Short-Term Power Load Prediction Based on the EMA-BiLSTM Combined Model *

GUO Beiyuan*, YIN Yanhe, LIN Xiongfeng, PENG Shifeng, BAI Yiming, ZHANG Tuo
(Zhongshan Power Supply Bureau, Guangdong Power Grid Co., Ltd., Zhongshan Guangdong 528400, China)

Abstract: Targeting at the problems of strong nonlinearity and uncertainty of power load and low prediction accuracy, an efficient multi-scale attention module is constructed. The short-term prediction method of the combined model is composed of efficient multi-scale attention module and bidirectional long short-term memory neural network. Firstly, the load data are decomposed into holiday, weekly and daily components through the Prophet model, highlighting the multi-scale time series characteristics of the load data. Secondly, the decomposed components are concatenated with date features and meteorological features, and the feature set is passed into the EMA module to extract multi-scale time series features. Finally, multi-scale features are introduced into BiLSTM for short-term time series prediction. The verification is carried out using the power load data of a certain area. The simulation examples show that the combined model proposed can better learn the characteristics of power loads and improve the accuracy of load forecasting.

Key words: power load forecasting; Prophet decomposition; bidirectional long short-term neural network; efficient multi-scale attention module

EEACC: 7220; 8110B **doi**: 10.3969/j.issn.1005-9490.2026.04.031

基于 EMA-BiLSTM 组合模型的电力负荷短期预测 *

郭倍源*, 尹雁和, 林雄锋, 彭石丰, 白一鸣, 张 脱
(广东电网有限责任公司中山供电局, 广东 中山 528400)

摘 要: 针对电力负荷非线性和不确定性强, 预测精度不高的问题, 构建了一种由高效多尺度注意力模块(Efficient Multi-Scale Attention, EMA)和双向长短期记忆(Bidirectional Long Short-Term Memory, BiLSTM)神经网络构成的组合模型短期预测方法。首先, 通过 Prophet 模型将负荷数据分解为节假日、周、日分量, 突出负荷数据的多尺度时序特征; 其次, 将分解好的各分量与日期特征、气象特征进行拼接, 将特征集通入 EMA 模块提取多尺度时序特征; 最后, 将多尺度特征通入 BiLSTM 网络进行短期时序预测。使用某地区电力负荷数据进行验证, 仿真算例表明, 所提组合模型能够更好地学习电力负荷特性, 提升了负荷预测的精度。

关键词: 电力负荷预测; Prophet 分解; 双向长短期神经网络; 高效多尺度注意力模块
中图分类号: TM714; TP183 **文献标识码**: A **文章编号**: 1005-9490(2026)04-0918-06

随着“双碳”目标以及新型电力系统的提出, 用户侧分布式能源的接入比例不断提高, 电力负荷呈现出更强的非线性和不确定性[1-3]。负荷预测作为电力系统规划和调度的重要组成部分, 精确的预测结果能够协助管理者制定可靠的方案并优化能源配置, 进而提升系统的经济性和可靠性[4-5]。

目前, 主流的电力系统负荷预测方法可分为统计学方法、机器学习方法和组合预测方法三类。统计学方法包括季节性自回归积分滑动平均模型(Seasonal Auto Regressive Integrated Moving Average Model, SARIMA)[6]、指数平滑法[7]等, 这类方法结构简单, 预测速度快, 应用于平稳的负荷序列时具有较好的表现。但在处理非线性负荷时效果不佳, 且难以充分考虑多因素对负荷的综合影响。机器学习由于其强大的非线性拟合能力, 被应用在了电力负荷预测领域, 常用的机器学习方法包括长短时记忆网络(Long Short-Term Memory, LSTM)[8]、XGBoost[9]、门控循环单元(Gated Recurrent Unit, GRU)[10]和时间卷积网络(Temporal Convolutional Network, TCN)[11]等。

随着电力负荷的非线性和不确定性不断增强, 单一预测模型往往难以兼顾不同时间尺度下的特征提取。为提升负荷预测的准确性, 许多研究采用组合模型, 针对负荷周期性等特点, 在分解、建模等不同环节选取合适方法。文献[12]以 TCN 模型为基础捕捉负荷数据中的长期依赖关系, 并结合双重多头自注意力挖掘多变量之间的内部关联, 从而有效提升负荷预测

项目来源: 南方电网公司科技项目(GDKJXM20240575)
收稿日期: 2025-06-17 **修改日期**: 2025-09-01

效果。文献[13]提出一种时空卷积注意力机制(Spatio-Temporal Convolutional Attention,STCA)并与双向长短期记忆(Bidirectional Long Short-Term Memory,BiLSTM)神经网络组合,实现对各子序列的预测。在组合模型中,研究者们往往使用集合经验模态分解(Ensemble Empirical Mode Decomposition,EEMD)[14]、变分模态分解(Variational Mode Decomposition,VMD)[15]、完全自适应噪声集合经验模态分解算法(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise,CEEMDAN)[16]等方法对负荷时序数据进行分解,得到多个模态分量,从而实现复杂序列的"简化",突出负荷特征,该类"分解-预测"的方法已成为组合模型中的一个重要分支。文献[17]采用经验小波变换对电力负荷序列进行初步分解,再结合样本熵和奇异谱分析对分解后的序列再分解,减少负荷序列非平稳性的影响,降低模型预测难度。文献[18]使用蜣螂优化(Dung Beetle Optimizer,DBO)算法优化 VMD 参数,增强分解效果。然而,上述自适应分解方法的参数需要依靠经验或者优化算法确定,存在分解效果不理想或者分解效率低的问题,除此之外,上述方法需要考虑输入到预测模型中的最佳模态数。

针对上述研究的不足以及实际应用中可能面临的问题,本文针对电力负荷的时序特征,提出一种基于 EMA-BiLSTM 组合模型的电力负荷短期预测方法。首先使用 Prophet 模型对负荷进行分解,再将分解后的负荷分量、原负荷数据与各影响因素(气象因素、日期因素)输入到高效多尺度注意力模块(Efficient Multi-Scale Attention,EMA)中提取全局时序特征,最后将全局特征输入到 BiLSTM 中进行短期电力负荷预测,实验结果表明与传统算法相比,本文提出的方法有效提高了预测精度,提高了短期电力负荷的预测能力。

1　电力负荷特性及影响因素分析

1.1　电力负荷特性

电力负荷具备明显的随机性、季节性和周期性特征。一方面,负荷曲线在日内表现为早晚高峰与深夜低谷,反映了居民生活和工业生产的规律性;另一方面,在周、月和季节尺度上,负荷会随工作日与周末的差异、气候条件的变化而呈现不同的用电水平。此外,电力负荷还受经济发展水平、社会活动规律以及节假日等特殊事件的显著影响。

1.2　电力负荷影响因素分析

温度、湿度等环境变量会通过影响用户的生产和生活方式,从而间接作用于电力负荷水平。例如,夏季高温会导致空调等制冷设备的大量使用,而冬季低温则会带来电采暖设备的集中开启,使负荷显著增加。为了定量分析气象因素与负荷的相关性,使用斯皮尔曼相关性系数计算负荷数据与气象数据的相关性,根据计算结果选取强相关性气象因素作为模型输入。斯皮尔曼相关性系数计算公式如下所示,计算结果如表 1 所示,根据计算结果,选取温度作为气象影响因素输入后续模型。

$$\rho = 1 - \frac{6\sum_{i=1}^{n} d_i^2}{n(n^2-1)} \tag{1}$$

式中:n 为样本数;d_i 为第 i 个样本在两个变量中的秩次差。

表 1　气象因素与光伏功率间的相关程度

影响因素	温度	湿度
相关系数	0.796	0.080

2　电力负荷预测算法原理

2.1　基于 Prophet 的负荷分解

电力负荷序列呈现明显的周期性特征,日内负荷波动表现为用电高峰与低谷,而工作日与周末之间则存在显著的用电差异。此外,节假日等特殊事件也会对负荷模式产生显著影响。为了有效提取并刻画这些时序特征,本文采用 Prophet 模型,充分利用其在时间序列分解方面的优势。Prophet 是一种基于加性分解思想的时间序列预测模型,能够通过拟合历史时序数据的变化规律,将时间序列分解为趋势、季节性、节假日效应及残差项。具体分解公式如下:

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t$$

式中:$g(t)$ 为长期趋势,刻画了负荷随时间的增长或下降趋势;$s(t)$ 为季节性,描述了日、周、年等周期性波动;$h(t)$ 为节假日效应,能够对节假日或特殊事件进行突变修正;ε_t 为残差,用于解释未建模的随机扰动。

2.2　高效多尺度注意力模块

电力负荷经过 Prophet 分解后,时序特征更加明显,但也增加了后续预测的特征量,为有效处理高维数据,提高预测准确性,本文引入了 EMA 特征提取模块[19]对各特征量进行处理。

EMA 能够同时捕捉数据中的短期与长期时序依赖,其主要由以下几个部分组成:特征分组策略、并行子网络、跨空间学习以及注意力权重的融合输出。各子模块协同作用,实现对不同尺度特征的提取和通道-空间注意力的高效融合,在减少计算复

杂度的同时,还能保留更多信息。

将输入的负荷特征图 $X \in \mathbf{R}^{C\times H\times W}$ 的通道维度 C 划分为 G 个子特征组,其中 C 为负荷特征数量,H 为负荷序列的时间维度,W 为 1。通过特征分组,能够降低模型计算量、避免通道维度上信息丢失。

EMA 采用三个并行路线来提取分组特征图的注意力权重。其中两条平行路线位于 1×1 分支,第三条路线位于 3×3 分支。1×1 分支沿 H 与 W 两个方向分别做一维全局平均池化,拼接后经共享的卷积/线性映射得到通道权重并 Sigmoid 重标定,该分支能够保留精确的位置信息并建立局部跨通道交互。3×3 分支用单个 3×3 卷积捕获更大感受野的上下文,补足 1×1 分支的局限。

对两分支中其中一支做二维全局平均池化得到全局描述,如下式所示:

$$z_e^c=\frac{1}{HW}\sum_{i=1}^{H}\sum_{j=1}^{W}e_{i,j}^c \tag{2}$$

式中:e 表示某分支输出,c 为通道索引。

接着将另一支经线性整形到匹配的维度,并使用矩阵点积构造第一张空间注意图;同理从另一对分支输出再构造第二张空间注意图。两张注意图再聚合并过 Sigmoid,得到最终的空间注意力权重 S:

$$S=\sigma(\mathrm{DotProd}(E_{1\times1},z_{E_{3\times3}})+\mathrm{DotProd}(E_{3\times3},z_{E_{1\times1}})) \tag{3}$$

式中:$E_{1\times1},E_{3\times3}\in\mathbf{R}^{C_g\times H\times W}$ 分别为经过 1×1 卷积分支和 3×3 卷积分支后得到的特征映射;$z_{E_{3\times3}}$ 表示对 $E_{3\times3}$ 做全局平均池化后得到的全局向量;$z_{E_{1\times1}}$ 表示对 $E_{1\times1}$ 做全局平均池化后得到的全局向量;$\mathrm{DotProd}(\cdot,\cdot)$ 表示矩阵点积;$\sigma(\cdot)$ 表示 Sigmoid 激活函数。

最后,通道重标定权重 W_c 与空间注意 S 共同作用于输入,所有特征组拼回即可得 $\hat{X}$:

$$\hat{X}^{(g)}=[1+S^{(g)}]\odot\{\sigma[W_c^{(g)}]\odot X^{(g)}\} \tag{4}$$

式中:$X^{(g)}$ 为输入的第 g 个组特征图;$W_c^{(g)}$ 为第 g 组的通道权重;$S^{(g)}$ 为第 g 组的空间注意力权重。$\hat{X}^{(g)}$ 为第 g 组增强特征。

EMA 作为特征提取模块,能够自动学习并提取出具有时序依赖关系的特征,从而为后续预测模型提供更加精细的输入特征。

2.3 双向长短期记忆神经网络

电力负荷具备非线性和不确定性等特点,同时呈现出明显的时序依赖性。为了更全面地刻画其动态变化规律并提升预测精度,本文选用 BiLSTM 作为时序拟合模型。

BiLSTM 由一个前向 LSTM 和后向 LSTM 组成,能够在每个时刻同时利用历史与未来信息,减少对单一时间方向的依赖,从而更全面地建模时序特征。其输出由前向与后向 LSTM 的隐状态拼接而成,公式如下:

$$h_t^{\mathrm{Bi}}=[h_t^{\mathrm{forward}};h_t^{\mathrm{backward}}] \tag{5}$$

式中:h_t^{Bi} 表示 t 时刻 BiLSTM 的输出;h_t^{forward} 表示前向 LSTM 在时刻 t 的隐状态;h_t^{backward} 表示后向 LSTM 在时刻 t 的隐状态。

BiLSTM 的预测过程见图 1。

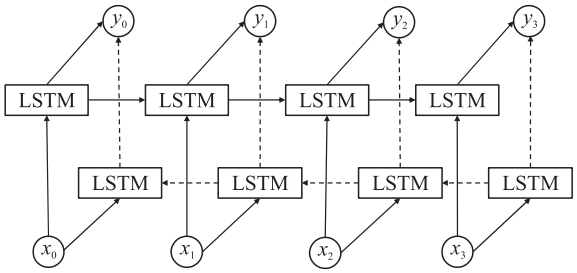

图 1 BiLSTM 神经网络

3 负荷预测框架

本文构建的电力负荷组合预测模型如图 2 所示。具体流程为:

①数据预处理:首先对原始电力负荷序列进行异常值识别,并采用插值方法对异常数据进行修正。随后,对历史负荷数据与气象数据进行时间戳和分辨率的统一处理,以确保不同数据源之间的时序对齐。

②基于 Prophet 的电力负荷序列分解:使用 Prophet 模型对原负荷数据进行分解,得到节假日、周和日分解量。

③特征拼接:在输入特征构建阶段,充分考虑日

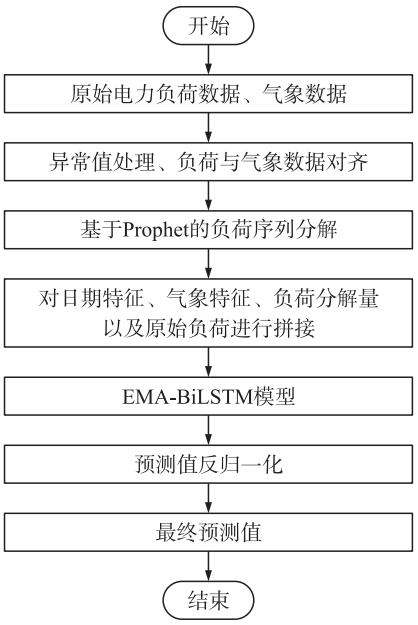

图 2 本文电力负荷组合预测模型流程图

期因素与气象因素对电力负荷的影响。日期因素中选取周日信息和节假日信息作为输入特征。其中，周日特征选用正余弦函数进行周期性编码：$T_{\mathrm{week},i}=\sin\left(2\pi\cdot\frac{\mathrm{week}_i}{7}\right)$，以此刻画一周内不同日期之间的循环关系。节假日特征选择二值变量进行标记，节假日标记为 1，非节假日标记为 0。气象因素中选取温度作为输入特征。最终，将温度数据、负荷的节假日、周、日分解量以及原始电力负荷序列进行归一化处理，拼接归一化后的各项数据以及日期特征。

④模型训练与测试：将拼接好的数据通入到 EMA-BiLSTM 模型中。EMA 模块在多尺度空间上高效提取时序特征，突出关键负荷模式并抑制冗余信息。BiLSTM 模块则在时间维度上同时捕获历史信息与未来趋势。训练过程中，采用划分的训练集对模型参数进行迭代优化，并利用验证集进行超参数调节与防止过拟合。最终，在测试集上对预测结果进行评估，以验证模型在实际负荷预测任务中的适用性。

4　仿真设置

4.1　仿真硬件平台

本文实验使用 Python 在 Intel Core i7-13700KF 3.40 GHz，内存 32 GB 的主机上实现。主机配备 Nvidia GeFore RTX 4060 Ti 显卡，在负荷功率预测的训练与测试过程中使用 GPU 加速计算。本文架构所包含的具体结构及其参数设置见表 2。

表 2　本文预测框架结构与参数设置

序号	结构	参数设定	序号	结构	参数设定
1	分组数	7	4	BiLSTM	40
2	通道基宽	7	5	随机丢弃层	0.1
3	激活函数	ReLU	6	全连接层	[80,24]

4.2　评价指标

为对比分析，实验选取方均根误差（Root Mean Square Error，RMSE）、平均误差（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。各指标的计算过程为：

$$y_{\mathrm{rmse}}=\sqrt{\frac{\sum_{i=1}^{n}(y_{\mathrm{act},i}-y_{\mathrm{pred},i})^2}{n}} \tag{6}$$

$$y_{\mathrm{mae}}=\frac{\sum_{i=1}^{n}|y_{\mathrm{act},i}-y_{\mathrm{pred},i}|}{n} \tag{7}$$

$$y_{\mathrm{mape}}=\frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_{\mathrm{act},i}-y_{\mathrm{pred},i}}{y_{\mathrm{act},i}}\right|\times 100\% \tag{8}$$

式中：n 为预测样本数，$y_{\mathrm{act},i}$ 和 $y_{\mathrm{pred},i}$ 分别为 i 时刻的实际值和预测值。

4.3　数据集划分

本文采用我国南方某地区 110 kV 变电站高压侧 2024 年 1 月 1 日至 2025 年 7 月 31 日的有功数据集和该地区的天气信息进行实验。采样间隔为 1 h。选取其中 2024 年 1 月 1 日至 2025 年 2 月 27 日的数据作为训练集和验证集，2025 年 2 月 28 日至 2025 年 7 月 31 日的数据作为测试集，对本文方法进行验证。考虑到实际工程应用需求，本文利用滑动窗口输入数据，选取预测时刻前 30 h 的历史数据、气象数据以及预测时刻的日期特征用于预测未来 24 h 的负荷。

5　电力负荷短期预测仿真结果分析

5.1　电力负荷数据分解

本次仿真首先对原始电力负荷序列进行 Prophet 分解，分解结果如图 3 所示。图 3（a）为原始负荷，从图中可以看出，在 6 月至 9 月期间，负荷

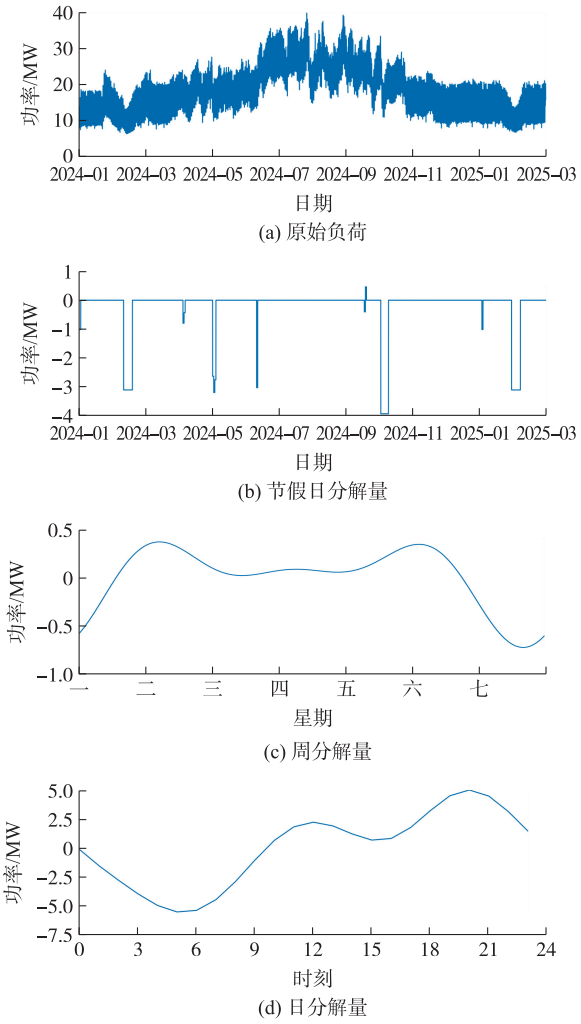

(a) 原始负荷

(b) 节假日分解量

(c) 周分解量

(d) 日分解量

图 3　Prophet 分解结果

呈现波动上升的趋势,主要原因在于夏季高温导致空调等制冷设备的使用显著增加。而在 2024 年 2 月和 2025 年 1 月等时段,负荷曲线出现明显的下凹现象,这与春节假期期间居民和工业用电量减少密切相关。图 3(b)为节假日分解量,能够有效反映出节假日对整体负荷水平的影响。图 3(c)为周分解量,体现了周内用电规律,工作日与休息日之间存在差异,休息日期间负荷水平下降。图 3(d)为日分解量,反映日用电特征,在 12:00 和 20:00 时刻左右达到一天中的用电高峰。

通过 Prophet 分解,可以清晰地揭示负荷在节假日效应、周周期与日周期等不同时间尺度上的变化规律,使后续预测模型能更好地捕捉负荷的时序特性。

5.2 预测结果及分析

为验证所提模型的有效性,将所提模型与 EMA-BiLSTM、CNN-BiLSTM、CNN-GRU、BiLSTM、GRU 预测模型进行对比。实验结果具体如表 3 所示,各模型预测结果曲线如图 4 所示。

表 3 预测结果对比

预测模型	评价指标		
	RMSE/MW	MAE/MW	MAPE/%
GRU	1.274	1.014	7.026
BiLSTM	1.111	0.886	6.140
CNN-GRU	1.080	0.867	6.024
CNN-BiLSTM	0.991	0.800	5.559
EMA-BiLSTM	0.904	0.725	5.078
Prophet-EMA-BiLSTM	0.751	0.601	4.306

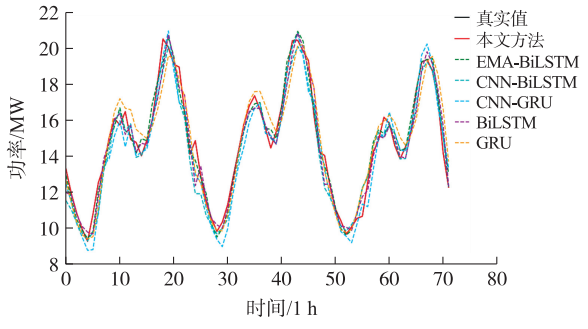

图 4 各模型预测结果曲线图

从图 4 可看出,相比其他模型,本文模型对真实值的跟踪效果最好。从表 3 可得,本文所提模型与 EMA-BiLSTM、CNN-BiLSTM、CNN-GRU、BiLSTM、GRU 的预测结果相比,预测精度最高,RMSE 分别缩小了 20.37%、31.96%、43.81%、47.94%和 69.64%,MAE 分别缩小了 20.63%、33.11%、44.26%、47.42%和 68.72%,MAPE 分别降低 0.772%、1.253%、1.718%、1.834%和 2.72%。本文模型与 EMA-BiLSTM 模型预测结果对比,RMSE、MAE 和 MAPE 均减小,说明了使用 Prophet 模型对负荷进行分解的有效性。对比单一模型 BiLSTM 和 GRU 的预测结果,说明组合模型相对于单个模型具有更高的预测精度。对比 CNN-BiLSTM 可以看出所提模型选用的 EMA 在数据特征处理方面优于 CNN。对比包含 BiLSTM 网络与 GRU 网络的预测结果可知,BiLSTM 的预测效果优于 GRU。

6 结论

针对电力负荷序列的非线性与波动性特征,本文构建了一种由高效多尺度注意力模块和双向长短期神经网络构成的组合模型短期预测方法,得出如下结论:

①本文构建的组合模型能够有效提高电力负荷短期预测的准确性,实验结果显示:本文模型的 RMSE 为 0.751 MW,MAE 为 0.601 MW,MAPE 为 4.306%。相较其他模型,本文模型的 RMSE 分别缩小 20.37%、31.96%、43.81%、47.94%和 69.64%,充分验证了本文构建方法的有效性。

②与单一模型相比,本文模型通过 EMA 模块标注关键特征并提取多尺度信息,突出负荷序列中的重要模式,抑制冗余信息;同时,利用 BiLSTM 模块在双向时序建模上的能力保证了对历史与未来依赖关系的有效捕捉,两者结合有效提高了电力负荷短期预测的精度。

③本文利用 Prophet 模型对原始负荷序列进行分解,提取出节假日、周和日分量,实现负荷在多时间尺度上的特征刻画。该分解方式为后续模型输入提供了可解释性的多尺度特征,有助于提高预测结果的可靠性。

参考文献:

[1] 陈振宇,刘金波,李晨,等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J]. 电网技术,2020,44(2):614-620.

[2] 李发崇,李鹏,高莲,等. 基于多尺度模型融合和 VMD-TCN-RF 混合网络的短期电力负荷预测方法[J]. 电子器件,2023,46(4):1035-1042.

[3] 冯汉中,詹鹏,区伟健,等. 基于 CEEMD-SE 和 TCN-LSTM 组合神经网络的超短期负荷预测[J]. 电子器件,2025,48(2):432-438.

[4] Zhu J Z, Dong H J, Zheng W Y, et al. Review and Prospect of Data-Driven Techniques for Load Forecasting in Integrated Energy Systems[J]. Applied Energy, 2022, 321:119269.

[5] Hou H,Liu C,Wang Q,et al. Review of Load Forecasting Based on Artificial Intelligence Methodologies, Models, and Challenges[J]. Electric Power Systems Research, 2022,210:108067.
[6] 徐晶,迟福建,葛磊蛟,等. 基于 SARIMA-GRNN-SVM 的短期商业电力负荷组合预测方法[J]. 电力系统及其自动化学报,2020,32(2):85-91.
[7] 杨国华,郑豪丰,张鸿皓,等. 基于 Holt-Winters 指数平滑和时间卷积网络的短期负荷预测[J]. 电力系统自动化,2022,46(6):73-82.
[8] 陈东海,徐立中,唐律,等. 基于改进 LSTM 的短期电力供需负荷预测方法研究[J]. 电子器件,2024,47(5):1331-1336.
[9] 孙超,吕奇,朱思瞳,等. 基于双层 XGBoost 算法考虑多特征影响的超短期电力负荷预测[J]. 高电压技术,2021,47(8):2885-2898.
[10] 姚程文,杨苹,刘泽健. 基于 CNN-GRU 混合神经网络的负荷预测方法[J]. 电网技术,2020,44(9):3416-3424.
[11] 李滨,陆明珍. 考虑实时气象耦合作用的地区电网短期负荷预测建模[J]. 电力系统自动化,2020,44(17):60-68.
[12] 周思思,李勇,郭钇秀,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.
[13] 保正泽,王磊,张鹏超,等. 基于混合特征选择与时空卷积注意力机制的短期负荷预测[J]. 电网技术,2025,49(12):5028-5037.
[14] 钟吴君,李培强,涂春鸣. 基于 EEMD-CBAM-BiLSTM 的牵引负荷超短期预测[J]. 电工技术学报,2024,39(21):6850-6864.
[15] Xiao W J,Mo L,Xu Z X,et al. A Hybrid Electric Load Forecasting Model Based on Decomposition Considering Fisher Information[J]. Applied Energy,2024,364:123149.
[16] 冉启武,张宇航. 基于模态分解及 GRU-XGBoost 短期电力负荷预测[J]. 电网与清洁能源,2024,40(4):18-27,34.
[17] 陈仕启,吴燕,杨德昌,等. 基于负荷二次分解与特征处理的电力系统短期负荷预测[J]. 高电压技术,2025,51(5):2571-2581.
[18] 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.
[19] Ouyang D L,He S,Zhang G Z,et al. Efficient Multi-Scale Attention Module with Cross-Spatial Learning[C]//2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Rhodes Island, Greece, IEEE,2023:1-5.

郭倍源(1989—),男,本科,高级工程师,主要研究方向为电力负荷预测及功率预测技术应用。