

基于 VMDT-POA-DELM-GPR 的两阶段短期负荷预测 *

王 强^{1,2} 刘宏伟¹ 聂子凡¹

(1. 三峡大学电气与新能源学院 宜昌 443002; 2. 智慧能源技术湖北省工程研究中心 宜昌 443002)

摘要:针对传统负荷预测方法精度不高的问题,为准确捕捉到负荷数据波动的规律,提出了一种两阶段负荷预测方法。第1阶段首先用变分模态分解(VMD)对原始负荷序列进行分解,得到分解处理后的残差分量,再采用时变滤波经验模态分解(TVF-EMD)方法进行特征提取;然后对全部子序列分别建立深度极限学习机(DELM)模型,同时利用鹈鹕优化算法(POA)进行参数寻优,叠加各子序列的预测值得到初始负荷预测值。第2阶段采用POA-DELM模型对误差分量进行预测;然后将第一阶段中所有子序列预测值和误差预测值作为特征输入到高斯过程回归(GPR)模型中,得到负荷最终的预测结果。结果表明,两阶段模型的均方根误差(RMSE)、平均绝对误差(MAE)分别为对比模型的4%~77%、4%~76%,而平均百分比误差(MAPE)仅为0.067 8%,可有效提高电力负荷的预测精度。

关键词:变分模态分解;时变滤波经验模态分解;鹈鹕优化算法;深度极限学习机;两阶段负荷预测

中图分类号: TM714 文献标识码:A 国家标准学科分类代码: 470.40

Two-stage short-term load forecasting based on VMDT-POA-DELM-GPR

Wang Qiang^{1,2} Liu Hongwei¹ Nie Zifan¹

(1. College of Electrical and New Energy, China Three Gorges University, Yichang 443002, China;
2. Hubei Provincial Engineering Research Center of Intelligent Energy Technology, Yichang 443002, China)

Abstract: For the sake of enhancing the power load forecasting accuracy, a two-stage short-term power load forecasting method is proposed. In the first stage, the original load series is decomposed using variational mode decomposition (VMD) to obtain the residual components after decomposition. Then, the time-varying filtering empirical mode decomposition (TVF-EMD) method is used for feature extraction. Next, a deep extreme learning machine (DELM) model is established for all subsequence, and pelican optimization algorithm (POA) is used to optimize the parameters. The initial load prediction value is obtained by adding the prediction value of each subsequence. In the second stage, the POA-DELM model is used to predict the error components. All subsequence prediction values and error prediction values in the first stage are input into the Gaussian process regression (GPR) model as features to obtain the final load prediction results. The results show that the root-mean-square deviation (RMSE) and mean absolute error (MAE) of the two-stage model are 4%~77% and 4%~76% of the comparison model respectively, while the average percentage error (MAPE) is only 0.067 8%, which can effectively improve the accuracy of power load forecasting.

Keywords: variational mode decomposition; time-varying filtering empirical mode decomposition; pelican optimization algorithm; deep extreme learning machine; two-stage load forecasting

0 引言

准确地预测电力负荷短期的需求量,有助于实现电力系统的平衡和稳定运行,避免供需失衡和电力中断等问题。

题。合理安排能源调度可以有效提高能源利用效率,减少电网运输过程中的能源浪费和成本^[1]。随着电力系统的规模不断扩大和复杂度增加,负荷序列的非线性和非平稳性急速上升,导致预测的困难程度增加^[2]。线性回归

收稿日期:2023-07-31

* 基金项目:国家自然基金科学基金(52077120)、宜昌科技研究与开发项目(A201230215)资助

法^[3]、时间序列模型法^[4]、指数平滑法^[5]等传统的方法处理能力弱、预测精度差,难以达到电网中负荷预测与日俱增的精准性。

为了降低非线性和非平稳性的影响,近年来研究中常采用先分解后预测的方法,将信号分解技术引入到模型中,通过组合模型进行负荷预测。即先通过信号分解方法处理复杂的原始负荷序列,得到一系列简单的子序列,再对各子序列分别构建相应的预测模型。典型的信号分解方法包含小波变换分解^[6]、经验模态分解(empirical mode decomposition, EMD)^[7]和变分模态分解(variational mode decomposition, VMD)^[8]。小波变换中分解个数和函数选取容易影响其分解效果,存在自适应性严重不足的问题^[9]。经验模态分解具有自适应性,没有主观因素的影响,但会出现端点效应和模态混叠现象^[10]。变分模态分解将原始信号分解成不同特征的本征模态分量,有效解决模态混叠现象,改善信号分解效果^[11]。然而 VMD 方法仍然存在如下问题:1)变分模态分解方法的性能与模态分量个数 k 密切有关,而对于参数的确定缺乏合理科学的评判标准,仅仅依据主观经验设定参数,会造成分解的效果和精度达不到理想状态。2)负荷序列经过 VMD 方法分解后,会存在剩余的残差分量。而该分量携带着原始序列的丰富信息,以往的方法通常进行舍弃,从而导致原始数据无法得到完整的分解,会限制模型整体的预测性能。

在短期负荷预测的过程中,预测模型的选取发挥着至关重要的作用。随着计算机技术的革新,支持向量机^[12]、随机森林^[13]、决策树^[14]等机器学习模型在电力负荷预测领域中迅速发展。但这类算法在处理时间序列数据时,难以捕捉到输入与输出之间的潜在时间依赖性。深度学习作为机器学习的一种延伸,以其高效的学习能力和自适应性,成为了当前研究的热点^[15]。其中主要包括卷积神经网络(convolutional neural networks, CNN)^[16]和循环神经网络(recurrent neural networks, RNN)^[17]。CNN 既能提取数据特征,也能捕捉时间序列的周期性,从而提高了模型的预测精度,但对于波动性强的数据,效果有所降低。RNN 通过循环结构能很好地处理时间序列数据,充分拟合负荷数据的特性。然而 RNN 存在梯度消失和无法捕捉长期依赖关系的问题。长短时记忆网络(long short-term memory, LSTM)是一种特殊的 RNN,其作为当下时序预测方面尤为盛行的深度神经网络,在序列中能处理长距离的依赖关系,减小梯度爆炸以及消失的问题^[18-19]。然而 LSTM 具有多个门控和记忆单元,需要调优的超参数较多,增加了网络的复杂性和训练的难度,导致在处理大规模数据时,其训练时间和计算成本较高^[20]。深度极限学习机(deep extreme learning machine, DELM)结合了深度学习和极限学习机(ELM)的优势,其网络结构得到较大简化。在训练过程中采用随机初始化的方式,大大减

少了超参数调优的个数,使得训练过程更加高效^[21]。但是 DELM 模型还存在如下不足:1)DELM 由多个极限学习机自编码器(extreme learning machine-automatic encode, ELM-AE)级联而成,训练时由正交矩阵随机确定初始的权值,会影响 DELM 的预测性能,造成波动性较大的预测结果;2)由于随机因素的影响,DELM 模型始终会存在预测误差,以往的研究并没有考虑到误差中隐藏的信息,导致预测结果的精度出现损失;3)所有分量构建 DELM 模型后会产生不同的预测分量,通常情况下只采用简单平均的集成方法,而在多数情况下,线性关系往往并不适用。

为了解决上述问题,提出了基于 VMD 分解、时变滤波经验模态分解(TVF-EMD)及鹈鹕算法(pelican optimization algorithm, POA)^[22]优化 DELM 的负荷预测模型,同时还提出误差修正和非线性集成的模型,该混合模型可分为两个阶段:在第 1 阶段先依据评判标准包络熵确定模态分量个数 k ,再利用 VMD 方法分解原始负荷数据,得到一组子序列,然后通过 TVF-EMD 算法^[23]对 VMD 分解后的残差分量再次分解,充分挖掘该分量蕴含的信息,让原始负荷序列得到完整的分解。建立 DELM 模型,利用 POA 算法对其权重参数寻优,对分解处理后的所有子序列分别进行预测,累加获得初始负荷预测序列。第 2 阶段先计算原始序列与初始序列间的误差序列,再采用 POA-DELM 模型对该序列进行预测,最后将第 1 阶段中所有子序列预测值和误差预测值输入到高斯过程回归(Gaussian processes regression, GPR)模型^[24]中,获得电力负荷最终的预测结果。

本文提出了一种评判指标包络熵,其适用于优化 VMD 方法的参数模态分量个数 k ,克服了主观经验选取的不足,避免了出现分解不足和过分解的问题,改善了该方法的分解性能和效果。针对 VMD 方法分解后产生的残差序列,利用 TVF-EMD 方法自适应地再次分解,充分提取该序列中的有效信息,解决了 VMD 方法分解不完整的问题,提高模型的预测精度。将 DELM 网络运用到负荷预测中,大幅度减少了传统深度学习网络的复杂性,随机初始化的方法有效提高了模型的训练速度,从而在较短时间内实现高精度的预测结果。利用鹈鹕算法对 DELM 网络的初始权重进行寻优,构建最优参数组合的模型,能避免预测结果出现较大的波动性问题,使得模型的预测性能更加有效稳定。提出了一种误差修正和非线性集成的模型,该模型充分利用了模型预测误差中有用的信息,减少随机因素对预测准确性的影响。将不同模态分量及误差分量的预测结果进行非线性集成,可以进一步提高模型的准确性。本文采用上述两阶段模型对澳大利亚的实测负荷进行预测,验证了其在负荷预测方面的可行性。在相同条件下,与其他模型分别进行对比实验,并通过多个评价指标进行全面分析,验证了该两阶段模型能更好的实现未来负荷值的精确预测。

1 研究方法

1.1 VMD 算法

VMD 是一种完全非递归、自适应的信号处理方法,能将复杂的负荷分解成若干个具有不同中心频率和有限带宽的模态分量^[25]。VMD 方法有效克服了传统信号处理方法出现的模态混叠问题,其中心思想是构建和求解变分问题,且满足式(1)的约束条件。

$$\begin{cases} \min_{(u_k),(\omega_k)} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_k u_k = f \end{cases} \quad (1)$$

式中: u_k 为分解后的第 k 个模态分量; ω_k 为该分量的中心频率; ∂_t 是对函数求时间的导数; $\delta(t)$ 为狄拉克函数; $*$ 为卷积运算; f 为输入序列。

VMD 方法受到其参数分解层数 k 的影响,取值合理时分解效果更好,文献[26] 采用包络熵指标,其表征信号的稀疏性程度,当信号中的周期性冲击特征明显时,此时信号的稀疏性较强,包络熵值较小。因此利用最小包络熵方法选取合理的分解层数 k 能取得较好的分解效果。包络熵的表达式如下:

$$\begin{cases} E_p = - \sum_{j=1}^N P_j \lg(P_j) \\ P_j = \frac{a(j)}{\sum_{j=1}^N a(j)} \\ a(j) = \sqrt{x^2(j) + \hat{x}^2(j)} \end{cases} \quad (2)$$

式中: E_p 是包络熵; P_j 是 $a(j)$ 的概率分布序列; $a(j)$ 是信号经希尔伯特变化后的包络信号; $x(j)$ 是信号。

1.2 TVF-EMD 算法

TVF-EMD 是 Li 等^[27] 于 2017 年提出的一种新的用于信号处理和分析的自适应算法,该算法能有效地解决传统信号处理方法中出现的模态分离、间歇及混叠问题,提供了更准确的时变分析结果。

1) 计算局部截止频率

首先由输入信号求出瞬时幅值 $A(t)$ 和瞬时频率 $\varphi'(t)$,然后利用瞬时幅值 $A(t)$ 的局部极大值和局部极小值通过插值运算获得瞬时均值 $a_1(t)$ 和瞬时包络 $a_2(t)$,同时利用瞬时频率 $\varphi'(t)$ 的局部极值经过插值过程后得出 $\eta_1(t)$ 和 $\eta_2(t)$,计算瞬时频率分量 $\varphi'_1(t)$ 和 $\varphi'_2(t)$,最后求解局部截止频率 $\varphi'_{bis}(t)$ 。

$$\varphi'_{bis}(t) = \frac{\varphi'_1(t) + \varphi'_2(t)}{2} = \frac{\eta_2(t) - \eta_1(t)}{4a_1(t)a_2(t)} \quad (3)$$

2) 信号重构

为了解决间歇成分的影响,重新对局部截止频率 $\varphi'_{bis}(t)$ 进行重构,得到一个新的信号 $f(t)$,即:

$$f(t) = \cos \left[\int \varphi'_{bis}(t) dt \right] \quad (4)$$

3) 计算停止准则 $d(t)$

给定一个带宽阈值 ξ ,若满足条件 $d(t) \leq \xi$,可认为是一个分量信号 IMF,如果不满足停止准则,令 $X(t) = X(t) - m(t)$,重复上述步骤。

$$d(t) = \frac{B_{\text{Loughlin}}(t)}{\varphi_{\text{avg}}(t)} \quad (5)$$

式中: $\varphi_{\text{avg}}(t)$ 是对所有分量瞬时频率进行加权平均的值; $B_{\text{Loughlin}}(t)$ 是信号的 Loughlin 瞬时带宽。

经过上述步骤处理后,残差信号如下:

$$res = \sum C_j(t) \quad (6)$$

式中: $C_j(t)$ 为残差分量通过 TVF-EMD 方法分解后的子序列。

1.3 POA 算法

POA 算法是由 Trojovsky 等^[28] 于 2022 年提出的一种新型随机元启发式算法,模拟鹈鹕觅食过程中的自然行为。鹈鹕种群捕食过程的核心思想分为勘探和开发两个阶段。

首先是依据问题的边界对鹈鹕种群进行随机初始化,其过程如下:

$$\begin{cases} x_{i,j} = l_j + rand \cdot (u_j - l_j) \\ i = 1, 2, \dots, N; j = 1, 2, \dots, m \end{cases} \quad (7)$$

式中: $rand$ 为 $[0, 1]$ 的随机数; u_j 和 l_j 分别为求解问题的第 j 维的上下界; $x_{i,j}$ 为第 i 个鹈鹕的第 j 维位置; N 为群体中成员的总数; m 为问题维数。

初始化后再根据觅食过程的两个阶段更新全部鹈鹕个体的位置。

1) 勘探阶段

鹈鹕个体向猎物位置进行移动,位置更新变化如下:

$$x_{i,j}^{p_1} = \begin{cases} x_{i,j} + rand \cdot (P_j - I \cdot x_{i,j}), & F_p < F_i \\ x_{i,j} + rand \cdot (x_{i,j} - P_j), & F_i \leq F_p \end{cases} \quad (8)$$

式中: $x_{i,j}^{p_1}$ 是勘探阶段更新后第 i 个鹈鹕在第 j 维的新位置; I 的取值是 0 或 1; F_p 是目标函数的值; P_j 是猎物在第 j 维的位置。

如果目标函数在某个位置得到改善,那么鹈鹕的位置也随之更新:

$$x_i = \begin{cases} x_i^{p_1}, & F_i^{p_1} < F_i \\ x_i, & F_i \leq F_i^{p_1} \end{cases} \quad (9)$$

式中: $F_i^{p_1}$ 为勘探阶段目标函数值; $x_i^{p_1}$ 为第 i 个鹈鹕的新位置。

2) 开发阶段

勘探结束后,鹈鹕个体进入开发阶段,位置变化如下:

$$x_{i,j}^{p_2} = x_{i,j} + R \cdot \left(1 - \frac{t}{T} \right) \cdot (2 \cdot rand - 1) \cdot x_{i,j} \quad (10)$$

式中: $x_{i,j}^{P_2}$ 是开发阶段更新后第 i 个鹈鹕在第 j 维的新位置; T 为最大迭代次数; t 为目前迭代次数; R 的取值为 0 或 2。

该阶段可由式(11)来求解更新鹈鹕位置。

$$x_i = \begin{cases} x_i^{P_2}, & F_i^{P_2} < F_i \\ x_i, & F_i \leq F_i^{P_2} \end{cases} \quad (11)$$

式中: $F_i^{P_2}$ 为开发阶段目标函数值; $x_i^{P_2}$ 为第 i 个鹈鹕的新位置。

1.4 DELM

ELM 网络结构简单且学习能力强,但面对海量高维的数据时,学习效率会大大地减弱,难以深入挖掘出这些数据中隐藏的信息。DELM 结合深度学习和 ELM 的特点^[29-30],通过连接多个 ELM,构建深层次的网络结构,能更全面地捕捉到数据间的映射关系,有效提高了非线性拟合能力和预测性能。

DELM 是以极限学习机自编码器为基本单位元,对样本数据进行训练和学习,其网络结构如图 1 所示。AE 是一种无监督学习算法,引入到 ELM 中,其特点是训练时输入等于输出。同时 ELM-AE 具有正交性,可以减少训练时长和传输过程中的数据损失。训练时首先原始输入数据作为第 1 个 ELM-AE 的目标输出,再将其进行正交化可以得到第 1 个隐含层的输入权值,然后第 1 个隐含层的输出作为下一个 ELM-AE 的输入,以此类推完成整个训练过程。输入权值 β 求解如下:

$$\beta = \left(\frac{\mathbf{I}}{C} + \mathbf{A}^T \mathbf{A} \right)^{-1} \mathbf{A}^T \mathbf{X} \quad (12)$$

式中: \mathbf{I} 为单位矩阵; C 为正则化参数; \mathbf{A} 为隐含层输出; \mathbf{X} 为输入数据。

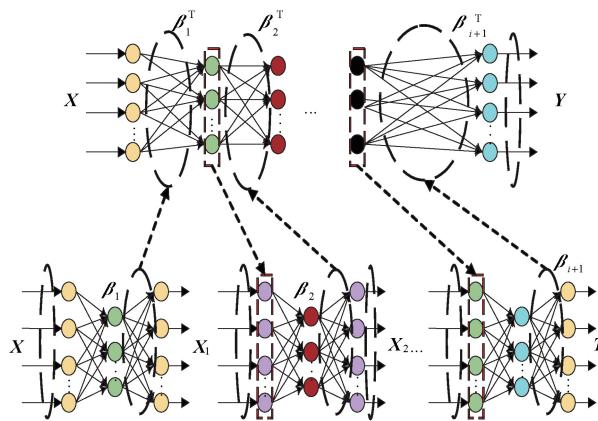


图 1 DELM 结构

1.5 POA-DELM 模型的建立

随机初始化 ELM-AE 中输入层权值,而训练时不会对其进行更新,直接导致 DELM 的性能不稳定,降低了网络的预测精度,通过 POA 算法对 DELM 权值参数寻优,能有效提高 DELM 预测精度和稳定性。POA-DELM 模

型流程如图 2 所示。

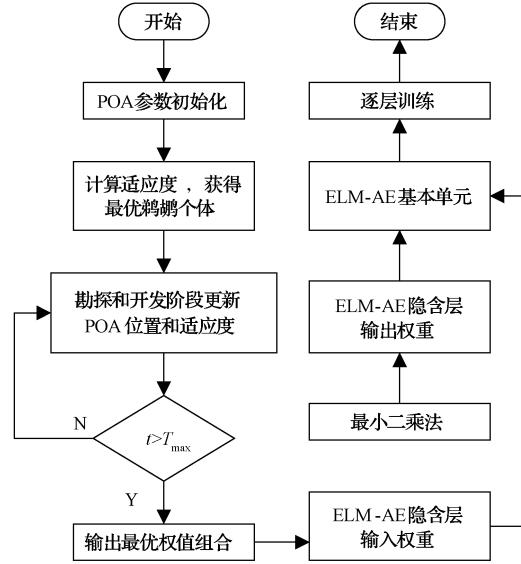


图 2 POA 优化 DELM 流程

1) 设置 POA 的参数,包括种群数量 N 、最大迭代次数 T_{\max} 、变量维度 d 和上下限 $[lb, ub]$ 。

2) 种群初始化,将所有权值组合作为每个鹈鹕的位置,经式(7)初始化鹈鹕种群个体的位置。

3) 将真实值和预测值间的均方误差作为适应度函数,计算并排序鹈鹕个体的适应度值,找出适应度值最小的作为最优鹈鹕个体。

4) 在勘探和开发阶段更新鹈鹕种群位置和适应度。将当前迭代与上一次迭代的最优个体比较,若优于上一代,则更新最优个体位置,否则不变。

5) 判断是否已达到最大迭代次数。若是,则结束,并将最优权值组合输入到 DELM 中,否则跳转至步骤 3)。

1.6 GPR

GPR 是一种基于高斯过程先验知识,估计后验分布,得出输入和输出的潜在关系,对数据进行回归的非参数方法,适用于高维复杂问题。模型建立如下:

$$\mathbf{Y} = f(\mathbf{x}) + \epsilon \quad (13)$$

式中: \mathbf{Y} 为真实值; $f(\mathbf{x})$ 为高斯过程函数; 噪声 $\epsilon \sim N(0, \delta_n^2)$ 。

可知关于真实值 \mathbf{Y} 的先验分布:

$$\mathbf{Y} \sim N(0, K(\mathbf{X}, \mathbf{X}) + \delta_n^2 \mathbf{I}_n) \quad (14)$$

式中: $K(\mathbf{X}, \mathbf{X})$ 为训练集本身的 n 阶正定协方差矩阵; \mathbf{I}_n 为 n 维单位矩阵。

于是真实值 \mathbf{Y} 和预测值 \mathbf{y} 的联合先验分布如下:

$$\begin{bmatrix} \mathbf{Y} \\ \mathbf{y} \end{bmatrix} \sim N \left(0, \begin{bmatrix} K(\mathbf{X}, \mathbf{X}) + \sigma_n^2 \mathbf{I}_n & K(\mathbf{X}, \mathbf{X}_*) \\ K(\mathbf{X}_*, \mathbf{X}) & K(\mathbf{X}_*, \mathbf{X}_*) \end{bmatrix} \right) \quad (15)$$

式中: $K(\mathbf{X}, \mathbf{X}_*)$ 为测试集和训练集间的协方差矩阵; $K(\mathbf{X}_*, \mathbf{X}_*)$ 为测试集本身的协方差矩阵。

则预测值 \mathbf{y} 的计算如下:

$$\mathbf{y} = K(\mathbf{X}, \mathbf{X}_*) [K(\mathbf{X}, \mathbf{X}) + \delta_n^2 \mathbf{I}_n]^{-1} \mathbf{Y} \quad (16)$$

2 电力负荷预测模型

2.1 建立 VMDT-POA-DELM-GPR 的两阶段模型

VMD 方法作为一种自适应的信号分解技术,克服了经验模态分解和集成经验模态分解方法处理过程中出现的模态混叠问题。由此,利用该方法对原始负荷序列进行分解,其中选取评判指标包络熵确定 VMD 方法的模态分量个数 k ,避免出现分解不足和过分解的问题,提供了更优的分解结果。再利用 TVF-EMD 方法分解剩余的残差序列,使得原始负荷序列得到了完整的分解,改善了整体的分解效果。

目前深度学习由于其高效的泛化能力和学习能力,在负荷预测模型中得到了广泛应用。DELM 是一种深度学习网络,融合了深度学习和极限学习机的优点,解决了传统的极限学习机泛化能力不足的问题,通过深度结构和分层无监督训练来提高特征学习能力和泛化能力。分层训练机制还可以大大减少模型的过拟合风险,加强网络的预测性能。并且鹏鹏算法对 DELM 权值参数寻优,进一步提升了网络的预测性能,增强预测结果的稳定性。

在预测过程中存在随机因素的影响,重构各模态分量的预测结果会产生误差分量。因此这里采用优化的 DELM 网络模型预测误差分量,再将所有模态分量和误差分量的预测结果进行 GPR 非线性集成。与经过预测误差修正的预测结果相比,误差修正和非线性集成的方法预测精度更高。

针对传统的预测方法难以捕捉到负荷数据波动的规律,本文建立了一种基于 VMDT-POA-DELM-GPR 的两阶段模型,模型预测过程如图 3 所示。

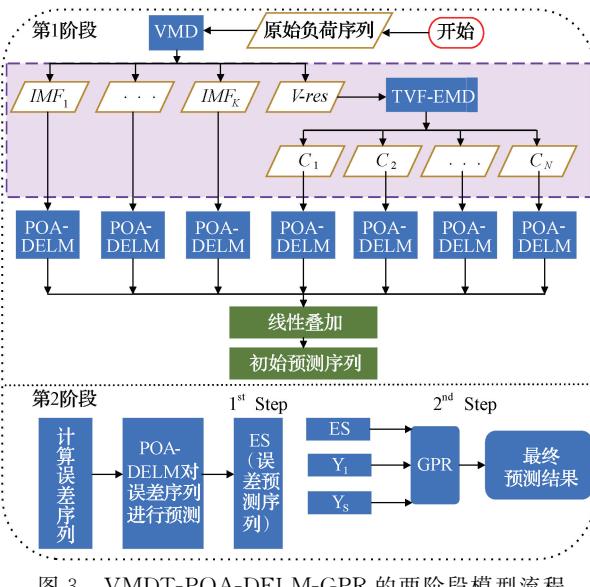


图 3 VMDT-POA-DELM-GPR 的两阶段模型流程

1) 利用 VMD 方法分解原始负荷序列,选取合理的评

判指标包络熵,再根据指标包络熵值最小化准则来设定分解数量 k ,不仅可以解决模态混叠现象,还能避免取值太小造成的重要信息丢失和取值太大产生额外的噪声。在选定分解数量 k 后,将原始负荷序列分解成 K 个不同频率的模态分量: $\{IMF_1, IMF_2, \dots, IMF_K\}$ 。

2) 对于 VMD 方法处理后剩余的残差序列,利用 TVF-EMD 方法对该序列再次进行分解,得到 N 个子序列 $\{C_1, C_2, \dots, C_N\}$ 。残差序列具有强随机性和不稳定性,而 TVF-EMD 方法具有频率分离性能提高、稳定性增强、抗噪声干扰鲁棒性强等优点,可以充分提取其隐含的丰富信息,进一步降低其波动的复杂性,使原始负荷数据得到完整的分解。

3) 将分解后的所有子序列分别输入到鹏鹏算法优化后的深度极限学习机模型中训练,得到各子序列的预测结果。具体来说是利用前 n 个时间点的实测数据预测第 $n+1$ 时间点的负荷值,进而得到初始负荷预测序列,至此第 1 阶段结束。模型训练过程中,输入和输出数据分别为:

$$\begin{cases} x(t) = (h_i^{(t-n)}, h_i^{(t-n+1)}, \dots, h_i^{(t-1)}) \\ h_i^{(t)} = f(h_i^{(t-n)}, h_i^{(t-n+1)}, \dots, h_i^{(t-1)}) \\ y(t) = h_i^{(t)} \end{cases} \quad (17)$$

式中: h_i 表示分解后的子序列; f 表示构建的 POA-DELM 模型。

4) 第 2 阶段中计算原始序列与初始预测序列相差的误差序列,再对误差序列构建 POA-DELM 模型进行预测,得到误差序列的预测结果 ES ,充分利用预测误差序列中的信息。最后将所有子序列和预测误差的预测结果输入到 GPR 模型中,进行非线性集成获得负荷最终的预测结果,进而提高整个预测模型的精度。GPR 模型训练时,输入和输出数据分别为:

$$\begin{cases} x(t) = (h_1^{(t)}, h_2^{(t)}, \dots, h_s^{(t)}, ES^{(t)}) \\ y(t) = g(h_1^{(t)}, h_2^{(t)}, \dots, h_s^{(t)}, ES^{(t)}) \end{cases} \quad (18)$$

式中: t 表示当前时刻点; g 表示构建的 GPR 模型。

2.2 模型性能评价指标

为验证本文提出的两阶段模型预测的精准度,采用误差指标对仿真结果进行分析。其中选取如下 3 种误差评估指标评估,分别为均方根误差(RMSE)、平均绝对误差(MAE)、平均百分比误差(MAPE),公式如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (\hat{y}_n - y_n)^2} \quad (19)$$

$$MAE = \frac{1}{N} \sum_{n=1}^N |\hat{y}_n - y_n| \quad (20)$$

$$MAPE = \frac{1}{N} \sum_{n=1}^N \left| \frac{\hat{y}_n - y_n}{y_n} \right| \times 100\% \quad (21)$$

式中: N 为样本容量; y_n 为第 n 时刻的实际值; \hat{y}_n 表示第 n 时刻的预测值。

3 实验仿真分析

本文采用澳大利亚百日实时电力负荷数据进行实验,该数据的采样周期为30 min,共包含4 800个样本点。将整个数据集以8:1:1的比例分别划分为训练集、验证集和测试集。训练集用以构建预测模型,验证集用以确定模型的超参数,测试集用以评估模型的预测性能。滑动窗口设置为10,原始电力负荷序列如图4所示。

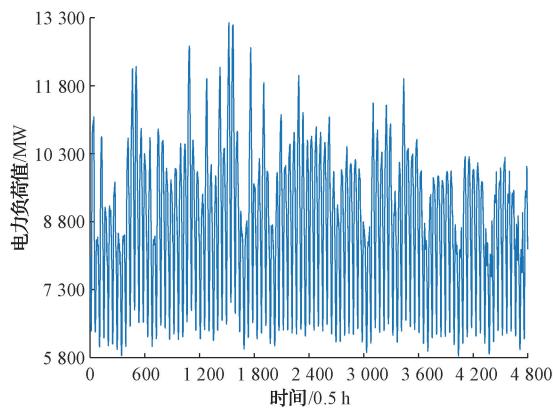


图4 原始电力负荷序列

3.1 负荷序列组合分解

在VMD分解原始负荷序列前,确定合理的预设值K,能有效地避免欠分解或过分解对预测精度的影响。VMD分解后各模态分量的包络熵值如表1所示,其中 δ_i 为各分量包络熵值。可以看出当K=6时获得最小的包络熵值1.939,故将分解数量K设定为6,其余参数均使用默认值。

表1 不同分量个数的包络熵

K	包络熵						
	δ_1	δ_2	δ_3	δ_4	δ_5	δ_6	δ_7
3	2.209	2.288	2.634	—	—	—	—
4	2.207	2.286	2.529	2.395	—	—	—
5	2.207	2.284	2.493	2.310	2.608	—	—
6	2.206	2.287	2.341	3.043	1.939	2.599	—
7	2.164	2.117	2.481	2.673	2.253	2.485	2.718

设置好参数,先通过VMD方法分解原始负荷数据,然后利用TVF-EMD方法对残差序列进行分解,充分考虑到残差序列中蕴含的丰富信息。VMD方法处理后的结果如图5所示,其中子序列7是VMD方法分解后剩余的残差序列。

3.2 结果对比与分析

POA-DELM模型的参数设如下:鹈鹕的种群数量N为20;最大迭代次数为100;DELM激活函数选取sigmoid;隐含层数为3;每层节点数为60。为了充分验证模型的预测性能,对8种模型的预测结果分别进行分析,所有预测模型的评价指标结果如表2所示。

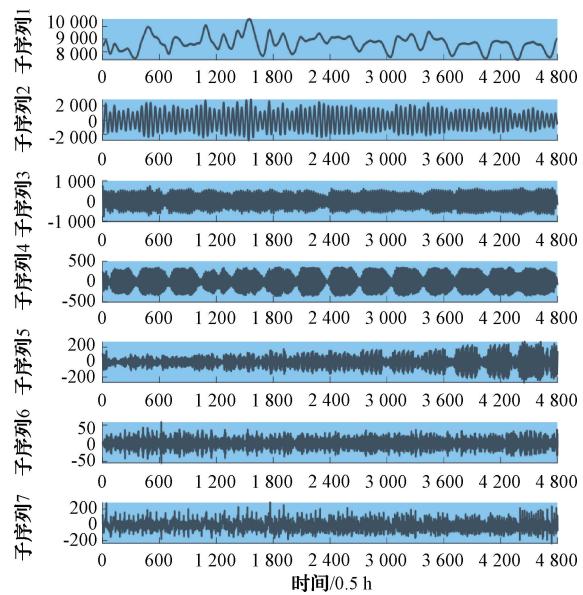


图5 VMD处理后的子序列

表2 不同模型的误差对比

模型	RMSE/MW	MAE/MW	MAPE/%
DELM	185.067 2	138.595 6	1.697 5
PSO-DELM	155.887 2	112.526 6	1.377 8
POA-DELM	135.891 4	95.424 2	1.164 3
EMD-POA-DELM	115.594 5	70.826 7	0.885 4
VMD-POA-DELM	55.921 6	41.394 4	0.502 9
VMĐT-POA-DELM	11.080 1	8.320 8	0.102 0
VMĐT-POA-DELM-EC	9.302 3	7.236 9	0.089 1
VMĐT-POA-DELM-GPR	7.209 1	5.478 3	0.067 8

由表2可以发现,本文所提出的两阶段模型预测性能最佳,3种评价指标RMSE、MAE和MAPE均小于其他的7种预测模型。然后从不同的角度分析模型的预测结果,DELM模型的权重参数经过PSO算法和POA算法寻优后,预测精度得到了有效的提升。相比较DELM模型,PSO-DELM模型和POA-DELM模型的RMSE分别减少了29.18、49.175 8 MW,MAE分别减少了26.069、43.171 4 MW,MAPE分别降低了0.319 7%、0.533 2%。而POA算法参数优化的效果更好,与PSO-DELM模型结果相比,POA-DELM模型的RMSE和MAE分别减少了19.995 8、17.102 4 MW,MAPE降低了0.213 5%。

不同分解方法与POA-DELM模型组合后,预测模型的RMSE、MAE最多分别减少了79.969 8、54.029 8 MW,MAPE也降低了0.661 4%,能有效提高模型的预测效果。与EMD方法相比,VMD方法进行分解后模型的预测结果RMSE、MAE分别减少59.672 9、29.432 3 MW,MAPE降低了0.382 5%。表明VMD方法分解效果好,可以有效提高模型的预测精度。而为了将原始负荷序列分解完整,

对 VMD 方法分解后剩余的残差序列,采用 TVF-EMD 方法再次分解,在 VMD 方法基础上模型整体的预测结果 RMSE、MAE 分别减少了 44.841 5、33.073 6 MW,且 MAPE 也降低了 0.400 9%。可以发现考虑 VMD 方法处理后的残差分量,能明显改善模型的预测性能。

最后考虑误差分量的信息,对 VMDT-POA-DELM 模型的预测结果进行误差修正,其预测结果的 RMSE、MAE 分别减少了 1.777 8、1.083 9 MW,MAPE 降低了 0.012 9%,可提高模型预测的准确性。将进行两阶段前后的模型预测结果进行对比,两阶段预测模型 RMSE、MAE 分别减少了 3.871、2.842 5 MW,MAPE 降低了 0.034 2%。与误差修正的模型对比,该两阶段模型 RMSE、MAE 分别减少了 2.093 2、1.758 6 MW,MAPE 降低了 0.021 3%。表明充分利用误差蕴含的信息,再通过 GPR 方法进行非线性集成的两阶段预测模型,具有更好的预测性能。本文提出的一种 VMDT-POA-DELM-GPR 两阶段预测模型整体的预测精度最高,RMSE 仅为其他模型的 4%~77%,MAE 则为其他模型的 4%~76%,MAPE 能达到 0.067 8%。

将各模型的预测结果进行对比,为了更清晰地表现各预测模型的区别,均为 1 d 的预测结果,不同模型的预测结果如图 6 所示。其中 M1~M8 分别对应表 2 从上到下所有的模型。

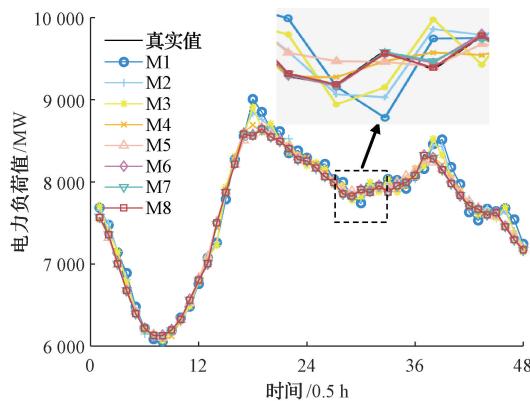


图 6 不同模型 1 d 的预测结果

从图 6 可以看出,与其他 7 种模型相比,本文提出的模型预测值和真实值更加吻合一致,具有最佳的预测精度。

为了进一步验证提出的两阶段模型有效性,绘制该模型与其他 7 种模型的预测误差绝对值分布的箱线图,更加直观地观察两阶段模型的预测性能,各模型的分布结果如图 7 所示。可以发现两阶段模型预测误差绝对值的分布最为集中,这表明两阶段模型预测结果的准确性最高,充分地验证了该模型的有效性。

为了更好地验证模型的优越性,分别利用各模型对工作日和休息日进行预测,全部预测模型的评价指标结果如

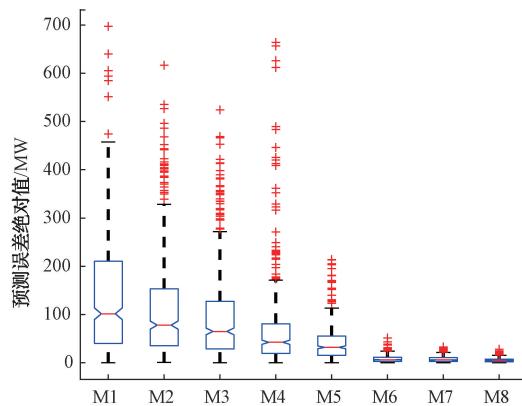


图 7 所有模型预测误差绝对值的箱线图

表 3、4 所示。

表 3 工作日各预测模型的误差对比

模型	RMSE/MW	MAE/MW	MAPE/%
DELM	62.010 4	14.171 4	0.168 2
PSO-DELM	52.961 4	11.472 5	0.136 5
POA-DELM	44.583 5	9.671 0	0.114 3
EMD-POA-DELM	20.618 3	4.921 2	0.058 9
VMD-POA-DELM	18.298 1	4.267 3	0.050 1
VMDT-POA-DELM	2.958 0	0.718 7	0.008 3
VMDT-POA-DELM-EC	2.407 4	0.603 7	0.007 0
VMDT-POA-DELM-GPR	1.934 6	0.478 7	0.005 6

从表 3 可以发现,对于工作日的负荷数据,本文提出的两阶段模型的预测精度提升程度最大,RMSE 从 62.010 4 MW 减少到 1.934 6 MW,MAE 也从 14.171 4 MW 减少到 0.478 7 MW,MAPE 从 0.168 2% 降低至 0.005 6%,RMSE、MAE、MAPE 均为其他模型的 3%~80%,预测性能均得到了显著的提升。

表 4 节假日各预测模型的误差对比

模型	RMSE/MW	MAE/MW	MAPE/%
DELM	56.419 2	12.383 7	0.162 3
PSO-DELM	47.994 1	10.226 0	0.134 0
POA-DELM	42.787 7	9.175 7	0.119 6
EMD-POA-DELM	25.113 9	5.996 4	0.081 2
VMD-POA-DELM	17.624 6	3.832 6	0.050 4
VMDT-POA-DELM	3.586 0	0.847 8	0.011 4
VMDT-POA-DELM-EC	3.083 8	0.742 9	0.010 0
VMDT-POA-DELM-GPR	2.213 3	0.550 0	0.007 4

从表 4 可以看出,节假日中该两阶段模型预测结果的 RMSE 从 56.419 2 MW 减少到 2.213 3 MW,仅为其他模型结果的 4%~72%,MAE 从 12.383 7 MW 减少到

0.55 MW, MAPE 从 0.162 3% 降低至 0.007 4%, 均为其他模型的 4%~74%, 对于节假日两阶段模型的预测精度也是最高的,由此可见该模型具有较强的可适性。

将本文提出的 VMDT-POA-DELM-GPR 模型的预测结果分别与其他模型的预测结果进行横向对比,结果如表 5 所示。

表 5 不同模型的横向对比结果

模型	RMSE /MW	MAE /MW	MAPE /%
EEMD-ACS-LSSVM ^[31]	59.201 3	43.381 6	0.526 5
VMD-SSA-HKELM ^[32]	57.634 5	42.437 9	0.515 2
VMD-LSTM-SVR ^[33]	42.513 1	30.429 6	0.372 5
CEEMD-CNN-BiGRU-RF ^[34]	28.634 2	23.492 0	0.292 5
VMD-CEEMADN-LSTM ^[35]	21.392 9	16.604 1	0.205 3
VMDT-POA-DELM-GPR	7.209 1	5.478 3	0.067 8

从表 5 可以看出,该两阶段模型预测结果的 RMSE 从 59.201 3 MW 减少到 7.209 1 MW, 仅为其他模型结果的 12%~34%, MAE 也从 43.381 6 MW 减少到 5.478 3 MW, MAPE 从 0.526 5% 降低至 0.067 8%, MAE、MAPE 均为其他模型的 13%~33%,由此可见本文提出的模型预测精度明显优于其他模型,具有最佳的预测性能。

4 结 论

针对短期电力负荷序列波动复杂、随机性强和非平稳性等特点,提出了一种基于 VMDT-POA-DELM-GPR 的两阶段短期电力负荷预测方法,通过实例验证及对比分析得出如下结论。

1) 通过 VMD 分解原始负荷序列,可以有效降低其复杂性和非平稳性,计算每个模态分量的包络熵值,以最小包络熵值的方法选取分解数 K , 然后对所有分量建模预测,能有效改善模型预测性能。

2) 在进行 VMD 处理后会存在残差分量,该分量中蕴含了原始负荷数据某些重要信息,而残差分量变化复杂,利用 TVF-EMD 方法进行分解,将残差分量考虑其中,模型整体的预测准确性会更高。

3) DELM 将深度学习和 ELM 结合,具有很强的非线性拟合能力,可以有效地应用于处理复杂的负荷数据,实现较好的预测结果。采用 POA 算法对 DELM 参数优化,能进一步提高模型的预测精度。

4) 在第 2 阶段对误差分量进行建模预测,再将所有分量的预测结果输入到 GPR 中,进行非线性集成。在实例仿真分析中,本文提出两阶段方法具有最好的预测性能,预测结果的精度也是最高的。

本文提出的模型不仅可以有效用于短期电力负荷预测,也适用于与本文数据集相类似的场景。虽然本文所提

方法展现出了较好的预测性能,但仍有进一步提升的空间。该模型没有考虑天气变化、季节性变化等气象因素,未来的工作可以在该方法基础上,从模型输入特征入手,考虑气象和日期等影响因素,并采用其他算法优化网络的权重参数,进一步提高短期电力负荷预测的精度。

参 考 文 献

- [1] 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.
- [2] HAN J, YAN L, LI Z. A task-based day-ahead load forecasting model for stochastic economic dispatch[J]. IEEE Transactions on Power Systems, 2021, 36(6): 5294-5304.
- [3] NURY H A, HASAN K, ALAM B J M. Comparative study of wavelet-ARIMA and wavelet-ANN models for temperature time series data in northeastern Bangladesh[J]. Journal of King Saud University-Science, 2017, 29(1): 47-61.
- [4] 刘士进, 孙立华, 郭鹏. 基于 EEDM-Arima 算法的某地区电力系统负荷预测及算例分析[J]. 电子测量技术, 2020, 43(7): 185-188.
- [5] 赵峰, 孙波, 张承慧. 基于多变量相空间重构和卡尔曼滤波的冷热电联供系统负荷预测方法[J]. 中国电机工程学报, 2016, 36(2): 399-406.
- [6] 赵倩, 郑贵林. 基于 WD-LSSVM-LSTM 模型的短期电力负荷预测[J]. 电测仪表, 2023, 60(1): 23-28.
- [7] QIU X H, REN Y, SUGANTHAN P N, et al. Empirical mode decomposition based ensemble deep learning for load demand time series forecasting[J]. Applied Soft Computing, 2017, 54: 246-255.
- [8] DRAGOMIRETSKIY K, ZOSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [9] LI B, ZHANG J, HE Y, et al. Short-term load-forecasting method based on wavelet decomposition with second-order gray neural network model combined with ADF test[J]. IEEE Access, 2017(5): 16324-16331.
- [10] 邓带雨, 李坚, 张真源, 等. 基于 EEMD-GRU-MLR 的短期电力负荷预测[J]. 电网技术, 2020, 44(2): 593-602.
- [11] 邢燕好, 于昊, 张佳, 等. 基于粒子群参数优化的 O-VMD 数据处理方法研究[J]. 仪器仪表学报, 2023, 44(4): 304-313.
- [12] 肖白, 赵晓宁, 姜卓, 等. 利用模糊信息粒化与支持向量机的空间负荷预测方法[J]. 电网技术, 2021, 45(1): 251-260.
- [13] APRILLI H, YANG H T, CHAO M H. Statistical

- load forecasting using optimal quantile regression random forest and risk assessment index[J]. IEEE Transactions on Smart Grid, 2021, 12(2): 1467-1480.
- [14] 谷云东, 马冬芬, 程红超. 基于相似数据选取和改进梯度提升决策树的电力负荷预测[J]. 电力系统及其自动化学报, 2019, 31(5): 64-69.
- [15] HUANG Y, GAO Y, GAN Y. A new financial data forecasting model using genetic algorithm and long short-term memory network [J]. Neurocomputing, 2021(425): 207-218.
- [16] HAO Z, LIU G, ZHANG H. Correlation filter-based visual tracking via adaptive weighted CNN features fusion [J]. IET Image Processing, 2018, 12 (8): 1423-1431.
- [17] SHI H, XU M H, LI R. Deep learning for household load forecasting-a novel pooling deep RNN[J]. IEEE Transactions on Smart Grid, 2018, 9(5): 5271-5280.
- [18] 王贺, 陈蔚峰, 熊敏, 等. 融合 CEEMDAN 和 ICS-LSTM 的短期风速预测建模[J]. 电子测量与仪器学报, 2022, 36(4): 17-23.
- [19] TAN M, YUAN S, LI S, et al. Ultra-short-term industrial power demand forecasting using LSTM based hybrid ensemble learning [J]. IEEE Transactions on Power Systems, 2020, 35(4): 2937-2948.
- [20] 杨龙, 吴红斌, 丁明, 等. 新能源电网中考虑特征选择的 Bi-LSTM 网络短期负荷预测[J]. 电力系统自动化, 2021, 45(3): 166-173.
- [21] 曾亮, 雷舒敏, 王珊珊, 等. 基于 OVMD-SSA-DELM-GM 模型的超短期风电功率预测方法[J]. 电网技术, 2021, 45(12): 4701-4712.
- [22] 朱锡山, 罗贞, 易灿灿, 等. 基于 POA-CNN-REGST 的电梯钢丝绳滑移量预测方法[J]. 机电工程, 2023, 40(6): 928-935.
- [23] 王秀杰, 张帅, 田福昌, 等. 基于 TVF-EMD-PSO-GRU 的月径流模型与应用研究[J]. 天津大学学报(自然科学与工程技术版), 2022, 55(8): 802-810.
- [24] 马偲征, 王聰, 王小荣, 等. 基于混合深度学习模型的风速区间预测研究[J]. 太阳能学报, 2023, 44(3): 139-146.
- [25] 李文武, 石强, 李丹, 等. 基于 VMD 和 PSO-SVR 的短期电力负荷多阶段优化预测[J]. 中国电力, 2022, 55(8): 171-177.
- [26] 李可, 李欣欣, 宿磊, 等. 基于 DTCWT 与 GA 改进稀疏分解的轴承故障诊断[J]. 华中科技大学学报(自然科学版), 2021, 49(6): 56-61.
- [27] LI H, LI Z, MO W. A time varying filter approach for empirical mode decomposition [J]. Signal Processing, 2017, 138: 146-158.
- [28] TROJOVSKY P, DEHGHANI M. Pelican optimization algorithm: A novel nature-inspired algorithm for engineering applications[J]. Sensors, 2022, 22(3): 855.
- [29] 唐晓, 陈芳, 许强, 等. 改进鲸鱼算法优化的多维度深度极限学习机短期负荷预测[J]. 山东电力技术, 2023, 50(1): 1-7.
- [30] 贺全玲, 魏秀业, 赵峰, 等. 基于 IEWT-DELM 的行星齿轮箱故障诊断[J]. 电子测量技术, 2023, 46(3): 190-196.
- [31] 姜贵敏, 陈志军, 李笑竹, 等. 基于 EEMD-ACS-LSSVM 的短期风电功率预测[J]. 太阳能学报, 2020, 41(5): 77-84.
- [32] 郭建帅, 崔双喜, 郭建斌, 等. 基于 VMD-SSA-HKELM 的超短期负荷预测[J]. 国外电子测量技术, 2022, 41(6): 105-111.
- [33] 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.
- [34] 曾亮, 狄飞超, 兰欣, 等. 基于 CEEMD-CNN-BiGRU-RF 模型的短期风电功率预测[J]. 可再生能源, 2022, 40(2): 190-195.
- [35] 向玲, 刘佳宁, 苏浩, 等. 基于 CEEMDAN 二次分解和 LSTM 的风速多步预测研究[J]. 太阳能学报, 2022, 43(8): 334-339.

作者简介

王强, 硕士, 副教授, 主要研究方向为电力系统电力电子装置、配电网电能质量、新能源发电及并网技术等。

E-mail:306371334@qq.com

刘宏伟(通信作者), 硕士研究生, 主要研究方向为电力系统保护与控制、短期电力负荷预测等。

E-mail:332756900@qq.com

聂子凡, 硕士研究生, 主要研究方向为电力系统及自动化。

E-mail:1064970166@qq.com