

DOI: 10.19783/j.cnki.pspc.240574

## 基于VMD和辅助任务学习的短期负荷预测方法

张恒<sup>1</sup>, 郑建勇<sup>1</sup>, 梅飞<sup>2</sup>, 徐睿麟<sup>3</sup>

(1. 东南大学电气工程学院, 江苏 南京 210096; 2. 河海大学电气与动力工程学院, 江苏 南京 211100;  
3. 东南大学苏州研究院, 江苏 苏州 215123)

**摘要:** 日高峰时段负荷的强波动性和随机性极大地影响了传统方法在进行负荷预测时的准确性, 提出一种基于变分模态分解(variational mode decomposition, VMD)与辅助任务学习的短期负荷预测方法。首先, 利用斯皮尔曼等级系数法确定与原始负荷具有强相关性的气象特征。然后, 采用变分模态分解算法逐次分离出原始负荷序列中的低频趋势和高频波动。接着, 将其与相关气象结合作为辅助任务训练数据输入 CNN-BiGRU 混合预测模型, 并通过共享特征及跨任务注意力机制降低负荷强波动性对负荷预测的影响, 实现对原始负荷的准确预测。最后, 以我国南方某地区近3年内社会负荷数据为例进行仿真验证。结果表明, 所提方法有效降低了日高峰时段负荷的强波动性和随机性对预测模型的影响, 提升了负荷预测的准确度。

**关键词:** 短期负荷预测; 变分模态分解; 辅助任务学习; 卷积神经网络; 双向门控循环单元

### Short-term load forecasting method based on VMD and auxiliary task learning

ZHANG Heng<sup>1</sup>, ZHENG Jianyong<sup>1</sup>, MEI Fei<sup>2</sup>, XU Ruilin<sup>3</sup>

(1. School of Electrical Engineering, Southeast University, Nanjing 210096, China; 2. College of Electrical and Power Engineering, Hohai University, Nanjing 211100, China; 3. Suzhou Research Institute of Southeast University, Suzhou 215123, China)

**Abstract:** The strong volatility and randomness of load during peak hours significantly affect the accuracy of traditional methods in load forecasting. To address the issue, this paper proposes a short-term load forecasting method based on variational mode decomposition (VMD) and auxiliary task learning. First, using the Spearman rank correlation coefficient method, meteorological features that have a strong correlation with the original load are determined. Subsequently, the VMD algorithm is used to successively separate the low-frequency trends and high-frequency fluctuations in the original load sequence. They are then combined with relevant meteorological data to be used as auxiliary task training data input into the CNN-BiGRU hybrid prediction model. By sharing features and employing a cross-task attention mechanism, the impact of strong load fluctuations on load prediction is reduced, ultimately achieving accurate predictions of the original load. Finally, simulation verification is conducted using load data from a specific region in southern China over the past three years. Results demonstrate that the proposed method effectively reduces the influence of strong volatility and randomness of load during peak hours on the forecasting model, thereby enhancing the accuracy of load forecasting.

This work is supported by the International Science and Technology Collaboration Project of Jiangsu Province (No. BZ2021012).

**Key words:** short-term load forecasting; VMD; auxiliary task learning; CNN; BiGRU

## 0 引言

负荷预测作为确保电网安全和经济运行的基础, 在现代电力系统中扮演着至关重要的角色<sup>[1]</sup>。随着用户侧分布式电源的快速发展和新能源的高比例并网, 电力负荷在高峰时段表现出的波动性和随

机性显著增强, 对短期负荷预测的准确度提出了更高的要求。

近年来, 机器学习和深度学习技术的迅猛发展为国内外学者开展短期负荷预测提供了多种解决方案, 长短期记忆(long short-term memory, LSTM)网络、门控循环单元(gated recurrent unit, GRU)、卷积神经网络(convolutional neural network, CNN)等被广泛应用于负荷预测并取得了良好效果<sup>[2-5]</sup>。在模型

基金项目: 江苏省国际科技合作项目资助(BZ2021012)

的应用与优化方面, 文献[6]提出一种基于 Prophet 和双重多头自注意力-时间卷积网络的超短期负荷预测框架, 从特征构建和模型优化两个角度出发实现预测模型准确度的提升。文献[7]针对负荷峰谷预测误差大的问题, 提出一种基于栅格法提取负荷曲线特征的卷积神经网络和 LSTM 网络混合预测模型, 通过栅格法对负荷曲线划分若干区间实现负荷峰谷值的定位, 利用 CNN-LSTM 模型挖掘负荷特征并进行负荷的短期预测, 有效提升了模型对于负荷峰谷差的预测精度。文献[8]提出一种基于改进 Bagging 算法与模糊最小窥视孔长短期记忆融合的短期负荷预测模型, 有效提升了模型的预测精度。

针对负荷波动性增大的问题, 研究者采用多种分解方法对负荷进行处理以减少负荷波动为预测带来的挑战<sup>[9-11]</sup>。文献[12]针对新型电力系统负荷“双高峰”特性愈发明显的问题, 通过引入非线性调频模态分解处理非线性非平稳数据, 并基于此构建 TCN-TPA-LSTM 组合预测模型实现电力负荷数据的预测。文献[13]为提高短期负荷预测精度, 采用变分模态分解(variational mode decomposition, VMD) 技术将原始历史负荷序列分解为一系列特征互异的模态函数, 对每个模态函数进行特征分析并分别建立负荷预测模型。文献[14]采用麻雀算法对 VMD 进行优化以确定其最佳的模态参量, 其次建立 mRMR-LSTM 模型对模态分量进行预测并对预测结果叠加得到最终的预测值。文献[15]利用经验模式分解自动地将目标负荷分解为若干个独立的内在模式, 避免了 VMD 需要提前设定参量的问题, 再利用多个指标从不同方面分析其规律性。

上述方法虽然取得了不错的预测效果, 但仍存在一些局限性。首先, 直接针对原始负荷分解所得分量进行预测, 使得模型难以有效利用与原始负荷具有强相关性的气象等重要信息, 预测准确度有待进一步提高。其次, 通过分解原始负荷并对各分量分别预测再求和的方法, 可以降低原始负荷强波动性为预测带来的挑战, 但随着分解分量的增加, 预测模型的计算负担亦随之增加, 在实际应用中计算资源将面临巨大挑战。因此, 需要构建更加全面、可行的预测方法, 以提高模型对于波动性较强电力负荷的预测准确度。

## 1 数据处理

### 1.1 变分模态分解

变分模态分解是基于经验模态分解提出的一种信号处理技术, 旨在从复杂信号中提取有用的模态

成分<sup>[16-17]</sup>, VMD 及其改进算法已被广泛应用于负荷数据处理, 本文采用 VMD 对原始负荷进行趋势提取。该算法通过解决一个约束优化问题, 以实现最小化各模态分量带宽的总和, 同时约束这些分量能够重构回原始信号, VMD 函数可表达为

$$\begin{cases} \min_{\{u_k\}} \{S(t)\} \\ S(t) = \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{2\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 \end{cases} \quad (1)$$

式中:  $S(t)$  为各模态分量带宽的总和;  $u_k(t)$  为第  $k$  个模态分量;  $\omega_k$  为对应的中心频率;  $K$  为模态的数量; “\*”表示卷积;  $\partial_t$  为关于时间的一阶导数;  $\delta(t)$  为狄拉克  $\delta$  函数。该算法通过拉格朗日乘数法来实现分解的模态分量重构后尽可能接近原始信号的同时最小化模态分量的带宽, 引入拉格朗日乘数  $\lambda(t)$  来处理约束条件, 形成拉格朗日函数。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|^2 + \alpha S(t) \quad (2)$$

式中:  $f(t)$  为原始负荷信号;  $\alpha$  为一个正则化参数, 用于控制模态分量带宽和重构误差之间的平衡。通过迭代更新模态分量  $u_k(t)$ 、对应的中心频率  $\omega_k$  以及拉格朗日乘数  $\lambda(t)$ , VMD 算法逐步逼近并最终求得最优解。

### 1.2 斯皮尔曼等级系数法

为了筛选出负荷的强相关气象特征、提高模型预测精度, 使用斯皮尔曼等级相关系数计算负荷数据与气象特征之间的相关性。相较于皮尔逊系数法、肯德尔等级相关系数法等其他方法, 斯皮尔曼等级系数法不要求数据服从正态分布, 且对异常值具有较强的鲁棒性。此外, 该方法专注于筛选出与负荷强相关的线性或非线性单调关系<sup>[18]</sup>, 在本文构建模型进行预测时能更好地挖掘气象特征与电力负荷之间的关系, 斯皮尔曼等级相关系数  $\rho$  的计算公式为

$$\rho = 1 - \frac{6 \sum d_i^2}{m(m^2 - 1)} \quad (3)$$

式中:  $d_i$  为第  $i$  个观测值在两个变量中的等级差;  $m$  为数据集中的观测值数量。

## 2 模型构建

### 2.1 卷积神经网络

卷积神经网络因其独特的权值共享和局部连接结构在挖掘数据特征方面表现出良好性能<sup>[19-21]</sup>。CNN 的结构通常包括输入层、卷积层、池化层、全连接层和输出层。卷积层负责对输入数据进行特征

提取；池化层减小卷积层的输出数据维度，同时保留重要信息；全连接层将前面层级的输出特征综合起来，进行最终的特征构建，CNN 结构如图 1 所示。

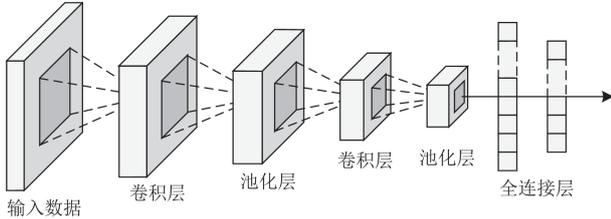


图 1 CNN 结构  
Fig. 1 CNN structure

本文采用相同结构的 CNN 作为输入层对多任务输入进行特征提取，并通过构建共享全连接层实现目标任务与辅助任务之间的特征信息共享。

### 2.2 双向门控循环单元

双向门控循环单元(bidirectional gated recurrent unit, BiGRU)通过更新门和重置门来调节信息的流动，解决了标准循环神经网络在处理长序列数据时遇到的梯度消失或梯度爆炸问题，并通过一个正向 GRU 层和一个反向 GRU 层增强了模型双向处理时间序列的能力，使其能够同时处理数据的过去和未来信息<sup>[22]</sup>。因此本文采用该网络完成模型的主要预测任务，其结构如图 2 所示。

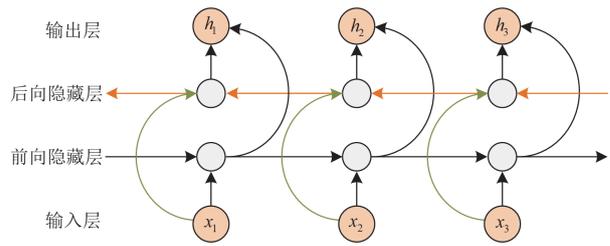


图 2 BiGRU 网络结构  
Fig. 2 BiGRU network structure

对于每个时间步，BiGRU 的隐藏状态在 GRU 的基础上更新为正向和反向两部分 GRU 的隐藏状态，可以更好地实现短期负荷预测任务。

### 2.3 辅助任务学习

辅助任务学习(auxiliary task learning, ATL)为多任务学习(multi-task learning, MTL)框架下的一种形式<sup>[23]</sup>，旨在通过设定与目标任务相关且更易于学习的任务提高目标任务的学习能力。

由于待预测地区日负荷高峰时段的波动性较强，采用直接对原始负荷建模预测的方式会使得模型在学习过程中难以捕捉相关气象特征对于负荷波动的影响，因此本文考虑将原始负荷提取出低频趋势和低频波动并分别建立预测任务，将其作为辅助任务以增强目标任务对于特征的学习能力。

本文设计的辅助任务网络结构如图 3 所示。

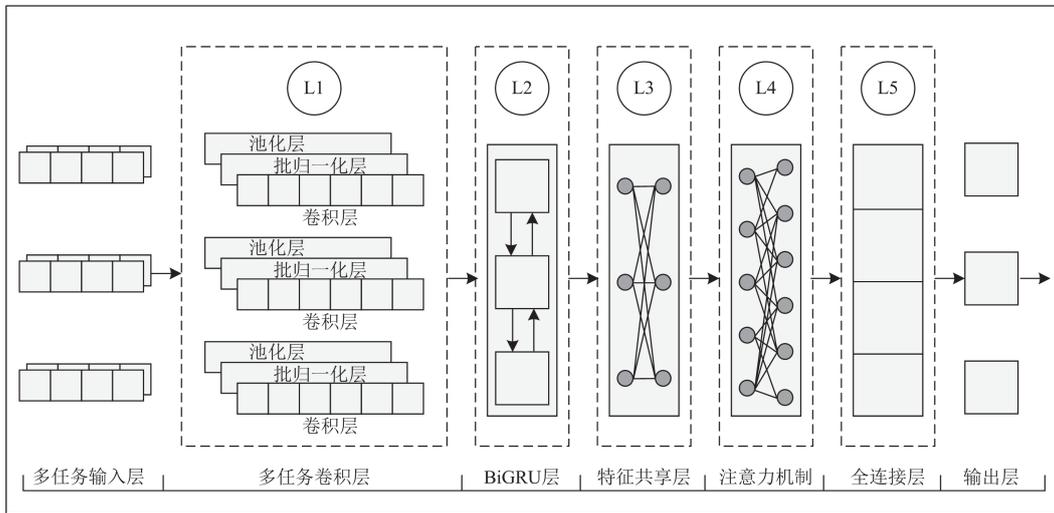


图 3 CNN-BiGRU 辅助任务网络结构

Fig. 3 CNN-BiGRU auxiliary task network structure

1) 目标任务设置为对原始负荷的预测任务，辅助任务为对原始负荷所提取趋势的预测任务，二者采用相同的输入特征与相同结构的 CNN 特征提取网络层。

2) 目标任务与辅助任务的特征通过全连接层进

行共享，实现多任务之间共享学习到的特征表示。

3) 通过在目标任务特征表示与辅助任务特征表示之间加入注意力模块，实现借助辅助任务动态调整目标任务的特征权重。简单注意力机制计算公式为

$$y = (\sigma(Wx + b)) \odot z \quad (4)$$

式中:  $\mathbf{x}$  为各任务输出的特征向量;  $\mathbf{W}$  为权重矩阵;  $\mathbf{b}$  为偏置向量;  $\sigma$  为 Sigmoid 激活函数;  $\mathbf{z}$  为各任务的输入特征; “ $\odot$ ” 表示逐元素相乘。

## 2.4 基于 VMD 和辅助任务学习的短期负荷预测方法实现流程

本文建立基于 VMD 和辅助任务学习的 ATL-CNN-BiGRU 预测模型实现对波动性较大负荷的预测。首先, 利用斯皮尔曼等级系数法确定与负荷强相关的气象特征, 通过 VMD 实现原始负荷低频趋势和高频波动提取, 并利用构建辅助任务实现对两者影响特征的分别学习, 进而增强目标任务对特征影响规律的学习能力, 同时目标任务保留原始序列中的细节信息进行学习, 最终实现负荷序列的准确预测。本文所提预测方法实现流程如图 4 所示。

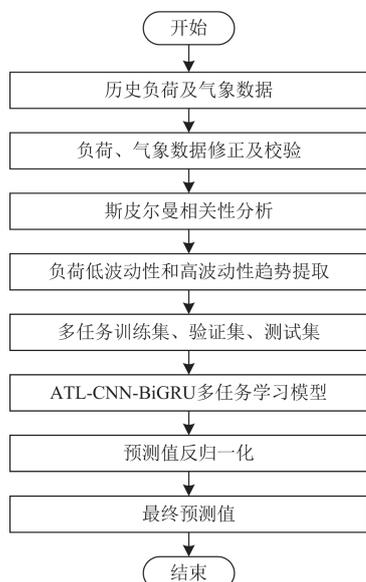


图 4 所提负荷预测方法实现流程图

Fig. 4 Implementation flow chart of the proposed load forecasting

## 3 算例分析

### 3.1 数据描述

本文算例使用了我国某南方地区近 3 年内某夏季的全社会负荷及气象数据, 气象数据采用欧洲中期天气预报中心采集的气象数据, 数据的采样频率均为 15 min 一次, 气象数据包含辐照度、总云量、高云量、中云量、低云量、2 m 温度、2 m 湿度等。负荷数据及气象数据采用的时间范围为同一年 6 月 1 日至 8 月 23 日。

### 3.2 辅助任务训练集构建

通过斯皮尔曼等级系数法分析原始负荷与气象特征的相关性, 得到相关性热图如图 5 所示。

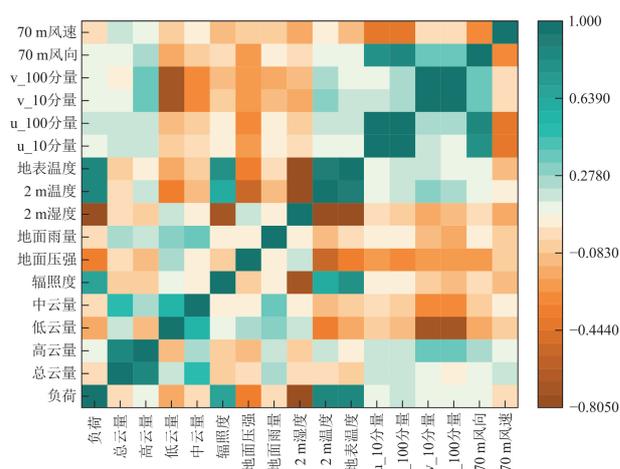


图 5 负荷与气象相关性热图

Fig. 5 Load and meteorological correlation heatmap

由图 5 可知, 较相关的气象特征依次为地表温度、2 m 温度、2 m 湿度、辐照度, 斯皮尔曼等级系数分别为 0.849、0.842、-0.77 和 0.648, 表明该 4 个气象与原始负荷具有较强相关性, 其余特征与负荷存在较低的相关性, 故本文利用上述 4 个气象因素进行实验分析。

使用 VMD 对原始负荷序列进行主趋势提取, 并对提取后剩余分量再次进行 VMD 趋势提取, 得到目标任务与两个辅助任务的待预测序列, 设置 VMD 的模态数量和初始化方式等参数进行负荷数据分解, 其中主要趋势的两天采样点曲线如图 6 所示。

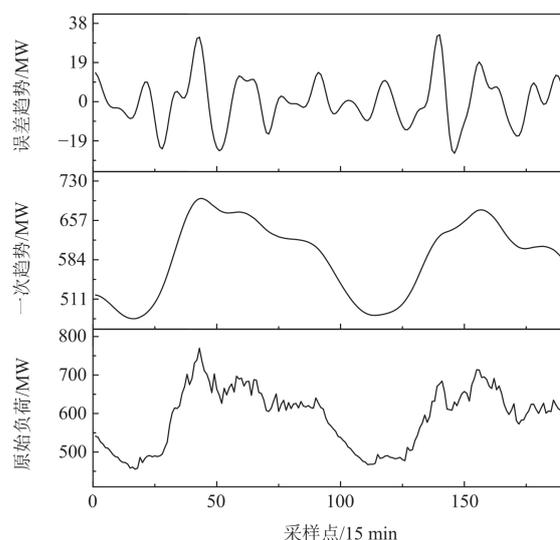


图 6 VMD 趋势图

Fig. 6 VMD trend graph

其中, 原始负荷为目标任务预测目标序列, 一次趋势为第一个辅助任务预测目标序列, 仅包含相

对平稳的低频趋势, 误差趋势以高频波动为主, 为第二个辅助任务预测目标序列。

### 3.3 评价指标

为评价模型预测效果, 本文采用均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE) 和平均绝对百分比误差 (mean absolute percentage error, MAPE) 作为评价指标, 其计算公式分别如式(5)一式(7)。

$$e_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (5)$$

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

$$e_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (7)$$

式中:  $n$  为样本数量;  $y_i$  为实际值;  $\hat{y}_i$  为预测值。

### 3.4 结果分析

为验证本文所提方法的有效性, 训练集取峰值负荷波动性较大的夏季负荷数据, 并取训练集中连续 3 天为测试数据, 利用本文所提模型进行实验, 选取最相关的气象因素及经 VMD 提取的趋势项构建训练集并设置无辅助任务的 CNN-BiGRU 预测模型、BiGRU 预测模型、单辅助任务 (single auxiliary task learning, SATL) 的 SATL-CNN-BiGRU 预测模型、单辅助任务的 SATL-BiGRU 预测模型和双辅助任务 (dual auxiliary task learning, DATL) 的 DATL-CNN-BiGRU 预测模型进行对比试验。

实验中上述模型网络层参数保持一致, 各模型所用网络层参数如下: 卷积层中卷积核数量为 128, 卷积核尺寸为 3; 池化层中池化操作的窗口大小为 1; BiGRU 层中神经元数量为 256; 共享层中神经元数量为 128。在此参数下开展对比试验, 研究本文所提方法与其他方法在进行短期负荷预测时的差异。

#### 1) 气象特征选取对预测结果的影响分析

选择不同数量的最相关气象因素作为输入特征对各预测模型进行实验。当气象特征数量为 1 个时, 上述模型负荷预测的结果和负荷真实值对比如图 7 所示。

由图 7 可知, 本文所提的辅助任务预测模型相较于其他预测模型具有最佳的预测效果, 其中 DATL-CNN-BiGRU 模型相较于 SATL-CNN-BiGRU 模型在负荷剧烈波动时段具有更好的预测效果。上述各模型在不同特征数量选择下的预测误差见表 1。

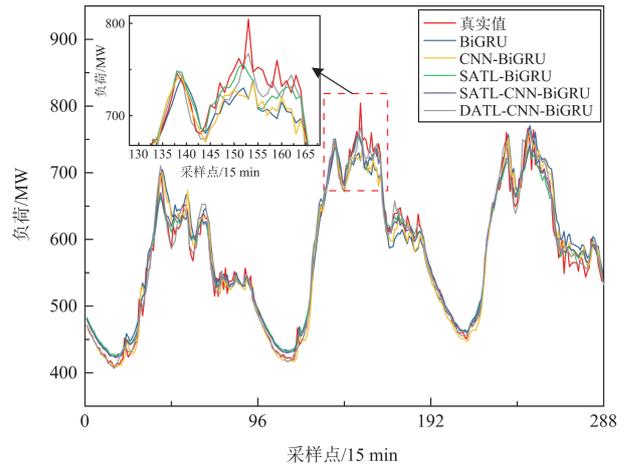


图 7 各模型预测结果

Fig. 7 Predicted results of five models

由表 1 可知, 本文所提 ATL-CNN-BiGRU 预测模型在多种特征选择情况下均具有最佳的误差指标。特别地, 当选择气象特征为 1 时, 本文所提 DATL-CNN-BiGRU 模型相较于传统的 CNN-BiGRU 模型的预测结果, RMSE、MAE、MAPE 分别降低了 7.036 MW、5.23 MW、0.903%, 这表明本文所提方法有效提高了预测模型在负荷波动时段的预测准确性。

#### 2) 不同模态数量设置对预测结果的影响分析

VMD 参数的设置影响着辅助任务中趋势的提取, 分别设置分解模态数量为 2—6, 得到不同模态数量设置下负荷预测误差见表 2。

由表 2 可知, 当 VMD 的分解模态数量  $K$  设置为 2 时模型的表现较好, 相较于  $K$  为 6 时, 本文所提 SATL-CNN-BiGRU 模型的预测结果指标 RMSE、MAE、MAPE 分别降低 4.294 MW、3.693 MW、0.625%; DATL-CNN-BiGRU 模型的预测结果指标 RMSE、MAE、MAPE 分别降低 8.016 MW、5.275 MW、0.819%。故本文所提模型在 VMD 模态数量设置较少时表现更优, 因其低频趋势分量可保留更多原始负荷信息并通过滤除高频波动分量增强模型对于相关特征的学习能力。

#### 3) 不同长度数据集设置对预测结果的影响分析

为探讨在不同长度数据集设置下模型的性能表现, 分别采用时间长度为 7 天、15 天、30 天、60 天及自 6 月开始的历史数据作为训练集对模型进行训练, 并对各模型预测误差和所用时长进行记录, 实验结果见表 3。

表 1 不同特征数量选择下的各模型预测误差

Table 1 Forecasting errors of five models under different feature quantity selections

模型	特征数量	RMSE/MW	MAE/MW	MAPE/%
BiGRU	1	23.256	18.089	3.093
	2	<b>20.535</b>	<b>15.024</b>	<b>2.498</b>
	3	22.127	17.030	2.865
	4	22.164	16.382	2.702
CNN-BiGRU	1	19.681	14.324	2.405
	2	<b>19.208</b>	<b>13.735</b>	<b>2.283</b>
	3	23.788	16.753	2.761
	4	21.264	15.701	2.642
SATL-BiGRU	1	19.426	15.273	2.854
	2	<b>18.329</b>	<b>12.752</b>	<b>2.178</b>
	3	20.020	16.198	2.568
	4	19.579	15.384	2.679
SATL-CNN-BiGRU	1	14.511	11.403	1.983
	2	14.490	11.473	2.003
	3	<b>13.341</b>	<b>9.706</b>	<b>1.619</b>
	4	14.737	11.269	1.949
DATL-CNN-BiGRU	1	<b>12.645</b>	<b>9.094</b>	<b>1.502</b>
	2	13.376	10.435	1.805
	3	13.528	10.263	1.750
	4	13.307	10.123	1.716

表 2 不同模态数量设置下负荷预测误差

Table 2 Load forecasting errors under different modal quantity settings

模型	分解模态数量	RMSE/MW	MAE/MW	MAPE/%
SATL-BiGRU	2	<b>15.593</b>	<b>10.348</b>	<b>2.625</b>
	3	19.248	14.947	3.158
	4	19.548	15.586	3.327
	5	18.154	13.325	2.942
	6	18.325	15.158	3.624
SATL-CNN-BiGRU	2	<b>10.037</b>	<b>7.753</b>	<b>1.362</b>
	3	15.040	11.818	2.059
	4	15.091	11.489	1.939
	5	14.560	10.734	1.797
	6	14.331	11.446	1.987
DATL-CNN-BiGRU	2	<b>4.875</b>	<b>3.827</b>	<b>0.685</b>
	3	9.940	7.584	1.320
	4	13.377	10.450	1.802
	5	11.972	8.844	1.503
	6	12.891	9.102	1.504

表 3 不同长度数据集设置下的负荷预测误差

Table 3 Load forecasting errors under different length dataset settings

模型	数据集长度/天	RMSE/MW	MAE/MW	MAPE/%	时长/s
BiGRU	7	36.337	28.089	4.598	43.008
	15	20.280	14.682	2.458	196.847
	30	16.989	12.364	2.103	200.216
	60	17.165	12.344	2.061	482.492
	81	<b>15.967</b>	<b>11.587</b>	<b>1.937</b>	502.570
CNN-BiGRU	7	34.296	27.512	4.610	42.144
	15	19.938	14.711	2.464	213.629
	30	17.255	12.412	2.089	265.534
	60	16.835	12.194	2.026	567.782
	81	<b>15.439</b>	<b>11.405</b>	<b>1.927</b>	705.016
SATL-BiGRU	7	36.749	28.578	4.692	87.465
	15	10.052	7.889	1.024	413.372
	30	4.673	4.813	1.503	428.251
	60	<b>4.532</b>	<b>4.639</b>	<b>1.377</b>	1014.681
	81	5.291	5.707	1.496	1152.382
SATL-CNN-BiGRU	7	34.581	27.714	4.815	80.633
	15	8.128	5.765	0.925	434.198
	30	3.549	3.615	0.569	530.322
	60	<b>3.454</b>	<b>3.259</b>	<b>0.477</b>	1162.267
	81	4.389	4.826	0.506	1403.264
DATL-CNN-BiGRU	7	35.689	27.721	4.541	122.150
	15	5.226	3.905	0.696	622.359
	30	2.912	2.267	0.389	789.862
	60	<b>2.362</b>	<b>1.891</b>	<b>0.325</b>	1715.909
	81	2.457	1.927	0.339	2109.056

由表 3 可知,从预测结果准确度角度分析,当数据集长度设置为 7 天时,由于训练数据不足,各模型预测结果表现较为相近;当数据集数量充足时,本文所提辅助任务预测模型较传统模型在预测准确度上实现了较大提升,如训练集长度由 7 天增加至 60 天时, DATL-CNN-BiGRU 模型的 RMSE、MAE 和 MAPE 指标分别降低了 33.327 MW、25.830 MW 和 4.216%,当数据集长度达到 60 天时,模型的预测结果已较为准确,但当数据集长度增至 81 天时,由于时间跨度较大的负荷相关性降低,预测准确度明显降低。

从训练时间角度分析,随着训练集数量的增加,模型训练时长随之增加。此外, CNN-BiGRU 与 BiGRU 模型训练时长较为接近,但由于 CNN 层的存在, CNN-BiGRU 模型所需训练时间普遍更长,随着训练集数量的增加,此特征更为凸显;单辅助任务预测模型 SATL-CNN-BiGRU 和 SATL-BiGRU 的训练时长约为传统模型 CNN-BiGRU 和 BiGRU 训练时长的 2 倍;双辅助任务模型 DATL-CNN-BiGRU

的训练时长约为传统 CNN-BiGRU 模型训练时长的 3 倍。

综合考虑预测准确度与训练时长,单辅助任务使用相对应传统模型约 2 倍的训练时长,可实现较大准确度的提升。在时间与计算资源允许的情况下,双辅助任务可在单辅助任务的基础上进一步提升预测的准确度。

#### 4) 负荷预测误差分析

当 VMD 参数  $K$  设置为 2、特征选择数量为 1 时,各模型的预测结果的误差分布箱线如图 8 所示。

由图 8 可知,在负荷剧烈波动时段,传统 BiGRU 模型和 CNN-BiGRU 模型的误差波动剧烈,且存在正负误差异常值交替出现的情况,通过引入辅助任务学习, SATL-BiGRU 模型、SATL-CNN-BiGRU 和 DATL-CNN-BiGRU 模型在负荷剧烈波动时段预测值与真实值的差值波动范围明显缩小,其中 DATL-CNN-BiGRU 模型误差波动范围最小且存在最少的突变异常值,预测结果更加准确。

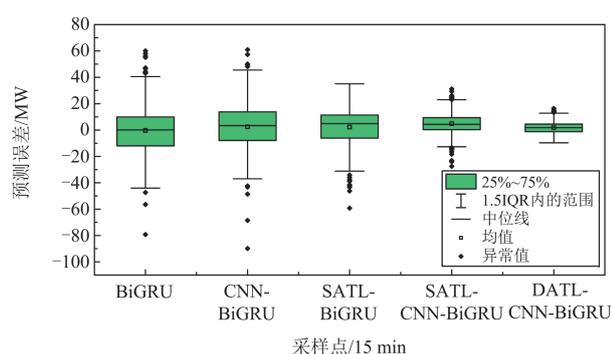


图 8 预测误差分布箱线图

Fig. 8 Boxplot of forecasting error distribution

## 4 结论

本文提出一种基于 VMD 和辅助任务学习的短期负荷预测方法, 有效降低了日高峰时段负荷强波动性对负荷预测准确性的影响, 有效提升了短期负荷预测精度。通过理论分析与算例验证, 得到如下结论。

1) 采用相同结构 CNN 网络层、特征共享层和跨任务注意力机制的 CNN-BiGRU 模型, 可以利用从辅助任务中学习的特征信息增强目标任务对特征的表达能力, 在负荷预测结果上表现出优良性能。

2) 基于 VMD 和辅助任务学习的短期负荷预测方法, 通过分别提取原始负荷中的低频趋势和高频波动并设立辅助预测任务, 能够实现与目标任务的特征信息共享, 进而提升模型对负荷预测的准确度。

3) 实验对比了不同 VMD 模态数量设置与气象选择下 BiGRU 模型、CNN-BiGRU 模型、SATL-BiGRU 模型、SATL-CNN-BiGRU 模型和 DATL-CNN-BiGRU 模型的预测结果, 评价指标及误差分析均验证了引入 VMD 提取负荷趋势作为辅助预测任务对模型预测准确度上的提升。

## 参考文献

- [1] 单葆国, 刘青, 张莉莉, 等. 新形势下“十四五”后三年中国电力需求形势研判[J]. 中国电力, 2023, 56(3): 1-11. SHAN Baoguo, LIU Qing, ZHANG Lili, et al. Analysis of China's power demand situation in the last three years of the "14th Five-Year Plan" under the new situation[J]. Electric Power, 2023, 56(3): 1-11.
- [2] 朱继忠, 苗雨旺, 董朝阳, 等. 基于 Attention-LSTM 与多模型集成的短期负荷预测方法[J]. 电力工程技术, 2023, 42(5): 138-147. ZHU Jizhong, MIAO Yuwang, DONG Chaoyang, et al. Short-term load forecasting method based on Attention-LSTM and multi-model integration[J]. Electric Power Engineering Technology, 2023, 42(5): 138-147.
- [3] ZHANG H, SUN H, KANG L, et al. Prediction of health level of multiform lithium sulfur batteries based on incremental capacity analysis and an improved LSTM[J]. Protection and Control of Modern Power Systems, 2024, 9(2): 21-31.
- [4] 欧阳福莲, 王俊, 周杭霞. 基于改进迁移学习和多尺度 CNN-BiLSTM-Attention 的短期电力负荷预测方法[J]. 电力系统保护与控制, 2023, 51(2): 132-140. OUYANG Fulian, WANG Jun, ZHOU Hangxia. Short-term power load forecasting method based on improved hierarchical transfer learning and multi-scale CNN-BiLSTM-Attention[J]. Power System Protection and Control, 2023, 51(2): 132-140.
- [5] 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): 108-116.
- [6] 周思思, 李勇, 郭钊秀, 等. 考虑时序特征提取与双重注意力融合的 TCN 超短期负荷预测[J]. 电力系统自动化, 2023, 47(18): 193-205. ZHOU Sisi, LI Yong, GUO Yixiu, et al. Ultra-short-term load forecasting based on temporal convolutional network considering temporal feature extraction and dual attention fusion[J]. Automation of Electric Power Systems, 2023, 47(18): 193-205.
- [7] 季玉琦, 严亚帮, 和萍, 等. 基于 K-Medoids 聚类与栅格法提取负荷曲线特征的 CNN-LSTM 短期负荷预测[J]. 电力系统保护与控制, 2023, 51(18): 81-93. JI Yuqi, YAN Yabang, HE Ping, et al. CNN-LSTM short-term load forecasting based on the K-Medoids clustering and grid method to extract load curve features[J]. Power System Protection and Control, 2023, 51(18): 81-93.
- [8] 蔡鑫祥, 撒奥洋, 周生奇, 等. 基于改进 Bagging 算法与模糊 MP-LSTM 融合的短期负荷预测模型[J]. 电气工程学报, 2022, 17(1): 164-170. CAI Xinxiang, HAN Aoyang, ZHOU Shengqi, et al. Short-term load forecasting model based on improved Bagging algorithm and fuzzy MP-LSTM fusion[J]. Journal of Electrical Engineering, 2022, 17(1): 164-170.
- [9] 叶剑华, 曹旌, 杨理, 等. 基于变分模态分解和多模型融合的用户级综合能源系统超短期负荷预测[J]. 电网技术, 2022, 46(7): 2610-2622. YE Jianhua, CAO Jing, YANG Li, et al. Ultra short-term load forecasting of user level integrated energy system based on variational mode decomposition and multi-model fusion[J]. Power System Technology, 2022, 46(7): 2610-2622.

- [10] 张家安, 李凤贤, 王铁成, 等. 一种采用记忆神经网络和曲线形状修正的负荷预测方法[J]. 电力工程技术, 2024, 43(1): 117-126.  
ZHANG Jia'an, LI Fengxian, WANG Tiecheng, et al. A load prediction method using memory neural network and curve shape correction[J]. Electric Power Engineering Technology, 2024, 43(1): 117-126.
- [11] 董新伟, 卜智龙, 陈鸣慧, 等. 基于 VMD-LSTMQR 的滚动母线负荷区间预测[J]. 电力工程技术, 2021, 40(6): 9-17.  
DONG Xinwei, BU Zhilong, CHEN Minghui, et al. Rolling bus load interval prediction based on VMD-LSTMQR[J]. Electric Power Engineering Technology, 2021, 40(6): 9-17.
- [12] 王博宇, 文中, 周翔, 等. 基于变分非线性调频模式分解及 TCN-TPA-LSTM 的短期电力负荷组合预测模型[J/OL]. 现代电力: 1-10[2024-04-09]. <https://doi.org/10.19725/j.cnki.1007-2322.2023.0250>.  
WANG Boyu, WEN Zhong, ZHOU Xiang, et al. Short-term load combination forecasting model based on variational nonlinear FM mode decomposition and TCN-TPA-LSTM[J/OL]. Modern Electric Power: 1-10[2024-04-09]. <https://doi.org/10.19725/j.cnki.1007-2322.2023.0250>.
- [13] 梁智, 孙国强, 李虎成, 等. 基于 VMD 与 PSO 优化深度信念网络的短期负荷预测[J]. 电网技术, 2018, 42(2): 598-606.  
LIANG Zhi, SUN Guoqiang, LI Hucheng, et al. Short-term load forecasting based on VMD and PSO optimized deep belief network[J]. Power System Technology, 2018, 42(2): 598-606.
- [14] 胡威, 张新燕, 李振恩, 等. 基于优化的 VMD-mRMR-LSTM 模型的短期负荷预测[J]. 电力系统保护与控制, 2022, 50(1): 88-97.  
HU Wei, ZHANG Xinyan, LI Zhen'en, et al. Short-term load forecasting based on an optimized VMD-mRMR-LSTM model[J]. Power System Protection and Control, 2022, 50(1): 88-97.
- [15] 牛东晓, 李媛媛, 乞建勋, 等. 基于经验模式分解与因素影响的负荷分析方法[J]. 中国电机工程学报, 2008, 28(16): 96-102.  
NIU Dongxiao, LI Yuanyuan, QI Jianxun, et al. A novel approach for load analysis based on empirical mode decomposition and influencing factors[J]. Proceedings of the CSEE, 2008, 28(16): 96-102.
- [16] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [17] 刘杰, 从兰美, 夏远洋, 等. 基于 DBO-VMD 和 IWOA-BILSTM 神经网络组合模型的短期电力负荷预测[J]. 电力系统保护与控制, 2024, 52(8): 123-133.  
LIU Jie, CONG Lanmei, XIA Yuanyang, et al. Short-term power load prediction based on DBO-VMD and an IWOA-BILSTM neural network combination model[J]. Power System Protection and Control, 2024, 52(8): 123-133.
- [18] SPEARMAN C. The proof and measurement of association between two things[J]. Studies in Individual Differences: The Search for Intelligence, 1961: 45-58.
- [19] 徐岩, 向益锋, 马天祥. 基于 EMD-CNN-LSTM 混合模型的短期电力负荷预测[J]. 华北电力大学学报(自然科学版), 2022, 49(2): 81-89.  
XU Yan, XIANG Yifeng, MA Tianxiang. Short-term power load forecasting method based on EMD-CNN-LSTM hybrid model[J]. Journal of North China Electric Power University (Natural Science Edition), 2022, 49(2): 81-89.
- [20] 吴昀炯, 赵健, 宣羿, 等. 基于多维负荷特性挖掘的电力特殊用户用电行为分析[J]. 电力建设, 2024, 45(3): 116-125.  
WU Yunteng, ZHAO Jian, XUAN Yi, et al. Analysis of power consumption behavior of special users based on multidimensional load characteristic mining[J]. Electric Power Construction, 2024, 45(3): 116-125.
- [21] 曾囿钧, 肖先勇, 徐方维, 等. 基于 CNN-BiGRU-NN 模型的短期负荷预测方法[J]. 中国电力, 2021, 54(9): 17-23.  
ZENG Youjun, XIAO Xianyong, XU Fangwei, et al. A short-term load forecasting method based on CNN-BiGRU-NN model[J]. Electric Power, 2021, 54(9): 17-23.
- [22] 龙小慧, 秦际赞, 张青雷, 等. 基于相似日聚类及模式分解的短期光伏发电功率组合预测研究[J]. 电网技术, 2024, 48(7): 2948-2957.  
LONG Xiaohui, QIN Jiyun, ZHANG Qinglei, et al. Short-term photovoltaic power prediction study based on similar day clustering and modal decomposition[J]. Power System Technology, 2024, 48(7): 2948-2957.
- [23] ZHANG Y, YANG Q. An overview of multi-task learning[J]. National Science Review, 2018, 5(1): 30-43.

收稿日期: 2024-05-10; 修回日期: 2024-08-23

作者简介:

张恒(2001—), 男, 通信作者, 硕士研究生, 研究方向为人工智能在新型电力系统中的应用; E-mail: 220222696@seu.edu.cn

郑建勇(1966—), 男, 博士, 教授, 博士生导师, 研究方向为综合能源系统控制与规划等; E-mail: jy\_zheng@seu.edu.cn

梅飞(1982—), 男, 博士, 讲师, 研究方向为智能电网与分布式电源。E-mail: mario82@163.com

(编辑 石晋美)