

DOI: 10. 20040/j. cnki. 1000-7709. 2023. 20221985

# 基于 CVMD-GRU-DenseNet 混合模型的 短期电力负荷预测

章 可<sup>1</sup>, 李 丹<sup>1</sup>, 孙光帆<sup>1,2</sup>, 谭 雅<sup>1,2</sup>, 贺 帅<sup>1,2</sup>

(1. 三峡大学电气与新能源学院, 湖北 宜昌 443002; 2. 新能源微电网湖北省协同创新中心, 湖北 宜昌 443002)

**摘要:** 针对电力负荷时序变化非线性和多周期性特点, 提出一种基于分解-预测-重构框架的 CVMD-GRU-DenseNet 短期负荷预测方法。分解阶段依据子序列间的相关熵确定 VMD 最佳分解数, 提高负荷序列分解质量; 预测阶段针对各子序列特点筛选输入特征, 规律性强的低频分量采用 GRU 神经网络预测模型, 强随机性的高频分量采用 DenseNet 神经网络预测模型; 最后将各分量的预测结果重构为负荷预测曲线。湖北某市四季的实际负荷算例结果表明, 该方法能有效提高短期负荷预测精度, 并具有较强的泛化能力。

**关键词:** 短期负荷预测; 变分模态分解; 相关熵; 门控循环单元; 密集连接卷积网络

**中图分类号:** TM715

**文献标志码:** A

**文章编号:** 1000-7709(2023)01-0207-04

## 1 引言

准确的短期电力负荷预测不仅能为电力公司制定发电计划提供可靠依据, 也有助于制定适当的备用和维护计划, 降低运维成本。短期负荷预测方法分为统计学方法、机器学习方法和深度学习方法<sup>[1]</sup>。近年来, 深度学习方法因其强大的数据特征挖掘能力成为研究热点。如长短期记忆网络 LSTM<sup>[2]</sup>通过增加门控结构, 解决了传统循环神经网络学习长序列时的梯度消失或爆炸问题。卷积神经网络 CNN<sup>[1]</sup>局部特征提取能力强, 但随着网络深度增加, 易出现训练结果不稳定和梯度消失问题。密集连接卷积网络 DenseNet<sup>[3]</sup>通过在层间建立连接关系, 减少网络参数和计算成本, 可加快特征信息传递速度。引入信号分解技术挖掘负荷的时序变化规律是提高负荷预测精度的另一重要手段。如经验模态分解 EMD<sup>[4]</sup>可自适应分解时序负荷, 但易发生模态混叠现象。具有非递归特点的变分模态分解 VMD<sup>[5,6]</sup>将序列的时域分解转化为频域变分优化问题求解, 鲁棒性更强, 但分解数  $K$  难以确定, 且现有研究大多对分解后不同频率的子序列采用相同的预测模

型, 可能导致预测误差进一步增大。对此, 本文提出一种基于 CVMD-GRU-DenseNet 混合模型的短期电力负荷预测方法, 以提高短期负荷预测精度和泛化能力, 为电力系统科学决策和安全稳定运行提供更准确的数据支撑。

## 2 基于 CVMD-GRU-DenseNet 的短期负荷预测

图 1 为 CVMD-GRU-DenseNet 短期负荷预测模型的整体框架, 主要由负荷时序分解、子序列预测和结果重构 3 部分组成。

### 2.1 负荷时序分解

VMD 通过构造约束变分问题, 将负荷时间序列  $f(t)$  分解为  $K$  个具有各自中心频率有限带宽的 IMF 本征模态函数  $u_k(t), k=1, 2, \dots, K$ , 即:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \otimes u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}$$
$$\text{s. t. } \sum_{k=1}^K u_k(t) = f(t) \quad (1)$$

式中,  $\omega_k$  为第  $k$  个 IMF 的中心频率;  $\delta(t)$  为狄拉克分布;  $\otimes$  为卷积运算符;  $t$  为采样时刻点。

由于分解次数  $K$  需要预设, 如设置不当将导

收稿日期: 2022-09-23, 修回日期: 2022-10-17

基金项目: 国家自然科学基金青年基金项目(51807109)

作者简介: 章可(1997-), 女, 硕士研究生, 研究方向为电力负荷与新能源预测, E-mail: zhangke970731@163.com

通讯作者: 李丹(1980-), 女, 博士、副教授、硕导, 研究方向为电力负荷与新能源预测和电力系统概率分析, E-mail:

lucy2140@163.com

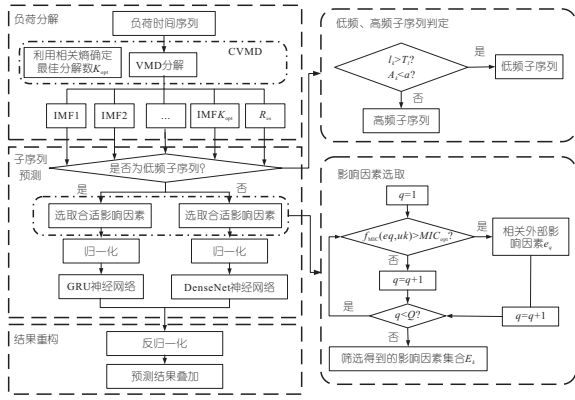


图 1 CVMD-GRU-DenseNet 模型的整体框架

Fig. 1 Overall framework of the CVMD-GRU-DenseNet model

致子序列模态混叠,影响后续预测精度,因此引入局部相似性度量评价函数——相关熵<sup>[7]</sup>,衡量任意两个 IMF 子序列  $u_i, u_j (i \neq j)$  之间的相似性:

$$\hat{V}_\sigma(u_i, u_j) = \frac{1}{T} \sum_{t=1}^T \exp\left(-\frac{\|u_i(t) - u_j(t)\|^2}{2\sigma^2}\right) \quad (2)$$

随着分解数  $K$  增加,可通过检测两两 IMF 分量间相关熵是否接近 1,判断对应  $K$  值下是否出现模态混叠,以此确定最佳分解数  $K_{opt}$ 。基于相关熵的变分模态分解(CVMD)的具体步骤如下。

算法 1: CVMD

输入待分解序列  $f(t), t=1, 2, \dots, T$

分解次数  $K \leftarrow 1$

设置参数  $\tau, \epsilon_1, \epsilon_2$

repeat

$K \leftarrow K + 1$

初始化参数  $\{\hat{u}_k^1\}, \{\omega_k^1\}, \hat{\lambda}^1$ , 迭代次数  $n \leftarrow 0$

repeat

$n \leftarrow n + 1$

for  $k=1:K$

更新  $\hat{u}_k^{n+1}$ :

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

更新  $\hat{\omega}_k^{n+1}$ :

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

end

更新  $\hat{\lambda}^{n+1}$ :

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau(f(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (5)$$

$$\text{until } \sum_{k=1}^K \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \epsilon_2$$

根据式(3)计算 IMF 分量间的相关熵最大值

$$V = \max_{\substack{i \neq j \\ i, j \in \{1, \dots, K\}}} (\hat{V}_\sigma(u_i, u_j))$$

until  $V > 1 - \epsilon_1$

$K_{opt} \leftarrow K$

其中,  $\hat{u}_k(\omega), f(\omega), \hat{\lambda}(\omega)$  分别为时域下的  $\hat{u}_k(t), f(t), \hat{\lambda}(t)$  经过傅里叶变换到频域的结果,  $\tau$  为噪声容忍度。

## 2.2 子序列预测

### 2.2.1 高、低频子序列判定

采用傅里叶变换<sup>[8]</sup>和自相关系数相结合的方法确定  $u_k$  的周期,并引入近似熵衡量子序列的复杂度。以综合判定子序列的高/低频属性。流程见图 1。

设  $u_k$  经过傅里叶变换得到  $c$  个可能周期  $F(u_k) = l_k^1, l_k^2, \dots, l_k^c$ , 求时延阶数分别为各周期时的自相关系数,其最大值  $\max_{l_k \in F(u_k)} (ACF(u_k, l_k))$  对应的时延阶数  $L_k^{opt}$  即为  $u_k$  的主周期。复杂度则采用近似熵来度量,具体步骤如下。

算法 2: 近似熵

输入时间序列  $u_k(t), t=1, 2, \dots, T$

设置参数  $m, r$ , 其中  $m$  为重构矢量的维度,  $r$  为相似容限

令  $d = m + 1$

repeat

$m \leftarrow m + 1$

将  $u_k(t)$  重构为  $m$  维矢量:

$$S_k(t) = [u_k(t), u_k(t+1), \dots, u_k(t+m-1)], \quad t=1, 2, \dots, T-m+1 \quad (6)$$

计算  $S_k(i)$  与  $S_k(j)$  的距离  $d_m[S_k(i), S_k(j)]$ :

$$d_m[S_k(i), S_k(j)] = \max_{k=0, \dots, m-1} |u(i+k) - u(j+k)| \quad (7)$$

定义  $C_m^i(r) = \frac{1}{T-m+1} \text{num}\{d_m[U_k(i), U_k(j)] < r\}$

求  $C_m^i(r)$  的自然对数并取平均值:

$$\phi^m(r) = \frac{1}{T-m+1} \sum_{j=1}^{T-m+1} \ln C_m^j(r) \quad (8)$$

until  $m = d$

近似熵表示为:

$$A(m, r) = \phi^m(r) - \phi^{m+1}(r) \quad (9)$$

通常  $m=2, r$  为  $(0.15 \sim 0.20)s, s$  为时间序列的标准差。

### 2.2.2 影响因素筛选

以最大信息系数 MIC 为评估指标筛选出与各分量相关性强的影响因素作为对应分量预测模型的输入变量。设负荷功率的影响因素集合  $E = \{e_q\} (q = 1, 2, \dots, Q)$ ,  $Q$  为全部影响因素个数。 $e_q$  与  $u_k$  之间的 MIC 值计算公式为:

$$f_{MIC}(e_q, u_k) = \frac{\sum_{e_q, u_k} p(e_q, u_k) \log_2 \frac{p(e_q, u_k)}{p(e_q)p(u_k)}}{\max_{r \times s < B} \log_2(\min(r, s))} \quad (10)$$

式中,  $p(\cdot)$  为概率密度分布函数;  $r \times s$  为网格尺度;  $B$  通常取样本总数的 0.6 次方。

影响因素的筛选流程见图 1, 将  $u_k$  待预测时刻前的历史回溯值  $u_k(t - T_i : t - 1)$  与筛选后的影响因素集  $E_k$  共同作为  $u_k$  预测模型的输入  $X_k = [u_k(t - T_i : t - 1), E_k] (k = 1, 2, \dots, K_{opt} + 1)$ 。

### 2.2.3 基于 GRU 的低频分量预测模型

由于 GRU 预测模型(图 2)的门控结构可避免时间序列长期依赖问题, 适用于对子序列中平滑且复杂度低、周期性明显的低频时序分量预测。




图 2 GRU 神经网络结构

Fig. 2 Structure of GRU

GRU 神经网络对信息的处理公式为:

$$r_t = \sigma(W_r [h_{t-1}, x_t]) \quad (11)$$

$$z_t = \sigma(W_z [h_{t-1}, x_t]) \quad (12)$$

$$\tilde{h}_t = \tanh(W_h [r_t \odot h_{t-1}, x_t]) \quad (13)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (14)$$

式中,  $z_t, r_t$  分别为更新门和重置门输出;  $W_*$  为权重矩阵;  $x_t$  为当前时刻输入;  $h_{t-1}$  为上一时刻隐含层信息;  $\sigma$  为 Sigmoid 激活函数;  $\odot$  为 Hadamard 乘积。

### 2.2.4 基于 DenseNet 的高频分量预测模型

DenseNet 网络(图 3)将  $M$  个密集连接模块输出和原始输入序列  $X_k$  相融合, 通过特征传递与复用, 实现随机性强的低频子序列分量预测。

DenseNet 网络输出为:

$$C_{l,k}^M = f(W_{l,k}^M \otimes X_k + b_{l,k}^M) + \sum_{m=1}^M \sum_{i=1}^l C_{i,k}^m \quad (15)$$

$$C_{i,k}^m = f(W_{i,k}^m \otimes X_k + b_{i,k}^m) + \sum_{j=1}^{i-1} C_{j,k}^m \quad (16)$$




图 3 DenseNet 神经网络结构

Fig. 3 Structure of DenseNet

式中,  $W_{i,k}^m, b_{i,k}^m$  分别为第  $k$  个子序列第  $m$  个密集连接块中第  $i$  层卷积核权重向量和偏置;  $f(\cdot)$  为包括批量归一化 BN 和 ReLU 激活函数的非线性函数。

为避免过拟合,  $M - 1$  个密集连接模块后添加 dropout 层, 并由线性全连接层输出预测值:

$$y_k = W_k \times C_{l,k}^M + b_k \quad (17)$$

## 3 算例分析

### 3.1 概况

以湖北省某市 2016 年 3 月至 2017 年 2 月每 15 min 的实际负荷数据为算例, 利用前 1 周历史负荷和预测日的气象和日历特征, 预测未来日 15 min 级负荷曲线。由图 4 可知, 其日均负荷曲线呈现显著的季节性, 为了更好地评价预测性能, 将样本集划分为春夏秋冬四季, 测试集分别选每季的最后 1 周。



图 4 湖北省某市日均负荷曲线

Fig. 4 Daily average load curve of a city in Hubei

### 3.2 CVMD 分解结果与输入变量

采用 CVMD 分解四季的时序负荷, 图 5 给出了随  $K$  值增加 IMF 最大相关熵的变化曲线,  $\epsilon_1 = 0.02$  时春、夏、秋、冬四季的  $K_{opt}$  分别为 6、5、5、5。分解后各分量的主周期及近似熵值见表 1。

四季趋势性分量 IMF1 中, 冬季 IMF1 周期最长, 表明冬季负荷变化更平稳。而 IMF2 呈现出一致的日周期性, 复杂度较低。从 IMF4 开始振幅变小, 波动加快, 且复杂度增加。本文定义  $l > 8$  h 且  $A < 8$  的分量定义为低频分量(表 1 中加粗显示), 其余为高频分量。




图 5 各季负荷不同 K 时的最大相关熵

Fig. 5 The maximum correntropy for different K in four seasons

表 1 子序列周期 l 及近似熵 A 统计表

Tab. 1 Period and approximate entropy statistics

子序列	指标	春季	夏季	秋季	冬季
IMF1	$l/15 \text{ min}$	<b>672</b>	<b>610</b>	<b>960</b>	<b>2 240</b>
	A	<b>5.38</b>	<b>5.1</b>	<b>5.09</b>	<b>4.52</b>
IMF2	$l/15 \text{ min}$	<b>96</b>	<b>96</b>	<b>96</b>	<b>96</b>
	A	<b>6.49</b>	<b>6.15</b>	<b>5.84</b>	<b>6.09</b>
IMF3	$l/15 \text{ min}$	10	<b>48</b>	<b>32</b>	<b>48</b>
	A	9.77	<b>7.18</b>	<b>7.68</b>	<b>7</b>
IMF4	$l/15 \text{ min}$	8	4	10	4
	A	10.36	11.42	9.89	11.47
IMF5	$l/15 \text{ min}$	4	2	3	2
	A	11.41	10.37	11.2	10.43
IMF6	$l/15 \text{ min}$	2			
	A	8.73			
Res	$l/15 \text{ min}$	6	10	10	10
	A	12.39	12.12	12.59	12.25

表 2 各季节负荷预测误差统计

Tab. 2 Statistics of load forecasting error in four seasons

模型	春季		夏季		秋季		冬季	
	$M_{MAPE}$	$R_{RMSE}/MW$	$M_{MAPE}$	$R_{RMSE}/MW$	$M_{MAPE}$	$R_{RMSE}/MW$	$M_{MAPE}$	$R_{RMSE}/MW$
SVM	2.51	50.36	3.92	95.59	2.45	52.19	3.11	70.43
CNN	2.19	44.10	3.69	94.62	2.17	49.58	2.64	68.93
LSTM	2.10	43.88	3.14	85.70	2.32	52.23	2.53	65.67
GRU	2.07	44.02	2.85	74.55	1.90	36.75	2.34	59.05
DenseNet	1.89	42.45	2.74	71.59	2.08	48.04	2.30	53.22
EMD-GRU-DenseNet	1.76	38.21	3.44	95.91	1.67	38.86	2.74	64.62
VMD-GRU-DenseNet	1.49	31.79	2.42	66.35	1.45	33.81	1.89	48.70
CVMD-GRU-DenseNet	<b>1.17</b>	<b>25.87</b>	<b>2.11</b>	<b>55.87</b>	<b>1.12</b>	<b>25.28</b>	<b>1.43</b>	<b>35.83</b>

图 7、8 中本文模型预测曲线均能较好地跟随实际负荷的变化趋势,尤其在负荷强波动区域。结合表 2 可知,本文模型的  $M_{MAPE}$ 、 $R_{RMSE}$  误差值显著低于常见的单一模型。与预测精度最高的 GRU 模型相比,各季节  $M_{MAPE}$  分别降低了 0.90%、0.74%、0.78%、0.91%。由于夏季负荷波动剧烈导致预测难度加大,本文模型的夏季  $M_{MAPE}$  负荷预测误差比其他季节高约 0.68%~0.99%。观察图 8、表 2 数据,本文模型的  $M_{MAPE}$ 、 $R_{RMSE}$  误差值相对其他组合模型也有所降低。由于 VMD 有效克服了 EMD 模态混叠现

象,基于 VMD 分解的组合模型预测误差在各季节的预测误差普遍更低。相较于直接将 EMD 分解次数作为 K 值的 VMD-GRU-DenseNet 模型,本文模型的四季  $M_{MAPE}$  分别降低了 0.32%、0.31%、0.33%、0.46%,表明 CVMD 的 K 值优选策略通过提高分解质量改善了各季节负荷的预测精度。




图 6 MIC 相关性分析

Fig. 6 MIC correlation analysis

### 3.3 预测结果分析

选取 SVM、CNN、LSTM、GRU 和 DenseNet 五种单一模型,以及 EMD-GRU-DenseNet、VMD-GRU-DenseNet 两种组合模型与本文模型对比,采用平均绝对百分误差  $M_{MAPE}$  和均方根误差  $R_{RMSE}$  作为预测精度指标<sup>[9]</sup>。春、夏、秋、冬负荷均值分别为 1 711.74、1 885.18、1 810.49、1 818.56 MW,标准差分别为 82.33、262.43、121.87、194.85 MW。各模型预测精度见表 2,其中最小误差加粗标注。图 7、8 给出了四季测试集周三的日负荷预测曲线。

## 4 结论

a. 提出了一种基于 CVMD-GRU-DenseNet

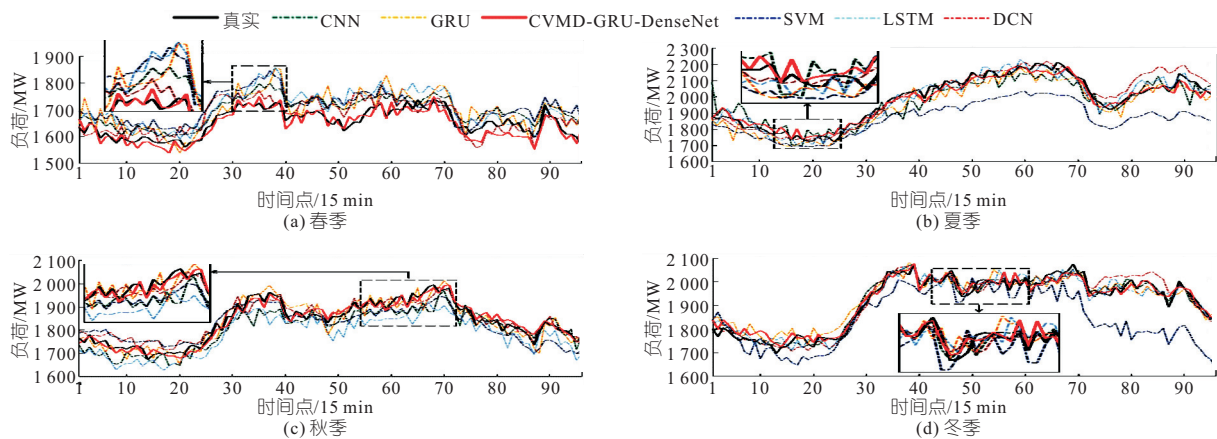


图 7 与单一模型的负荷预测结果对比

Fig. 7 Comparison of load forecasting results with the single-forecasting models

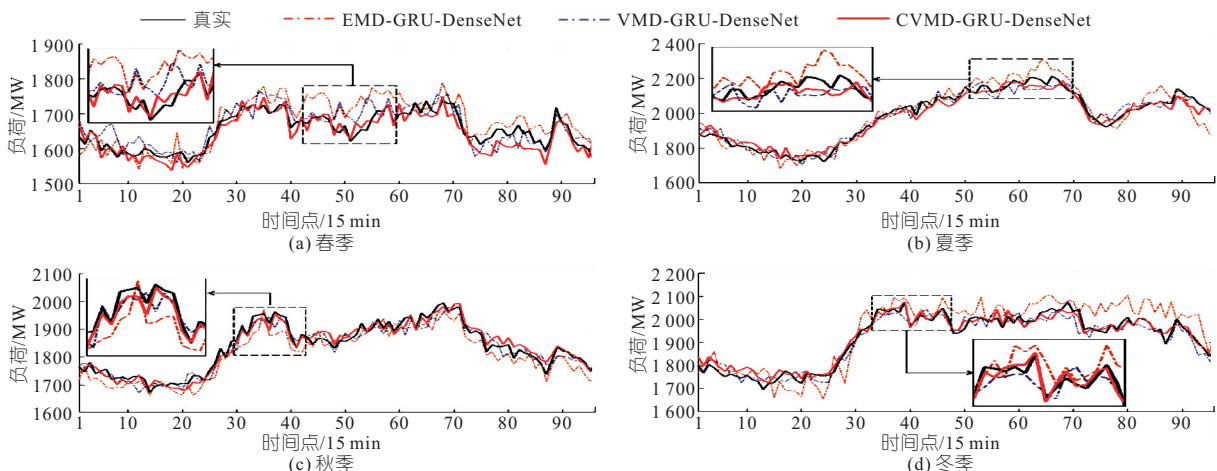


图 8 CVMD-GRU-DenseNet 与组合预测方法的负荷预测结果对比

Fig. 8 Comparison of load forecasting results with the hybrid forecasting methods

混合模型的短期电力负荷预测方法。实际四季负荷算例的验证结果表明,所提组合预测模型的  $M_{MAPE}$  预测误差比常见单一模型降低 0.63%~1.81%,比基于 EMD 或传统 VMD 分解的组合模型降低 0.31%~1.33%,且对不同季节泛化性较强。

**b.** 本文方法通过提高短期负荷预测的精度和泛化性,可更好满足实际电力系统短期负荷预测的需求,具有重要的工程实用价值。

参考文献:

[1] 程江洲,潘飞,鲍刚,等.基于 MAC-WD-CNN-MC-NN 模型的超短期负荷预测[J].水电能源科学,2021,39(9):205-209.  
 [2] 李丹,张远航,杨保华,等.基于约束并行 LSTM 分位数回归的短期电力负荷概率预测方法[J].电网技术,2021,45(4):1356-1364.  
 [3] HUANG G, LIU Z, LAURENS V, et al. Densely Connected Convolutional Networks [C]// IEEE Computer society. IEEE computer society, 2016.

[4] 刘建华,李锦程,杨龙月,等.基于 EMD-SLSTM 的家庭短期负荷预测[J].电力系统保护与控制,2019,47(6):40-47.  
 [5] 段雪滢,李小腾,陈文洁.基于改进粒子群优化算法的 VMD-GRU 短期电力负荷预测[J].电工电能新技术,2022,41(5):8-17.  
 [6] 吴松梅,蒋建东,燕跃豪,等.基于 VMD-PSO-多核极限学习机的短期负荷预测[J].电力系统及其自动化学报,2022,34(5):18-25.  
 [7] LIU W, POKHAREL P P, PRINCIPE J C. Correntropy: A Localized Similarity Measure[C]// International joint conference on neural networks. IEEE, 2006.  
 [8] 黄星宇,罗萍萍,谢琳宇,等.基于 Nuttall 窗的全相位傅里叶电力谐波检测[J].水电能源科学,2020,38(6):192-195.  
 [9] 马梦冬,彭道刚,王丹豪.基于 EEMD-LSTM 的区域能源短期负荷预测[J].浙江电力,2020,39(4):29-35.

