

# 基于新能源客车的电池预警技术研究

黄政祥<sup>1,2</sup>, 李 祥<sup>1,2</sup>, 杨 凯<sup>1,2</sup>, 罗 思<sup>1,2</sup>, 汪昕源<sup>1,2</sup>

(1. 长沙中车智驭新能源科技有限公司, 长沙 410083;

2. 中车时代电动汽车股份有限公司, 湖南 株洲 412007)

**摘 要:**新能源车动力电池的不稳定性,导致电池故障发生速度很快。为此,本文提出一种动力电池故障安全预警方法,通过应用新能源车联网大数据平台的电池数据进行统计分析,提前预警可能存在问题的动力电池单体。

**关键词:**新能源客车; 动力电池; 预警技术

**中图分类号:**U469.1; TM910 **文献标志码:**A **DOI:**10.15917/j.cnki.1006-3331.2025.03.003

## Research on Battery Warning Technique Based on New Energy Bus

HUANG Zhengxiang<sup>1,2</sup>, LI Xiang<sup>1,2</sup>, YANG Kai<sup>1,2</sup>, LUO Si<sup>1,2</sup>, WANG Xinyuan<sup>1,2</sup>

(1. Changsha CRRC Intelligent Control and New Energy Technology Co., Ltd., Changsha 410083, China;

2. CRRC Times Electric Vehicle Co., Ltd., Zhuzhou 412007, China)

**Abstract:** The instability of power batteries in new energy vehicles is the reason for the rapid occurrence of battery failures. Therefore, this paper proposes a warning method of power battery faults safety, which uses battery data from the new energy vehicle networking big data platform to conduct data statistical analysis, and then early warns power battery units of potential being problem.

**Key words:** new energy bus; power battery; warning technique

动力电池作为新能源汽车的核心部件,其安全性能直接影响着车辆的安全,而确保电池安全性的基础就是实现对电池各项数据的实时监控。目前,电池数据的监控主要由电池管理系统(Battery Management System, BMS)来实现, BMS 通过检测电池单体的电压、电流、压差、温度、内阻等参数的变化来进行故障报警<sup>[1-5]</sup>。该故障报警机制属于被动响应式监测,仅在参数异常后触发告警,存在上报间隙就已经发生热失控的问题。鉴于此,本文提出一种动力电池安全预警方法,能够精准预测未来某个时间范围内电池单体是否会出现异常,并根据预测结果提前干预,防止发生热失控。

## 1 电池预警技术原理

电池预警技术原理为:①获取新能源车辆电池系

统单体电池的电压数据;②清洗数据,去除异常数据;③对清洗后的单体电池电压数据进行统计计算;④构建动力电池预警规则,并根据规则进行异常预警。本文重点对数据计算过程和预警规则进行介绍。

### 1.1 数据计算

计算的维度包括:电池系统中所有单体电池电压数据的平均值、标准偏差、第一四分位数、第二四分位数(亦称中位数)、第三四分位数、四分位距、上限、下限。详细计算过程如下:

1) 分析所有单体电池电压数据的分布特征,若数据呈正态分布,则无需进行转换操作;若数据不符合正态分布,则对数据进行取对数或开根号处理,使其转换为正态分布。典型的正态分布如图1所示。

2) 计算正态分布的平均值 $\mu$ 和标准偏差 $\sigma$ :平均值 $\mu$ 是衡量数据集中趋势的指标,反映了数据的中

收稿日期:2024-10-09。

第一作者:黄政祥(1989—),男,工程师,主要从事新能源车平台软件研发与设计工作。E-mail:huangzhengxiang.cy@crrecg.cc。

心位置;标准偏差  $\sigma$  是衡量数据离散程度的指标,反映了数据的波动范围。




图1 典型的正态分布图

①平均值  $\mu$  的计算方式是数据集中所有数值的总和除以数值的个数。公式如下:

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i$$

式中:  $n$  为数据集中数值的个数;  $x_i$  为数据集中的第  $i$  个数值。

②标准偏差  $\sigma$  的计算公式如下:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2}$$

3) 计算正态分布的第一四分位数  $Q_1$ 、第二四分位数  $Q_2$ 、第三四分位数  $Q_3$ 、四分位距  $IQR$ 、上限  $U$ 、下限  $L$ , 其含义及计算公式分别如下:

①第一四分位数  $Q_1$  表示数据集中有 25% 的数据小于或等于这个值, 计算公式为  $Q_1 = \mu - 0.675\sigma$ 。其中, 0.675 这个数值来源于标准正态分布的性质, 由概率 25% 反算出对应的数据偏离值范围为  $\mu - 0.675\sigma$ 。

②第二四分位数  $Q_2$  表示数据集中有 50% 的数据小于或等于该值, 计算公式为  $Q_2 = \mu$ 。

③第三四分位数  $Q_3$  表示数据集中有 75% 的数据小于或等于该值, 计算公式为  $Q_3 = \mu + 0.675\sigma$ 。其中, 0.675 这个数值的来源同上, 由概率 75% 反算出对应的数据偏离值范围为  $\mu + 0.675\sigma$ 。

④四分位距  $IQR$  表示  $Q_3$  和  $Q_1$  之差, 表示数据集中间 50% 数据的范围。计算公式为  $IQR = Q_3 - Q_1 = 2 \times 0.675\sigma = 1.35\sigma$ 。

⑤上限  $U$  是数据集中最大的正常值的估计值。

任何大于  $U$  的数据点都被视为潜在的异常值。计算公式为  $U = Q_3 + 1.5 \times IQR = 2.5Q_3 - 1.5Q_1 = \mu + 2.7\sigma$ 。

⑥下限  $L$  是数据集中最小的正常值的估计值。任何小于  $L$  的数据点都被视为潜在的异常值。计算公式为  $L = Q_1 - 1.5 \times IQR = 2.5Q_1 - 1.5Q_3 = \mu - 2.7\sigma$ 。

各四分位数之间的关系如图 2 所示。




图2 各四分位数之间的关系

## 1.2 预警规则

根据上述计算结果构建动力电池预警规则: 若  $L(\mu - 2.7\sigma) > \text{电池单体电压数据 } x > U(\mu + 2.7\sigma)$ , 则判定该电池单体数据可能存在异常, 并进行预警。此预警规则比行业中通用的  $3\sigma$  预警规则 (即  $\mu - 3\sigma \leq x \leq \mu + 3\sigma$  为正常) 更严格。

## 2 电池预警技术的验证

### 2.1 获取单体电池电压数据

从我司新能源车联网大数据平台中随机抽取一辆新能源车, 并随机抽取标号为 1# 的单体电池电压数据, 时间范围为 2023 年 8 月 30 日 15:27:30 至 16:54:40, 部分电压数据见表 1。

表1 1#单体电池的部分电压数据

| 时刻       | 电压/V | 时刻       | 电压/V |
|----------|------|----------|------|
| 15:27:30 | 3.18 | 15:41:40 | 3.17 |
| 15:27:40 | 3.18 | 15:41:50 | 3.23 |
| 15:27:50 | 3.18 | 16:42:00 | 3.43 |
| 15:28:00 | 3.18 | 16:42:10 | 3.35 |
| 15:28:10 | 3.18 | 16:42:20 | 3.35 |
| 15:28:20 | 3.18 | 16:42:30 | 3.35 |
| 15:28:30 | NULL | 16:42:40 | 3.35 |
| 15:33:40 | 3.0  | 16:42:50 | 3.32 |
| 15:39:10 | 3.48 | 16:54:30 | 3.32 |
| 15:41:30 | 3.15 | 16:54:40 | 3.32 |

## 2.2 对动力电池数据进行清洗

对表 1 中的单体电池电压数据进行清洗,过滤掉其中的异常数据(主要有 NULL 值<sup>[6]</sup>)后另外存储。

## 2.3 对动力电池电压数据进行统计计算

对清洗后另外存储的 180 个电压数据绘制直方图,如图 3 所示。根据动力电池 1#单体电压范围  $[3.0, 3.48]$ ,将其分成 6 组,各中心电压分别为 3.0、3.10、3.20、3.30、3.40、3.50 V,等宽距离为 0.02 V。




图 3 直方图

从图 3 可知,数据分布呈现出中间高、两边低且左右大致对称的特征,初步表明其符合正态分布。

为了进一步验证所取数据是否符合正态分布,引入正态 Q-Q 图法。正态 Q-Q 图法通过分位数据的图形化评估数据集的实际分布与正态分布之间的匹配程度。其基本原理是通过可视化图形比较数据点的排序统计分位数与理论正态分布的分位数之间的匹配关系<sup>[7]</sup>。此处的  $Q$ (分位数)与前面分位数概念的区别为:前面指四分位数的每一部分概率相等;此处指每一组数据的分布频率相等。

作 Q-Q 图的步骤为:①根据数据选择分位数,并对数据进行升序排序,得到有序数据集。②假设数据符合正态分布,使用标准正态分布的累积分布函数(CDF)来查找理论分位数<sup>[8-10]</sup>。③绘制 Q-Q 图:将实际分位数( $Q$ )作为  $x$  轴,理论分位数( $Q$ )作为  $y$  轴,在坐标系中标出所有数据对点。④如果大多数数据对点都紧密分布在  $45^\circ$  直线附近,则表明该数据集很可能符合正态分布。

根据前面的步骤,具体计算如下:①为了清晰地描绘正态 Q-Q 图,根据经验选择三十分位数,将 180 个数据点分成 30 份,形成 31 个分位数据点。②计算出 180 个数据的平均值  $\mu$  为 3.259 4 V,标准偏差  $\sigma$

为 0.099 067 V,再通过累积分布函数查找 31 个实际分位数( $Q$ )对应的理论分位数( $Q$ )。③将实际分位数和对应的理论分位数的数据导入到 SPSS 工具绘制正态 Q-Q 图,如图 4 所示。




图 4 单体 1 电池电压正态 Q-Q 图

从图 4 可知,所有数据对点近似分布在一条  $45^\circ$  直线附近,再次表明数据基本符合正态分布。图 4 中,横坐标为从小到大排列的实际电压数据分位数  $Q$ ;纵坐标为对应的理论电压分位数  $Q$ ,基于假设数据符合正态分布计算得出。

因此,在动力电池单体电压数据符合正态分布的前提下,计算其四分位距、上限值、下限值,分别为 0.117 5 V、3.38 V、3.26 V。

## 2.4 电池预警方法效果验证

在我司新能源汽车大数据平台中,随机抽取 2 辆被本文预警方法识别为磷酸铁锂电池单体电压数据异常的电动车。其中,1 号车被识别为电压数据异常的单体为 6 号、17 号、59 号、134 号、147 号、151 号、159 号;2 号车被识别为电压数据异常的单体为 23 号、67 号、76 号、101 号、164 号、166 号、267 号、289 号、323 号。

为验证上述识别的有效性,用万用表对上述被识别为电压数据异常的单体电池进行拆包检测。首先,拆开 1 号车辆的电池包,用万用表检测电池单体电压,发现电压数据异常的单体为 6 号、17 号、59 号、134 号、147 号,即 1 号车的预警识别准确率为 71.43%;然后对 2 号车进行同样的拆包检测,发现其预警识别准确率为 55.56%。

从实际验证结果看,该预警方法的识别准确率还不算高,但具有一定的指导意义。在实际应用中,我司除了应用该预警方法外,还结合电压波动一致性模

型、压降一致性模型进行综合评判。

### 3 结束语

新能源汽车大数据平台采集的 BMS 电池报警数据<sup>[11]</sup>仅适用于紧急处理, 无法实现动力电池故障的提前预警。本文提出的预警方法能够弥补 BMS 预警功能的不足, 降低车辆电池事故的发生率, 提高整车安全性。后续研究需进一步提高预警识别的准确率。

### 参考文献:

- [1] 郑州宇通客车股份有限公司. 一种基于数据挖掘的车辆故障诊断方法及系统: 201610279367. 0[P]. 2018-09-25.
- [2] 张亮, 桂康哲, 王兴月, 等. 基于新能源汽车大数据的蓄电池亏电预警研究[J]. 时代汽车, 2020(15): 62-63.
- [3] 刘木林, 卜凡涛, 林辉, 等. 电动汽车动力电池热失控过程分析及预警机制设计[J]. 汽车实用技术, 2020(5): 15-17.
- [4] 赖银麟, 杨凯, 刘皓, 等. 锂离子电池安全预警方法综述[J]. 储能科学与技术, 2020, 9(6): 1926-1932.
- [5] 李丹, 刘继红, 周恩飞, 等. 基于 BP 神经网络的动力电池热失控预警方法研究[J]. 客车技术与研究, 2024, 46(5): 7-10.
- [6] 王丹璐, 吴刘仓, 郑桂芬. 基于偏正态数据下位置、均值回归模型的参数估计[J]. 应用数学, 2021, 34(3): 590-599.
- [7] 中国电力科学研究院有限公司, 国家电网有限公司, 国网浙江省电力有限公司. 一种电池模组的预警方法及预警装置: 202010358987. X[P]. 2020-08-11.
- [8] 时玉帅, 熊金峰, 樊海梅. 动力电池常见故障分析与预警方法[J]. 广东化工, 2019, 46(13): 115-116.
- [9] 余承其, 张照生, 刘鹏, 等. 大数据分析技术在新能源汽车行业的应用综述——基于新能源汽车运行大数据[J]. 机械工程学报, 2019, 55(20): 3-16.
- [10] 天津市捷威动力工业有限公司. 一种锂离子电池安全预警装置: 202022994891. 0[P]. 2021-08-03.
- [11] 浙江吉利控股集团有限公司, 吉利汽车研究院(宁波)有限公司. 一种新能源车辆动力电池预警法及系统: 202110476497. 4[P]. 2022-11-22.
- [8] 宋锐, 陈辉, 肖志光, 等. 基于几何矩采样的车道检测算法[J]. 中国科学: 信息科学, 2017, 47(4): 455-467.
- [9] 邓天民, 谢鹏飞, 余洋, 等. 双分支特征自适应融合的车道线检测方法[J/OL]. 吉林大学学报(工学版). <https://doi.org/10.13229/j.cnki.jdxbgxb.20240397>.
- [10] TABELINI L, BERRIEL F R, PAIXÃO M T, et al. Polylanenet: lane estimation via deep polynomial regression[C]//ICPR. 2020 25th International Conference on Pattern Recognition (ICPR). IEEE, 2021: 6150-6156.
- [11] QIN Z, WANG H Y, LI X. Ultra fast structure-aware deep lane detection[C]//University of Edinburgh. Computer Vision - ECCV 2020. Lecture Notes in Computer Science. Berlin: Springer, 2020: 276-291.
- [12] HONDA H, UCHIDA Y. CLRRerNet: improving confidence of lane detection with LaneIoU [C]//IEEE. 2024 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). New York: IEEE, 2024: 1165-1174.
- [13] HOU Y N, MA Z, LIU C X, et al. Learning lightweight lane detection cnns by self attention distillation[C]//IEEE. 2019 IEEE/CVF International Conference on Computer Vision (ICCV). New York: IEEE, 2019: 1013-1021.
- [14] 范英, 石磊, 苏伟伟, 等. 基于 PINet+RESA 网络的车道线检测算法[J]. 江苏大学学报(自然科学版), 2023, 44(4): 373-378.
- [15] PAN X G, SHI J P, LUOP, et al. Spatial as deep: Spatial CNN for traffic scene understanding[C]//AAAI. Proceedings of the AAAI Conference on Artificial Intelligence, 32. Palo Alto: AAAI Press, 2018: 7276-7283.
- [16] CHEN L C, PAPADREOU G, KOKKINOS I, et al. Deeplab: semantic image segmentation with deep convolutional nets, atrousconvolution, and fully connected crfs[J]. IEEE transactions on pattern analysis and machine intelligence, 2018, 40(4): 834-848.
- [17] PHILION J. Fastdraw: addressing the long tail of lane detection by adapting a sequential prediction network [C]//IEEE. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New York: IEEE, 2019: 11582-11591.

(上接第8页)