties of DLR and wind power[J]. High Voltage Engineering, 2021, 47(4): 1204-1214.
- [10] ALVAREZ D L, SILVA F F D, MOMBELLO E E, et al. Conductor temperature estimation and prediction at thermal transient state in dynamic line rating application[J]. IEEE Transactions on Power Delivery, 2018, 33(5): 2236-2245.
- [11] 孙辉, 卢雪立, 高正男, 等. 基于 AL-BILSTMDN 的输电线动态热极限概率预测[J]. 电力系统及其自动化学报, 2024, 36(6): 110-118.
- SUN H, LU X L, GAO ZH N, et al. AL-BILSTMDN based transmission lines dynamic thermal rating probability prediction[J]. Proceedings of the CSU-EPSA, 2024, 36(6): 110-118.
- [12] 秦爽, 朱秋成, 施宇丹. 基于 MI-LSTM 输电线动态参数修正的电力系统可用输电能力计算[J]. 东北电力技术, 2023, 44(11): 1-6.
- QIN SH, ZHU Q C, SHI Y D. Available transfer capability calculation of power systems based on MI-LSTM transmission line dynamic parameter modification [J]. Northeast Electric Power Technology, 2023, 44(11): 1-6.
- [13] YANG X, HU Z, TIAN Y, et al. Short-term heavy overload forecasting method of distribution net line based on CNN-GRU with Attention mechanism[J]. Journal of Electric Power Science and Technology, 2023, 38(1): 201-209.
- [14] 刘明林. 基于 EMD-DBO-BiLSTM 的风电外送线路载流量预测方法[J]. 山东电力技术, 2024, 51(7): 19-26, 60.
- LIU M L. Wind power transmission line ampacity prediction method based on EMD-DBO-BiLSTM[J]. Shandong Electric Power, 2024, 51(7): 19-26, 60.
- [15] 蒲晓云, 杨靖, 杨兴, 等. 基于分解技术的 IZOA-Transformer-BiGRU 短期风电功率预测[J]. 电子测量技术, 2025, 48(2): 39-48.
- PU X Y, YANG J, YANG X, et al. Short-term wind power prediction based on decomposition technology using IZOA-Transformer-BiGRU [J]. Electronic Measurement Technology, 2025, 48(2): 39-48.
- [16] 王强, 刘宏伟, 聂子凡. 基于 VMDT-POA-DELM-GPR 的两阶段短期负荷预测[J]. 国外电子测量技术, 2024, 43(1): 101-109.
- WANG Q, LIU W H, NIE Z F. Two-stage short-term load forecasting based on VMDT-POA-DELM-GPR[J]. Foreign Electronic Measurement Technology, 2024, 43(1): 101-109.
- [17] 李瀚儒, 刘智健, 来立永, 等. 考虑气象参数预测误差条件分布的架空输电线路载流量概率预测方法[J]. 中国电力, 2024, 57(2): 103-114.
- LI H R, LIU ZH J, LAI L Y, et al. Current-carrying capacity probability prediction of overhead transmission line considering conditional distribution prediction errors of meteorological parameters [J]. Electric Power, 2024, 57(2): 103-114.
- [18] 石欣, 张夏恒, 朱雅亲, 等. 基于 VMD-NARX 的 MOSFET 剩余使用寿命预测方法[J]. 仪器仪表学报, 2023, 44(9): 275-286.
- SHI X, ZHANG X H, ZHU Y Q, et al. Method for predicting the remaining useful life of MOSFET based on VMD-NARX [J]. Chinese Journal of Scientific Instrument, 2023, 44(9): 275-286.
- [19] 白毅翔, 陈志英, 张修伦, 等. 基于改进 VMD-WT 的油浸式变压器局部放电超声信号去噪方法[J]. 电子测量与仪器学报, 2024, 38(12): 237-249.
- BAI Y X, CHEN ZH Y, ZHANG X L, et al. Ultrasonic signal denoising method for partial discharge of oil-immersed transformer based on improved VMD-WT [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(12): 237-249.
- [20] 袁建华, 蒋文军, 李洪强, 等. 基于 SSA-BiLSTM 非线性组合方法的光伏功率预测[J]. 电子测量技术, 2023, 46(21): 63-71.
- YUAN J H, JIANG W J, LI H Q, et al. Photovoltaic power forecasting based on SSA-BiLSTM nonlinear combination method [J]. Electronic Measurement Technology, 2023, 46(21): 63-71.
- [21] 赵昱坡, 黄伟, 张剑飞. 基于混合尺度健康因子的 LSTM-Transformer 锂电池寿命预测[J]. 电子测量技术, 2024, 47(11): 112-122.
- ZHAO Y P, HUANG W, ZHANG J F. Lithium battery remaining useful life prediction based on hybrid scale health factors using LSTM-Transformer model [J]. Electronic Measurement Technology, 2024, 47(11): 112-122.
- [22] 王安康, 王浩磊, 王树才. 基于三次样条插值法的柱



面近场测量欠采样修正算法研究[J]. 电波科学学报, 2024, 39(2): 339-344.

WANG AN K, WANG H L, WANG SH C. Under sampled modified algorithm for cylindrical near-field measurement based on cubic spline interpolation[J]. Chinese Journal of Radio Science, 2024, 39(2): 339-344.

- [23] 严伯伦, 谢红刚, 杨明. 微气象分析与载流量预测结合的动态线路增容方法[J]. 电力系统及其自动化学报, 2022, 34(12): 137-144.

YAN B L, XIE H G, YANG M. Dynamic line rating method combining micrometeorological analysis and Ampacity Forecasting [J]. Proceedings of the CSU-EPSA, 2022, 34(12): 137-144.

- [24] 胡锐, 乔加飞, 李永华, 等. 基于 WOA-VMD-SSA-LSTM 的中长期风电预测[J]. 太阳能学报, 2024, 45(9): 549-556.

HU R, QIAO J F, LI Y H, et al. Medium and long term wind power forecast based on WOA-VMD-SSA-LSTM [J]. Acta Energiæ Solaris Sinica, 2024, 45(9): 549-556.

## 作者简介

王帅(通信作者), 硕士研究生, 主要研究方向为架空输电线路动态增容技术。

E-mail: 17761280515@163.com

申杰文, 硕士研究生, 主要研究方向为电力系统控制与预测。

E-mail: 3039695101@qq.com

徐彬, 硕士研究生, 主要研究方向为架空线路动态增容技术及其在电力系统运行分析与控制中的应用。

E-mail: mrxbin@126.com

朱振东, 博士研究生, 主要研究方向为电力系统预测研究。

E-mail: 202208080011002@ctgu.edu.cn