

# 考虑环境因素的电动汽车充电站实时负荷预测模型

李波, 王宁, 吕叶林, 陈宇

(同济大学汽车学院, 上海 201804)

**摘要:** 为了减少电动汽车大规模集成到电网造成的不利影响, 提出了一种能够实现充电站充电负荷精准预测的方法。该方法利用 LightGBM (light gradient boosting machine) 与 XGBoost (eXtreme gradient boosting) 模型构建线下-线上组合模型。考虑充电负荷、时间、温度、天气等历史数据, 利用 LightGBM 模型初步建立充电负荷线下预测模型; 基于 XGBoost 模型, 以线下预测模型输出负荷和实际负荷的误差为优化目标, 实时变化的交通流量为协变量, 建立线上预测模型, 并对初步预测结果进行误差修正。某市实际充电站预测结果表明, 相比于随机森林 (RF)、LightGBM 模型、XGBoost 模型、多层感知机 (MLP) 以及 LightGBM-RF 组合模型, 该组合模型具有更高的预测精度, 同时可以准确预测不同充电站的实时充电负荷。

**关键词:** 电动汽车; 充电负荷预测; LightGBM (light gradient boosting machine); XGBoost (eXtreme gradient boosting); 在线学习

中图分类号: U469.72

文献标志码: A

## Real-time Load Prediction Model of Electric Vehicle Charging Station Considering Environmental Factors

LI Bo, WANG Ning, LÜ Yelin, CHEN Yu

(School of Automotive Studies, Tongji University, Shanghai 201804, China)

**Abstract:** To mitigate the adverse effects of large-scale integration of electric vehicles into the grid, a method for the precise prediction of charging station load is proposed in this paper. The method employs a combination of LightGBM and XGBoost to construct offline-online ensemble models. Historical data including charging load, time, temperature, and weather are considered. Firstly, a charging load offline prediction model is established using LightGBM. Based on the XGBoost model, with the error

between offline prediction model output load and actual load as the optimization target, and the real-time varying traffic flow as a covariate, an online prediction model is developed, and the error correction is performed on preliminary prediction results. Predictions from actual charging stations in a certain city indicate that compared to random forest (RF), LightGBM, XGBoost, multilayer perceptron (MLP), and LightGBM-RF ensemble models, the ensemble model demonstrates higher prediction accuracy while accurately forecasting real-time charging loads for different charging stations.

**Keywords:** electric vehicles; charging load prediction; LightGBM; XGBoost; e-learning

电动汽车具有 2 种属性, 一种属性是需要充电, 另一种属性是可以随机移动, 因此电动汽车被视为随机性的移动负荷。这 2 种属性给电网运营带来了一系列挑战。大规模电动汽车并入电网充电容易导致电网负荷过载, 从而影响能源系统<sup>[1-4]</sup>。充电过程中引入的高次谐波使电网面临谐振风险, 对电气设备的正常工作造成影响。同时, 电动汽车的充电随机性易导致电网运行电压变动, 增加网络损耗和运行成本<sup>[5-7]</sup>。为了减少电动汽车集成到电网的不利影响, 准确的充电负荷预测至关重要<sup>[8-9]</sup>。充电负荷预测能够实现对电网能量的削峰填谷, 确保电动汽车与电网的高效协调运行<sup>[10-13]</sup>。

充电负荷预测研究方法分为模型驱动法和数据驱动法<sup>[14]</sup>。数据驱动法通过数据分析探索充电负荷历史数据规律以实现充电负荷预测, 数据规模和种类都会影响预测的准确性。温度、天气状况、交通状况等因素通过影响车主的充电行为间接对充电负荷造成影响, 电池特性、起始电量、充电时间及功率等

收稿日期: 2022-08-21

基金项目: 国家电网总部科技项目 (5108-202119040A-0-0-00)

第一作者: 李波, 高级工程师, 博士生, 主要研究方向为智能电网、新能源汽车数据挖掘。

E-mail: 1425024368@qq.com

通信作者: 陈宇, 硕士生, 主要研究方向为新能源汽车数据挖掘。E-mail: chenyu815@outlook.com



论文  
拓展  
介绍

因素直接影响充电负荷<sup>[10]</sup>。机器学习算法被广泛应用于充电负荷预测<sup>[15]</sup>。王华彪等<sup>[16]</sup>根据电动汽车充电负荷时序性特点,基于深度学习提出了融合注意力机制的双向长短时记忆网络模型,能够有效挖掘负荷序列之间的关系,从而进行准确预测。Feng等<sup>[17]</sup>考虑电价和温度的影响,提出了一种多变量残留校正灰色模型和长短时记忆网络模型的组合预测方法,相比于单个模型能够更有效地提高预测准确性。Shen等<sup>[18]</sup>提出了一种基于生成对抗网络的数据生成方法,并在长短时记忆网络中采用一种名为Mogriifier的门控机制,能够在稀缺数据集上获得准确的电动汽车充电负荷预测结果。李恒杰等<sup>[19]</sup>充分考虑充电负荷的影响因素,自定义能量集成轻量梯度提升模型,选择占用资源极低的LightGBM模型作为基础回归器生成层,并使用提升集成法对基础回归器群进行串行优化。吴丹等<sup>[20]</sup>基于Stacking集成学习策略,采用XGBoost与LightGBM算法构建充电负荷预测的基学习器,通过岭回归算法融合基学习器结果,输出最终充电负荷预测值。

上述文献聚焦于预测方法的构建,将所有特征同时输入模型中进行预测,缺乏对输入特征实时变化的考量。为充分利用数据的实时变化,采用适合于高维度海量数据的LightGBM与XGBoost模型构建线下-线上组合模型,分批输入特征。LightGBM模型对天气、温度等实时变化小的特征进行线下模型训练,XGBoost模型对实时变化大的交通流数据进行线上模型完善,从而更好地适应环境因素的实时变化。将充电负荷预测范围精确到以充电站为单位,以能够精准预测任意组合充电站的充电负荷为目标。实验结果表明,该线下-线上组合模型是一个在充分考虑输入数据实时变化的前提下实现多个充电站充电负荷精准预测的通用模型。

## 1 充电站充电负荷特性分析

通过调研获取了国内某个城市86个公用充电站的充电负荷数据,对充电站充电特性及共性进行分析。

将充电站每小时输出功率数据的质量作为筛选指标,选取充电站充电功率数据进行分析,数据周期为2021-01-01—2021-12-20,采样频率为每小时记录一次,每个充电站共记录8 496条数据。图1展示了各充电站每小时充电功率的最大值与最小值,充电功率最小值均为零,说明各充电站均有无车充电

的情况。各充电站充电功率最大值差异较大,最大差距可达1 MW,这与各充电站的地理位置以及充电桩数量、功率有关。

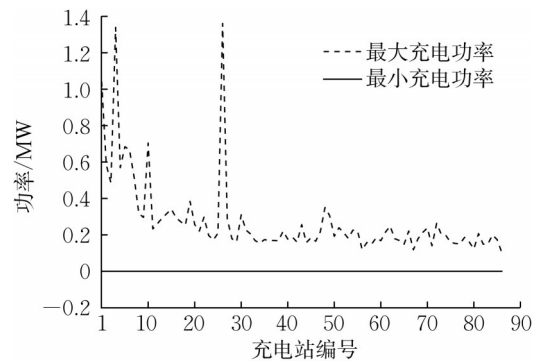


图1 各充电站充电功率极值曲线

Fig.1 Extreme value curve of charging power of each charging station

图2为某一充电站不同周期下的充电功率变化曲线。由图2a可知,该充电站每小时的充电功率最小值为零,最大值超过1 MW,波动幅度大,难以直接观察变化规律。图2b展示了该充电站某月的充电功率变化趋势,可见每周的数据具有一定相似性,均存在充电功率为零后曲线大幅波动再次归零的趋势。图2c为该充电站某周的充电功率变化曲线,可见该周每天均存在充电功率为零的情况,发生时间集中在一天的较早时间段。通过图2d可进一步发现,充电功率为零的情况集中在凌晨后半段,符合多数驾驶人的作息规律。

## 2 充电负荷预测模型

### 2.1 LightGBM

LightGBM是由梯度提升决策树(GBDT)改进所得的集成算法,在进行分类、预测、数据挖掘时,能够解决GBDT因数据量过大而出现的过拟合、训练速度缓慢等问题<sup>[21]</sup>,具有快速、低内耗、高准确性的优势<sup>[22]</sup>。

为了防止过拟合现象的发生,LightGBM模型采用直方图算法和带深度限制的Leaf-wise(按叶子生长)策略。直方图算法能够将连续的特征值离散化,并以离散值个数为宽度构造相应直方图。利用直方图存放遍历数据时产生的统计量,可在占用内存更小的情况下加速遍历以寻找最佳分割点<sup>[23]</sup>。Leaf-wise策略通过搜索定位每一层叶子,实现对分裂增益最大叶子的精准分裂,并通过深度限制避免过度

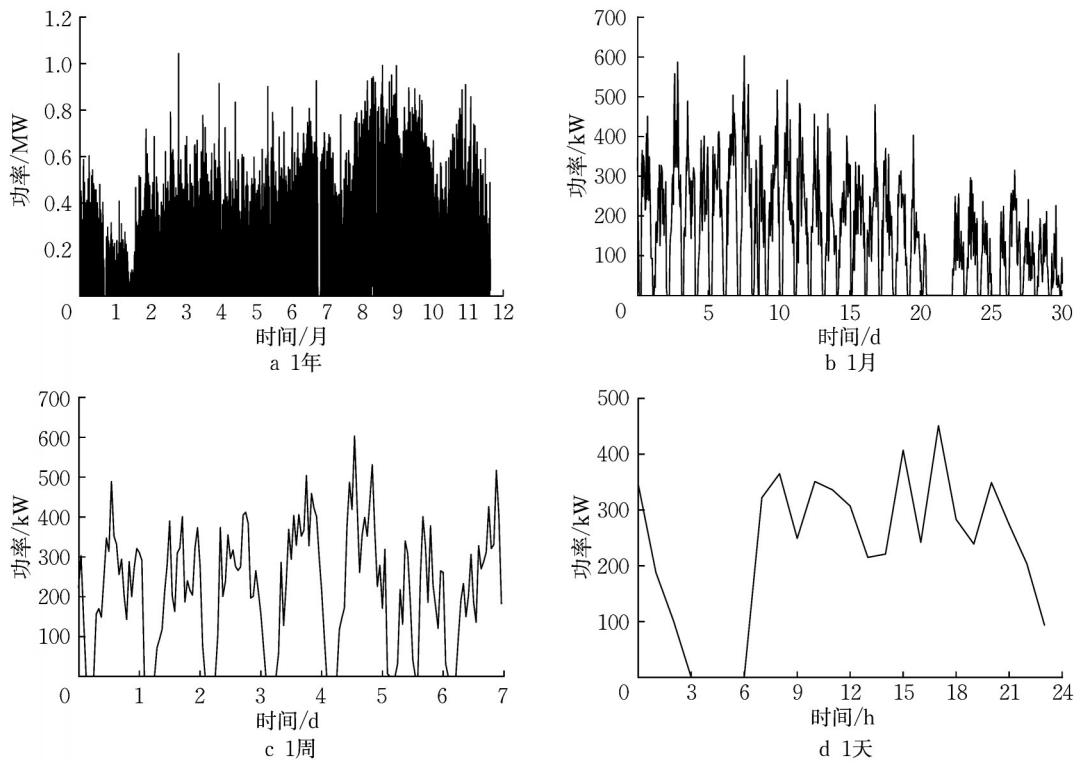


图2 某充电站充电功率变化曲线

Fig.2 Charging power change curve at a charging station

拟合,还直接支持类别特征和高效并行<sup>[24]</sup>。LightGBM模型采用单边梯度采样,在有效减少数据量的同时最大程度保证精度<sup>[22]</sup>,还采用互斥特征捆绑将2个不会同时为零的特征进行捆绑,有效减少高维数据的特征维数,缩短模型训练时间<sup>[25]</sup>。LightGBM模型的高训练速度、低内存消耗、高精度的特性适用于线下预测的高维度海量数据,故选择其作为线下预测模型。

## 2.2 XGBoost

XGBoost是一种决策树模型,以减小残差为目标,不断构建子模型、生成预测值,直到残差能够满足系统的误差要求,预测精度随迭代次数的增加而提高<sup>[26]</sup>。XGBoost是性能更加优秀的集成学习方法,广泛应用于分类任务和回归问题。

相比于GBDT和随机森林,XGBoost模型做出了多项改进。通过添加正则化术语有效控制决策树的复杂性,提高模型的概括能力,从而减少过度拟合的风险。同时,XGBoost模型能够实现随机采样和缺失值自动处理,支持二阶泰勒展开以去除目标函数中的常数项、选择并行化特征以及自定义损失函数,有效提升预测速度<sup>[27-29]</sup>。

相比于XGBoost模型,LightGBM模型虽然具有更高的运算精度与速度,但是其Leaf-wise策略更易

出现过拟合,而且线上模型的实时性大大增加了深度限制的设置难度。为了充分发挥线上模型的修正作用,最终选择XGBoost模型进行线上学习。

## 2.3 模型组合方法

为了提高模型的预测精度,首先构建一个训练完备的线下模型,再通过实时滚动的线上模型对结果进行进一步的修正。组合模型预测框架如图3所示。具体步骤如下:

(1) 线下模型建立。将充电站历史充电负荷、天气、温度、日期等数据作为输入,构造历史充电负荷统计量和与日期相关的新特征,所有特征共同输入LightGBM模型中得到充电站充电负荷预测值 $y_1$ 。可根据预测需要选择参与训练的充电站,对充电站数目不加限制,所有充电站的信息拼接后共同输入模型。

(2) 线上模型建立。将预测站点附近的交通流量实时信息作为新的输入数据,选择的站点需与步骤(1)中一致。然后,通过XGBoost模型对真实充电负荷 $\hat{y}$ 与预测值 $y_1$ 之间的残差 $e$ 进行预测,即 $e = \hat{y} - y_1$ ,最终输出 $e$ 。

(3) 结果输出。将线下模型得到的充电站充电负荷预测值 $y_1$ 与线上模型得到的残差 $e$ 加和作为最终的充电负荷预测值 $y_2$ ,即 $y_2 = y_1 + e$ 。



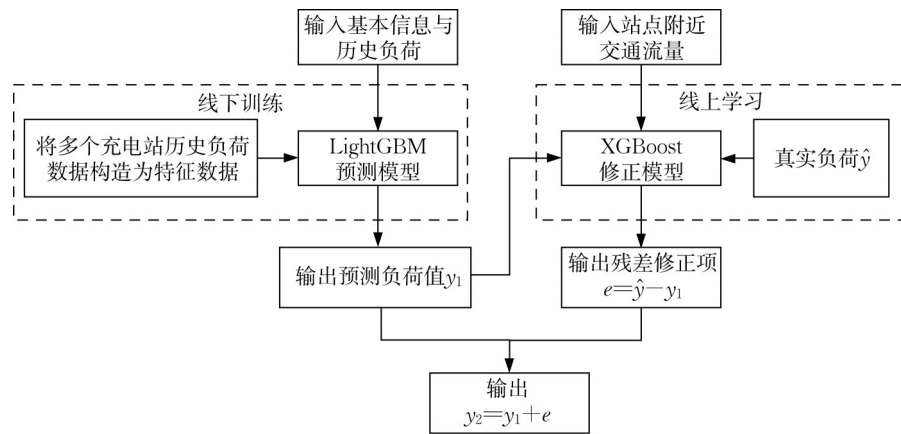


图3 预测框架

Fig.3 Prediction framework

### 3 充电站充电负荷预测分析

#### 3.1 数据分析与处理

##### 3.1.1 数据分析

除分析充电站历史充电负荷数据影响外,还着重考虑温度、天气、交通流量等因素对充电负荷的影响。温度与天气数据通过公开数据获得。图4a为某市2021年的最低与最高温度变化情况,全年最高温度为37℃,最低温度为-5℃,变化趋势符合该市大陆性季风气候的特点。图4b展示了某市2021年天气情况分布,在统计的24种天气情况中,小雨是2021年发生最频繁的天气。

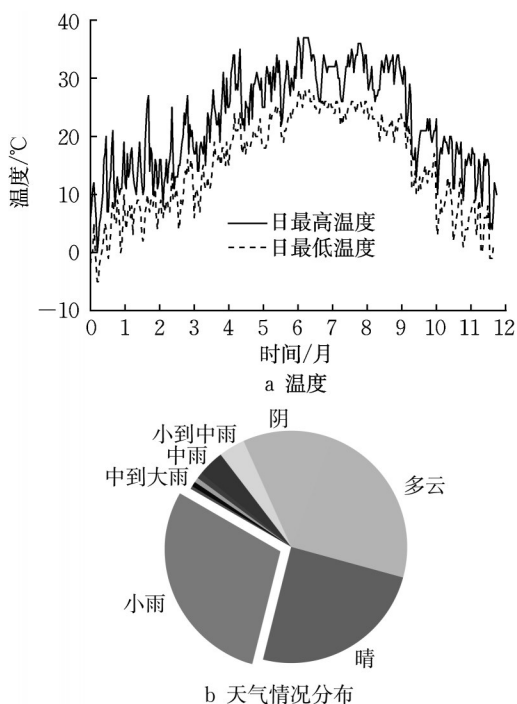


图4 某市2021年温度和天气情况分布

Fig.4 Temperature and weather map of a city in 2021

交通流量数据是由百度地图基于海量的交通出行大数据、车辆轨迹大数据和位置定位大数据等挖掘计算所得,包括拥堵指数和平均速度两部分,采样频率为5 min采样一次。图5为某市某条路段的交通流量变化。拥堵指数为实际行程时间与畅通行程时间的比值,平均速度为该路段车辆的实际平均车速,两者的关系呈反比,与图5展示的情况一致。拥堵指数计算式为

$$\eta = \frac{t_s}{t_c} = \frac{v_c}{v_s} \quad (1)$$

式中: $\eta$ 为拥堵指数; $t_s$ 为车辆实际行程时间; $t_c$ 为车辆畅通行程时间; $v_c$ 为车辆畅通情况下平均车速; $v_s$ 为车辆实际平均车速。

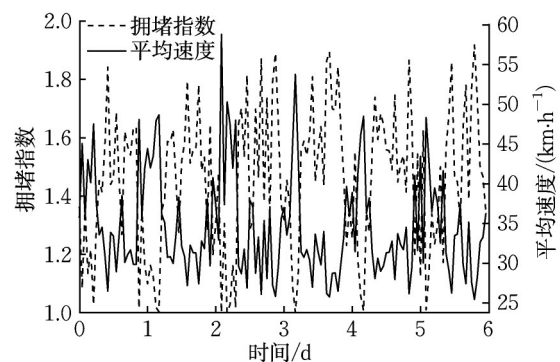


图5 某市某路段拥堵指数与平均速度随时间的变化

Fig.5 Variation of traffic congestion index and average speed with time at certain road section in a city

图6为某市00:00—23:25时3条路段的交通拥堵系数变化情况。不同路段的拥堵指数受地理位置、天气、偶发事件等因素影响,在变化趋势、极值等方面具有较大差别,难以进行预测,适合作为线上模

型的输入数据。

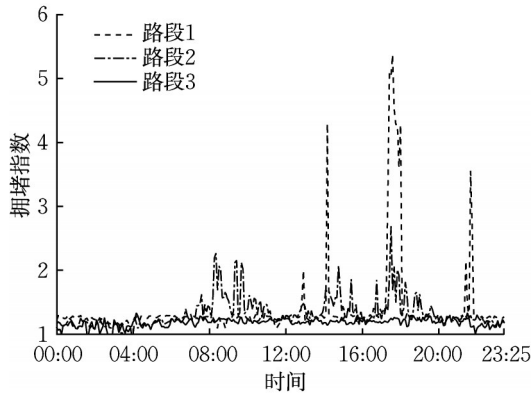


图6 某市3条路段拥堵指数随时间的变化

Fig.6 Variation of traffic congestion index with time at three road sections in a city

### 3.1.2 特征工程

原始数据只包括时间、充电站历史充电负荷、天气、温度和交通流量数据,为了进一步提高预测的准确性以及更加精确地描述数据,需从原始数据中进一步提取特征。将输出功率发生时间的月、日、星期、时刻信息进行拆分,构造 month、day、dayofweek 和 hour 特征。然后,判断该时间是一年中的第几天、第几个星期、是否为工作日,构造 days、week 和 is\_workday 特征。针对充电站的输出功率数据,采用时间窗移动方法,选择预测前1~4 h的输出功率作为新特征,并计算前2~4 h输出功率的最大值、最小值、均值与标准差,对特征进一步补充。模型最终输入特征如表1所示。

### 3.2 评价指标

在机器学习的回归分析中,采用线性回归决定系数( $R^2$ )进行回归预测时会考虑元素分布,相比于对称平均绝对百分比误差( $e_{\text{SMAPE}}$ )更具真实性,并且不存在可解释性限制,同时相比于均方误差( $e_{\text{MSE}}$ )、均方根误差( $e_{\text{RMSE}}$ )、平均绝对误差( $e_{\text{MAE}}$ )和平均绝对百分比误差( $e_{\text{MAPE}}$ )可解释性更佳<sup>[30]</sup>。选取 $R^2$ 作为预测模型的评价指标。由于充电站存在功率为零的情况,该情况会造成平均绝对百分比误差无法计算,因此选择加权平均绝对百分比误差( $e_{\text{WMAPE}}$ )作为模型的另一评价指标。 $R^2$ 与加权平均绝对百分比误差计算式如下所示:

$$R^2 = \frac{\sum (y_i - \bar{y})^2}{\sum (\hat{y}_i - \bar{y})^2} \quad (2)$$

$$e_{\text{WMAPE}} = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{\sum_{i=1}^n \hat{y}_i} \quad (3)$$

表1 模型的输入特征

Tab.1 Input characteristics of the model

类型	名称	说明
特征1	pdate	充电功率记录时间
特征2	days	一年的第几天
特征3	month	所在月份
特征4	week	一年的第几个星期
特征5	day	所在月份的第几天
特征6	hour	几点
特征7	dayofweek	周几
特征8	is_workday	是否为工作日
特征9	tem_max	当日最高温度
特征10	tem_min	当日最低温度
特征11	weather_day	当日白天天气
特征12	weather_night	当日夜晚天气
特征13	rolling_1h	预测时刻前1 h的输出功率
特征14	rolling_2h_max	预测时刻前2 h的输出功率最大值
特征15	rolling_2h_min	预测时刻前2 h的输出功率最小值
特征16	rolling_2h_mean	预测时刻前2 h的输出功率均值
特征17	rolling_2h_std	预测时刻前2 h的输出功率标准差
特征18	rolling_2h	预测时刻前2 h的输出功率
特征19	rolling_3h_max	预测时刻前3 h的输出功率最大值
特征20	rolling_3h_min	预测时刻前3 h的输出功率最小值
特征21	rolling_3h_mean	预测时刻前3 h的输出功率均值
特征22	rolling_3h_std	预测时刻前3 h的输出功率标准差
特征23	rolling_3h	预测时刻前3 h的输出功率
特征24	rolling_4h_max	预测时刻前4 h的输出功率最大值
特征25	rolling_4h_min	预测时刻前4 h的输出功率最小值
特征26	rolling_4h_mean	预测时刻前4 h的输出功率均值
特征27	rolling_4h_std	预测时刻前4 h的输出功率标准差
特征28	rolling_4h	预测时刻前4 h的输出功率
特征29	station_name	充电站名称

式中: $n$ 为测试样本数量; $\hat{y}_i$ 为第 $i$ 个样本的真实值; $y_i$ 为第 $i$ 个样本的预测值; $\bar{y}$ 为样本均值。

### 3.3 结果比较与分析

#### 3.3.1 特征重要性分析

线上XGBoost模型的输入变量只有一个流量特征,因此只对线下LightGBM模型的多个特征的重要性进行分析。回归分析时LightGBM模型采用分裂信息增益作为决策树的重要性构建指标,特征在决策树中出现次数越多则越重要,该特征的信息增益总和也越大。信息增益计算式为

$$G_s = G_l - \frac{N_l}{N_t} G_1 - \frac{N_r}{N_t} G_r \quad (4)$$

式中: $N_l$ 、 $N_r$ 分别为左右子节点的样本总数; $N_t = N_l + N_r$ ;  $G_1$ 、 $G_r$ 分别为左右子节点的基尼系数。筛选信息增益最大的前29个特征构建特征重要性分析图,结果如图7所示。

重要性为零的特征在图7中不会体现。图7a中共有27个特征的重要性分析结果,缺少days和station\_name因素的结果,图7b中共有28个特征的重要性分析结果,缺少days因素的结果。这表明

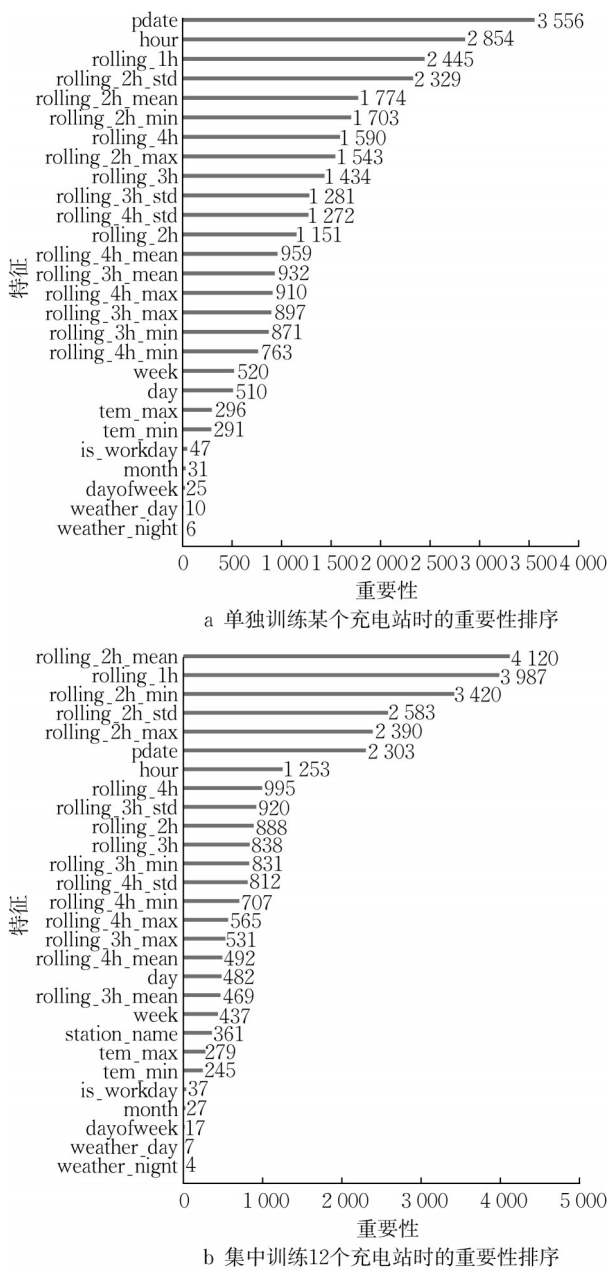


图 7 充电站特征重要性分析

Fig.7 Importance analysis of charging station features

days 因素对模型预测性能的提升并无显著帮助,在决策树中从未被用作分裂点,训练单个充电站和集中训练多个充电站的过程中其重要性均为零。此外,训练单个充电站的过程中 station\_name 因素为定值,其重要性同样被认为是零。

对图 7a、b 进行分析比较可发现,一个充电站和多个充电站的情况下,特征重要性具有高度相似性,时间因素与历史充电负荷统计值均处在重要性排序的前列,说明这 2 类数据是影响充电负荷预测的主要因素。天气在图 7a、b 中均未排到一个较高的位置,说明天气没有起到重要作用,这一结论佐证了天

气数据不会为充电负荷预测模型性能带来显著改善的观点<sup>[31]</sup>。同时发现,station\_name 因素的重要性不是很高,与时间、温度等因素相比,充电站自身属性对于充电站充电负荷预测重要性相对较低。以上分析为建立通用模型提供了有力的理论支持。

### 3.3.2 结果分析

为了验证 LightGBM 与 XGBoost 组合模型的有效性,将实验数据按照 4:1 的比例划分为训练集和测试集,选择单一算法模型随机森林(RF)、LightGBM、XGBoost、多层感知机(MLP)以及组合模型 LightGBM-RF 作为对比模型,与 LightGBM 与 XGBoost 组合模型的充电负荷预测结果进行对比,结果如表 2 所示。对比分析结果表明,LightGBM 与 XGBoost 组合模型在  $R^2$  和  $e_{WMAPE}$  上均表现最佳。 $R^2$  提升到了 0.999 928,其余模型则均未能超过 0.999 900; $e_{WMAPE}$  降低至 0.227 7%,远低于其余模型的最佳值 0.825 6%。相较单一模型,LightGBM-XGBoost 利用组合模型的优势,充分考虑数据的实时性,预测精度更优。比较 2 个组合模型,两者只在线上模型的选择上存在区别,XGBoost 模型相较于 RF 模型更能适应线上输入数据的特点,因此 LightGBM-XGBoost 组合模型相较于 LightGBM-RF 组合模型预测精度更高。

表 2 6 种模型的预测结果

Tab.2 Prediction results of six models

模型	评价指标	
	$R^2$	$e_{WMAPE}/\%$
RF	0.998 539	0.863 0
LightGBM	0.998 108	2.275 2
XGBoost	0.998 527	2.117 6
MLP	0.996 865	3.015 8
LightGBM-RF	0.999 661	0.825 6
LightGBM-XGBoost	0.999 928	0.227 7

分别选择 1、12、24、36、48、60、72、84 个充电站对模型进行训练,再从该城市 3 个不同的市辖区分别选择一个典型充电站进行充电负荷预测,3 个充电站分别命名为充电站 1、充电站 2、充电站 3,验证组合模型的通用性,结果如图 8 所示。

选择的 3 个充电站均在单站训练的情况下得到最优预测结果,随着充电站数目的增加,预测结果均出现不同程度的波动,但并未形成一个稳定的变优或变坏趋势,仍处在一个优异表现的范围内,说明 LightGBM-XGBoost 组合模型能够有效实现一个模型对多个充电站的预测。



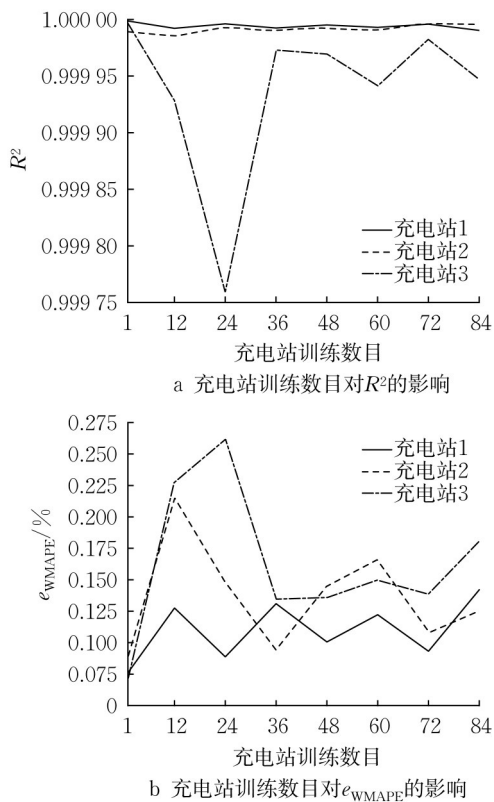


图8 充电站数目对 $R^2$ 和 $e_{WMAPE}$ 的影响

Fig.8 Effect of the number of charging stations on  $R^2$  and  $e_{WMAPE}$

## 4 结语

新能源汽车的高速发展为电网带来压力,实现充电站充电负荷的精准预测十分必要。考虑天气、温度、交通流量等影响因素,构建了时间、历史充电负荷统计量等新特征,基于LightGBM与XGBoost模型提出了线下-线上相结合的组合算法。以数据的实时变化为标准,分批将数据输入线下-线上模型,并通过选择不同数目的充电站进行训练,创建了一个能够精准预测多个充电站充电负荷的通用模型。相比RF、LightGBM、XGBoost、MLP模型以及LightGBM-RF组合模型,LightGBM-XGBoost组合模型的预测结果具有更高的精度,并且线下线上相结合的形式能够实现模型结果的实时更新,对于新能源汽车与电网的有效整合具有积极影响。

未来应对算法进行进一步优化,探究充电车辆的类型、充电站位置等因素对充电站充电负荷预测的影响,优化参与训练充电站的选择标准,减少充电站的不同组合对预测精度的影响,构建更具通用性的模型。

## 作者贡献声明:

李 波:论文框架设计,建模仿真,论文撰写与修改。  
王 宁:研究思路指导,论文审阅与修改。  
吕叶林:数据采集与分析,论文撰写。  
陈 宇:图表绘制,论文撰写。

## 参考文献:

- [1] 夏文芳. 电动汽车用电负荷预测及对城市电网的影响[J]. 农村电气化, 2018(11): 9.  
XIA Wenfang. Electric vehicle load prediction and analysis of influence of electric vehicle load on urban power network [J]. Rural Electrification, 2018(11): 9.
- [2] MÜLLER M, BLUME Y, REINHARD J. Impact of behind-the-meter optimised bidirectional electric vehicles on the distribution grid load[J]. Energy, 2022, 255: 124537.
- [3] ALLENSPACH C, HOGGER R, OBUSHEVS A, *et al.* Implementation of quasi-static time series simulations for analysis of the impact of electric vehicles on the grid[C]//2019 IEEE 60th International Scientific Conference on Power and Electrical Engineering of Riga Technical University (RTUCON). Piscataway: IEEE, 2019: 1-10.
- [4] ZWEISTRA M, JANSSEN S, GEERTS F. Large scale smart charging of electric vehicles in practice [J]. Energies, 2020, 13(2): 298.
- [5] 魏阳陆. 电动汽车充电对电网影响综述[J]. 时代汽车, 2022(2): 108.  
WEI Yangzhe. Overview of the impact of electric vehicle charging on the power grid [J]. Times Automotive, 2022(2): 108.
- [6] 金兆鹏. 电动汽车大规模接入对电网安全运行影响及管控措施分析[J]. 装备维修技术, 2019(4): 159.  
JIN Zhaopeng. Analysis of the impact of large-scale access of electric vehicles on the safe operation of power grid and control measures [J]. Equipment Technology, 2019(4): 159.
- [7] 陈男, 孙晓东, 马志鹏. 电动汽车接入电网对电网谐波的影响 [J]. 电子测试, 2021(17): 122.  
CHEN Nan, SUN Xiaodong, MA Zhipeng. The impact of electric vehicles connected to the grid on grid harmonics [J]. Electronic Test, 2021(17): 122.
- [8] BUZNA L, DE FALCO P, FERRUZZI G, *et al.* An ensemble methodology for hierarchical probabilistic electric vehicle load forecasting at regular charging stations [J]. Applied Energy, 2021, 283: 116337.
- [9] DENG S, CHEN F, WU D, *et al.* Quantitative combination load forecasting model based on forecasting error optimization [J]. Computers and Electrical Engineering, 2022, 101: 108125.
- [10] 蔡黎, 葛棚丹, 代妮娜, 等. 电动汽车入网负荷预测及其与电网互动研究进展综述[J]. 智慧电力, 2022, 50(7): 96.  
CAI Li, GE Pengdan, DAI Nina, *et al.* Review of research progress on load prediction and grid interaction of electric vehicles [J]. Smart Power, 2022, 50(7): 96.
- [11] 王哲, 万宝, 凌天晗, 等. 基于谱聚类和LSTM神经网络的电动公交车充电负荷预测方法[J]. 电力建设, 2021, 42(6): 58.

- WANG Zhe, WAN Bao, LING Tianhan, *et al.* Electric bus charging load forecasting method based on spectral clustering and LSTM neural network [J]. *Electric Power Construction*, 2021, 42(6): 58.
- [12] 王琨, 高敬更, 张勇红, 等. 基于LSTM神经网络的复合变量电动汽车充电负荷预测方法技术研究[J]. *工业仪表与自动化装置*, 2019(1): 27.
- WANG Kun, GAO Jinggeng, ZHANG Yonghong, *et al.* Study on forecasting method of charging load of hybrid variable electric vehicle based on LSTM neural network [J]. *Industrial Instrumentation & Automation*, 2019(1): 27.
- [13] ZHENG Y, SHAO Z, ZHANG Y, *et al.* A systematic methodology for mid-and-long term electric vehicle charging load forecasting: the case study of Shenzhen, China [J]. *Sustainable Cities and Society*, 2020, 56: 102084.
- [14] 陈丽丹, 张尧, FIGUEIREDO A. 电动汽车充放电负荷预测研究综述[J]. *电力系统自动化*, 2019, 43(10): 177.
- CHEN Lidan, ZHANG Yao, FIGUEIREDO A. Overview of charging and discharging load forecasting for electric vehicles [J]. *Power System Automation*, 2019, 43(10): 177.
- [15] 梁宏涛, 刘红菊, 李静, 等. 基于机器学习的短期负荷预测算法综述[J]. *计算机系统应用*, 2022, 31(10): 25.
- LIANG Hongtao, LIU Hongju, LI Jing, *et al.* Survey on short-term load forecasting algorithm based on machine learning [J]. *Computer Systems & Applications*, 2022, 31(10): 25.
- [16] 王华彪, 李小勇. 基于融合注意力机制改进双向长短期记忆网络在电动汽车充电负荷中的预测研究[J]. *电网与清洁能源*, 2022, 38(6): 104.
- WANG Huabiao, LI Xiaoyong. Prediction of electric vehicle charging load based on integrating attention mechanism to improve BiLSTM [J]. *Power System and Clean Energy*, 2022, 38(6): 104.
- [17] FENG J, YANG J, LI Y, *et al.* Load forecasting of electric vehicle charging station based on grey theory and neural network [J]. *Energy Reports*, 2021, 7: 487.
- [18] SHEN X, ZHAO H, XIANG Y, *et al.* Short-term electric vehicles charging load forecasting based on deep learning in low-quality data environments [J]. *Electric Power Systems Research*, 2022, 212: 108247.
- [19] 李恒杰, 朱江皓, 傅晓飞, 等. 基于集成学习的电动汽车充电站超短期负荷预测[J]. *上海交通大学学报*, 2022, 56(8): 1004.
- LI Hengjie, ZHU Jianghao, FU Xiaofei, *et al.* Ultra-short-term load forecasting of electric vehicle charging stations based on ensemble learning [J]. *Journal of Shanghai Jiao Tong University*, 2022, 56(8): 1004.
- [20] 吴丹, 雷琰, 李芝娟, 等. 基于XGBoost与LightGBM集成的电动汽车充电负荷预测模型[J]. *电子技术应用*, 2022, 48(9): 44.
- WU Dan, LEI Ting, LI Zhijuan, *et al.* Electric vehicle charging load forecasting based on XGBoost and LightGBM integration model [J]. *Application of Electronic Technique*, 2022, 48(9): 44.
- [21] 邱瑞东, 何山, 董宁, 等. 基于LSTM-LGB模型的光伏电站辐照强度预测[J]. *安徽大学学报(自然科学版)*, 2021, 45(3): 66.
- QIU Ruidong, HE Shan, DONG Ning, *et al.* Irradiation intensity prediction of photovoltaic power station based on LSTM-LGB model [J]. *Journal of Anhui University (Natural Sciences)*, 2021, 45(3): 66.
- [22] 肖迁, 穆云飞, 焦志鹏, 等. 基于改进LightGBM的电动汽车电池剩余使用寿命在线预测[J]. *电工技术学报*, 2022, 37(17): 4517.
- XIAO Qian, MU Yunfei, JIAO Zhipeng, *et al.* Improved LightGBM based remaining useful life prediction of lithium-ion battery under driving conditions [J]. *Transactions of China Electrotechnical Society*, 2022, 37(17): 4517.
- [23] 昌玲, 邓国安. 基于LightGBM及LSTM融合的科技园区短期负荷预测[J]. *湖南电力*, 2021, 41(6): 31.
- CHANG Ling, DENG Guoan. Short term load forecasting of science and technology park based on integration of LightGBM and LSTM [J]. *Hunan Electric Power*, 2021, 41(6): 31.
- [24] 蔡明, 孙杰, 李培德, 等. 三种机器学习算法在回归应用中的对比分析[J]. *智能计算机与应用*, 2022, 12(8): 165.
- CAI Ming, SUN Jie, LI Peide, *et al.* Comparative analysis of three machine learning algorithms in regression application [J]. *Intelligent Computers and Applications*, 2022, 12(8): 165.
- [25] 卢锦玲, 郭鲁豫, 张梦雪, 等. 基于MGS-LGBM算法的电力系统暂态稳定评估[J]. *电力科学与工程*, 2020, 36(3): 52.
- LU Jinling, GUO Luyu, ZHANG Mengxue, *et al.* Power system transient stability assessment based on MGS-LGBM [J]. *Electric Power Science and Engineering*, 2020, 36(3): 52.
- [26] 肖宇, 赵建有, 叱干都, 等. 基于XGBoost的短时出租车速度预测模型[J]. *交通信息与安全*, 2022, 40(3): 163.
- XIAO Yu, ZHAO Jianyou, CHIGAN Du, *et al.* A short-term prediction model for taxi speed based on XGBoost [J]. *Journal of Transport Information and Safety*, 2022, 40(3): 163.
- [27] 杨洋, 谷震浩. 基于XGBoost-DNN的中期电力负荷预测[J]. *计算机系统应用*, 2021, 30(9): 186.
- YANG Yang, GU Zhenhao. Mid-term power load forecasting based on XGBoost-DNN [J]. *Computer System & Applications*, 2021, 30(9): 186.
- [28] DONG J, CHEN Y, YAO B, *et al.* A neural network boosting regression model based on XGBoost [J]. *Applied Soft Computing*, 2022, 125: 109067.
- [29] 代业明, 周琼. 基于改进Bi-LSTM和XGBoost的电力负荷组合预测方法[J]. *上海理工大学学报*, 2022, 44(2): 138.
- DAI Yeming, ZHOU Qiong. Power load combination forecasting method based on improved Bi-LSTM and XGBoost [J]. *Journal of University of Shanghai for Science and Technology*, 2022, 44(2): 138.
- [30] CHICCO D, WARRENS M J, JURMAN G. The coefficient of determination  $R$ -squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation [J]. *PeerJ Computer Science*, 2021, 7: e623.
- [31] AMARA-OUALI Y, GOUDE Y, HAMROUCHE B, *et al.* A benchmark of electric vehicle load and occupancy models for day-ahead forecasting on open charging session data [C]// *Proceedings of the Thirteenth ACM International Conference on Future Energy Systems*. New York: ACM, 2022: 193-207.