

# 基于 ICEEMDAN-TA-LSTM 模型的主动 配电网短期运行态势预测

刘 舒<sup>1</sup>, 姚尚坤<sup>2</sup>, 周 敏<sup>3</sup>, 朱 峰<sup>2</sup>, 田书欣<sup>2</sup>, 肖文渊<sup>2</sup>

(1. 国网上海市电力公司电力科学研究院, 上海 200437; 2. 上海电力大学电气工程学院, 上海 200090;  
3. 国网上海市电力公司浦东供电公司, 上海 200120)

**摘 要:** 主动配电网运行态势预测是充分保障配电网安全、稳定运行及感知潜在故障的重要手段。针对主动配电网运行态势的快速精确预测, 提出一种基于 ICEEMDAN-TA-LSTM 模型的主动配电网短期运行态势预测方法。首先, 通过改进模态分解将原始序列分解成若干稳定的时序分量, 降低原始数据的不规律性; 其次, 提出融合残差、特征以及时间注意力的三重注意力机制的主动配电网时序预测模型, 深度挖掘各运行态势要素内相关性及要素间互相关性; 同时, 利用改进蝠鲞寻食优化算法对模型超参数寻优, 综合提升模型整体预测精度; 然后, 从节点、支路角度出发, 提出节点电压越限裕度、支路负载严重度以及电压/电流波动态势评价指标, 多层次表征配电网运行态势; 最后, 以改进 IEEE 33 节点为典型算例, 验证所提模型的可行性及有效性。

**关 键 词:** 主动配电网; 运行态势; 改进蝠鲞寻食优化算法; 三重注意力机制; 波动系数

DOI: 10.19781/j.issn.1673-9140.2023.06.019 中图分类号: TM714 文章编号: 1673-9140(2023)06-0175-12

## Active distribution network operating situation prediction based on ICEEMDAN-TA-LSTM model

LIU Shu<sup>1</sup>, YAO Shangkun<sup>2</sup>, ZHOU Min<sup>3</sup>, ZHU Feng<sup>2</sup>, TIAN Shuxin<sup>2</sup>, XIAO Wenyuan<sup>2</sup>

(1. Electric Power Research Institute, State Grid Shanghai Electric Power Company, Shanghai 200437, China; 2. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China; 3. Pudong Power Supply Company, State Grid Shanghai Electric Power Company, Shanghai 200120, China)

**Abstract:** The active distribution network operation situation prediction is an important tool to guarantee the safety and stability of the distribution network and the hazard perception. For the fast and accurate prediction of active distribution network operation, this paper proposes an active distribution network short-term operation prediction method based on ICEEMDAN-TA-LSTM model. Firstly, the original sequence is decomposed into several stable time series components by improving the modal decomposition to reduce the irregularity of the original data. At the same time, the improved manta ray feeding optimization algorithm is used to optimize the model's hyperparameters to comprehensively improve the overall prediction accuracy of the model. Then, from the perspective of nodes and branches, the node voltage overrun margin, branch load severity and voltage/current fluctuation evaluation indexes are proposed to characterize the distribution network operation situation at multiple levels. Finally, the feasibility and effectiveness of the model proposed in this paper

收稿日期: 2022-08-08; 修回日期: 2023-02-16

基金项目: 国网上海市电力公司科技项目(52094021N004)

通信作者: 田书欣(1985—), 男, 博士, 讲师, 主要从事电网运行分析等研究; E-mail: tsx396@shiep.edu.cn

are verified by taking the improved IEEE 33 node as a typical calculation example.

**Keywords:** active distribution network; operational dynamics; improved manta ray seeking optimization algorithm; triple attention mechanism; fluctuation coefficient

大量接入分布式电源、电动汽车以及供需侧多元互动已成为主动配电网的主要特征<sup>[1]</sup>。然而,由于主动配电网中电源和负荷等要素的不可预测性,配电网运行状态复杂多变<sup>[2]</sup>。相对于输电网,配电网的运行态势对运行要素的变化十分敏感,这种敏感性可能会直接影响到配电网的电能质量甚至是用户的用电可靠性。因此,亟需提出合适的主动配电网运行态势预测方法,以准确分析主动配电网未来运行态势变化,进一步提高主动配电网安全可靠运行水平。

分布式电源出力和负荷等运行要素的准确预测是捕捉主动配电网未来运行态势变化的重要基础。目前,已经提出的时序预测方法主要分为3类:第1类是数学工具和统计方法,主要有卡尔曼滤波<sup>[3]</sup>、自回归<sup>[4]</sup>以及自回归移动平均<sup>[5]</sup>等模型,通常适用于线性和静止时间序列;第2类是人工智能算法,具有出色的自学习和非线性映射能力,主要包括极限学习机<sup>[6]</sup>、支持向量机<sup>[7]</sup>和神经网络<sup>[8]</sup>等。其中,长短期记忆网络(long-short term memory, LSTM)是目前电力行业时间序列预测中应用较多的一种网络模型。文献[9]利用LSTM进行负荷预测,结果表明,与传统的反向传播神经网络(backpropagation neural network, BP)、极限学习机等相比,LSTM具有更好的预测性能。然而,单一LSTM模型的优势仅限于较短序列,应对长时间序列的学习能力不足,并且对于风光等有高维特征的数据信息挖掘能力较弱。文献[10]提出一种基于卷积神经网络(convolutional neural network, CNN)和LSTM的短期风电功率预测模型,利用CNN卷积层和池化层分别对数据进行特征提取和数据降维,再输入LSTM进行预测,这种组合可能导致某些重要特征信息被忽略;文献[11]将时间和特征注意力机制引入CNN和双向LSTM模型用以超短期负荷预测,通过不同权重以区分不同时间负荷序列的贡献度,但并未考虑不同特征对预测结果的贡献度。第3类是组合算法,如利用遗传算法(genetic algorithm, GA)<sup>[12]</sup>和贝叶斯算法<sup>[13]</sup>等人工智能算法进行参数寻优。文献[14]利用粒子群算法(particle

swarm optimization, PSO)优化LSTM的超参数组合,以解决LSTM的超参数选择难题。蝠鲞觅食优化算法(manta ray foraging optimization, MRFO)是受蝠鲞群体觅食启发而设计的新型智能算法,相较于粒子群算法、布谷鸟算法等具有寻优效果更好和易于实现等优点<sup>[15]</sup>。但主动配电网时序数据的不确定性使得智能算法优化效果有限。此外,鉴于分布式电源出力和负荷变化的非平稳性和强波动性,通过增加前置序列分解环节构建组合预测模型,能够提升模型的预测精度。文献[16]首先通过变分模态分解将非平稳的负荷序列分解为多个相对平稳的模态分量,并利用LSTM对每个模态分量进行预测,解决LSTM预测非稳定性时序数据效果差的问题。

态势预测是态势感知的状态预测阶段,用于预测未来配电网源荷等运行要素的变化趋势,同时可以实时评估配电网的运行风险<sup>[17]</sup>。基于最小二乘向量机负荷预测和潮流计算,文献[18]提出一种获取配电网未来时刻运行状态的方法,但该方法并未考虑分布式电源的接入,且未对负荷预测精度和预测结果的精确性进行分析;文献[19]提出一种基于数据挖掘和机器学习算法的配电网态势感知方法,通过将态势感知建模为事件分类、检测和判别问题,分析配电网的状态;文献[20]结合历史量测电压数据和实时状态估计,对下一时刻配电网各节点电压相量进行预测,进而实现配电网的态势预测,但该类方法依赖于量测数据的准确性,且只能反应电压变化情况。

综上所述,本文同时将智能算法和模态分解引入LSTM网络,提出一种基于ICEEMDAN-TA-LSTM模型的主动配电网短期运行态势预测方法,对现有方法进行补充和完善。首先,采用一种改进的完全自适应噪声集合经验模态分解(improved complete ensemble empirical mode decomposition, ICEEMDAN)算法<sup>[21]</sup>对输入样本进行序列分解,以克服CEEMDAN分解后可能出现伪模态以及残余噪声不能完全消除的问题,将配电网负荷和分布式电源等运行要素的功率数据进行序列分解,降低原

始数据的不规律性;再提出一种融合残差、特征以及时间注意力的三重注意力机制 LSTM (triple attention mechanism based LSTM, TA-LSTM) 网络模型进行短期预测;同时,提出一种改进的 MRFO 算法对模型超参数寻优,综合提升模型的预测性能。其次,结合负荷和风电的实测历史数据,用所提模型对配电网未来节点负荷和风电等运行要素的功率进行预测,并提出节点电压越限裕度、支路负载严重度和节点电压/支路电流的波动系数等多层面指标,通过各时间断面的潮流计算获取配电网实时、精确和直观的运行态势。最后,通过对所提模型与其他预测模型的效果对比以及改进 IEEE 33 节点配电网的算例分析,验证本文所提方法的准确性和有效性。

## 1 ICEEMDAN 算法

ICEEMDAN 是在完全集合经验模态分解 (complete ensemble empirical mode decomposition, CEEMDAN) 算法基础上改进而来,在信号分解迭代过程中,加入一定量的高斯白噪声并对生成的信号分量求均值<sup>[21]</sup>。对于输入样本  $x(t)$ , ICEEMDAN 算法的分解流程如下。

1) 加入高斯白噪声于原始时间序列,得到第  $i$  次待分解信号:

$$x_i(t) = x(t) + \varepsilon_0 E_1(\omega_i(t)), \quad i = 1, 2, \dots, n \quad (1)$$

式中,  $\omega_i(t)$  为零均值单位方差高斯白噪声;  $\varepsilon_0$  为噪声;  $E_1(\omega_i(t))$  为  $\omega_i(t)$  的第 1 个 EMD 分量。

2) 通过 EMD 分解计算  $x_i(t)$  的局部平均值,得到第 1 次分解的残差  $r_1(t)$  和第 1 个模态分量 (intrinsic mode functions, IMF)  $\bar{I}_{MF_1}(t)$ :

$$\begin{cases} r_1(t) = \frac{1}{n} \sum_{i=1}^n M(x_i(t)) \\ \bar{I}_{MF_1}(t) = x - r_1(t) \end{cases} \quad (2)$$

式中,  $M(\cdot)$  为产生局部均值的操作符。

3) 计算第 2 个残差  $r_2(t)$  和第 2 个模态分量  $\bar{I}_{MF_2}(t)$ :

$$\begin{cases} \bar{I}_{MF_2}(t) = \frac{1}{n} \sum_{i=1}^n M(\bar{I}_{MF_1}(t) + \varepsilon_1 E_2(\omega_i(t))) \\ r_2(t) = \bar{I}_{MF_1}(t) - \bar{I}_{MF_2}(t) \end{cases} \quad (3)$$

4) 对于其余每个阶段,即  $k = 1, 2, \dots, n$ , 根据上述步骤,计算第  $k$  个剩余信号和模态分量,得到:

$$\begin{cases} \bar{I}_{MF_{k+1}}(t) = \frac{1}{n} \sum_{i=1}^n M(\bar{I}_{MF_k}(t) + \varepsilon_k E_k(\omega_i(t))) \\ r_k(t) = \bar{I}_{MF_{k-1}}(t) - \bar{I}_{MF_k}(t) \end{cases} \quad (4)$$

5) 重复步骤 4), 直到余量信号无法再分解,最终得到  $n$  个模态分量和剩余信号  $R_e(t)$ , 剩余分量的频率成分最低,周期大于信号的记录长度,可将其视为信号的总趋势。原始信号序列  $x(t)$  可表示为

$$x(t) = \sum_{i=1}^K \bar{I}_{MF_i}(t) + R_e(t) \quad (5)$$

## 2 基于 TA-LSTM 的运行要素预测模型

### 2.1 LSTM 网络

LSTM 网络在循环神经网络基础上增加了遗忘门 (forget gate, FG)、输入门 (input gate, IG)、输出门 (output gate, OG), 并在结构中引入存储数据状态的“记忆功能”模块,有效解决了 RNN 因梯度激增和消失而无法构建较长时间序列预测模型的问题<sup>[22]</sup>。LSTM 的单元结构如图 1 所示。

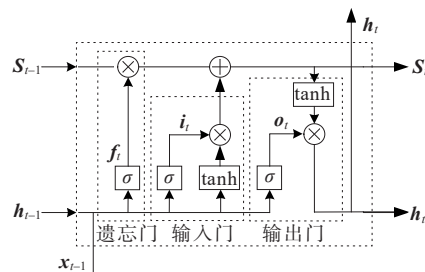


图 1 LSTM 单元结构

Figure 1 LSTM cell structure diagram

FG 控制上一时刻单元状态  $s_{t-1}$  中需要保存的信息,并将其保存到当前单元状态  $s_t$  中;IG 控制当前时刻的输入  $x_t$  有多少信息保存到当前单元状态  $s_t$  中;OG 控制的是当前单元状态  $s_t$  中的信息量,将其保存到当前输出状态  $h_t$  中。LSTM 算法的更新和计算为

$$f_t = \sigma(\mathbf{w}_f \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f) \quad (6)$$

$$i_t = \sigma(\mathbf{w}_i \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i) \quad (7)$$

$$o_t = \sigma(\mathbf{w}_o \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o) \quad (8)$$

$$\hat{s}_t = \tanh(\mathbf{w}_s \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_s) \quad (9)$$

$$s_t = f_t \otimes s_{t-1} + i_t \otimes \hat{s}_t \quad (10)$$

$$h_t = o_t \otimes \tanh(s_t) \quad (11)$$

式(6)~(11)中, $f_i, i_i, o_i, s_i, h_i$ 分别为FG、IG、OG、记忆单元和输出单元的状态矩阵; $\sigma$ 为Sigmoid激活函数; $\hat{s}_i$ 为当前记忆单元状态的候选值向量; $w_f, w_i, w_o, w_s$ 分别为FG、IG、OG和记忆单元的权重矩阵; $b_f, b_i, b_o, b_s$ 分别为FG、IG、OG和记忆单元的偏置项; $\tanh(\cdot)$ 为激活函数; $\otimes$ 表示矩阵对应元素相乘。

## 2.2 三重注意力机制

配电网负荷、分布式电源等运行要素历史数据中包含功率信息及其对应的环境和气象等相关信息。注意力机制能够很好地挖掘各运行要素的历史数据以及相关特征信息变化规律,提升信息处理的效率。为提高LSTM的预测效果,本文将残差、特征以及时序注意力引入LSTM网络中,构成TA-LSTM网络,如图2所示。

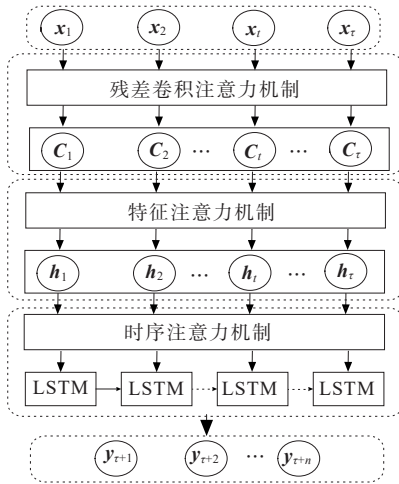


图2 TA-LSTM模型结构

Figure 2 TA-LSTM structure diagram

残差注意力机制对外源数据初步进行数据间互相关性的挖掘;特征注意力机制进一步深度捕捉外源序列与目标序列间的互相关性;时间注意力机制挖掘时序数据历史层面的内相关性,通过差异化动态权重的分配,提高模型预测精度。

### 1) 残差注意力。

本文将CNN和残差块结构进行融合形成残差注意力模块,对输入的外源数据进行非线性局部特征提取,挖掘数据中的局部特征信息。残差块结构保证原始数据中的重要特征信息不会丢失。残差注意力机制的拓扑结构如图3所示。

设输入功率数据为向量 $X=[x^1, x^2, \dots, x^K]$ ,其中 $K$ 为输入序列个数。将 $X$ 输入RCNN网络,送入

卷积模块按以下公式进行卷积操作,即

$$C_1 = f_c(\omega_{c_1} \odot X + b_{c_1}) \quad (12)$$

$$C_2 = f_c(\omega_{c_2} \odot C_1 + b_{c_2}) + X \quad (13)$$

式(12)、(13)中, $C_1, C_2$ 分别为一维、二维卷积层的输出特征向量; $f_c(\cdot)$ 为卷积层激活函数; $\odot$ 为卷积运算; $\omega_{c_1}, \omega_{c_2}$ 分别为一维、二维卷积层的权重矩阵; $b_{c_1}, b_{c_2}$ 为一维、二维卷积层的偏置向量。




图3 残差卷积注意力模块结构

Figure 3 structure diagram of residual convolution attention module

### 2) 特征注意力。

特征注意力机制对残差注意力层输出的结果进行深度空间特征提取,以挖掘特征序列与目标特征之间的相关性。通过权重概率分布机制,对影响程度不同的特征进行动态权重分配。

以第 $t$ 个时间步为例,单步输入特征向量 $c_t = [c_t^1, c_t^2, \dots, c_t^K]$ ,注意力权重向量为

$$e_t = v_e^T \sigma(\omega_e c_t + b_e) \quad (14)$$

式中, $e_t = [e_t^1, e_t^2, \dots, e_t^K]$ 为 $t$ 时刻各输入特征对应的注意力权重分布; $v_e, \omega_e$ 均为注意力权重的权重矩阵; $b_e$ 为注意力权重的偏置向量。

通过对 $e_t$ 采用Softmax函数归一化处理,得到第 $k$ 个特征注意力系数 $\alpha_t^k$ ,将输入特征向量 $c_t$ 重新计算为加权向量 $\tilde{c}_t$ ,即

$$\alpha_t^k = \frac{\exp(e_t^k)}{\sum_{j=1}^n \exp(e_t^j)} \quad (15)$$

$$\tilde{c}_t = (\alpha_t^1 c_t^1, \alpha_t^2 c_t^2, \dots, \alpha_t^K c_t^K)^T \quad (16)$$

### 3) 时间注意力。

时间注意力机制挖掘时序数据的时间序列特征,按照对预测结果的贡献度来分配序列各历史时刻的权重。 $c_t$ 经特征注意力模块编码后得到LSTM的隐藏层状态:

$$h_t = f_{\text{LSTM}}(h_{t-1}, \tilde{c}_t, s_{t-1}) \quad (17)$$

式中, $f_{\text{LSTM}}(\cdot)$ 为LSTM单元。

通过时间注意力模块对 $h_t$ 进行解码操作,赋予



LSTM单元输出的隐藏状态不同权重得分 $\gamma_i^t$ ,并与相应历史时刻隐藏层状态进行加权,得到综合时序信息状态 $r_t$ ,计算过程如下:

$$d_i = v_d^\top \sigma(\mathbf{w}_d \mathbf{h}_i + \mathbf{b}_d) \quad (18)$$

$$\gamma_i^t = \exp(d_i) / \sum_{j=1}^{\tau} \exp(d_j^t) \quad (19)$$

$$r_t = \sum_{i=1}^{\tau} \gamma_i^t \mathbf{h}_i \quad (20)$$

式(18)~(20)中, $\mathbf{d}_t = [e_1^t, e_2^t, \dots, e_\tau^t]$ 为 $t$ 时刻对应各历史时刻的时间注意力权重分布; $\tau$ 为输入序列时间窗口长度; $v_d$ 、 $\mathbf{w}_d$ 均为注意力权重的权重矩阵; $\mathbf{b}_d$ 为注意力权重的偏置向量。

最后经输出层得到未来 $n$ 步的预测结果:

$$\mathbf{y}_{t+n} = \sigma(\mathbf{w}_r \mathbf{r}_t + \mathbf{b}_r) \quad (21)$$

式中, $\mathbf{w}_r$ 、 $\mathbf{b}_r$ 分别为全连接层的权重矩阵和偏置向量。

### 2.3 改进蝠鲮觅食优化算法

为解决TA-LSTM在训练过程中需频繁进行超参数调节的问题,利用IMRFO算法进行超参数智能寻优。

MRFO是通过观察蝠鲮觅食行为而提出的一种新型种群优化算法。蝠鲮种群的觅食策略有3种:链式、旋风式和翻筋斗式。利用不同觅食策略对搜索空间内进行探索和开发,进而实现参数寻优。

链式觅食过程的数学表达式为

$$x_i^d(t+1) = \begin{cases} x_i^d(t) + r(x_{\text{best}}^d(t) - x_i^d(t)) + \alpha \cdot (x_{\text{best}}^d(t) - x_i^d(t)), & i=1 \\ x_i^d(t) + r(x_{i-1}^d(t) - x_i^d(t)) + \alpha \cdot (x_{\text{best}}^d(t) - x_i^d(t)), & i=2, 3, \dots, n \end{cases} \quad (22)$$

$$\alpha = 2r \sqrt{|\log r|} \quad (23)$$

式(22)、(23)中, $x_i^d(t)$ 、 $x_{\text{best}}^d(t)$ 为第 $t$ 代的第 $i$ 个个体、最优个体在 $d$ 维空间的位置; $r$ 为 $[0, 1]$ 均匀分布的随机数; $\alpha$ 为权重因子。

螺旋式觅食过程有如下2种情况。

①当 $t/T > \text{rand}$ 时,数学表达式为

$$x_i^d(t+1) = \begin{cases} x_{\text{best}}^d(t) + r(x_{\text{best}}^d(t) - x_i^d(t)) + \beta \cdot (x_{\text{best}}^d(t) - x_i^d(t)), & i=1 \\ x_{\text{best}}^d(t) + r(x_{i-1}^d(t) - x_i^d(t)) + \beta \cdot (x_{\text{best}}^d(t) - x_i^d(t)), & i=2, 3, \dots, n \end{cases} \quad (24)$$

$$\beta = 2 \exp\left(r_1 \cdot \frac{T-t+1}{T}\right) \sin(2\pi r_1) \quad (25)$$

式中, $\beta$ 为权重因子; $r_1$ 为 $[0, 1]$ 均匀分布的随机数; $T$ 为最大迭代次数。

②当 $t/T \leq \text{rand}$ 时,数学表达式为

$$x_{\text{rand}}^d(t) = x_1 + r(x_u - x_1) \quad (26)$$

$$x_i^d(t+1) =$$

$$\begin{cases} x_{\text{rand}}^d(t) + r(x_{\text{rand}}^d(t) - x_i^d(t)) + \beta \cdot (x_{\text{rand}}^d(t) - x_i^d(t)), & i=1 \\ x_{\text{rand}}^d(t) + r(x_{i-1}^d(t) - x_i^d(t)) + \beta \cdot (x_{\text{rand}}^d(t) - x_i^d(t)), & i=2, 3, \dots, n \end{cases} \quad (27)$$

式(26)中, $x_{\text{rand}}^d(t)$ 为随机产生的一个新位置; $x_u$ 、 $x_1$ 分别为搜索空间的上、下限。

翻筋斗式寻食过程的数学表达式为

$$x_i^d(t+1) = x_i^d(t) + S(r_2 x_{\text{best}}^d(t) - r_3 x_i^d(t)) \quad (28)$$

式中, $S$ 为翻筋斗因子; $r_2$ 、 $r_3$ 为 $[0, 1]$ 均匀分布的随机数。

然而,实际应用中MRFO算法存在无法保证最优解为全局最优、种群多样性差等缺点。因此,通过以下2种策略将MRFO改进为IMRFO算法。

1) 基于改进Tent映射法获取初始种群。

随机生产的初始种群会对算法求解速度和精度产生影响。混沌序列的随机性、规律性以及遍历性等特点导致生成的初始解复杂多样,因此混沌序列生成的初始解易于收敛。与其他映射相比较,Tent映射能生成更均匀分布的序列<sup>[23]</sup>,因此,本文采用Tent映射来设置蝠鲮种群的初始位置,以改善MRFO的初始种群多样性,其表达式为

$$x_{k+1} = \begin{cases} 2x_k, & 0 \leq x_k \leq 0.5 \\ 2(1-x_k), & 0.5 \leq x_k \leq 1 \end{cases} \quad (29)$$

但是迭代过程中存在不稳周期点,因此引入随机方程进行改进。当 $x_k$ 落入不稳周期点或5以内的小周期循环<sup>[24]</sup>时,可通过以下公式进行改进,即

$$x_{k+1} = \begin{cases} 2(x_k + 0.1 \text{rand}(0, 1)), & 0 \leq x_k \leq 0.5 \\ 2(1 - (x_k + 0.1 \text{rand}(0, 1))), & 0.5 \leq x_k \leq 1 \end{cases} \quad (30)$$

2) 自适应非线性递减权重系数。

在MRFO算法的链式觅食寻优迭代过程中,由于 $r$ 在 $[0, 1]$ 内随机生成,使得后期的搜索步长与前期相同,从而降低了搜索速度。因此,将 $r$ 改为

$$r = 1 - \exp\left(-\frac{T-t}{T}\right)^2 \quad (31)$$

随着  $t$  的增加  $r$  会逐渐减小,增强了算法迭代前期的局部寻优能力。

在翻筋斗式觅食过程中,翻筋斗因子  $S$  为定值;而在迭代后期,算法需要更小的搜索步长,过大的值会削弱算法搜索能力。因此,将  $S$  改为

$$S = (S_{\max} - S_{\min}) \frac{T-t}{T} + S_{\min} \quad (32)$$

式中,  $S_{\max}$ 、 $S_{\min}$  分别为翻筋斗因子  $S$  的上、下限,随着  $t$  的增加  $S$  会逐渐减小,增强了迭代后期的局部搜索和寻优能力。

#### 2.4 IMRFO 优化 TA-LSTM 模型流程

在 TA-LSTM 模型中,通过 IMRFO 算法对 TA-LSTM 网络中输入步长、学习率和隐藏层神经元个数等参数进行寻优,利用训练数据集的均方根误差作为 TA-LSTM 网络的适应度来进行搜索,直至得到最优的超参数值。IMRFO 优化 TA-LSTM 模型流程主要步骤如下:

1) 设置 TA-LSTM 网络超参数,包括输入步长、学习率以及 LSTM 隐藏层神经元个数的取值搜索范围;

2) 将 IMRFO 算法中的种群规模、最大迭代次数以及维度参数进行初始化,按式(29)、(30)生成初始种群;

3) 根据步骤1)初始化的超参数搭建 TA-LSTM 网络模型,将输入样本训练和预测结果的均方根误差作为各个体的适应度值;

4) 计算种群内蝠鲮个体适应度值,得到当前最优个体和对应的适应度值;

5) 根据 IMRFO 算法的3种寻食方式,通过式(22)~(28)进行个体的更新;

6) 判断蝠鲮个体适应度值是否趋向稳定或达到迭代次数上限,若是,则获得 TA-LSTM 网络的最优超参数组合,执行步骤7);否则,返回步骤1);

7) 获取具有最优超参数的 TA-LSTM 模型。

### 3 基于运行要素预测的主动配电网运行态势获取

#### 3.1 主动配电网运行态势

配电网潮流计算是配电网运行状态分析的重

要基础<sup>[25]</sup>。对于一个给定拓扑结构和元件参数的配电网,输入发电侧和负荷侧参数进行潮流计算,可得各节点电压、各支路电流的值以及全网潮流分布图景。然而,这些潮流计算结果难以直观反应配电网的运行态势,需要进一步的数据处理,以实现实时、精确且直观的态势理解。本文以含风电的配电网为例,首先对配电网未来风电和负荷功率进行预测,并将预测结果作为输入进行潮流计算,以获取未来配电网运行状态;然后采用节点电压越限裕度、支路负载严重度和节点电压/支路电流波动系数等指标,从节点、支路2个不同层面对配电网未来运行态势进行表征分析。

1) 节点电压越限裕度指标。

针对节点电压变化可能导致的电压越限问题,提出电压越限裕度  $E_{i,t}^U$  来反映配电网各节点电压在未来的变化趋势:

$$E_{i,t}^U = \begin{cases} 1 + \left| \frac{\hat{U}_{i,t} - \bar{U}_i}{\bar{U}_i} \right|, & \hat{U}_{i,t} \geq \bar{U}_i \\ 1 - \left| \frac{\hat{U}_{i,t} - \bar{U}_i}{\bar{U}_i} \right|, & \hat{U}_{i,t} < \bar{U}_i \end{cases} \quad (33)$$

式中,  $\hat{U}_{i,t}$  为待预测节点  $i$  在未来  $t$  时刻的电压标么值;  $\bar{U}_i$  为第  $i$  个节点电压的上下限的均值,本文节点电压标么值的上、下限分别取 1.07、0.95,故  $\bar{U}_i = 1.01$ 。

2) 支路负载严重度指标。

针对支路电流的过载安全问题,利用效用风险理论和连续分段函数思想,提出支路负载严重度  $E_{l,t}^L$ ,反映各条支路在未来的变化趋势:

$$R_{l,t}^L = \left| \frac{\hat{I}_{l,t}}{I_{l,N}} \right| \quad (34)$$

$$E_{l,t}^L = \begin{cases} 0, & 0 \leq R_{l,t}^L < 0.2 \\ 1.4 \times R_{l,t}^L - 0.28, & 0.2 \leq R_{l,t}^L < 0.7 \\ e^{R_{l,t}^L - 0.7} - 0.3, & R_{l,t}^L \geq 0.7 \end{cases} \quad (35)$$

式中,  $R_{l,t}^L$  为未来  $t$  时刻第  $l$  条线路的负载率;  $\hat{I}_{l,t}$  为未来  $t$  时刻第  $l$  条待预测支路的电流;  $I_{l,N}$  为第  $l$  条线路的额定电流。

3) 节点电压和支路电流波动系数指标。

为了量化节点电压和支路电流的波动系数,同

时评估节点电压/支路电流受分布式电源和负荷变化影响程度,引入统计学中变异系数的概念,提出节点电压波动系数  $B_i^U$  和支路电流波动系数  $B_l^I$ ,表达式如下:

$$B_i^U = \frac{1}{\bar{U}_{i,t}} \cdot \sqrt{\frac{1}{T} \sum_{t=1}^T (\hat{U}_{i,t} - \bar{U}_{i,t})^2} \quad (36)$$

$$B_l^I = \frac{1}{\bar{I}_{l,t}} \cdot \sqrt{\frac{1}{T} \sum_{t=1}^T (|\hat{I}_{l,t}| - \bar{I}_{l,t})^2} \quad (37)$$

式(36)、(37)中,  $\hat{U}_{i,t}$ 、 $\hat{I}_{l,t}$  分别为待预测节点  $i$  在未来  $t$  时刻的电压值和待预测支路  $l$  在未来  $t$  时刻的电流值;  $\bar{U}_{i,t}$ 、 $\bar{I}_{l,t}$  分别为待预测节点  $i$  在未来  $T$  时段的预测电压平均值和待预测支路  $l$  在未来  $T$  时段的预测电流平均值。

### 3.2 基于 ICEEMDAN-TA-LSTM 模型的主动配电网运行态势预测流程

综合前文所述内容,得到基于 ICEEMDAN-TA-LSTM 模型的配电网运行态势预测的流程,如图 4 所示。




图 4 基于 ICEEMDAN-TA-LSTM 模型的运行态势预测流程

Figure 4 Flow chart of operating situation prediction based on ICEEMDAN-TA-LSTM model

## 4 算例分析

本文以改进的 IEEE 33 节点主动配电网作为研究对象,其拓扑结构如图 5 所示,包含 33 个节点、32 条支路,并在节点 16、20、31 处接入风力发电机,其容量分别为 1 000、500、500 kW。选取 2017 年 1 月 1 日—12 月 31 日某地区负荷功率数据和环境数据作为历史数据,并结合西部某地区风电场同时时间段的实测风机历史数据,采样间隔均为 15 min,所用数据均已经过异常数据处理。将负荷和风机出力历史数据折算至对应额定功率下的标么值,分别乘以 IEEE 33 系统负荷和风机出力的额定功率值,作为 IEEE 33 系统中负荷和风电功率的历史数据。采用所提的 ICEEMDAN-TA-LSTM 模型,对未来 24 h 系统中各节点负荷和风机出力变化趋势进行预测,并通过主动配电网潮流计算获取配电网运行态势。

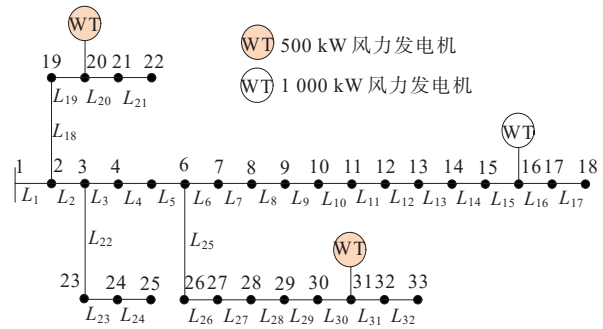



图 5 改进的 IEEE 33 节点主动配电网


Figure 5 Improved IEEE-33 nodes of ADN

### 4.1 基于 ICEEMDAN 的负荷和风电功率序列分解

ICEEMDAN 算法添加高斯白噪声的标准差为 0.2,添加次数为 200。由于输入样本较多,仅给出节点 16 为期一周的风机功率数据(额定功率为 1 000 kW),以及节点 7 为期一周的负荷数据(额定功率为 200 kW)各自所对应的 ICEEMDAN 分解结果,如图 6 所示。通过 ICEEMDAN 算法,将原始数据进行分解,能够降低原始数据非平稳性和不规则性,有利于提高配电网运行要素预测精度。



(a) 节点 7



(b) 节点 16

图 6 节点 7 负荷数据和节点 16 风机功率数据的 ICEEMDAN 分解结果

Figure 6 ICEEMDAN decomposition results of load data at node 7 and WT output data at node 16

### 4.2 基于 ICEEMDAN-TA-LSTM 的负荷和风电功率预测结果对比分析

将节点 16 的风电功率数据的分解序列 ( $\bar{I}_{MF_1} \sim \bar{I}_{MF_8}, R_c$ ) 和相应的日气象数据作为输入数据,以风电功率历史数据的前 70% 作为训练集,后 30% 作为测试集。对 2017 年 11 月 27 日 24:00 为起始时刻的未来 24 h 进行风电功率预测,获取到 28 日 0~24 h 风电功率变化预测结果。未来 0~24 h 风电功率变化趋势用同样的方法获得,这里以节点 7 的负荷为例并进行预测。本文对于预测模型的性能,采用文献 [26] 中所用的均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE) 和拟合优度系数 ( $R^2$ ) 作为指标对预测结果进行评估。

#### 1) 风电功率预测结果分析。

首先,为了检验所提 IMRFO 算法对 TA-LSTM 模型参数的优化性能,本文将 IMRFO 算法与原始 MRFO、PSO 和 GA 算法进行对比,设置各算法参数,即种群规模为 10,迭代次数上限为 20。TA-LSTM 的输入步长  $l_a$ 、学习率  $l_n$ 、隐藏层神经元个数  $l_n$  等参数的搜索范围分别为  $[1, 20]$ 、 $[0.001, 0.01]$  和  $[1, 100]$ , 利用 RMSE 作为 TA-LSTM 网络的适应度来进行搜索,各算法的适应度值迭代变化如图 7 所示。




图 7 各优化算法的适应度值变化曲线

Figure 7 Change curve of fitness value of each optimization algorithm

由图 7 可知,PSO、GA 算法相较于 MRFO 算法寻优能力差,极易陷入局部最优,所得适应度值较大;通过对比 IMRFO 与 MRFO 算法,IMRFO 的寻优能力更强,所得适应度值更小,表现出良好的寻优性能,也表明本文对 MRFO 算法改进策略的有效性。因此,对于 TA-LSTM 模型超参数优化性能,所提 IMRFO 算法优于原始 MRFO、PSO 和 GA 算



法,也表明本文对 MRFO 算法改进策略的有效性。

IMRFO 算法的超参数在迭代中的变化情况如图 8 所示,可知 IMRFO 算法最终寻优 TA-LSTM 模型的超参数分别为步长  $l_d=20$ 、学习率  $l_a=0.020 2$ 、隐藏层神经元个数  $l_n=73$ 。因此,在后续分析中,均将 IMRFO 算法作为对模型的超参数的优化方法。进一步,为验证本文所提的 ICEEMDAN-TA-LSTM 模型的预测性能,将所提方法、TA-LSTM(超参数优化)、TA-LSTM 和 LSTM 模型进行对比,各模型的风电功率负荷预测结果如图 9 所示,预测性能如表 1 所示。




图 8 IMRFO 算法的各超参数寻优变化

Figure 8 Optimization changes of each hyperparameter of IMRFO algorithm




图 9 不同模型的风电功率预测结果

Figure 9 WT output prediction results of different models

表 1 风电功率预测结果的评价指标比较

Table 1 Comparison of evaluation indexes of WT output prediction results

预测模型	$e_{RMSE}/kW$	$e_{MAE}/kW$	$R^2$
本文方法	26.946 6	19.575 7	0.986 3
TA-LSTM(超参数优化)	58.956 3	43.741 3	0.934 5
TA-LSTM	63.883 6	47.581 3	0.923 1
LSTM	88.223 4	69.280 2	0.853 3

通过对图 9 和表 1 的结果进行数值分析可知,本文所提 ICEEMDAN-TA-LSTM 模型相较于 LSTM 模型, RMSE 降低了 66.06%、MAE 降低了 71.74%、 $R^2$  提升了 13.48%,说明所提 ICEEMDAN-TA-LSTM 模型相对于最基础的 LSTM 模型具有显著提升;相较于 TA-LSTM(超参数优化)模型, RMSE 降低了 54.29%、MAE 降低了 55.24%、 $R^2$  提升了 5.54%,表明引入模态分解方法可以有效提升神经网络处理非稳定性时序数据的效果;相较于 TA-LSTM 模型, RMSE 降低了 57.82%、MAE 降低了 58.86%、 $R^2$  提升了 6.85%,表明引入模态分解以及智能优化具有良好的适配性,同时引入这 2 个机制能够有效提升模型预测精确性。

### 2) 负荷预测结果分析

对节点 7 的负荷功率进行与上述同样的对比分析,负荷预测结果如图 10 所示,各模型预测性能如表 2 所示。通过对负荷的预测结果进行分析也能得到类似结果,说明本文所提 ICEEMDAN-TA-LSTM 模型要优于其他 3 个对比模型,具有优异的预测性能。




图 10 不同模型的负荷预测结果

Figure 10 Power load prediction results of different models

表 2 负荷预测结果的评价指标比较

Table 2 Comparison of evaluation indexes of power load prediction results

预测模型	$e_{RMSE}/kW$	$e_{MAE}/kW$	$R^2$
本文方法	0.802 6	0.646 1	0.972 0
TA-LSTM(超参数优化)	2.018 1	1.450 9	0.823 0
TA-LSTM	2.121 4	1.590 7	0.804 4
LSTM	3.011 4	2.454 8	0.605 8

### 4.3 基于 ICEEMDAN-TA-LSTM 预测模型的运行态势获取及结果分析

为获取主动配电网的短期运行态势,首先,根据本文所提 ICEEMDAN-TA-LSTM 模型获取所有节点负荷和风电功率的预测结果;然后,在获取

IEEE 33节点系统未来24 h负荷和风电功率的变化趋势后,通过多时间断面的潮流计算分析,分别得到未来24 h中系统每个节点的电压越限裕度指标和每条支路的负载严重度指标,如图11、12所示。




图11 各节点电压越限裕度指标

Figure 11 The node voltage over-limit margin index of each node




图12 各支路负载严重度指标

Figure 12 The branch load severity index of each branch

从图11可以看出,负荷和风电功率预测值的节点电压越限裕度指标均处在 $[0.95, 1.00]$ 范围内,指标正常范围为 $[0.94, 1.06]$ ,故无节点电压存在越限情况,各节点电压处于正常状态。负荷和风电功率预测值支路负载严重度指标见图12,其值均处在 $[0.0, 0.7]$ 的正常运行范围内,但支路22、23的负载严重度指标长时间接近0.7,存在重载运行风险。为了评估节点电压越限裕度指标和支路负载严重度指标运行态势预测结果的准确性,利用MAE进行量化分析,基于负荷和风电功率的真实值和预测值,得到每个时间断面上各节点的电压越限裕度指标和各支路的支路负载严重度指标的MAE,如图13所示。显然,各节点的电压越限裕度指标的MAE均低于 $1.3 \times 10^{-3}$  p.u.,各节点的电压相角MAE均低于 $1.5 \times 10^{-2}$  p.u.,效果比较精确。因此,本文所提预测模型能够对全网各节点、支路的节点电压越限裕度和支路负载严重度指标等运行态势进行精确预测。




图13 节点电压越限裕度和支路负载严重度指标的平均绝对误差

Figure 13 MAE of node voltage over-limit margin index and branch load severity index

各节点电压和各支路电流的波动系数指标如图14所示,由负荷和风电功率的真实值和预测值所得到的波动系数指标基本吻合。其中,节点15、16、17的电压波动系数指标值较高,支路7、30、31的电流波动系数指标值较高,表明这些节点和支路的运行态势受分布式电源和负荷波动的影响程度大,需要重点关注。




图14 各节点电压和各支路电流的波动系数指标

Figure 14 Fluctuation index of node voltage and current of each branch

## 5 结语

本文以改进的IEEE 33节点系统为典型案例,利用模态分解及IMRFO算法优化的TA-LSTM模型实现配电网风电功率预测及负荷预测,并利用电压越限裕度、支路负载严重度和电压/电流波动指标表征主动配电网未来运行态势。

1) 融合三重注意力机制的LSTM网络能够高效挖掘时序信息的内相关性以及信息间的互相关性,充分提高LSTM网络的预测精度。

2) ICEEMDAN方法可以将不规则和波动性强的输入样本分解成若干规则序列,提高模型整体精度。同时,引入的IMRFO算法可以自动进行神经网络超参数调整,与ICEEMDAN算法有较好的适配性。

3) 提出的节点电压越限裕度、支路负载严重度和节点电压/支路电流的波动系数指标可以直观地反应配电网的运行态势,进一步实现直观精确的态势理解,感知主动配电网的运行轨迹。

考虑主动管理措施的影响,并开展主动配电网的优化运行以及运行趋势预警的相关研究,将作为后续的工作重点。

### 参考文献:

- [1] 金韬,黄云龙,谈历,等.基于TTU分布式决策的配电系统弹性调度策略研究[J].供用电,2022,39(3):61-68.  
JIN Tao, HUANG Yunlong, TAN Li, et al. Research on resilient dispatching strategy of distribution system based on TTU distributed decision[J]. Distribution & Utilization, 2022,39(3):61-68.
- [2] 严正,孔祥瑞,徐潇源,等.微型同步相量测量单元在智能配电网运行状态估计中的应用[J].上海交通大学学报,2018,52(10):1195-1205.  
YAN Zheng, KONG Xiangrui, XU Xiaoyuan, et al. Applications of micro synchronous phasor measurement units in state estimation of smart distribution network[J]. Journal of Shanghai Jiaotong University, 2018, 52(10): 1195-1205.
- [3] 孙怡,何光宇,翟少鹏.基于无迹卡尔曼滤波的电力系统抗差动态估计[J].电测与仪表,2020,57(4):1-6.  
SUN Yi, HE Guangyu, ZHAI Shaopeng. Robust dynamic estimation for power system based on unscented Kalman filter[J]. Electrical Measurement & Instrumentation, 2020, 57(4): 1-6.
- [4] 甘祥前,任超,刘林波,等.基于TLS的非线性GM-AR高边坡变形预测模型及应用[J].水电能源科学,2018,36(3):150-153.  
GAN Xiangqian, REN Chao, LIU Linbo, et al. Nonlinear GM-AR model of high slope deformation prediction based on TLS and its application[J]. Water Resources and Power, 2018,36(3):150-153.
- [5] 田波,朴在林,郭丹,等.基于改进EEMD-SE-ARMA的超短期风功率组合预测模型[J].电力系统保护与控制,2017,45(1):72-79.  
TIAN Bo, PIAO Zailin, GUO Dan, et al. Wind power ultra short-term model based on improved EEMD-SE-ARMA[J]. Power System Protection and Control, 2017,45(1):72-79.
- [6] 丁学辉,许海林,罗颖婷,等.基于随机森林特征优选与MAEPSO-ELM算法的变压器DGA故障诊断[J].电力科学与技术学报,2022,37(2):181-187.  
DING Xuehui, LUO Hailin, LUO Yingting, et al. Transformer DGA fault diagnosis based on the random forest feature optimization and MAEPSO-ELM algorithm [J]. Journal of Electric Power Science and Technology, 2022,37(2):181-187.
- [7] 张帅可,罗萍萍.基于混合分布模型的风电功率超短期预测误差分析[J].电力科学与技术学报,2020,35(5):111-118.  
ZHANG Shuaike, LUO Pingping. Ultra short-time prediction error analysis of wind power based on mixed distribution model[J]. Journal of Electric Power Science and Technology, 2020,35(5):111-118.
- [8] LEE D, KIM K. Recurrent neural network-based hourly prediction of photovoltaic power output using meteorological information[J]. Energies, 2019,12(2):215.
- [9] RASHEDI E, NEZAMABADIPOUR H, SARYAZDI S. GSA: a gravitational search algorithm[J]. Information Sciences, 2009,179(13):2232-2248.
- [10] 刘雨佳,樊艳芳,白雪岩,等.基于特征交叉机制和误差补偿的风力发电功率短期预测[J].电工技术学报,2023,38(12):3277-3288.  
LIU Yujia, FAN Yanfang, BAI Xueyan, et al. Short-term wind power prediction based on feature crossover mechanism and error compensation[J]. Transactions of China Electrotechnical Society, 2023,38(12):3277-3288.
- [11] 任建吉,位慧慧,邹卓霖,等.基于CNN-BiLSTM-Attention的超短期电力负荷预测[J].电力系统保护与控制,2022,50(8):108-116.  
REN Jianji, WEI Huihui, ZOU Zhuolin, et al. Ultra-short-term power load forecasting based on CNN-BiLSTM-Attention[J]. Power System Protection and Control, 2022,50(8):109-116.

- [12] 朱显辉,于越,师楠,等. BP神经网络的分层优化研究及其在风电功率预测中的应用[J]. 高压电器,2022,58(2): 158-163+170.  
ZHU Xianhui, YU Yue, SHI Nan, et al. Research on hierarchical optimization of BP neural network and its application in wind power prediction[J]. High Voltage Apparatus,2022,58(2):158-163+170.
- [13] 张其霄,董鹏,王科文,等. 基于贝叶斯优化 LSTM 的发动机剩余寿命预测[J]. 火力与指挥控制,2022,47(4):85-89.  
ZHANG Qixiao, DONG Peng, WANG Kewen, et al. Residual service life prediction for aircraft engines based on bayesian optimal long short-term memory network[J]. Fire Control & Command Control,2022,47(4): 85-89.
- [14] 高鹭,孔繁苗,张飞,等. 基于 IPSO-BiLSTM-AM 模型的超短期风电功率预测方法[J]. 智慧电力,2022,50(4):27-34.  
GAO Lu, KONG Fanmiao, ZHANG Fei, et al. Ultra short-term wind power prediction method based on IPSO-BiLSTM-AM model[J]. Smart Power,2022,50(4):27-34.
- [15] ZHAO W G, WANG L Y, ZHANG Z X. Artificial ecosystem-based optimization: a novel nature-inspired meta-heuristic algorithm[J]. Neural Computing and Applications,2019,32:9383-9425.
- [16] 伍骏杰,张倩,陈凡,等. 计及误差修正的变分模态分解—长短期记忆神经网络短期负荷预测[J]. 科学技术与工程,2022,22(12):4828-4834.  
WU Junjie,ZHANG Qian,CHEN Fan,et al.Short-term load forecasting with error correction and variational mode decomposition-long short-term memory[J]. Science Technology and Engineering,2022,22(12):4828-4834.
- [17] 葛磊蛟,李元良,陈艳波,等. 智能配电网态势感知关键技术及实施效果评价[J]. 高电压技术,2021,47(7):2269-2280.  
GE Leijiao, LI Yuanliang, CHEN Yanbo, et al. Key technologies of situational awareness in smart distribution network and evaluation of implementation effects[J]. High Voltage Engineering,2021,47(7):2269-2280.
- [18] 于涛,刁守斌,祝永刚,等. 基于态势感知的智能配电网运行状态评估[J]. 山东电力技术,2020,47(2):13-19.  
YU Tao, DIAO Shoubin, ZHU Yonggang, et al. Operation state evaluation of the smart distribution systems based on the situation awareness[J]. Shandong Electric Power,2020, 47(2):13-19.
- [19] 李欣桐,俞小勇,阳国燕,等. 基于微型 PMU 数据挖掘的智能配电网态势感知方法研究[J/OL]. 电测与仪表:1-9 [2021-06-29]. <http://hp.kns.cnki.net/shiep.vpn358.com/kcms/detail/23.1202.TH.20210629.1233.004.html>.
- LI Xintong, YU Xiaoyong, YANG Guoyan, et al. Research on situation awareness method of smart distribution network based on micro PMU data mining[J/OL]. Electrical Measurement & Instrumentation: 1-9[2021-06-29]. <http://hp.kns.cnki.net/shiep.vpn358.com/kcms/detail/23.1202.TH.20210629.1233.004.html>.
- [20] 李延真,郭英雷,彭博,等. 基于多时间尺度状态估计的配电网实时态势预测[J]. 电力工程技术,2020,39(2): 127-134.  
LI Yanzhen, GUO Yinglei, PENG Bo, et al. Real-time situation prediction of distribution network based on multi-time scale state estimation[J]. Electric Power Engineering Technology,2020,39(2): 127-134.
- [21] COLOMINAS M A, SCHLOTTHAUER G, TORRES M E. Improved complete ensemble EMD: a suitable tool for biomedical signal processing[J]. Biomedical Signal Process and Control,2014,14: 19-29.
- [22] KONG W C, DONG Z Y, JIA Y W. et al. Short-term residential load forecasting based on LSTM recurrent neural network[J]. IEEE Transactions on Smart Grid,2019, 10(1):841-851.
- [23] 张浩,张铁男,沈继红,等. Tent混沌粒子群算法及其在结构优化决策中的应用[J]. 控制与决策,2008,23(8):857-862.  
ZHANG Hao, ZHANG Tienan, SHEN Jihong, et al. Research on decision-makings of structure optimization based on improved Tent PSO[J]. Control and Decision, 2008,23(8):857-862.
- [24] 雍静,赵瑾,邹嘉嘉,等. 基于混沌增强烟花算法的多能源系统并网优化调度[J]. 电网技术,2019,43(10):3725-3733.  
YONG Jing, ZHAO Jin, HUAN Jiajia, et al. Grid optimization scheduling of multi-energy systems based on chaotic enhanced fireworks algorithm[J]. Power System Technology,2019,43(10):3725-3732.
- [25] 王守相,梁栋,葛磊蛟. 智能配电网态势感知和态势利导关键技术[J]. 电力系统自动化,2016,40(12):2-8.  
WANG Shouxiang, LIANG Dong, GE Leijiao. Key technologies of situation awareness and orientation for smart distribution systems[J]. Automation of Electric Power Systems,2016,40(12):2-8.
- [26] 苏向敬,周汶鑫,李超杰,等. 基于双重注意力 LSTM 神经网络的可解释海上风电出力预测[J]. 电力系统自动化, 2022,46(7): 141-151.  
SU Xiangjing, ZHOU Wenxin, LI Chaojie, et al. Interpretable offshore wind power output forecasting based on dual-stage attentional long short-term memory[J]. Automation of Electric Power Systems, 2022, 46(7): 141-151.