

引用格式:伍毅平,杨傲然,陈家源,等. 基于 LightGBM 的电动汽车动力电池故障双层诊断模型[J]. 北京工业大学学报, 2025, 51(2): 183-191.

WU Y P, YANG A R, CHEN J Y, et al. Double-layer diagnosis model for electric vehicle power battery faults based on LightGBM[J]. Journal of Beijing University of Technology, 2025, 51(2): 183-191. (in Chinese)

基于 LightGBM 的电动汽车动力电池故障 双层诊断模型

伍毅平^{1,2}, 杨傲然^{1,2}, 陈家源^{1,2}, 荣建³, 马俊^{1,2}, 宋鹏^{1,2}

(1. 北京工业大学交通工程北京市重点实验室, 北京 100124; 2. 北京工业大学城市交通学院, 北京 100124;
3. 广州大学土木工程学院, 广州 510006)

摘要: 动力电池是电动汽车的能量之源,需要准确预测动力电池故障并识别其故障类型以保障电动汽车的安全性和可靠性。基于 10 辆纯电动汽车 6 个月的实车监测数据,提取 16 个特征数据为输入,以电池故障类型为输出,通过模型训练和参数调优,建立了基于 LightGBM 的电动汽车动力电池故障双层诊断模型。上层模型用于判断车辆动力电池是否存在故障,下层模型对具体故障类型进行诊断分析。结果表明:该模型能够完全正确预测电动汽车动力电池是否发生故障,诊断故障类型的准确率达 94.05%。同时,根据模型结果特征值排序筛选出了影响动力电池是否发生故障的主要特征。研究成果为识别电动汽车动力电池状态、分析故障类型以及诊断故障原因提供了方法支撑。

关键词: 电动汽车; 动力电池; 故障诊断; LightGBM; 双层模型; 特征排序

中图分类号: U 491

文献标志码: A

文章编号: 0254-0037(2025)02-0183-09

doi: 10.11936/bjtxb2023030031

Double-layer Diagnosis Model for Electric Vehicle Power Battery Faults Based on LightGBM

WU Yiping^{1,2}, YANG Aoran^{1,2}, CHEN Jiayuan^{1,2}, RONG Jian³, MA Jun^{1,2}, SONG Peng^{1,2}

(1. Beijing Key Laboratory of Traffic Engineering, Beijing University of Technology, Beijing 100124, China;

2. College of Metropolitan Transportation, Beijing University of Technology, Beijing 100124, China;

3. School of Civil Engineering, Guangzhou University, Guangzhou 510006, China)

Abstract: Power battery is the energy source for electric vehicles. It is of great significance to ensure the safety and reliability of electric vehicles by accurately predicting power battery failures and identifying their fault types. Based on the 6-month actual vehicle monitoring data of 10 pure electric vehicles, 16 feature data were extracted as input and the battery fault type was used as the output. A double-layer diagnosis model for electric vehicle power battery faults based on LightGBM was established through model training and parameter tuning. The upper-layer model was used to determine whether the vehicle power battery is fault. The lower-layer model diagnosed and analyzed the specific fault type. Results show

收稿日期: 2023-03-26; 修回日期: 2023-04-13

基金项目: 国家自然科学基金资助项目(52102403)

作者简介: 伍毅平(1990—), 男, 副教授, 主要从事驾驶行为、交通安全、智能交通方面的研究, E-mail: wuyiping@bjut.edu.cn

that whether the electric vehicle power battery will be fault can be correctly predicted. The accuracy of diagnosing the fault type is 94.05%. Meanwhile, the main features that affect the failure of the power battery are screened out according to the ranking of the eigenvalues of the model results. This study provides an approach for identifying the state of electric vehicle power battery, analyzing the fault type and diagnosing the cause of the fault.

Key words: electric vehicle; power battery; fault diagnosis; LightGBM; double-layer model; feature sorting

“双碳”目标背景下新能源汽车尤其是电动汽车发展迅速,已经成为现代汽车发展的主要方向。动力电池是电动汽车的能量之源,是电动汽车安全稳定运行的关键。电池状况异常可能导致车辆故障甚至交通事故,对驾驶人和乘客造成安全风险。因此,及时准确预测电动汽车动力电池状态并诊断其故障类型和致因,对于保障电动汽车安全与稳定运行具有重要意义。

目前,可以将众多故障诊断方法大致分为3类,分别为基于知识的诊断方法、基于模型的诊断方法以及基于数据驱动的诊断方法^[1]。基于知识的诊断方法不需要借助复杂的数学模型,主要是依靠经验和理论知识进行故障诊断,比较方便实施,但获取知识库的难度较大,从而导致应用范围在一定程度上受限制^[2]。基于模型的诊断方法通过借助数学、物理等领域已有的原理构建模型,将实际测量值与模型估计值进行比较,得到残差信号,从而进一步实现故障诊断^[3]。当有足够多的机理知识或物理原理时,基于模型的方法更有针对性,并且能够取得较好的诊断结果。但随着各种设备越来越复杂,系统的原理知识难以获得,从而很难建立精度较高的模型。基于数据驱动的诊断方法以采集得到的监测数据为基础,结合各种数据挖掘技术描述系统运行的状况,从而达到故障诊断的目的^[4]。在机器学习、深度学习等技术蓬勃发展的今天,基于数据驱动的诊断方法正逐渐成为故障诊断领域的研究热点。该方法不过分依赖于经验知识,也不过多需要被诊断设备具体的数学、物理模型,主要通过故障数据进行分析和处理并结合合适的算法进行诊断^[5]。

近年来,众多国内外学者基于数据驱动的诊断方法对电动汽车动力电池故障诊断进行研究。目前该类方法主要可以分为统计分析法和机器学习法。在统计分析层面,Xia等^[6]提出一种基于相关系数分析法的短路故障检测方法,通过计算电池单体电压之间的相关系数,判断电池系统是否

出现短路。Li等^[7]提出一种基于类内相关系数的电池电压故障检测方法,并对从电动汽车服务管理中心采集到的电压数据进行仿真,验证了该方法在电池故障诊断中的有效性。Kang等^[8]提出一种基于交错式电压测量拓扑和改进相关系数法的多故障诊断策略,可以诊断电池内部短路和外部短路等故障。杨洋等^[9]根据电池单体电压采样数据,提出一种利用相关系数法对电池组连接松脱故障进行诊断的方法,并通过数学推导和仿真实验证明方法的有效性。

在机器学习层面,李晓辉等^[10]考虑电池历史状态数据,设计了一种基于模糊神经网络的动力电池故障诊断系统,实现对电池故障的诊断并给出故障的严重程度。谢静等^[11]将模糊诊断技术与反向传播(back propagation, BP)神经网络相结合,构建了一种以电池电压为主要故障特征的故障诊断模型。赵士博^[12]结合模糊逻辑和径向基函数(radial basis function, RBF)神经网络设计动力电池故障诊断系统,成功实现对电池容量变小、内阻过大、充电不足和自放电大这4种故障类型的准确诊断。刘振宇^[13]结合减聚类算法,提出一种基于改进的RBF神经网络的动力电池故障诊断方案,实现了动力电池单体故障诊断。

上述研究主要是基于电池电压数据进行故障诊断,能够较好地诊断出一种或几种故障类型,但动力电池故障类型较多,其诊断范围仍需拓展。本文以新能源汽车的实际行驶数据为基础分析电池故障,在原始数据中拥有32个特征信息,包含车辆状态、车速、电压、电流以及温度等,避免了仅依靠电池电压数据来诊断电池故障的局限。此外,统计原始数据发现,有97.5%的数据处于安全状态,而出现故障的数据仅占2.5%,因此本文将诊断过程分为2个阶段,建立双层模型先判断电池是否存在故障,再甄别具体故障类型。

在诊断方法的选取上,本文主要基于梯度提升

决策树(gradient boosting decision tree, GBDT)^[14]开展研究。GBDT 计算简单,易于训练,可解释性强,具有高效、快速和并行等优点,能够在相对短的时间内对大型数据做出可行且效果良好的分析。LightGBM(light gradient boosting machine)^[15]是实现 GBDT 算法的框架,能够支持高效率的并行训练。相对于广泛使用的 XGBoost,LightGBM 具有训练速度更快、占用内存更低等优点。王思宇等^[16]利用金融信贷机构的数据集,证明 LightGBM 算法的效果要优于 LR、CART、NB、RFC、ETC、XGBoost。张国庆等^[17]采用 LightGBM 算法预测德国信用卡违约情况,并选取 Logistic、SVM、随机森林等常用模型进行对比,结果表明 LightGBM 模型预测效果最好。LightGBM 算法也被广泛应用到医学^[18]、机械故障检测^[19]、风力发电功率预测^[20]、航班延误预测^[21]和高校就业预测^[22]等多个方向。因此,本文提出一种基于 LightGBM 的电动汽车电池故障双层诊断模型,以期实现基于实车运行数据的电池故障及其类型准确识别。

1 数据处理

1.1 样本数据说明

本文所用数据来源于新能源汽车国家大数据联盟的开放数据,为某品牌的 10 辆纯电动汽车近 6 个月的实际行驶数据,数据采集字段符合国标 GB/T 32960 要求,数据采集周期为 10 s,获得的样本总数约为 551 万条。

1.2 数据预处理

由于汽车传感器在数据采集过程中受到信号波动影响,可能出现数据不完整、存在异常值、出现重复数据等情况,因此在正式分析前,通过填补缺失值、光滑噪声数据、平滑或删除离群点等对数据进行清洗,主要原则如下:

1) 对于缺失值、空值,采取删除样本数据或删除变量的方法。如数据集中的“充电储能装置故障代码列表”数据均为空值,因此删除该字段。

2) 对于异常值,根据数据集中字段的有效值范围进行筛选,将超出有效值范围的样本数据删除。如数据集中“总电流”的有效值范围为 0 ~ 20 000,其中有的值为 -1 782,故将其删除。

3) 对于在各样本之间没有差异性的数据字段,采用删除的方法。如数据集中的“运行模式”均为纯电动,“单体电池总数”均为 95 个等,因此在后续研究中不考虑这些字段。

4) 删除与电池故障预警之间没有关系的字段信息,如数据集中的“车辆 ID”。

5) 对于数据集中个别数据量较少的故障类型数据,采用删除法。在众多故障数据中,大部分故障类型的数据量都在 100 条甚至 1 000 条以上,而有些故障类型仅有 1 条或十几条数据,由于数据量差距悬殊,因此这些故障类型在本文中不予考虑。

对原有的 551 万数据进行数据预处理后,得到剩余样本数约为 377 万条。

1.3 数据样例

本文采用电动汽车实际运行数据分析电池故障类型,该数据集共有 32 个字段,经过数据预处理之后,选取了其中的 20 个特征数据字段,如表 1 所示。

表 1 数据字段信息

Table 1 Data field information

数据字段名称	字段定义
vehicle_state	车辆状态
charging_status	充电状态
speed	车速
gear	挡位
total_volt	总电压
total_current	总电流
mileage	累计里程
standard_soc	SOC-国标
max_cell_volt	电池单体电压最高值
max_cell_volt_id	最高电压电池
min_cell_volt	电池单体电压最低值
min_cell_volt_id	最低电压电池
max_temp	最高温度值
max_temp_probe_id	最高温度探针
min_temp	最低温度值
min_temp_probe_id	最低温度探针
max_alarm_lvl	最高报警等级
isulate_r	绝缘阻值
dcdc_stat	DC-DC 状态
alarm_info	通用报警标志

部分数据样例如表 2 所示,其中,在车辆状态一列:“1”表示启动状态;“2”表示熄火状态;“3”表示其他状态。在充电状态一列:“1”~“4”分别表示停车充电、行驶充电、未充电、充电完成。在最高报警等级一列:“0”表示无故障;“1”表示 1 级故障,即不影响车辆正常行驶的故障;“2”表示 2 级故障,即影响车辆性能,需要驾驶员限制行驶的故障;“3”表示

表2 部分数据样例
Table 2 Sample of some data

车速/(0.1 km·h ⁻¹)	车辆状态	充电状态	总电压/(0.1 V)	总电流/(0.1 A)	累计里程/(0.1 km)	最高报警等级
0	1	3	3 830	28	1 553 504	0
345	1	3	3 425	9	639 298	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
0	1	3	3 254	10	1 471 569	1
0	2	3	3 255	0	1 471 569	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮
0	3	3	3 441	0	890	2
0	3	3	3 441	0	890	2

3级故障,也是最高级别故障,指驾驶员应立即停车处理或请求救援的故障。

2 基于 LightGBM 的电池故障双层诊断模型

基于 LightGBM 的电池故障双层诊断模型其构建流程如图 1 所示。将数据预处理之后得到的数据集 D1 进行特征选择,以确定特征数据和标签数据,上层模型判断电池是否故障,筛选电池安全数据,将剩余的故障数据集 D2 代入下层模型并进行调参调优,根据预测结果评估模型性能。

2.1 电池故障预测模型

2.1.1 模型构建

经过数据预处理,获得电池故障车辆数据 9 156 条,电池安全车辆数据约为 376 万条,由于电池安全与故障的数据量差距悬殊,故从电池安全车辆数据中随机抽取其中的 1/400(即 9 398 条数据)进行后续研究,以保证安全与故障 2 类数据量相当。

对特征数据进行分析,得到各特征数据之间的相关性热力图。根据图中不同方块的颜色可以判断特征之间相关性的强弱,颜色越深代表相关性越强。相关系数 r 的取值范围为 $[-1, 1]$,一般认为, $|r| \geq 0.8$ 时,表明高度相关; $0.5 \leq |r| < 0.8$ 时,表明中度相关; $0.3 \leq |r| < 0.5$ 时,表明低度相关; $|r| < 0.3$ 时,说明 2 个变量之间相关性极弱^[23]。

由图 2 可知,总电压和 SOC-国标、电池单体电压最高值之间的相关性最强,相关系数为 0.97;车辆状态和 DC-DC 状态之间高度相关,相关系数为 0.90;车速和总电流中度相关,相关系数为 0.68;最高报警等级与 SOC-国标低度相关,相关系数为

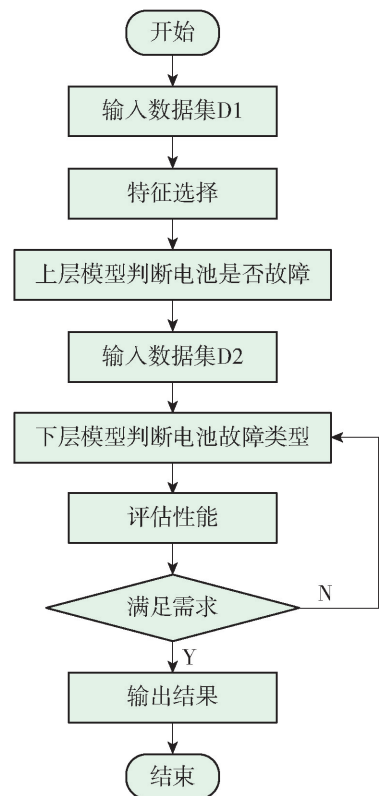


图1 基于 LightGBM 的电池故障诊断流程

Fig. 1 Battery fault diagnosis process based on LightGBM

-0.33;充电状态和车辆状态之间的相关系数为 0,说明这 2 个特征完全不相关。

本文对相关系数 $|r| \geq 0.8$ 的特征进行筛选^[24],删除 SOC-国标、电池单体电压最高值以及 DC-DC 状态,选取表 1 中除“通用报警标志”以及上述 3 个字段以外的其他 16 个字段作为特征数据。标签数据中,将电池安全车辆标记为 0,将电池故障车辆标记为 1。本模型使用默认参数,将数据按 4:1 的比例划分为训练集和测试集。




图 2 电池故障预测模型特征数据相关性热力图

Fig.2 Correlation heat map of characteristic data of battery failure prediction model

2.1.2 模型效果

混淆矩阵是以矩阵形式呈现算法性能的可视化效果。矩阵的行表示真实值,矩阵的列表示预测值,对角线的数值表示预测正确的样本数量。混淆矩阵对角线上的数值越大,对角线的颜色越深,表明模型的精度越高。模型效果测试结果的混淆矩阵如图 3 所示。其中:TP 为 1 901,即有 1 901 个安全样本被正确预测;TN 为 1 810,即有 1 810 个电池故障样本被正确预测;FN、FP 均为 0。这说明该模型预测精度达到 100%。

利用模型预测结果对特征指标重要性进行排序,可以筛选出影响动力电池是否发生故障的主要




图 3 电池故障预测模型混淆矩阵

Fig.3 Confusion matrix of battery failure prediction model

特征。由图 4 可见,车速、最高报警等级、总电压、总电流等特征的重要程度较高。其中,车速是最重要的特征,约占比 55%,说明车速对动力电池的安全性具有很大的影响,控制合理的车速有助于减小电池出现故障的概率。最高报警等级能直观显示出电池的故障程度,数值越大,表明电池的故障程度越严重。总电压对动力电池的安全性能有影响,电压过高或者过低均可能增加电池故障的风险。总电流排在第 4 位,当动力电池长时间通过较大电流时,电池温度持续上升,严重影响电池稳定性和使用寿命,导

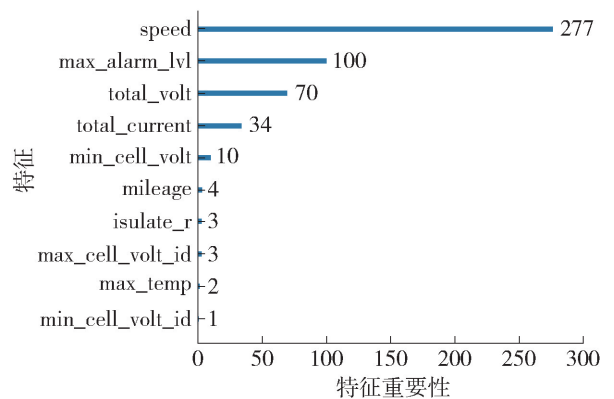


图 4 电池故障预测模型特征重要性

Fig.4 Feature importance of battery failure prediction model

致发生故障的可能性增加。

2.2 故障类型预测模型

2.2.1 模型构建

选取表1中除“通用报警标志”“SOC-国标”“电池单体电压最高值”“DC-DC状态”以外的其他16个字段作为特征数据。由于数据集中部分故障存在重叠现象,对于此类数据,应将并行故障单独提取出来,表示为新的故障类型^[25]。因此,数据集共涉及12种电池故障类型,将标签数据列中

12种通用报警标志依次标记为0~11。标记后的通用报警标志及其对应的故障类型如表3所示。考虑到动力电池是电动汽车的能量之源,电池出现问题可能会导致制动系统、驱动电机、DC-DC出现故障,因此也将其统一归类为动力电池故障类型。

将数据集按照4:1的比例分为训练集和测试集,使用LightGBM算法进行多分类预测,LightGBM的主要参数如表4所示。

表3 动力电池故障类型

Table 3 Types of power battery faults

通用报警标志	定义	故障类型标记
16	SOC 低报警	0
2048	绝缘报警	1
4096	DC-DC 温度报警	2
8192	制动系统报警	3
16384	DC-DC 状态报警	4
32768	驱动电机控制器温度报警	5
40960	制动系统、驱动电机控制器温度报警	6
49152	DC-DC 状态、驱动电机控制器温度报警	7
57344	制动系统、DC-DC 状态、驱动电机控制器温度报警	8
65536	高压互锁状态报警	9
73728	制动系统、高压互锁状态报警	10
106496	制动系统、驱动电机控制器温度、高压互锁状态报警	11

表4 LightGBM 的主要参数

Table 4 Main parameters for LightGBM

模型参数	含义	默认参数值
n_estimators	迭代次数	100
learning_rate	学习率	0.1
max_depth	树的最大深度	-1
num_leaves	叶子节点数	31
min_data_in_leaf	叶子具有最小节点数	20
feature_fraction	特征子抽样	1
bagging_fraction	降采样	1
bagging_freq	降采样频率	0
lambda_l1	L1 正则化	0
lambda_l2	L2 正则化	0
min_split_gain	执行切分的最小增益	0

2.2.2 调参优化

使用GridSearchCV方法对模型进行调参,该方法将K折交叉验证和网格搜索封装在一起,可以在给定的参数范围内找到精度最高的参数。设定模型

的调参范围,依次对表4中的迭代次数、学习率、树的最大深度、叶子节点数、叶子具有最小节点数、特征子抽样、降采样、降采样频率、L1正则化、L2正则化等参数进行调参,调参结果如表5所示。

表 5 调参结果

Table 5 Parameter adjustment results

模型参数	调参范围	调参结果
n_estimators	[100, 1000]	100
learning_rate	[0.001, 1]	0.021
max_depth	[1, 11]	9
num_leaves	[2, 105]	30
min_data_in_leaf	[1, 102]	11
feature_fraction	[0.01, 1]	0.54
bagging_fraction	[0.01, 1]	0.66
bagging_freq	[0, 10]	3
lambda_l1	[0, 1]	0
lambda_l2	[0, 1]	0
min_split_gain	[0, 1]	0.1

2.2.3 模型效果

为了评估多分类模型在多组数据上的总体性能,使用宏平均(macro average)原则来进行计算,即根据每个类别的准确率、召回率与 F1 分数求得算术平均值。将数据集中电池出现故障的数据合并,经过数据预处理,形成具有 9 156 个样本、16 个特征变量、12 个标签的数据集。选取 80% 数据集作为训练集,20% 作为测试集,用调参后的结果替换模型的默认参数,对故障类型进行多分类预测。经过调参,得到模型预测结果的准确率为 94.05%,精确率为 91.34%,召回率为 85.39%,F1 分数为 0.876 8。

图 5 为该模型的混淆矩阵,其中 SOC 低报警、绝缘报警和 DC-DC 温度报警这 3 种故障类型均被正确预测,而制动系统报警、DC-DC 状态报警、驱动

电机控制器温度报警以及其他故障类型存在预测错误的情况。以制动系统报警为例,TP = 209,即有 209 个样本被正确预测为制动系统报警;FN = 17,即有 17 个样本被预测成其他故障类型;FP = 32,即有 32 个样本被错误预测为制动系统报警;TN = 1 573,即有 1 573 个非制动系统报警故障的样本被正确预测为其他故障类型。

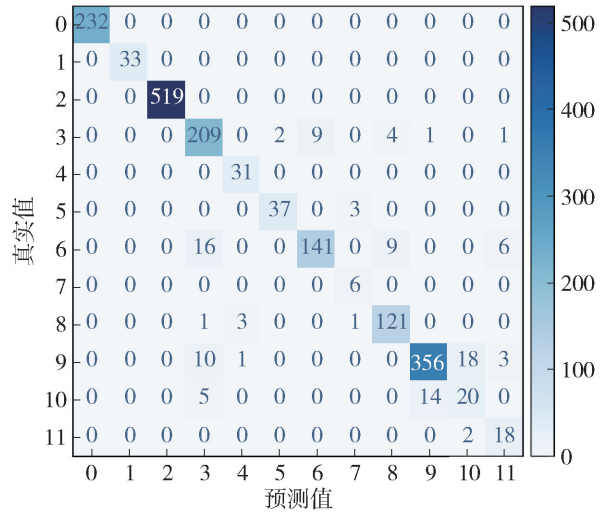


图 5 电池故障类型分类模型混淆矩阵

Fig. 5 Confusion matrix for battery failure type classification model

利用 LightGBM 模型结果对特征进行重要性排序,为后续分析提供依据。绝缘阻值、总电压、电池单体电压最低值和最高电压电池等特征的重要性较高,对结果影响较大,如图 6 所示。其中绝缘阻值是最重要的特征,约占比 23.7%,说明在已发生故障的电池中,有极大可能是绝缘电阻出现了问题。动

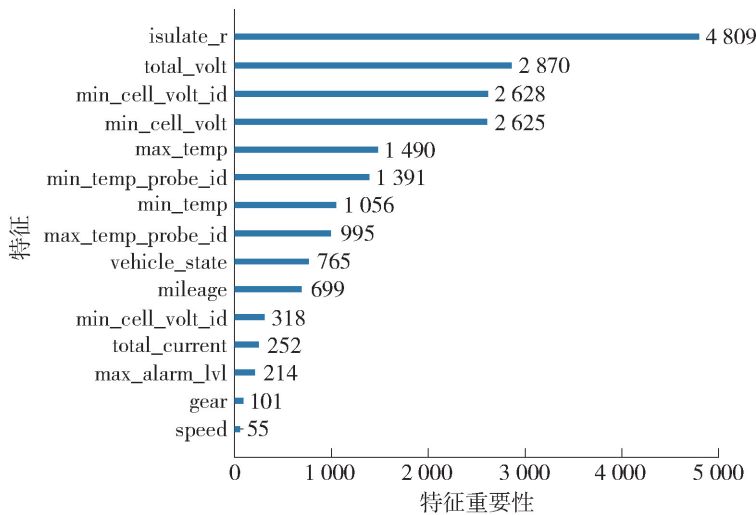


图 6 电池故障类型分类模型特征重要性

Fig. 6 Feature importance of battery fault type classification model

力电池组一般是由多个单体电池串并联而成,电池组的绝缘损坏将造成高压漏电,严重时可能造成人员、外围设备的损坏和安全事故^[26]。为了保证动力电池的安全,要求绝缘电阻应具有较好的绝缘能力,而绝缘阻值的大小能够在一定程度上反映设备的绝缘状态。电池使用时间变长,以及环境温度湿度的变化,可能造成绝缘材料老化,导致电池出现故障。

3 结论

1) 基于 10 辆纯电动汽车 6 个月的实车监测数据,以预测识别电池故障类型为目标,提取 16 个特征数据作为输入、故障类型为输出,构建了一种基于 LightGBM 的电动汽车动力电池故障双层诊断模型。

2) 电池故障诊断模型诊断过程分为 2 个阶段,上层模型用于判断电池是否发生故障,下层模型用于诊断具体的故障类型。模型能够完全正确预测电动汽车动力电池是否发生故障,诊断故障类型的准确率达 94.05%,并且可以得到影响动力电池是否发生故障的主要特征。

3) 研究可为更加准确全面地预测电动汽车动力电池状态、分析故障类型以及诊断故障原因提供支撑。由于抽样数据中动力电池故障数据有限,部分特征数据缺失,未来应考虑收集更丰富全面的故障数据,进一步提升动力电池故障诊断精度,扩大诊断类型覆盖范围。此外,由于数据局限性,本文没有考虑各个厂家动力电池之间的差异、不同电池类型的差别以及室外温度等外界参数的干扰,后续将进一步拓展动力电池自身差异性以及外部条件影响的研究,并考虑将 LightGBM 算法与其他算法对比以提升结果稳定性。

参考文献:

[1] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-9, 16.
LI H, XIAO D Y. Review of data-driven fault diagnosis methods[J]. Control and Decision, 2011, 26(1): 1-9, 16. (in Chinese)

[2] 钟凯. 基于多元统计分析的故障检测与诊断研究[D]. 大连: 大连理工大学, 2020.
ZHONG K. Research on fault detection and diagnosis based on multivariate statistical analysis [D]. Dalian: Dalian University of Technology, 2020. (in Chinese)

[3] 孙振宇, 王震坡, 刘鹏, 等. 新能源汽车动力电池系统故障诊断研究综述[J]. 机械工程学报, 2021, 57(14): 87-104.

SUN Z Y, WANG Z P, LIU P, et al. Review of fault diagnosis of power battery system of new energy vehicles [J]. Journal of Mechanical Engineering, 2021, 57(14): 87-104. (in Chinese)

[4] 郭天骥. 基于机器学习的数据驱动故障诊断方法研究[D]. 杭州: 浙江工业大学, 2019.
WU T J. Research on data-driven fault diagnosis method based on machine learning [D]. Hangzhou: Zhejiang University of Technology, 2019. (in Chinese)

[5] HAMMER B, HASENFUSS A, SCHWENKER F, et al. Artificial neural networks in pattern recognition [J]. Lecture Notes in Computer Science, 2010, 7477(2): 389-392.

[6] XIA B, SHANG Y, NGUYEN T, et al. A correlation based fault detection method for short circuits in battery packs[J]. Journal of Power Sources, 2017, 337: 1-10.

[7] LI X, WANG Z. A novel fault diagnosis method for lithium-ion battery packs of electric vehicles [J]. Measurement, 2018, 116: 402-411.

[8] KANG Y, DUAN B, ZHOU Z, et al. A multi-fault diagnostic method based on an interleaved voltage measurement topology for series connected battery packs [J]. Journal of Power Sources, 2019, 417: 132-144.

[9] 杨洋, 杨林, 李冬冬, 等. 电动汽车电池组连接松脱故障诊断[J]. 汽车技术, 2019(5): 43-48.
YANG Y, YANG L, LI D D, et al. Fault diagnosis of loose connection of electric vehicle battery pack [J]. Automotive Technology, 2019(5): 43-48. (in Chinese)

[10] 李晓辉, 张向文, 周永健, 等. 模糊神经网络的动力电池故障诊断系统[J]. 电源技术, 2019, 43(8): 1391-1394.
LI X H, ZHANG X W, ZHOU Y J, et al. Power battery fault diagnosis system based on fuzzy neural network[J]. Power Sources, 2019, 43(8): 1391-1394. (in Chinese)

[11] 谢静, 于群. 基于模糊神经网络电动汽车电池故障诊断研究[J]. 中国新技术新产品, 2022(6): 20-23.
XIE J, YU Q. Research on battery fault diagnosis of electric vehicle based on fuzzy neural network[J]. China New Technology and New Products, 2022(6): 20-23. (in Chinese)

[12] 赵士博. 电动汽车动力电池故障诊断方法研究[D]. 沈阳: 辽宁工业大学, 2021.
ZHAO S B. Research on fault diagnosis method of electric vehicle power battery [D]. Shenyang: Liaoning University of Technology, 2021. (in Chinese)

[13] 刘振宇. 基于数据挖掘的电动汽车动力电池故障诊断方法研究[D]. 济南: 山东大学, 2022.
LIU Z Y. Research on fault diagnosis method of electric

- vehicle power battery based on data mining[D]. Jinan: Shandong University, 2022. (in Chinese)
- [14] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system [C] // Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016: 785-794.
- [15] KE G, MENG Q, FINLEY T, et al. LightGBM: a highly efficient gradient boosting decision tree[C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook: Curran Associates, Inc., 2017: 3149-3157.
- [16] 王思宇, 陈建平. 基于 LightGBM 算法的信用风险评估模型研究[J]. 软件导刊, 2019, 18(10): 19-22.
WANG S Y, CHEN J P. Research on credit risk assessment model based on LightGBM algorithm [J]. Software Guide, 2019, 18(10): 19-22. (in Chinese)
- [17] 张国庆, 昌宁. 基于 LightGBM 的银行信用卡违约研究[J]. 科技资讯, 2019, 17(12): 8-9.
ZHANG G Q, CHANG N. Research on bank credit card default based on LightGBM[J]. Science and Technology Information, 2019, 17(12): 8-9. (in Chinese)
- [18] LIU Y, YU Z, CHEN C, et al. Prediction of protein crotonylation sites through LightGBM classifier based on SMOTE and elastic net [J]. Analytical Biochemistry, 2020, 609: 113903.
- [19] TANG M, ZHAO Q, DING S X, et al. An improved lightGBM algorithm for online fault detection of wind turbine gearboxes[J]. Energies, 2020, 13(4): 807.
- [20] JU Y, SUN G, CHEN Q, et al. A model combining convolutional neural network and LightGBM algorithm for ultra-short-term wind power forecasting [J]. IEEE Access, 2019, 7: 28309-28318.
- [21] 丁建立, 孙玥. 基于 LightGBM 的航班延误多分类预测[J]. 南京航空航天大学学报, 2021, 53(6): 847-854.
DING J L, SUN Y. Multi-classification prediction of flight delay based on LightGBM[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2021, 53(6): 847-854. (in Chinese)
- [22] 罗丹, 刘旋. 基于 LightGBM 的高校就业预测模型[J]. 电脑与电信, 2020(8): 64-67, 85.
LUO D, LIU X. College employment prediction model based on LightGBM[J]. Computer and Telecommunications, 2020(8): 64-67, 85. (in Chinese)
- [23] 赵海龙, 张丹丹, 黄松, 等. 基于皮尔逊相关系数的海南省地闪密度与雷击故障关系分析[J]. 高压电器, 2019, 55(8): 186-192.
ZHAO H L, ZHANG D D, HUANG S, et al. Analysis of the relationship between ground flash density and lightning strike failure in Hainan Province based on Pearson's correlation coefficient [J]. High Voltage Apparatus, 2019, 55(8): 186-192. (in Chinese)
- [24] 李梦飞, 黄宏成. 基于实车行驶数据的某型号纯电动汽车健康状态模型研究[J]. 传动技术, 2018, 32(3): 8-13.
LI M F, HUANG H C. Research on health state model of a certain model of pure electric vehicle based on real vehicle driving data [J]. Drive Technology, 2018, 32(3): 8-13. (in Chinese)
- [25] 胡澜也, 蒋文博, 李艳婷. 基于 LightGBM 的风力发电机故障诊断[J]. 太阳能学报, 2021, 42(11): 255-259.
HU L Y, JIANG W B, LI Y T. Fault diagnosis of wind turbine based on LightGBM[J]. Journal of Solar Energy, 2021, 42(11): 255-259. (in Chinese)
- [26] 王玉, 游志宇, 刘永鑫, 等. 动力电池组绝缘电阻检测与故障定位[J]. 电子测量技术, 2022, 45(5): 157-162.
WANG Y, YOU Z Y, LIU Y X, et al. Insulation resistance detection and fault location of power battery pack [J]. Electronic Measurement Technology, 2022, 45(5): 157-162. (in Chinese)

(责任编辑 杨开英)