

基于自适应辛几何模态分解-多元线性回归-卷积 长短时记忆的台区电力负荷预测

方磊¹, 楚成博¹, 何映虹¹, 冯隆基¹, 刘福政², 王宁², 张法业²

(1. 国网江苏省电力有限公司南京供电分公司, 江苏省 南京市 210000;

2. 山东大学 控制科学与工程学院, 山东省 济南市 250061)

Power Load Forecasting in Station Areas Based on ASGMD-MLR-CLSTM

FANG Lei¹, CHU Chengbo¹, HE Yinghong¹, FENG Longji¹, LIU Fuzheng²,

WANG Ning², ZHANG Faye²

(1. Nanjing Power Supply Branch, State Grid Jiangsu Electric Power Co., Ltd., Nanjing 210000, Jiangsu Province, China;

2. School of Control Science and Engineering, Shandong University, Jinan 250061, Shandong Province, China)

摘要: 准确预测台区的电力负荷, 能够促使电力企业合理安排调度计划, 保障台区电力安全 and 经济稳定运行。为了充分挖掘电力负荷数据的特征, 提高预测的精度, 提出一种基于自适应辛几何模态分解 (adaptive symplectic geometry mode decomposition, ASGMD)、多元线性回归 (multiple linear regression, MLR) 和卷积长短时记忆 (convolutional long short-term memory, CLSTM) 网络的电力负荷预测方法。首先, 应用 ASGMD 将台区负荷数据分解为弱相关和强相关两种分量; 然后, 利用 MLR 和 CLSTM 分别对上述两种分量分别进行预测; 最后, 组合各模型结果, 得到最终负荷预测值。实例分析结果表明, 所提模型较其他模型具有更高的预测准确度。

关键词: 电力负荷预测; 自适应辛几何模态分解; 多元线性回归; 卷积长短时记忆网络

Abstract: Accurately predicting the power load in a station area can encourage power companies to arrange dispatching plans reasonably, ensuring the safety and stable economic operation of the station area. To fully exploit the characteristics of power load data and improve the accuracy of forecasting, a power load prediction method based on adaptive symplectic geometry mode decomposition (ASGMD), multiple linear regression (MLR) and convolutional long short-term memory (CLSTM) was proposed. Firstly, ASGMD was applied to decompose the station load data into two components: weakly

correlated and strongly correlated. Secondly, MLR and LSTM were adopted to forecast the above two components, respectively. Finally, the load forecast value was obtained by combining the results of each model. The experiments show that the proposed method obtains higher forecasting accuracy than other models.

Keywords: power load forecasting; adaptive symplectic geometry mode decomposition (ASGMD); multiple linear regression (MLR); convolutional long short-term memory (CLSTM)

DOI: 10.19725/j.cnki.1007-2322.2023.0112

0 引言

随着社会的不断发展, 电力负荷预测在规划和指定电量供需平衡中发挥着不可替代的作用, 精准的预测可以指导和保障该地区电网的经济运行。另一方面, 随着电网的不断扩大、电气设备接入的增加以及信息技术的不断完善, 智能电网数据收集变得越来越准确, 为负荷预测提供了可靠、海量的数据, 这有助于深度学习的应用^[1-2]。

面对当前多样化的电力系统结构, 传统的电力负荷预测难以达到预测精度, 因此需要更精确的预测模型。目前, 电力负荷预测有两种类型, 即时间序列分析法和机器学习法^[3]。时间序列分析方法是按数据按时间顺序排列, 形成统计时间序列, 并应用数学方法进行预测, 但这仅限于线性预测, 一旦遇到非线性和波动性数据, 其预测结果将有很大偏差。随着人工智能技术的蓬勃发

基金项目: 国网江苏省电力有限公司新技术项目 (JS2102150)。

Project Supported by New Technology Project of State Grid Jiangsu Electric Power Co., Ltd.(JS2102150).

展，机器学习是当前电力负荷预测的主流，主要包含支持向量机、随机森林、卷积神经网络、长短时记忆网络^[4]等。文献^[5]提出了一种基于深度回归森林的预测方法，通过多粒度扫描提取时序特征，级联森林输入，取得了良好的效果；文献^[6]通过引入改进粒子群算法（improved particle swarm optimization, IPSO），改进了长短时记忆（long short-term memory, LSTM）的神经元个数、损失率等参数，并应用于电力负荷的预测，验证了方案的可行性。

同时，将电力负荷数据按不同的特性，分为不同的成分，并选取相应的模型进行分步预测，可以有效地提高预测准确度^[7]。常用的时序分解方法包含小波分解、经验模态分解^[8]等。文献^[9]先采用变分模态分解（variational modal decomposition, VMD）算法，将负荷数据分解为各个模态分量，然后分别输入预测模型进行预测；文献^[10]基于小波分解理论，详细讨论了负荷数据的类别划分、影响因素和智能预测等，提供了一定的参考借鉴。为了进一步提高信号的分解性能，潘海洋^[11]提出了辛几何模态分解，可以有效地保护时间序列的结构，自适应地分解为若干独立分量。然而，涉及到相似分量重组的问题，并未有明确说明，因此构造相互独立的分解分量对于信号特征提取十分必要。

为了充分挖掘电力负荷数据的特征，进而提高预测精度，本文提出一种基于自适应辛几何模态分解（adaptive symplectic geometry mode decomposition, ASGMD）-多元线性回归（multiple linear regression, MLR）-卷积长短时记忆（convolutional long short-term memory, CLSTM）的台区电力负荷预测方法。通过 ASGMD 将数据分解为若干辛几何分量（symplectic geometry components, SGCs），再根据层次聚类 and 信噪比，分为弱相关和强相关两种分量；同时，在 LSTM 单元中的各个门限之间引入卷积操作，可以更好地提取数据中隐含的关联信息，用于预测强相关分量，弱相关分量则使用 MLR。最后，组合各模型结果，得到最终负荷预测值。

1 自适应辛几何模态分解 ASGMD

1) 相空间重构。

设信号为 $x = x_1, x_2, \dots, x_n$ ，则相空间 X 可以构造为

$$X = \begin{bmatrix} x_1 & x_{1+\tau} & \cdots & x_{1+(d-1)\tau} \\ \vdots & \vdots & \ddots & \vdots \\ x_m & x_{m+\tau} & \cdots & x_{m+(d-1)\tau} \end{bmatrix} \quad (1)$$

式中 $m = n - (d-1)\tau$ 。 n 为信号长度，由时间序列决定； d 为延迟时间； τ 为嵌入维度，一般取 $\tau = 1$ 。

2) 辛几何相似变化。

通过协方差矩阵 $A = X^T X$ ，构造哈密顿矩阵 M ，具体表达式为

$$M = \begin{bmatrix} A & 0 \\ 0 & -A^T \end{bmatrix} \quad (2)$$

令 $N = M^2$ ，构造辛正交矩阵 Q ，可得

$$Q^T N Q = \begin{bmatrix} B & R \\ 0 & B^T \end{bmatrix} \quad (3)$$

Q 为矩阵 A 的特征值 δ_i 对应的特征向量，其中 Q 可由辛相似变换获得。

3) 矩阵重构。

$$\begin{cases} S_i = Q_i^T X^T \\ Z_i = Q_i S_i \\ Z = Z_1 + Z_2 + L + Z_d \end{cases} \quad (4)$$

式中 S_i 为变换系数矩阵。

4) 对角平均。

对特征维度为 $m \times d$ 的重构矩阵 Z_i 进行对角平均，可得

$$y_k = \begin{cases} \frac{1}{k} \sum_{p=1}^k z_{p,k-p+1}^*, & 1 \leq k < d^* \\ \frac{1}{d^* \sum_{p=1}^{d^*} z_{p,k-p+1}^*}, & d^* \leq k \leq m^* \\ \frac{1}{n-k+1} \sum_{p=k-m^*+1}^{n-m^*+1} z_{p,k-p+1}^*, & m^* < k \leq n \end{cases} \quad (5)$$

式中： $d^* = \min(m, d)$ ； $m^* = \max(m, d)$ 。最终，时间序列 x 可被转化为 d 组长度为 n 的序列之和，即

$$Y = Y_1 + Y_2 + \cdots + Y_d \quad (6)$$

对于获得的 d 个初始单分量，计算前 h 个分量的和，然后通过计算余量信号的归一化均方差^[11]比值，来确定迭代分解的终止条件，当小于设定的阈值时，则终止。

至此，通过传统的辛几何模态分解（symplectic geometry mode decomposition, SGMD）方法，可以获得 h 个初始单分量。

5) 层次聚类。

利用层次聚类,对传统 SGMD 方法所得的 SGCs 分量进行重组,可以有效地将单分量集合中相似度较高的分量进行组合,并且最大化地区分各组合分量之间的差异^[12]。

将每一个分量 Y_i 视作聚类中心 $o_i = (Y_i)$, 则聚类集合为 $O = (o_1, o_2, \dots, o_h)$ 。聚类组合 $O_{ij} = (O_i, O_j)$ 的类间距离 H_{ij} 可由式 (7) 得到。

$$H_{ij}(C_i, C_j) = \frac{1}{n^2} \sum_{x \in C_i} \sum_{y \in C_j} h(x, y) \quad (7)$$

$$h(x, y) = \left[\sum_{i=1}^n |x_i - y_i|^2 \right]^{1/2} \quad (8)$$

选择 H_{ij} 中最小的聚类组合 (O_i, O_j) 合并为 $O_m = O_i \cup O_j$, 同时合并相应的 (Y_i, Y_j) 为 Y_m , 则新的分量组合和新的聚类集合分别如式 (9)、(10) 所示。

$$Y = Y_1 + Y_2 + \dots + Y_{h-1} \quad (9)$$

$$O = (O_1, O_2, \dots, O_{h-1}) \quad (10)$$

重复上述聚类操作,当分组数为 l 时停止,此时可得聚类辛几何分量为

$$Y = Y_1^* + Y_2^* + \dots + Y_l^* \quad (11)$$

6) 分量筛选。

复杂电网环境中的电力数据往往包含强相关和弱相关的组成部分,传统 SGMD 方法将所有的分量视为强相关信息进行预测,会导致效果不佳,选取较少的分量则会丢失关键信息成分,影响预测的准确性。本文引入信噪比^[13]理论,有效地区分了 SGMD 分解的强相关分量和弱相关分量。定义信号 $(x = x_1, x_2, \dots, x_n)$ 与前 t 个 SGCs 组合分量间的信噪比为

$$SNR_t = 10 \ln \frac{\sum_{i=1}^n x_i^2}{\sum_{i=1}^n \left(x_i - \sum_{t=1}^t SGC_t^i \right)^2} \quad (12)$$

当 $SNR_{t+1} - SNR_t < 0$ 时, t 点为最佳分离点,则强相关分量和弱相关分量分别为

$$Y_S = Y_1^* + Y_2^* + \dots + Y_t^* \quad (13)$$

$$Y_W = Y_{t+1}^* + Y_{t+2}^* + \dots + Y_l^* \quad (14)$$

值得注意的是,在采用相应模型进行预测时,组成强相关分量的每个分量都需要视为单分量进行模型输入,而弱相关分量则不同,需要将组成

的分量全部视为弱相关分量进行模型输入。

2 MLR-CLSTM 混合预测模型

2.1 MLR 模型

针对电力负荷数据中趋势相对平稳的弱相关成分,采用 MLR 模型相较于传统的神经网络、聚类模型,预测准确度更高,由于模型结构简单,不需人为参数调整,因此预测速度也相对较快^[14],其模型如式 (15) 所示。

$$\hat{Y} = \beta[1, Y_W] + n \quad (15)$$

式中: Y_W 表示历史数据; $\hat{Y}$ 表示预测数据; β 表示回归系数; n 表示随机扰动。

通过最小二乘计算回归函数,用于弱相关成分的预测如式 (16) 所示。

$$\hat{\beta} = (Y_W' Y_W)^{-1} Y_W' \gamma \quad (16)$$

2.2 CLSTM 模型

采用 MLR 对强相关成分进行预测,可能因为波动性导致模型无法收敛,而 LSTM 模型在训练时通过优化算法修正连接权值,可以非线性地拟合波动性数据,并且解决了长期依赖的问题。相较于传统的 LSTM 网络,采用卷积计算替代权重更新,可以更好地提取数据中的相互关联信息。在 LSTM 模型的各个单元门限中添加一维卷积操作^[15],构造 CLSTM 模型,降低特征提取的难度,挖掘时间序列的相关性,结构如图 1 所示。




图 1 CLSTM 网络结构

Fig. 1 Network architecture of CLSTM

将 CLSTM 中各单元更新如下

$$f_t = \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \odot C_{t-1} + b_f) \quad (17)$$

$$i_t = \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \odot C_{t-1} + b_i) \quad (18)$$

$$B_t = f_t \odot B_{t-1} + i_t \odot \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \quad (19)$$

$$o_t = \sigma(W_{x0} * X_t + W_{h0} * H_{t-1} + W_{C0} \odot C_t + b_0) \quad (20)$$

$$H_t = o_t \odot \tanh(B_t) \quad (21)$$

式中： σ 为激活函数； W 为连接权值； B 为状态信息； b 为偏差。

2.3 MLR-CLSTM 混合模型

电力负荷数据由于多重因素的相互作用，波动性较强，采用原始数据和单一预测模型无法满足准确性的要求，效果不佳。为了充分改善此类问题，采用“多分量-多模型”的思想，将原始电力负荷数据进行 ASGMD 分解，构造强相关和弱相关分量，分别采用 MLR-CLSTM 模型进行数据预测，最后整合各模型的预测结果以提高精度，并基于完整的评价指标和误差标准进行评估，详细流程如图 2 所示。




图 2 ASGMD-MLR-CLSTM 网络的负荷预测流程图

Fig. 2 Flowchart of load forecasting based on ASGMD-MLR-CLSTM

3 实例分析

3.1 数据预处理

采用江苏省某电网公司辖区内台区某变压器历史负荷数据为样本，进行相关验证，并与实际负荷进行对比。选取某年 1 月 1 日到后年 5 月 16 日共 864 d 的数据，前 698 d 用作训练，后 166 d 用作数据预测，每天隔 1 h 进行采样，则每天可采样 24 个点。采集得到的台区有功功率数据中含有大量的异常数据，其中包含功率数据缺失、零值等异常数据，对这些历史负荷数据进行预处




图 3 数据预处理方法流程图

Fig. 3 Diagram of data preprocessing

理，如图 3 所示，完成剔除异常值、填补空缺值等的操作。

通过 min-max 归一化，对电力负荷数据进行线性变化，映射到 [0,1] 之间，如式 (22) 所示：

$$\tilde{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (22)$$

数据预处理之后的台区有功功率数据如图 4 所示，将其组成时间序列数据，作为后续算法的输入。




图 4 南京市某台区电力负荷数据

Fig. 4 Power load data of a station area in Nanjing

3.2 误差指标

本文选取均方根误差 (root mean squared error, RMSE)、平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE) 作为误差评价指标，其计算公式如下

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n |\hat{p}(i) - p(i)|^2} \quad (23)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\hat{p}(i) - p(i)| \quad (24)$$

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^N \frac{|\hat{p}(i) - p(i)|}{p(i)} \times 100\% \quad (25)$$

式中： $p(i)$ 为电力负荷数据的实际值； $\hat{p}(i)$ 为预测值； n 为样本数量。

误差评价指标越小，预测越精确。

3.3 预测分析

将数据预处理后的电力负荷数据进行 ASGMD 分解，可以得到多组强相关分量和一组弱相关分量，分别如图 5 和图 6 所示。从图 5、6 可以看出，电力负荷的大部分相关信息主要集中在前几个强相关分量，对于弱相关分量，其幅值相对较小。




图 5 ASGMD 分解的强相关分量

Fig. 5 Strong correlation components decomposed by ASGMD




图 6 ASGMD 分解的弱相关分量

Fig. 6 Weak correlation components decomposed by ASGMD

为了验证本文所提算法的优势，首先采用单一模型进行比较，主要有支持向量回归（support vector regression, SVR）、深度置信网络（deep belief network, DBN）、MLR 和 CLSTM 等，并采用上文所提的误差评价标准评估所提方法的性能，结果如表 1 所示。为了更直观地展示预测模型的性能，将包含真实数据和预测模型的预测结果进行绘制，如图 7 所示。从图 7 可见，MLR 和 CLSTM 模型对负荷数据的预测相对较好。

为验证引入 ASGMD 方法的必要性和优势以及 CLSTM 的效力，采用 ASGMD 分别与 MLR、

表 1 单一模型的预测指标对比
Table 1 Comparison of forecasting indexes of single models

单一模型	RMSE/kW	MAE/kW	MAPE/%
SVR	542.68	415.04	5.01
DBN	417.56	331.94	4.23
MLR	353.58	269.39	3.48
CLSTM	216.28	154.13	3.12




图 7 单一模型的预测结果

Fig. 7 Forecasting results of single models

LSTM 和 CLSTM 的模型组合来验证预测效果，其误差评价指标如表 2 所示，直观预测结果如图 8 所示。结合单一模型的效果来看，采用组合模型所展现出的预测效果更加精准，且 CLSTM 要比 LSTM 的精确度要高。ASGMD 在提取负荷数据的强弱相关性能上存在一定的优势。

为了验证本文所提 ASGMD-MLR-CLSTM 模

表 2 组合模型的预测指标对比
Table 2 Comparison of forecasting indexes of combined models

组合模型	RMSE/kW	MAE/kW	MAPE/%
ASGMD-MLR	205.12	140.75	2.74
ASGMD-LSTM	216.45	151.62	2.42
ASGMD-CLSTM	221.68	157.65	2.37




图 8 组合模型的预测结果

Fig. 8 Forecasting results of combined models

型的性能，首先采用 ASGMD 分解，得到强相关分量和弱相关分量，并将强相关分量依次输入到 CLSTM 模型中，得出强相关分量的预测数据。然后，将弱相关分量输入到 MLR 模型中，得出弱相关分量的预测数据。最后，组合各模型结果得到最终负荷预测值。误差评价标准结果如表 3 所示，预测结果如图 9 所示。基于上述分析，汇总不同模型的预测趋势，生成各模型的预测结果对比图，如图 10 所示。

表 3 ASGMD-MLR-CLSTM 的预测指标
Table 3 Forecasting indexes of ASGMD-MLR-CLSTM

模型	RMSE/kW	MAE/kW	MAPE/%
ASGMD-MLR-CLSTM	198.27	138.41	1.41




图 9 ASGMD-MLR-CLSTM 的预测结果
Fig. 9 Forecasting results of ASGMD-MLR-CLSTM




图 10 不同模型的预测结果图
Fig. 10 Forecasting results of different models

通过对比预测指标可以看出，本文所提方法能够降低分解分量所造成的模态混叠影响，区分

强弱相关分量，并且较好地挖掘数据中时序的内在关联，在各个指标中均有较低的范畴，预测误差相对较好。而从预测结果的对比中可以看出，本文所提模型预测结果更准确，更贴近于真实值。

4 结论

针对台区电力负荷预测，本文提出基于“多分量-多模型”的组合预测模型。模型使用 ASGMD 将台区负荷数据分解为弱相关和强相关两种分量，利用 MLR 和 LSTM 分别对上述两种分量进行预测，并通过组合各模型结果，得到最终的负荷预测值。实验结果表明，文中所述方法在曲线拟合和精度预测方面均有良好的性能，是一种有效的电力负荷预测方法。

参考文献

[1] 方娜,李俊晓,陈浩,等.基于变分模态分解的卷积神经网络-双向门控循环单元-多元线性回归多频组合短期电力负荷预测[J].现代电力,2022,39(4):441-448.
FANG Na, LI Junxiao, CHEN Hao, *et al.* Multi-frequency combination short-term power load forecasting with convolutional neural networks-bidirectional gated recurrent unit-multiple linear regression based on variational mode decomposition[J]. Modern Electric Power, 2022, 39(4): 441-448(in Chinese).
[2] 简定辉,李萍,黄宇航,等.基于 CNN-LSTM 网络的短期电力负荷预测[J].电工电气,2022(9):1-6.
JIAN Dinghui, LI Ping, HUANG Yuhang, *et al.* Short-term power load forecasting based on CNN-LSTM[J]. Electro-technics Electric, 2022(9): 1-6(in Chinese).
[3] 张未,余成波,王士彬,等.基于 VMD-LSTM-Light-GBM 的多特征短期电力负荷预测[J].南方电网技术,2023,17(2):74-81.
ZHANG Wei, YU Chengbo, WANG Shibin, *et al.* Multi-featured short-term power load forecasting based on VMD-LSTM-Light-GBM[J]. Southern Power System Technology, 2023, 17(2): 74-81(in Chinese).
[4] 徐岩,向益锋,马天祥.基于粒子群算法优化参数的 VMD-GRU 短期电力负荷预测模型[J].华北电力大学学报(自然科学版),2023,50(1):38-47.
XU Yan, XIANG Yifeng, MA Tianxiang. VMD-GRU short-term power load forecasting model based on optimized parameters of partical swarm algorithm[J]. Journal of North China Electric Power University(Natural Science

- Edition), 2023, 50(1): 38–47(in Chinese).
- [5] 黄文思, 陆鑫, 陈婧, 等. 基于深度回归森林的短期电力负荷预测 [J]. 电气自动化, 2023, 45(1): 18–20, 25.
HUANG Wensi, LU Xin, CHEN Jing, *et al.* Short-term electrical load forecasting based on deep regression forest[J]. Electrical Automation, 2023, 45(1): 18–20, 25(in Chinese).
- [6] 赵一鸣, 吉月辉, 刘俊杰, 等. 基于 EMD-IPSO-LSTM 模型的短期电力负荷预测 [J]. 国外电子测量技术, 2023, 42(1): 132–137.
ZHAO Yiming, JI Yuehui, LIU Junjie, *et al.* Short term power load forecasting based on EMD-IPSO-LSTM model[J]. Foreign Electronic Measurement Technology, 2023, 42(1): 132–137(in Chinese).
- [7] 章可, 李丹, 孙光帆, 等. 基于 CVMD-GRU-DenseNet 混合模型的短期电力负荷预测 [J]. 水电能源科学, 2023, 41(1): 207–211, 166.
ZHANG Ke, LI Dan, SUN Guangfan, *et al.* Short-term power load forecasting based on CVMD-GRU-DenseNet hybrid model[J]. Water Resources and Power, 2023, 41(1): 207–211, 166(in Chinese).
- [8] 方娜, 李俊晓, 陈浩, 等. 基于 CNN-GRU-MLR 的多频组合短期电力负荷预测 [J]. 计算机仿真, 2023, 40(1): 118–124.
FANG Na, LI Junxiao, CHEN Hao, *et al.* Multi-frequency combination short-term power load forecasting based on CNN-GRU-MLR[J]. Computer Simulation, 2023, 40(1): 118–124(in Chinese).
- [9] 陆磊, 张铭飞, 朱浩钰. 基于 VMD-IPSO-LSSVM 的短期电力负荷预测研究 [J]. 电工技术, 2022(24): 175–178, 197.
LU Lei, ZHANG Mingfei, ZHU Haoyu. Research on short-term power load forecasting based on VMD-IPSO-LSSVM[J]. Electric Engineering, 2022(24): 175–178, 197(in Chinese).
- [10] 杨再鹤, 向铁元, 郑丹. 基于小波变换和 SVM 算法的微电网短期负荷预测研究 [J]. 现代电力, 2014, 31(3): 74–79.
YANG Zaihe, XIANG Tieyuan, ZHENG Dan. Short-term load forecasting of microgrid based on wavelet transform and support vector machines[J]. Modern Electric Power, 2014, 31(3): 74–79(in Chinese).
- [11] 潘海洋. 基于辛几何模态分解和支持矩阵机的机械故障诊断方法 [D]. 长沙: 湖南大学, 2019.
- [12] 曲海阔, 张哲宇, 刘扬, 等. 一种面向工控联网设备的层次聚类方法 [J]. 现代电子技术, 2022, 45(23): 76–82.
QU Haikuo, ZHANG Zheyu, LIU Yang, *et al.* Hierarchical clustering method for industrial control networking equipment[J]. Modern Electronics Technique, 2022, 45(23): 76–82(in Chinese).
- [13] 李云峰, 高云鹏, 蔡星月, 等. 自适应辛几何模态分解和短时能量差分因子在电能质量扰动检测中的应用 [J]. 电工技术学报, 2022, 37(17): 4390–4400.
LI Yunfeng, GAO Yunpeng, CAI Xingyue, *et al.* Application of adaptive symplectic geometry modal decomposition and short-time energy difference factor in power quality disturbance detection[J]. Transactions of China Electrotechnical Society, 2022, 37(17): 4390–4400(in Chinese).
- [14] 杨秀, 胡钟毓, 田英杰, 等. 基于 EMD-Stacking-MLR 的台区配变短期负荷预测方法 [J]. 电器与能效管理技术, 2022(2): 53–62.
YANG Xiu, HU Zhongyu, TIAN Yingjie, *et al.* Short-term load forecasting method of distribution transformer based on EMD-Stacking-MLR[J]. Electrical & Energy Management Technology, 2022(2): 53–62(in Chinese).
- [15] 刘龙庚, 翟俐民, 韩云祥. 基于卷积 LSTM 模型的航空器轨迹预测 [J]. 计算机工程与设计, 2022, 43(4): 1127–1133.
LIU Longgeng, ZHAI Limin, HAN Yunxiang. Aircraft trajectory prediction based on conv LSTM[J]. Computer Engineering and Design, 2022, 43(4): 1127–1133(in Chinese).

收稿日期: 2023–03–28

作者简介:

方磊 (1991), 男, 博士, 高级工程师, 通信作者, 研究方向为电力计量、营销大数据等, E-mail: njgw_fl@163.com;

楚成博 (1988), 男, 硕士, 高级工程师, 研究方向为电量计量管理, E-mail: njgw_ccb@163.com;

何映虹 (1996), 女, 硕士, 研究方向为计量指标管控、线损分析管控, E-mail: njgw_hyh@163.com;

冯隆基 (1981), 男, 硕士, 高级工程师, 研究方向为电力计量、营销大数据等, E-mail: njgw_flj@163.com;

刘福政 (1993), 男, 博士研究生, 研究方向为智能控制与故障诊断, E-mail: liufuzheng2520@163.com;

王宁 (1998), 男, 硕士研究生, 研究方向为电力大数据分析, E-mail: snail_wn@163.com;

张法业 (1984), 男, 博士, 高级实验师, 研究方向为电力大数据分析、深度学习、智能感知与故障诊断等, E-mail: zhangfaye@sdu.edu.cn.