

基于 LSTM-TSLightGBM 可变权重组合模型的 短期电力负荷预测

谷 卫,徐 龙,唐 飞,王 建

(常州铁道高等职业技术学校,江苏 常州 213000)

摘要:随着能源需求的快速增长和智能电网的快速发展,电力负荷的波动性显著增强,传统预测方法面临非线性特征处理能力不足的挑战。本文提出了一种基于 LSTM-TSLightGBM 可变权重组合模型的短期电力负荷预测方法。该方法融合了 LSTM 的时序建模能力和 TSLightGBM 的高效特征提取能力,并通过引入动态权重分配策略,实现了根据预测误差动态调整模型权重。实验结果表明,与现有单一模型和其他混合模型相比,本文所提模型在均方根误差(RMSE)、平均绝对误差(MAE)和拟合度(R^2)等评估指标上均表现出色, RMSE 达到了 419.1 MW, MAE 达到了 374.4 MW, R^2 达到了 0.995, 显著优于其他对比模型,验证了其高精度和高鲁棒性,为短期负荷预测提供了一种有效的解决方案。

关键词:短期电力负荷预测;LSTM;TSLightGBM;可变权重

中图分类号:X831;TM715 **文献标志码:**A **文章编号:**1001-9898(2026)01-0026-08

Short Term Power Load Forecasting Based on LSTM-TSLightGBM Variable Weight Combination Model

GU Wei, XU Long, TANG Fei, WANG Jian

(Changzhou Railway Higher Vocational and Technical School, Changzhou 213000, China)

Abstract: With the rapid growth of energy demand and the rapid development of smart grid, the volatility of power load has increased significantly, and the traditional forecasting methods are facing challenges due to their insufficient ability to handle non-linear characteristics. This paper presents a short-term power load forecasting method based on lstm-tslightgbm variable weight combination model. The model combines the time series modeling ability of LSTM and the efficient feature extraction ability of tslightgbm. Through the introduction of a dynamic weight allocation strategy, it realizes the dynamic adjustment of model weights according to prediction errors. The experimental results show that, compared with the existing single model and other hybrid models, the proposed model performs well in the evaluation indexes such as root mean square error (RMSE), mean absolute error (MAE) and goodness of fit (R^2). Specifically, the RMSE reaches 419.1 MW, the MAE reaches 374.4 MW, and the R^2 reaches 0.995, which is significantly better than other comparative models, verifying its high accuracy and high robustness, and providing an effective solution for short-term load forecasting.

Key words: short term power load forecasting; LSTM; TSLightGBM; variable weight

0 引言

随着能源需求的快速增长和智能电网的快速发展,短期电力负荷预测作为电力系统优化调度的核心环节,其重要性日益凸显。短期负荷预测不仅为电力企业制定发电计划、优化资源配置提供科学依据,还能有效降低运营成本、保障电网安

全稳定运行。在可再生能源大规模并网和电力市场自由化的背景下,负荷波动性显著增强,传统预测方法面临严峻挑战,如 ARIMA^[1]虽能捕捉线性时序趋势,但难以处理负荷数据的非线性特征;SVM 通过核函数映射可部分解决非线性问题^[2],但在高维场景下面临计算复杂度高、参数敏感性强的缺陷;随机森林^[3]和 XGBoost^[4-5]等集成模型

收稿日期:2025-02-25 修回日期:2025-05-27

作者简介:谷 卫(1995-),男,硕士研究生,研究方向为嵌入式系统,电力负荷预测。

虽提升了泛化能力,却缺乏对时序动态特性的建模能力。

近年来,深度学习模型因其强大的非线性建模能力成为研究热点。长短期记忆网络(LSTM)^[6]和门控循环单元(GRU)^[7]被广泛应用于时序预测任务。文献[8]提出基于 LSTM 的负荷预测模型,验证了其对于长期依赖关系的捕捉能力,但单一 LSTM 模型对高维特征交互的处理能力有限。文献[9]采用 GRU 模型结合注意力机制,提升了模型对关键时间步的聚焦能力,但仍存在对静态特征利用率低的问题。此外,梯度提升树模型如 XGBoost、LightGBM 因其高效的特征选择和并行计算能力受到关注。文献[10]利用 XGBoost 构建负荷预测模型,在特征工程方面表现优异,但缺乏对时序动态变化的适应性。

为进一步融合不同模型的优势,混合模型成为近年来的研究趋势。文献[11]提出 ARIMA 与 SVM 的组合模型,通过统计模型捕捉线性趋势,机器学习模型处理非线性残差,但模型权重固定,无法动态适应数据分布变化。文献[12]将随机森林与多层感知机(MLP)结合,利用 RF 进行特征筛选后输入 MLP 进行预测,但未充分考虑时序特征的连续性。文献[13]尝试将 XGBoost 与 LSTM 结合,通过固定权重分配策略融合两类模型,实验表明其预测精度优于单一模型,但固定权重限制了模型对局部数据特征的适应性。文献[14]提出的 ARIAM-XGBoost 模型结合 ARIMA 与 XGBoost,虽在部分场景下表现良好,但对高维非线性数据的处理能力仍显不足。文献[15]的 XGBoost-LSTM 模型通过串联结构实现特征互补,但未引入动态权重机制,导致模型在复杂波动场景下稳定性欠佳。

尽管现有研究取得了显著进展,但仍存在以下关键问题:1)现有混合模型多采用简单串联或固定权重策略,未能充分挖掘不同模型在时序建模与特征提取方面的互补性。2)电力负荷受天气、节假日等多因素影响,数据分布呈现时变性,而现有方法缺乏动态权重调整机制,导致模型在突变场景下预测性能下降。3)传统集成方法在处理高维特征时,存在计算冗余和过拟合风险,如 LightGBM 虽通过 GOSS 和 EFB 算法优化计算效率,但其与深度学习模型的协同机制仍需进一

步探索^[16]。

针对上述问题,本文提出一种基于 LSTM-TSLightGBM 可变权重组合模型的短期电力负荷预测方法。首先针对电力负荷的时变特性,改进传统 LightGBM 算法,构建 TSLightGBM 模型;在此基础上,通过动态权重分配策略将 LSTM 的时序建模能力与 TSLightGBM 的特征提取优势进行融合,旨在解决固定权重组合难以适应负荷波动的问题。最后,利用实际电网负荷数据构建多种对比模型进行实验分析,验证本文所提方法的有效性。

1 算法原理

1.1 LSTM 模型

电力负荷数据具有显著的时序依赖性和动态波动特性,例如负荷曲线受历史周期影响显著,同时受气温突变、节假日事件等影响呈现非平稳性。传统时序模型仅能建模线性关系,难以处理上述复杂特性。LSTM 通过门控机制(遗忘门、输入门、输出门)选择性保留和更新信息,其核心优势在于通过细胞状态跨时间步传递关键信息,解决负荷序列中长期周期特征的捕捉问题,并利用 Sigmoid 和 Tanh 激活函数有效表征负荷受外部因素引发的突变模式。LSTM 模型的内部结构如图 1 所示。




图 1 LSTM 神经元结构

LSTM 单元的门控结构由输入门、输出门和遗忘门组成。输入数据 x_t 在 LSTM 单元中的前向传播过程可以由式(1)–(6)表示:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t]) + b_C \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

$$\mathbf{O}_t = \sigma(\mathbf{W}_o \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o) \quad (5)$$

$$\mathbf{h}_t = \mathbf{O}_t * \tanh(\mathbf{C}_t) \quad (6)$$

式中: $\mathbf{f}_t$ 为遗忘门 Sigmoid 层的输出向量; $\tilde{\mathbf{C}}_t$ 为更新记忆细胞信息的向量; $\mathbf{i}_t$ 为输入门神经网络层的输出向量; $\mathbf{O}_t$ 为输出门神经网络层的输出向量; $\mathbf{b}_f$ 、 $\mathbf{b}_i$ 、 $\mathbf{b}_c$ 、 $\mathbf{b}_o$ 分别为遗忘门、输出门、更新记忆细胞状态层及输出层的偏移量; $\mathbf{W}_f$ 、 $\mathbf{W}_i$ 、 $\mathbf{W}_c$ 、 $\mathbf{W}_o$ 为 4 个神经网络层权重; σ 、 $\tanh$ 分别为 Sigmoid 函数和双曲正切函数; $\mathbf{C}_t$ 为记忆状态, 结合输出门信息 $\mathbf{O}_t$ 得到当前 LSTM 单元输出的隐藏状态 $\mathbf{h}_t$ 。

1.2 TSLightGBM 模型

电力负荷预测需融合多源高维特征, 传统集成模型面临特征维度灾难和静态特征交互的挑战。TSLightGBM 通过 GOSS 算法保留梯度大的关键样本, 减少 90% 计算量, 并利用 EFB 算法将冲突率低的高维特征合并, 提升特征交互效率。直方图加速技术通过离散化特征值使分割点搜索效率提升, 适应实时预测需求。

1.2.1 LightGBM 算法

LightGBM 是基于决策树算法的分布式梯度增强框架。与 XGBoost 类似, LightGBM 添加正则项, 对损失函数进行二阶泰勒展开, 并使用一阶和二阶导数信息。目标函数 $J^{(t)}$ 如式(7)所示:

$$J^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) + \text{constan } t \quad (7)$$

为求 f_t , 使 $\sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t)$ 的值最小, 其中 $\Omega(f_t)$ 是正则化术语。

GBDT 需要扫描所有数据来估计信息增益的所有可能分割点, 这会消耗时间和内存。LightGBM 使用 GOSS 算法来减少样本, 使用 EFB 算法来捆绑特征, 从而降低算法的时间复杂性。

1.2.2 GOSS 算法和 EFB 算法

首先, GOSS 算法根据梯度的绝对值将样本从大到小排序, 从排序后的样本中提取 $a\%$ 的样本, 并保留所有 $a\%$ 的样本。然后, 它从剩余的 $(1-a\%)$ 样本中随机抽取 $b\%$ 的样本, 以保持原始

分布, 放大 $[(1-a\%)b\%]$ 的样本, 并将它们乘以 $(1-a\%)/b\%$ 。新的信息增益如式(8)所示:

$$\tilde{V}_J(d) = \frac{1}{n} \left(\frac{(\sum_{x_i \in A_l} g_i + \frac{1-a}{b} \sum_{x_i \in B_l} g_i)^2}{n_l^j(d)} + \frac{(\sum_{x_i \in A_r} g_i + \frac{1-a}{b} \sum_{x_i \in B_r} g_i)^2}{n_r^j(d)} \right) \quad (8)$$

式中: $\tilde{V}_J(d)$ 为在特征上选择分裂点的估计方差增益; n 为高斯算法过滤样本后节点的样本总数; $n_l^j(d)$ 为节点的左样本数; $n_r^j(d)$ 为节点的右样本数; g_i 为第 i 个样本的一阶梯度值; $\frac{1-a}{b}$ 为权重放大系数。

EFB 算法最初使用特征之间的关系构建加权无向图。然后, 根据节点的程度按降序对节点进行排序。程度越大, 与其他特征的冲突越大。最后, 它遍历每个特征并将其分配给现有的特征包, 或者创建一个新的特征包以最小化总体冲突。

1.2.3 直方图算法

直方图算法大大提高了 LightGBM 模型的效率, 该模型可以离散化特征序列并直接支持原生类别。无需像 XGBoost 中的情况那样, 使用类似的一次热编码进行特征数字化, 并将其转换为多维 0/1 特征, 这在空间和时间上都不高效。直方图算法将浮点特征值离散化为 m 个整数, 并构建宽度为 m 的直方图。遍历数据时, 离散化值用作索引, 以在直方图中累积统计信息。一旦数据被遍历, 直方图将累积所需的统计信息。根据直方图的离散值, 找到最佳分割点。与 GBDT(遍历每个特征的所有可能分割点以找到最佳分割点)相比, LightGBM 需要更小的内存还提高了速度。算法如图 2 所示。




图 2 直方图算法

LightGBM 使用逐叶策略每次在所有叶节点中分割增益最大的叶节点, 同时限制树的最大深

度以防止过度拟合。二叉树的分裂增益如式(9)–(11)所示:

$$G_{\text{ain}} = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (9)$$

$$G_j = \sum_{i \in I_j} g_i, i = 1, 2, \dots, n; j = 1, 2, \dots, T \quad (10)$$

$$H_j = \sum_{i \in I_j} h_i, i = 1, 2, \dots, n; j = 1, 2, \dots, T \quad (11)$$

式中: γ 为每次引入新叶子节点的复杂性成本; G_j 和 H_j 分别为样本集误差函数的一阶导数和二阶导数; G_L 和 G_R 分别为分裂后左子节点和右子节点样本的一阶梯度之和; H_L 和 H_R 分别为分裂后左子节点和右子节点样本的二阶梯度之和; λ 为 L2 正则化系数,用于控制叶子节点权重的平滑程度,防止过拟合。

TSLightGBM 在 LightGBM 基础上针对电力负荷预测需求进行了三方面改进:首先,引入滞后负荷、滑动均值等时序衍生特征,提升模型对周期规律的捕捉能力;然后,通过先验知识限制非相关特征(如节假日与湿度)的交互分裂,减少过拟合风险;最后,采用滚动时间窗口更新模型参数,适应负荷数据的动态演化特性。

1.3 动态权重分配策略

电力负荷受气象突变、节假日事件等时变因素影响,其数据分布呈现非平稳性和局部特征差异性。固定权重策略无法适应负荷波动场景下的模型性能变化,TSLightGBM 对气温特征的敏感性更高,需提升其权重;而常态日 LSTM 的时序建模能力更优。动态权重分配通过实时计算预测误差矩阵,利用拉格朗日乘数法调整模型权重,使组合模型能够自适应强化优势模型的贡献。

LSTM 和 LightGBM 是两种完全不同的模型。前者对时间序列的性质敏感,而后者比前者具有更强的特征提取能力。这两种模型的预测能力存在差异。然而,总体预测效果较差的模型并不意味着该模型对所有样本的预测能力较差。鉴于两种模型在处理数据方面的不同优势,本文通过动态权重分配策略方法将模型进行组合,避免

了单个模型的整体缺点,提高了模型性能的稳定性。最佳加权组合方法的计算步骤如下。

步骤 1:找到偏差矩阵 $\mathbf{E}$ 。

$$\mathbf{E} = \begin{bmatrix} \sum_{i=1}^N e_{1T}^2 & \sum_{i=1}^N e_{1T} e_{2T} \\ \sum_{i=1}^N e_{1T} e_{2T} & \sum_{i=1}^N e_{2T}^2 \end{bmatrix} \quad (12)$$

式中: N 为数据集中包含的样本数; e_{1T} 和 e_{2T} 分别为 LSTM 模型和 LightGBM 模型在时间 T 时的预测值和真实值之间的误差。

步骤 2:通过拉格朗日乘数法得到最佳权重。

$$[\omega_1, \omega_2]^T = \frac{\mathbf{E}^{-1} \mathbf{R}}{\mathbf{R}^T \mathbf{E}^{-1} \mathbf{R}} \quad (13)$$

式中: ω_1 和 ω_2 分别为 LSTM 和 LightGBM 模型的权重系数,系数之和为 1; $\mathbf{R} = [1, 1]^T$ 。

步骤 3:根据权重系数得到最终的电力负荷预测结果。

$$\hat{y}_T = \omega_1 \hat{y}_{1T} + \omega_2 \hat{y}_{2T} \quad (14)$$

式中: $\hat{y}_T$ 为 LSTM-LightGBM 在时间 T 的电力负荷预测结果; $\hat{y}_{1T}$ 和 $\hat{y}_{2T}$ 分别为 LSTM 和 LightGBM 模型的电力负荷预测结果。

2 基于 LSTM-TSLightGBM 的加权组合预测模型

2.1 数据来源和数据预处理

本研究选择了实际应用场景的数据集进行测试:中国东南部某城市(标记为 SC)的电力负荷数据集,时间跨度为 2016 年 11 月至 2017 年 8 月,包含日均电力负荷、日最高气温、日最低气温、日平均气温、相对湿度、日降雨量等多个维度,样本总量约为 32 428 条记录。负荷数据呈现显著周期性特征,如日负荷高峰集中于 9:00—12:00 和 18:00—21:00,工作日负荷均值较周末高约 15%;季节性差异明显,夏季(6—8 月)日均负荷较冬季(11—1 月)增长 22%~35%,主要受空调制冷需求驱动;节假日(如春节)负荷较平日下降 40%~50%。为了验证所提 LSTM-TSLightGBM 模型在电力负荷预测方面的性能,将数据集分别划分为训练集、验证集和测试集,比例为 6:2:2。

由于对原始数据的统计通常是不完整的,在

采集和存储过程中会受到噪声的干扰,从而导致一些数据的缺失和错误。因此,本文在获得原始电力负荷数据后,用原始负荷的中值填充缺失值,用邻近算法替换离群值。本文的所有实验均在 Python3.8 环境中运行,深度学习模型使用 Pytorch 和 Tensorflow 第三方库,实验硬件 CPU 为英特尔 i9-14900KF 处理器, GPU 为英伟达 3090 显卡,内存为 32 GB。

2.2 组合模型预测构建流程

组合模型预测步骤如下。

1) 数据预处理:对原始数据进行预处理,按照一定比例划分训练集和测试集。

2) 单预测模型构建:在训练集上分别训练 LSTM 模型和 TSLightGBM 模型,确定模型最优参数,并将测试集用于实际的电力负荷预测。

3) 最优加权组合预测模型构建:根据拉格朗日乘数法得到最佳权重,通过计算得到组合模型最终预测结果。

4) 模型评价分析:根据预测模型的评价指标比较模型的预测能力,分析模型预测效果。组合模型预测流程如图 3 所示。




图 3 LSTM-TSLightGBM 模型预测流程

2.3 电力负荷预测影响因素分析

为了更深入地理解数据特征及其背后的影响因素,本研究进行了相关性分析。相关性分析图

如图 4 所示,直观地展示了负荷数据与其他潜在影响因素之间的关联程度。通过分析,日均负荷与各因素的相关系数为 $-0.026 \sim 0.120$,整体相关性较弱。其中,温度相关因素(最高温度、最低温度、平均温度)与电力负荷的相关系数分别为 0.10、0.11 和 0.12,虽有一定相关性,但未达到显著水平。此外,降雨量与日均负荷的相关性为 -0.026 ,呈现出微弱的负相关关系。因此,尽管气温等因素在一定程度上影响电力负荷,但其作用相对有限,节假日安排等非气象因素可能对负荷变化具有更复杂的影响。




图 4 相关性分析

2.4 模型构建和评价指标

为了评估 LSTM-TSLightXGB 网络模型的预测性能,本文采用均方根误差(RMSE)、平均绝对误差(MAE)和拟合度 R^2 对算法模型进行评价。其计算式如式(15)~(17)所示:

$$R_{MSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

$$M_{AE} = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (17)$$

式中: y_i 和 $\hat{y}_i$ 分别为第 i 次测试的实际值和算法模型输出值; n 为测试总次数; $\bar{y}$ 为算法模型输出的平均值。

其中, MAE 和 RMSE 的值越小,说明模型预测效果越好, R^2 的值越接近 1,说明预测模型的拟

合效果越好。

3 结果与分析

3.1 模型构建

3.1.1 LSTM 模型构建

影响神经网络性能的参数太多。因此,根据以往的经验,确定激活函数为 ReLU,优化算法为 Adam 算法。设置两个隐藏层,学习率设置为默认参数 0.01,随机删除部分神经元,概率为 0.2。设置预实验,对次要参数进行粗略调整。在预实验中,批大小设置为 16、32 和 64,迭代训练 epoch 数设置为 100 和 200 来建模训练样本,设置两个隐藏层,批数设置为 32,epoch 数设置为 100。同时,验证集的 MAE 在最近 50 次训练中呈上升趋势,因此设置了一种机制(early_stopped)来防止模型过拟合。根据以往经验,预实验完成的参数设置如表 1 所示。

表 1 LSTM 模型主要参数

参数	设置
Activation function	ReLU
Optimization algorithm	Adam
Learning rate	0.01
Discard rate	0.2
Batch parameters	32
Epochs	100

3.1.2 TSLightGBM 模型构建

考虑到 TSLightGBM 模型参数较多,树的集成模型主要受树的数量、最大深度和学习率的影响。本文对 TSLightGBM 的 3 个主要参数进行调整。树的数量($n_{estimators}$)在[100,250,500,1 000,2 000]内调整,最大树深度(max_depth)在[6,8,10,12,16]内调整,学习率($learning_rate$)在[0.01,0.05,0.10]内调整。最终调整结果如表 2 所示。

表 2 TSLightGBM 模型主要参数

参数	设置
$n_{estimators}$	1 000
max_depth	10
$learning_rate$	0.01

3.2 预测精度对比分析

为了检验本文所提 LSTM-TSLightGBM 模型的有效性,设计两组实例研究。

1)与单一模型对比分析

本文构建了 MLP、SVR、LSTM、GRU 及 XGBoost 5 个单一模型进行对比。对比结果如图 5 所示,单一模型的误差对比结果如图 6 所示,各模型的具体评估指标对比如表 3 所示。




图 5 与单一模型对比结果




图 6 单一模型误差对比结果

表 3 模型评估指标对比

模型	R_{MSE}/MW	M_{AE}/MW	$R^2/\%$
MLP	4 375.2	3 400.9	0.621
SVR	3 668.6	2 474.7	0.733
LSTM	1 709.7	1 230.7	0.862
GRU	1 369.3	903.5	0.882
XGBoost	901.5	500.1	0.913
LSTM-TSLightGBM	419.1	374.4	0.995

由表 3 及图 5—6 可知,单一模型虽能捕捉负荷大致趋势,但在精度上存在明显瓶颈。相比于单一模型中表现最佳的 XGBoost 模型,本文所提 LSTM-TSLightGBM 模型在各项指标上均实现了显著优化:RMSE 从 901.5 MW 降低至 419.1 MW,MAE 降低了约 25.1%,拟合度 R^2 提升至 0.995。这主要归因于单一模型的局限性:MLP 与 SVR 难以处理时序动态变化,LSTM 与 GRU 对高维特征交互挖掘不足,而 XGBoost 虽特征提取能力强但缺乏对时序依赖性的建模。本文模型通过融合时序与特征提取优势,并辅以动态权重,显

著降低了预测误差。

2)与其他混合模型对比分析

为全面评估模型性能,本文选取文献[2]、[7]、[8]、[10]及[12]中的方法进行对比,预测结果如图 7 所示。由图 7 可知,LSTM-TSLightGBM 模型的波动趋势与真实值最为贴合,尽管个别时间点的预测略有偏差,但整体展现出更高的精度与稳定性。为进一步量化分析,各模型的误差对比及评估指标分别如图 8 和表 4 所示。




图 7 与其他混合模型对比结果




图 8 混合模型误差对比结果

表 4 混合模型评估指标对比

模型	R_{MSE}/MW	M_{AE}/MW	$R^2/\%$
RF-MLP ^[12]	891.3	687.5	0.917
GRU-RF ^[7]	766.1	597.6	0.931
CNN-SVM ^[2]	701.2	524.7	0.953
LSTM-XGBoost ^[10]	655.6	499.6	0.967
GCN-LSTM ^[8]	585.8	463.3	0.975
LSMT-TSLightGBM	419.1	374.4	0.995

由表 4 可知,LSTM-TSLightGBM 模型在各项评估指标上均表现最优。与对比模型中性能最佳的 GCN-LSTM 相比,本模型的 RMSE 和 MAE 分别降低了约 28.8%和 19.2%, R^2 提升至 0.995,展现出极高的预测精度与拟合能力。

模型性能的显著提升主要归因于架构设计与权重策略的优化。现有混合模型存在明显局限:

GCN-LSTM 主要针对图结构数据,对纯时序特征的敏感度不如预期;LSTM-XGBoost 与 GRU-RF 虽结合了时序与集成模型的优势,但采用的固定权重策略难以适应电力负荷的时变分布;RF-MLP 与 CNN-SVM 则受限于基础模型对时序动态捕捉能力的不足。相比之下,本文模型不仅通过改进 TSLightGBM 强化了对高维时序特征的挖掘,更利用动态权重分配策略实现了模型贡献度的自适应调整,从而在复杂波动场景下实现了对现有方法的全面超越。

3.3 消融模型对比分析

为了分析本文所提组合模型中不同模块的必要性,将本文模型进行组合分析。通过将本文提出的 LSTM-TSLightGBM 模型、单一的 LSTM、LightGBM、TSLightGBM 模型以及混合 LSTM-LightGBM 模型分别进行对比,以验证本文所提预测模型的高精确度。消融模型对比结果如表 5 所示。

表 5 消融模型对比分析

模型	R_{MSE}/MW	M_{AE}/MW	$R^2/\%$
LSTM	1 709.7	1 230.7	0.862
LightGBM	1 564.1	1 336.8	0.889
TSLightGBM	1 156.7	903.4	0.903
LSTM-LightGBM	673.6	436.5	0.971
LSMT-TSLightGBM	419.1	374.4	0.995

表 5 的消融实验结果表明,本文所提 LSTM-TSLightGBM 模型通过多机制融合实现了性能的层级跃升。首先,与单一模型 LSTM、LightGBM、TSLightGBM 相比,组合模型表现出显著优势,其 RMSE 降幅达 63.8%~75.4%, R^2 提升了 9.2~15.3 个百分点。这验证了将 LSTM 的时序建模能力与 LightGBM 的特征提取能力结合的必要性。其次,为了验证改进策略的有效性,与基础混合模型 LSTM-LightGBM 相比,本文模型在引入 TSLightGBM 改进及动态权重分配策略后, RMSE 进一步降低了 37.8%,MAE 降低了 14.5%。这一显著提升证明,单纯的模型叠加效果有限,而通过时序特征强化与动态权重自适应调整,能有效解决传统静态组合模型对负荷波动适应性不足的问题,是实现高精度预测的关键所在。

4 结论

本文聚焦于短期电力负荷预测,针对传统方

法在处理复杂、时变数据时的不足,提出了一种基于 LSTM-TSLightGBM 可变权重组合模型的新方法。该方法结合了 LSTM 的时序建模优势和 TSLightGBM 的特征提取能力,并通过动态权重调整机制,显著提升了预测精度和鲁棒性。实验结果表明,该模型在各项指标上均优于现有方法,在极端天气等突发场景下的预测误差仍较显著。未来将通过引入实时气象预警数据与迁移学习策略,增强模型对罕见事件的适应性,为短期电力负荷预测提供了一种高效解决方案。

展望未来,随着智能电网和可再生能源的发展,电力负荷预测将面临更多挑战。需要继续优化模型,提升其在极端条件下的预测性能,并探索更多先进技术与方法的融合,为电力系统的稳定运行和高效管理贡献力量。

参考文献:

- [1] BENTO P M R, POMBO J A N, CALADO M R A, et al. Stacking ensemble methodology using deep learning and ARIMA models for short-term load forecasting[J]. *Energies*, 2021, 14(21): 7378.
- [2] AN W, GAO B, LIU J, et al. Predicting hourly heating load in residential buildings using a hybrid SSA-CNN-SVM approach[J]. *Case Studies in Thermal Engineering*, 2024, 59(13): 104516.
- [3] 张羽姗,周亚同.基于 VMD-SSA-RF 算法的短期电力负荷预测模型优化[J]. *电工电能新技术*, 2024, 43(12): 30-39.
- [4] DONG X, DENG S, WANG D. A short-term power load forecasting method based on k-means and SVM[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2022, 13(11): 5253-5267.
- [5] SINGH S N, MOHAPATRA A. Data driven day-ahead electrical load forecasting through repeated wavelet transform assisted SVM model[J]. *Applied Soft Computing*, 2021, 111(8): 107730.
- [6] 曾进辉,苏旨音,肖 锋,等.基于生成对抗网络和 EMD-SSA-LSTM 的短期电力负荷预测[J]. *电子测量技术*, 2024, 47(20): 92-100.
- [7] 刘 明,尚 尚.基于 K_means++聚类与 RF_GRU 组合模型的电力负荷预测方法研究[J]. *计算机与数字工程*, 2024, 52(6): 1662-1667, 1702.
- [8] CHEN H, ZHU M, HU X, et al. Research on short-term load forecasting of new-type power system based on GCN-LSTM considering multiple influencing factors[J]. *Energy Reports*, 2023, 9(11): 1022-1031.
- [9] LI C, GUO Q, SHAO L, et al. Research on short-term load forecasting based on optimized GRU neural network[J]. *Electronics*, 2022, 11(22): 3834.
- [10] ZHANG L, JÁNOŠÍK D. Enhanced short-term load forecasting with hybrid machine learning models: CatBoost and XGBoost approaches[J]. *Expert Systems with Applications*, 2024, 241(6): 122686.
- [11] AZANI N W, TRISYA C P, SARI L M, et al. Performance comparison of ARIMA, LSTM and SVM models for electric energy consumption analysis[J]. *Public Research Journal of Engineering, Data Technology and Computer Science*, 2024, 1(2): 1022-1031.
- [12] 谢 洋,陆新建,邵晓雯,等.基于 MLP-RF 组合模型预测加氢裂化装置柴油产量[J]. *化学工程*, 2024, 52(11): 66-70.
- [13] 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.
- [14] DAI Y, ZHOU Q, LENG M, et al. Improving the Bi-LSTM model with XGBoost and attention mechanism: A combined approach for short-term power load prediction[J]. *Applied Soft Computing*, 2022, 130(2): 109632.
- [15] XMAZIBUKO T, AKINDEJI K. Hybrid forecasting for energy consumption in south Africa: LSTM and XGBoost approach[J]. *Energies*, 2025, 18(16): 4285.
- [16] 张 未,余成波,王士彬,等.基于 VMD-LSTM-LightGBM 的多特征短期电力负荷预测[J]. *南方电网技术*, 2023, 17(2): 74-81.

本文责任编辑:王丽斌