

采用似然比检测的电动车锂离子电池传感器故障检测方法

刘盼芝^{1,2}, 巫春玲^{1,2}, 李艳波^{1,2}, 郭国防³

- (1. 长安大学能源与电气工程学院, 710064, 西安;
2. 长安大学陕西省交通新能源开发、应用与汽车节能重点实验室, 710064, 西安;
3. 陕西重型汽车有限公司, 710200, 西安)

摘要: 为了降低电池管理系统中传感器故障对电动汽车性能的影响,设计了一种采用似然比检测的故障诊断方法。首先,建立电池等效电路模型,并进行参数辨识,使用扩展卡尔曼滤波(EKF)算法,对所建立的电池模型进行状态估计;接着,根据状态估计结果计算电池端电压残差,并结合电池荷电状态估计,使用似然比检测方法处理残差数据,对电池传感器故障进行诊断,提高故障检测方法的效率;最后,使用电池工况实验数据验证算法的有效性和适应性。结果表明,设计的方法能及时准确地检测到 2 种传感器故障。对于给定的测试条件,电压故障时根据端电压残差检测所需诊断时间在 20 s 内;根据荷电状态(SOC)残差检测所需诊断时间在 100 s 内;电流故障时根据端电压残差检测所需诊断时间在 20 s 内;根据 SOC 残差检测所需诊断时间在 400 s 内。同样测试条件下,采用传统的累积和方法(CUSUM)的诊断时间分别是 20 s 内、445 s 以上、150 s 以上和 1 000 s 以上,可见设计的方法可以明显缩短诊断时间。同时,该方法对故障有较好的敏感性,可以检测传感器小幅度故障,当电压故障信号为正常电压 1% 时仍可以实现故障检测。另外,当电压和电流传感器的发生多次故障时,该方法仍能实现故障检测目标。

关键词: 电池模型;似然比检测;电池传感器故障;故障检测;残差

中图分类号: U469.72 **文献标志码:** A

DOI: 10.7652/xjtuxb202601021 **文章编号:** 0253-987X(2026)01-0211-12

Fault Detection Method for Lithium-Ion Battery Sensors in Electric Vehicles Using Likelihood Ratio Test

LIU Panzhi^{1,2}, WU Chunling^{1,2}, LI Yanbo^{1,2}, GUO Guofang³

- (1. School of Energy and Electrical Engineering, Chang'an University, Xi'an 710064, China;
2. Shaanxi Key Laboratory of New Transportation Energy Development, Application and Vehicle Energy Saving Technology, Chang'an University, Xi'an 710064, China;
3. Shaanxi Heavy Duty Automobile Co., Ltd., Xi'an 710200, China)

Abstract: To mitigate the impact of sensor faults in battery management systems on electric vehicle performance, a fault diagnosis method based on likelihood ratio test theory is designed. First, an equivalent circuit model of the battery is established and parameter identification is performed. The extended Kalman filter (EKF) algorithm is used for state estimation of the established battery model. Subsequently, based on the state estimation results, the terminal

收稿日期: 2025-05-06。 作者简介: 刘盼芝(1980—),女,副教授;李艳波(通信作者),男,教授。 基金项目: 国家自然科学基金资助项目(52172324);陕西省重点研发计划资助项目(211432220216)。

网络出版时间: 2025-09-09

网络出版地址: <https://link.cnki.net/urlid/61.1069.t.20250908.1643.006>

voltage residual of the battery is calculated. Considering the state of charge (SOC) estimation, the likelihood ratio test method is applied to process the residual data, enabling diagnosis of battery sensor faults and improving the efficiency of the fault detection method. Finally, the effectiveness and adaptability of the algorithm are verified using battery operating condition experimental data. The results show that this method can timely and accurately detect two types of sensor faults. Under the given test conditions, for voltage faults, the diagnosis time required based on terminal voltage residuals is within 20 s; based on SOC residuals, it is within 100 s. For current faults, the diagnosis time based on terminal voltage residuals is within 20 s; based on SOC residuals, it is within 400 s. Under the same test conditions, the diagnosis time using the traditional cumulative sum (CUSUM) method is within 20 s, over 445 s, over 150 s, and over 1 000 s, respectively. This demonstrates that the proposed method significantly reduces diagnosis time. Additionally, the method exhibits good sensitivity to faults, enabling the detection of minor sensor faults. It can still detect faults when the voltage fault signal is as low as 1% of the normal voltage value. Moreover, the method remains effective in detecting faults even when multiple faults occur in voltage and current sensors.

Keywords: battery model; likelihood ratio test; battery sensor failure; fault detection; residual

由于环境污染和能源危机,包括纯电动汽车、混合动力汽车和插电式混合动力汽车在内的电动汽车日益受到重视。近年来,多次报道在电动汽车使用中,由于电池故障引起的安全事故会阻碍电动汽车的进一步推广和应用,因此电池组的安全性已经成为一个至关重要的问题。电池管理系统(BMS)通过监测电压、电流和温度来预测电池当前的工作状态,保持较高的安全诊断精度。为了提高电池状态识别和故障诊断的效率,人们一直在努力开发各种可靠的BMS。然而,大多数研究都集中在电池的荷电状态(SOC)、健康状态(SOH)、能量状态和剩余使用寿命(RUL)的估计上,对电池可靠性和应用技术的研究相对较少,也不够全面,但是电池的可靠性对于电动汽车的运行至关重要。

实际上,在动力电池的实际应用中,需要获得电池运行参数来判断电池的可靠性。当前的数据采集很困难,并联支路的数据采集容易受到电磁干扰的影响,只能直接采集电压、电流、温度3个参数,因此学者们提出了许多基于电压、电流和温度参数变化的电池故障诊断和预测方法。同时,根据数据处理方法的不同,研究方法可分为热模型分析方法、电压模型分析方法和数据驱动方法。

基于模型的方法需要精确的数学模型来模拟电池系统的行为并了解其潜在特征,主要使用状态观测器或卡尔曼滤波器来估计模型中与电流或电压相关的状态参数,并根据测量值产生的残差判断故

障^[1-2],从而可实现实时故障诊断和分离。

为了诊断电压和电流传感器故障,文献[3]提出了采用电池等效电路模型用于进行电池传感器的故障诊断,计算测量电压和估计电压的残差,基于累加和的方法对传感器故障进行监测,该方法对电压传感器故障敏感度高于电流传感器故障。Liu等^[4]采用自适应扩展卡尔曼滤波(AEKF)估计每个单体电池的电池状态参数,计算电池端电压的残差,然后通过统计推断方法评估残差,以确定故障位置。Xiong等^[5]提出了一种简单有效的基于模型的传感器故障诊断方案,用于串联锂离子电池组电流或电压传感器故障的检测和隔离。采用安时积分法计算真实荷电状态,采用递推最小二乘和无迹卡尔曼滤波联合估计方法得到估计荷电状态,然后计算SOC残差和端电压残差,通过比较电池组中每个单元的残差和预定义阈值,可以隔离故障的电流或电压传感器。Yu等^[6]提出了一种基于等效电路模型的电池传感器故障检测方法,并采用无迹卡尔曼滤波(UKF)算法对电池状态参数进行估计,进而计算电池参数的残差。采用开路电压残差发生器和容量残差发生器产生多重残差,基于开路电压残差和容量残差分别推导出电压和电流传感器的故障值,并将其应用于电池参数的容错控制和状态估计。

文献[7]提出了一种新的电池等效电路模型(VICO),模型的输入为电压,输出为电流,在新的等效电路模型基础上,采用无迹卡尔曼滤波对电池

状态进行估计,并生成残差,对电流传感器的故障电流进行估计。文献[8]基于改进的电压为输入、电流为输出模型,提出了串联电池组电流、电压传感器故障检测与隔离的系统方法,电池状态参数估计采用的是自适应卡尔曼滤波算法。

文献[9]采用基于比例积分观测器(PIO)的方法,完成对电流传感器故障的检测,并给出了电流传感器故障的补偿方法。文献[10]建立了电池组的热学模型和电学模型,采用递推最小二乘算法对模型参数进行辨识,采用粒子滤波对电池组的温度和电压进行估计,克服了系统噪声和非线性的问题,通过多次残差评估,检测并隔离电压、电流、温度传感器、电池等故障。文献[11]提出了一种多阶段筛选策略,通过机器学习算法识别电池异常端电压,通过局部离群值算法反馈验证,实现传感器故障诊断。

根据仿真结果,这些算法都可以准确地检测故障情况,但是响应时间较长,由于采用了累加和的方法,其检测结果容易受到系统噪声和误差的影响。另外在设置阈值时,通常采用的是固定阈值方法,不能随着用户对误报概率的要求变化而变化,在实际检测中有可能发生误报概率过大的问题。所以,为了确定电池电压和电流传感器的故障,本文采用EKF算法估计电池故障下端电压,并与无故障下观测电压比较,形成残差,结合统计信号检测方法来判断传感器是否发生故障。故障阈值设定为可随着用户对误报概率的要求变化而变化,在保障误报概率的尽可能不变时,最大化检测概率。采用马里兰大学公开的电池数据集,选用二阶电路等效模型,并利用 Matlab 联合计算软件平台^[11-13]1stOpt 软件进行二阶 RC 等效电路模型的离线参数辨识^[14]。本文基于电路模型,提出了基于似然比检测理论的动力单体电池传感器故障检测方法,可以检测传感器小幅度故障,以及电压和电流传感器多次故障情况,在保证检测准确的基础上,快速得知传感器故障情况。

1 电池模型

电池等效阻容模型如图 1 所示。考虑到模型的准确度、计算精度和计算复杂度,本次实验采用二阶 RC 等效电路模型。其中, U_{oc} 为电源的开路电压, R_0 为电池的欧姆内阻, R_1 、 R_2 为极化内阻, U_1 、 U_2 分别为极化内阻 R_1 和 R_2 上的端电压, C_1 、 C_2 为极化电容, I 为流经电池的电流, U_t 为电池端电压^[15]。




图 1 二阶 RC 等效电路模型

Fig. 1 Second-order RC equivalent circuit model

根据基尔霍夫定律,可以得到上述模型的连续方程

$$\begin{cases} \dot{U}_1 = -\frac{1}{C_1 R_1} U_1 + \frac{1}{C_1} I \\ \dot{U}_2 = -\frac{1}{C_2 R_2} U_2 + \frac{1}{C_2} I \\ U_t(t) = U_{oc}(t) - IR_0 - U_1 - U_2 \end{cases} \quad (1)$$

SOC 理论值可以通过安时积分法来确定

$$S_{oc}(t) = S_{oc}(t_0) + \int_{t_0}^t \frac{\xi i(\tau)}{Q} d\tau \quad (2)$$

式中: $S_{oc}(t)$ 为 SOC 的实时值; $S_{oc}(t_0)$ 为电池的初始 SOC 值(初始电量); Q 为电池额定容量; i 为电池电流; ξ 为电池库伦效率,本文取值 1。

2 基于 EKF 的 SOC 估计

2.1 EKF 基本思想

卡尔曼滤波的基本思想是通过融合系统的动态模型和实际测量数据,得到对系统状态的最优估计,在面对不完全和带有噪声的传感器数据时表现出色,通过迭代更新,逐步优化状态的估计值。卡尔曼滤波主要流程:①预测步骤使用系统的动态模型进行状态预测;②更新步骤使用测量值对预测的状态进行修正。扩展卡尔曼滤波在数学上与卡尔曼滤波相似,但引入了状态转移和观测方程的雅可比矩阵,以适应非线性系统,预测和更新的公式仍然保持卡尔曼滤波的形式,引入雅可比矩阵使其能够处理更广泛的问题^[16]。

设该离散化非线性系统状态方程和输出方程为

$$\begin{cases} \mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_{k-1} \\ \mathbf{y}_k = g(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{v}_k \end{cases} \quad (3)$$

式中: $\mathbf{x}_k$ 为 k 时刻 U_1 和 U_2 的状态变量; $\mathbf{y}_k$ 为 U_t 的输出; $\mathbf{u}_k$ 为电流 I 的输入; $\mathbf{w}_{k-1}$ 为过程噪声; $\mathbf{v}_k$ 为观测噪声; $f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1})$ 系统状态函数; $g(\mathbf{x}_k, \mathbf{u}_k)$ 为系统输出函数。

令

$$\begin{aligned} \mathbf{A}_k &= \frac{\partial f(\mathbf{x}_k, \mathbf{u}_k)}{\partial \mathbf{x}_k}; \quad \mathbf{B}_k = \frac{\partial f(\mathbf{x}_k, \mathbf{u}_k)}{\partial \mathbf{u}_k} \\ \mathbf{C}_k &= \frac{\partial g(\mathbf{x}_k, \mathbf{u}_k)}{\partial \mathbf{x}_k} \end{aligned}$$

由式(3)可得到

$$\begin{bmatrix} U_1(k) \\ U_2(k) \\ S_{OC}(k) \end{bmatrix} = \begin{bmatrix} e^{-\frac{\Delta T}{R_1 C_1}} & 0 & 0 \\ 0 & e^{-\frac{\Delta T}{R_2 C_2}} & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} U_1(k-1) \\ U_2(k-1) \\ S_{OC}(k-1) \end{bmatrix} + \begin{bmatrix} R_1(1 - e^{-\frac{\Delta T}{R_1 C_1}}) \\ R_2(1 - e^{-\frac{\Delta T}{R_2 C_2}}) \\ \frac{\Delta T}{Q} \end{bmatrix} I(k-1) + \omega(k) \quad (4)$$

式中: ΔT 为采样周期; $\omega(k)$ 为符合高斯分布的过程噪声, 均值为 0, 方差为 $Q(k)$ 。 $\omega(k)$ 用来描述在状态转移过程中因系统建模的精度不足而造成的状态噪声及其未知输入引起的误差。

设电压 U_t 为系统输出, 可得系统的离散输出方程为

$$U_t(k) = U_{oc}(S_{OC}(k)) - R_0 I(k) - U_1(k) - U_2(k) + v(k) \quad (5)$$

式中: $v(k)$ 为符合高斯分布的量测噪声, 均值为 0, 方差为 $R(k)$ 。 $v(k)$ 用来描述因系统传感器测得的输入不精准或者外界干扰所导致的误差。

2.2 扩展卡尔曼滤波步骤

基于状态空间表达式(式(4)、式(5)), 扩展卡尔曼滤波过程如图 2 所示。其中: $\hat{x}_{k/k}$ 和 $P_{k/k}$ 分别为状态估计及其误差协方差的估计, $k=0$ 为初始值; $\hat{x}_{k/k-1}$ 和 $P_{k/k-1}$ 分别为状态估计及其误差协方差的一步预测; K_k 为卡尔曼增益; e_k 为状态估计的新息, 即估计值与测量值之间的估计误差。




图 2 扩展卡尔曼滤波过程

Fig. 2 Extended Kalman filtering process

3 基于偏差的故障检测策略

3.1 故障检测策略

由于电流、电压传感器主要是霍尔效应传感器, 电池系统中最常见的传感器故障类型是偏差故障。当传感器出现故障时, 电池电流和端电压传感器的输出可以建模为

$$\begin{cases} I^m = I^r + I_f \\ U^m = U^r + U_f \end{cases} \quad (6)$$

式中: 上标 m 表示电流和电压的实测值; 上标 r 表示电流和电压的真实值; I_f 和 U_f 分别为对应传感器故障引起的电流和电压的偏差。

在本研究中需要做出以下两个假设:

假设 1 I_f 和 U_f 都是有限值;

假设 2 传感器的噪声为高斯白噪声^[17]。

本文采用扩展卡尔曼算法计算电池荷电状态估计值。经过实验可知, 在存在传感器故障的情况下, 电池端电压误差和 SOC 估计误差也会变大。受此启发, 本文提出了如图 3 所示的传感器故障诊断方案, 结合电池端电压残差和 SOC 残差进行故障检测。因此, 本文的残差可定义为

$$\begin{cases} r_o = U_{fe} - U_{re} \\ r_s = S_{fe} - S_{re} \end{cases} \quad (7)$$

式中: U_{fe} 和 U_{re} 分别为故障时电池端电压和无故障时电池端电压 EKF 估计值; S_{fe} 和 S_{re} 分别为故障时 EKF 算法估计的 SOC 值和无故障的 SOC 值。

在状态估计模块中, 利用 EKF 方法对电池端电压进行估计。在电流传感器正常工作时, 通过 EKF 估计电池的端电压 U_{re} ; 在电流故障诊断模块中, 通过 EKF 估计电池的故障端电压 U_{fe} 。然后, 通过预先设定的故障诊断阈值 T_{ho} 来判断当前传感器的故障。如果 U_{fe} 没有偏离 U_{re} , 则可以确定无故障; 如果 U_{fe} 偏离 U_{re} , 且大于设定的阈值则可以确定存在故障。同理, 电压传感器故障情况下的, 利用 EKF 方法估计出电池状态参数, 计算电池端电压, 与端电压实际值比较生成残差。最后, 根据单元平均恒虚警率(CA-CFAR)方法计算残差动态阈值, 将残差与阈值进行比较, 从而可以判断出当前时刻是否存在故障, 以此往复进行电池系统故障的实时监测。

3.2 传感器故障检测中的阈值设置

在无故障时, 经过对电池端电压误差进行概率密度函数拟合, 发现其分布符合高斯分布, 见图 4。因此, 电池传感器故障检测可以等价为其状态参数误差变化的检测。因为误差变化数据可以拟合为




图 3 基于 EKF 的电池单体传感器故障检测策略

Fig. 3 Battery sensor fault detection scheme based on EKF

高斯分布,定义误差的对数似然比函数^[18]如下

$$s(r) = \log \frac{p_{H_1}(r)}{p_{H_0}(r)} \geq T_h \quad (8)$$

式中: r 为状态参数误差; $s(r)$ 为误差对数似然比; H_0 为假设无故障信号; H_1 为假设故障信号; p_{H_0} 为 H_0 假设下的误差概率密度函数(经拟合为高斯分布); p_{H_1} 为 H_1 假设下的概率密度函数。




图 4 端电压误差分布拟合

Fig. 4 Fitting of terminal voltage error distribution

似然比函数是一个常用的检验器,其门限值为 T_h ,由实用准则来确定。当概率密度函数 $p_{H_0}(r)$ 确定时,对于一个给定的虚警概率(即误报率) P_{FA} ,门限 T_h 可由下式确定

$$P_{FA} = \int_{r > T_h} p_{H_0}(r) dr \quad (9)$$

具体的检测算法(对高斯概率密度函数的方差的估计方法)不同,得到的阈值 T 计算表达式也不同,本文的计算方法详见 3.3 小节。

3.3 恒虚警率(CFAR)检测

恒虚警率检测方法重点是将信号与阈值进行比较,因此检测方面的关键工作是提出适当的阈值。通常,阈值与检测概率和虚警概率(即误报率)有着重要关系。在许多系统中,希望检测阈值不仅能最大限度地提高检出概率,而且能将误报率保持在预设水平以下。关于如何确定检测阈值,已有大量文献^[18-20]报导,CFAR 技术解决了这些问题。在 CFAR 中,当需要对检测单元进行检测时,会根据相邻参考单元估计噪声功率计算检测阈值。

在进行故障检测过程时,阈值计算中的高斯概率密度函数中方差 σ^2 通常是未知的,需要从训练单元估计一个 σ^2 。现代信号检测中大多采用这种方法,基本 CFAR 方法中常用的形式有均值类,如单元平均(CA)、最大选择平均 CFAR(GOCA)、最小选择平均 CFAR(SOCA),有序统计类(OS)以及基本形式的各种变形^[19]。本文拟采用 CA-CAFR 方

法,使用当前待检测数据周围一定范围的单元格的平均值来确定被测单元格的阈值,如图 5 所示。

CFAR 检测器的性能取决于窗口的大小和形状,以及阈值的设置。通常,选择合适的窗口和阈值需要进行大量的实验,以便在各种条件下获得最佳性能。CFAR 检测器将窗口分为参考单元 1,2,...,N、保护单元 P 和检测单元 D,如图 5 所示。




图 5 CA-CFAR 检测原理

Fig. 5 CA-CFAR detection principle

计算过程中,用参考单元数据来估算背景噪声功率值,保护单元用来防止检测单元的数据对相邻单元数据的影响。CA-CFAR 算法使用平方律检测器时,估计的阈值^[20]为

$$T_h = \frac{\beta}{2N} \sum_{i=1}^{2N} x_i \quad (10)$$

式中: x_i 是平方律检测器的输出; β 为门限因子,计算方法如下

$$\beta = 2N(P_{FA}^{-1/2N} - 1) \quad (11)$$

其中, N 为检测量左右两侧相邻参考单元的数量。检测过程如图 5 所示。本文实验中 N 取值 10, 误报概率是 $P_{FA} = 10^{-3}$ 。按照式(11)计算得到 $\beta = 8.25$, 将其代入式(10), 根据实时更新的检测量两侧单元数据即可计算得到实时的检测阈值 T_h 。

4 故障检测策略验证分析

为了验证本文传感器故障诊断方案的有效性, 本文使用马里兰大学公开数据集, 以 18650 型号磷酸铁锂电池为研究对象, 进行了验证。首先是通过混合动力脉冲特性(HPPC)工况^[21]数据提取电池的 RC 参数; 其次结合扩展卡尔曼滤波方法, 利用动态压力测试(DST)工况和完全城市驾驶循环(FUDS)工况下的数据集^[22-23], 对所提出的故障诊断方法的

检测性能进行仿真验证; 最后分析了不同实验工况下, 该方法仿真结果及产生此结果的原因。

由于在实际应用中, 多种故障同时发生的几率较小, 本文假设每次只发生一种故障。测量到的电池数据出现异常情况时, 可能是电池故障, 也可能是传感器方面出现故障。本文只考虑传感器故障, 不考虑电池本身或其他部件发生故障, 这是因为两种不同故障反映在电池特性上会有一定差异, 例如电池内部故障时, 导致电池温度的迅速上升, 引发化学反应, 进一步可能导致电池发生热失控或者电池膨胀和电解液泄漏。结合这些特征, 可以确定电池故障还是传感器故障。针对本文的研究内容, 传感器故障时通过计算测得的电压的异常情况, 判断传感器是否发生故障。

这里的传感器故障不仅指传感器硬件故障, 还包括一些未知因素导致的信号异常。传感器故障直接影响测量结果, 因此通过在实验中传感器测量的原始数据中注入故障信号来实现传感器故障。

为了定量说明算法的检测性能, 在故障检测领域, 衡量故障识别过程有效性的指标通常包括检测时间、检测率、误报率、漏报率, 以及综合效率。为了更好地验证本文方法的有效性, 考虑了上述 5 个性能指标, 还采用了多次重复的方法, 进行随机抽样,

根据统计实验求近似解,计算方法的性能指标。每种故障测试 1 000 次,发生时间随机选取。

4.1 电压传感器故障诊断测试

为了验证本文方法对不同程度的故障检测的有效性,设置了不同的电压传感器故障幅值及多个故障发生时间,仿真参数误报率为 0.001,检测窗口长度为 20。

对电压传感器在 4.0~4.1 ks 分别注入 0.1 V 和 0.04 V 的信号偏差,图 6 和图 7 给出了基于 DST 工况实验数据的电压传感器故障发生时的检测结果。同理,图 8 和图 9 给出了 FUDS 工况实验数据下的结果。由图 6~9 可以看出,在两种不同程度的故障下,该方法的诊断时间延迟都非常短,说明当电压出现故障时,可以及时地检测到。基于 DST 工况实验数据时,在故障电压为 0.1 V 和 0.04 V 时诊断分别耗时 5 s 和 8 s。在相同实验条件下,采用累积和的残差评价方法(对残差和直接用报警阈值评价),诊断耗时平均分别为 7 s 和 11 s。相比基于累积和的残差评价方法^[24-26],两种方法都能较快地发现故障。




图 6 0.1 V 信号偏差单次故障检测结果(DST 工况)

Fig. 6 Single fault detection under 0.1 V signal deviation (DST)




图 7 0.04 V 的信号偏差单次故障检测结果(DST 工况)

Fig. 7 Single fault detection under 0.04 V signal deviation (DST)




图 8 0.1 V 信号偏差单次故障检测结果(FUDS 工况)

Fig. 8 Single fault detection under 0.1 V signal deviation (FUDS)




图 9 0.04 V 信号偏差单次故障检测结果(FUDS 工况)

Fig. 9 Single fault detection under 0.04 V signal deviation (FUDS)

实验过程中发现,窗口的长度对于检测性能会有影响,当检测窗口长度大于故障持续时间时,检测性能理想;反之,检测性能会受到影响,检测概率会下降。所以本方法应用过程中,需要考虑实验数据来调整检测窗口的大小。

图 10 给出了 DST 工况时电压传感器 0.1 V 故障发生在 4.0~4.1、4.2~4.3、4.4~4.5、4.8~4.9 ks 时,该算法的检测结果。另外,当注入的电压故障信号为 0.04 V 时,该算法仍可准确检测到故障。同理,图 11 为 FUDS 工况时,故障信号幅值 0.04 V 发生在上述 4 个时间段对应的仿真结果。由图 10 和图 11 仿真结果可以看出,当在电池运行过程中多次出现故障且信号幅值较小时,该方法能够及时准确追踪到故障情况。

两种工况指定故障时,其检测性能指标见表 1 和表 2。从中可以看出,其误报率(P_F)基本维持在恒定水平,漏检率(P_M)为 0,检测率(P_D)基本接近 1。




图 10 0.1 V 信号偏差多次故障检测结果(DST 工况)
Fig. 10 Multi-fault detection under 0.1 V signal deviation (DST)




图 11 0.04 V 多次故障检测结果(FUDS 工况)
Fig. 11 Multi-fault detection under 0.04 V signal deviation (FUDS)

为了量化检测效率指标,在应用中通过加权公式,综合评价检测效率 η 。 η 计算式如下

$$\eta = \alpha \frac{1}{T} + \delta(1 - P_D) + \gamma(1 - P_M) \quad (12)$$

式中： α 、 δ 、 γ 为权重系数； T 为故障诊断时间。考虑 3 个指标的重要性确定权重系数， $\alpha = 0.4$ ， $\delta = 0.3$ ， $\gamma = 0.3$ 。结合表 1 和表 2 中各指标平均值，计算得到 η 为 0.63。

表 1 DST 工况下电压故障时检测性能指标
Table 1 Detection performance indicators under voltage faults (DST)

参数	0.1 V 故障		0.04 V 故障	
	1 组故障	4 组故障	1 组故障	4 组故障
检测率	1	1	1	0.096 0
误报率	0.003 3	0.002 0	0.004 2	0.005 0
漏报率	0	0	0	0.004 0

表 2 FUDS 工况下电压故障时检测性能指标
Table 2 Detection performance indicators under voltage faults (FUDS)

参数	0.1 V 故障		0.04 V 故障	
	1 组故障	4 组故障	1 组故障	4 组故障
检测率	1	1	1	1
误报率	0.007 7	0.012 0	0.012 5	0.015 6
漏报率	0	0	0	0

上述验证是基于端电压残差进行的故障诊断。接着将电池荷电状态作为故障指标,进行如下验证。仿真实验中涉及的故障电压偏差为 0.1 V,仿真中设置电压故障持续时间为 500 s,电池 SOC 估计结果见图 12,SOC 误差见图 13。




图 12 电压故障下 DST 工况的电池 SOC 估计结果
Fig. 12 SOC estimation of EKF under voltage faults (DST)




图 13 电压故障下 DST 工况的电池 SOC 残差
Fig. 13 SOC estimation error of EKF under voltage faults (DST)

由图 12、图 13 可知,在 DST 工况下,故障时电池 SOC 偏差出现逐渐增大的现象,说明 SOC 估计值逐渐偏离对应非故障时电池 SOC 值,其故障诊断时间约为 100 s。在相同实验条件下,采用累积和的残差评价方法,诊断耗时为 445 s。相比基于累积和的残差评价方法,本文方法能较快地发现故障。由此可以看出,SOC 作为检测指标时,检测时间长于电压作为检测指标的检测时间,但是可以将其作为

判定电压故障的补充条件。经过后续实验验证,当设置为电流传感器故障时,检测结果与此类似。另外,实验中还测试了故障持续时间为 1 000 s 时,电池 SOC 变化情况,与故障持续时间 500 s 所需检测时间接近,变化趋势也相似。

最后,在 FUDS 工况时,对相同故障条件下的检测性能进行了仿真,结果见图 14、图 15。如图 14 所示,可以获知电池状态 SOC 也是随着故障电压产生而增大,但是在一段较长的时间后,EKF 方法会逐渐纠正这种偏差。这与 DST 工况下的试验结果一致。值得注意的是,此时由于 FUDS 工况电流变化比较剧烈,导致其 SOC 估计的残差变化也比较剧烈。




图 14 电压故障下 FUDS 工况的电池 SOC 估计结果

Fig. 14 SOC estimation of EKF under voltage faults (FUDS)




图 15 电压故障下 FUDS 工况的电池 SOC 残差

Fig. 15 SOC estimation error of EKF under voltage faults (FUDS)

4.2 电流传感器故障诊断测试

为了验证本文提出的电池传感器故障检测方法,对不同程度的故障检测的有效性和适应性,本文设置了不同的电流传感器故障大小、多个故障发生时间。仿真参数误报概率为 0.001,检测窗口长度为 20。

对电流传感器在 4.0~4.1 ks 分别注入 0.2 A 和 0.008 A 的信号偏差,图 16、图 17 给出了基于 DST 工况实验数据的故障检测结果。从中可以看出,在两种不同程度的故障下,检测到故障所用的时

间都非常短,说明当电流出现故障时,可以及时地检测到故障。它们在故障电流为 0.2 A 和 0.008 A 时,检测故障所需时间分别为 14 s 和 16 s。在相同实验条件下,采用累积和的残差评价方法,诊断耗时平均分别为 159 s 和 187 s,可知电流传感器故障比电压传感器故障的所需要的检测时间要长一些。造成这种差别的原因是端电压残差是通过电压的测量值与估计值之间的差值所得。




图 16 0.2 A 信号偏差单次故障检测结果(DST 工况)

Fig. 16 Single fault detection under 0.2 A signal deviation (DST)




图 17 0.008 A 信号偏差单次故障检测结果(DST 工况)

Fig. 17 Single fault detection under 0.008 A signal deviation (DST)

在发生多次故障时,该方法的检测结果见图 18。由仿真结果可以看出,当在电池运行过程中多次出现故障时,本文方法能够及时准确追踪到故障情况。

图 19、图 20 给出了 FUDS 工况下单次故障和多次故障的检测结果。根据仿真结果可知,在设定的电流故障情况下,本文方法同样可以及时地检测到故障。




图 18 0.2 A 的信号偏差多次故障检测结果(DST 工况)
Fig. 18 Multi-fault detection under 0.2 A signal deviation (DST)




图 19 0.2 A 的信号偏差单次故障检测结果(FUDS 工况)
Fig. 19 Single fault detection under 0.2 A signal deviation (FUDS)




图 20 0.4 A 的信号偏差多次故障检测结果 (FUDS 工况)
Fig. 20 Multi-fault detection under 0.4 A signal deviation (FUDS)

在相同的实验故障设置条件下,以电池 SOC 残差作为故障判定指标对本文方法的有效性进行验证。

FUDS 工况下,在 4 ks 注入 0.2 A 的信号偏差,估计结果见图 21、图 22,诊断时间为 336 s。在相同实验条件下,采用累积和的残差评价方法,诊断耗时均为 1 006 s。故障信号幅值为 0.008 A 时,两种方法检测时间分别为 355 s 和 1 514 s,可见检测时间明显长于电压传感器故障检测时间,这与前面分析结果一致。




图 21 电流故障下 FUDS 工况的电池 SOC 估计
Fig. 21 SOC estimation of EKF under current faults (FUDS)




图 22 电流故障下 FUDS 工况的电池 SOC 误差
Fig. 22 SOC estimation error of EKF under current faults (FUDS)

仿真结果给出了两种工况下,指定故障时检测性能指标见表 3 和表 4。从中可以看出:误报率基本维持在恒定水平,漏报率为 0,检测率基本接近 1;当电流故障幅值减小时,误报率有一定增大的趋势。

表 3 DST 工况电流故障时检测性能指标

Table 3 Detection performance indicators under current faults (DST)

参数	0.2 A 故障		0.008 A 故障	
	1 组故障	4 组故障	1 组故障	4 组故障
检测率	1	1	1	0.920 0
误报率	0.005 0	0.006 0	0.023 0	0.035 0
漏报率	0	0	0	0.080 0

表 4 FUDS 工况电流故障时检测性能指标

Table 4 Detection performance indicators under current faults (FUDS)

参数	0.2 A 故障		0.008 A 故障	
	1 组故障	4 组故障	1 组故障	4 组故障
检测率	1	1	1	0.960 0
误报率	0.003 4	0.002 9	0.054 0	0.090 0
漏报率	0	0	0	0.040 0

5 结 论

本文采用单元平均恒虚警率方法计算故障阈值,设计了动力电池传感器故障检测方法,并使用公开数据集对其性能进行了仿真验证。主要结论如下:采用 CA-CFAR 检测方法估计阈值,可以根据残差的变化动态给出阈值,在保障误报概率的不变时,最大化检测概率。仿真结果表明,不同实验工况和故障幅值下,本文方法都能有效检测到故障。同传统累积和方法相比,本文方法可以节省诊断时间 60% 以上,并且保持误报概率基本不变。另外,当电压和电流传感器发生多次故障时,本文方法仍能有效地检测到故障。

本文方法在实际应用中还存在一些问题有待完善。首先是在实际应用中电池温度的变化,可能对故障诊断结果产生影响。另外,本文是以单体电池为研究对象,现有的方法面对实际电池组中大量的电池单体存在计算负荷大的问题。最后,在卡尔曼滤波对电池状态估计中,需要对所涉及的噪声协方差等多次反复调试。

参考文献:

[1] ISERMANN R. Model-based fault-detection and diagnosis-status and applications [J]. Annual Reviews in Control, 2005, 29(1): 71-85.

[2] KANG Yongzhe, DUAN Bin, ZHOU Zhongkai, et al. Online multi-fault detection and diagnosis for battery packs in electric vehicles [J]. Applied Energy, 2020, 259: 114170.

[3] LIU Zhentong, HE Hongwen. Model-based sensor fault diagnosis of a lithium-ion battery in electric vehicles [J]. Energies, 2015, 8(7): 6509-6527.

[4] LIU Zhentong, HE Hongwen. Sensor fault detection and isolation for a lithium-ion battery pack in electric vehicles using adaptive extended Kalman filter [J]. Applied Energy, 2017, 185(Part 2): 2033-2044.

[5] XIONG Rui, YU Quanqing, SHEN Weixiang, et al. A sensor fault diagnosis method for a lithium-ion battery pack in electric vehicles [J]. IEEE Transactions on Power Electronics, 2019, 34(10): 9709-9718.

[6] YU Quanqing, WAN Changjiang, LI Junfu, et al. A model-based sensor fault diagnosis scheme for batteries in electric vehicles [J]. Energies, 2021, 14(4): 829.

[7] YU Quanqing, DAI Lei, XIONG Rui, et al. Current sensor fault diagnosis method based on an improved equivalent circuit battery model [J]. Applied Energy, 2022, 310: 118588.

[8] HE Hongwen, LIU Zhentong, HUA Yin. Adaptive extended Kalman filter based fault detection and isolation for a lithium-ion battery pack [J]. Energy Procedia, 2015, 75: 1950-1955.

[9] XU Jun, WANG Jing, LI Shiyang, et al. A method to simultaneously detect the current sensor fault and estimate the state of energy for batteries in electric vehicles [J]. Sensors, 2016, 16(8): 1328.

[10] TIAN Jiaqiang, WANG Yujie, CHEN Zonghai. Sensor fault diagnosis for lithium-ion battery packs based on thermal and electrical models [J]. International Journal of Electrical Power & Energy Systems, 2020, 121: 106087.

[11] 孙立珍, 赵乐乐. 基于 MATLAB 和 1stOpt 的非线性曲线拟合比较 [J]. 现代计算机, 2020(31): 28-30.

SUN Lizhen, ZHAO Lele. Comparison of nonlinear curve fitting based on MATLAB and 1stOpt [J]. Modern Computer, 2020(31): 28-30.

[12] 李春, 刘泽民, 陈恒杰, 等. PeakFit、1stOpt 在弗兰克-赫兹实验数据处理中的应用 [J]. 大学物理实验, 2018, 31(5): 117-123.

LI Chun, LIU Zemin, CHEN Hengjie, et al. Application of PeakFit and 1stOpt in data processing of the Frank-Hertz experiment [J]. Physical Experiment of College, 2018, 31(5): 117-123.

[13] 颜鲁林. 基于 1stOpt 软件下的铅酸电池放电曲线模型研究 [J]. 甘肃高师学报, 2018, 23(5): 5-7.

YAN Lulin. A study on lead-acid battery discharge curve based on the 1stOpt software [J]. Journal of Gansu Normal Colleges, 2018, 23(5): 5-7.

[14] 邱新宇. 稳健的锂电池等效电路模型参数辨识及荷电状态估计研究 [D]. 西安: 西安理工大学, 2019.

[15] 胡雯博. 储能锂电池荷电状态估计算法研究 [D]. 西安: 长安大学, 2023.

[16] 陈晓飞, 蒋淑霞, 崔祥波, 等. 基于融合 EKF 与改进 DELM 的锂电池 SOC 实时估计 [J/OL]. 电源学报, (2024-08-23) [2025-04-25]. <https://link.cnki.net/>

- urlid/12.1420.TM.20240822.1755.006.
- CHEN Xiaofei, JIANG Shuxia, CUI Xiangbo, et al. Real-time SOC estimation for lithium batteries based on fusing EKF and improved DELM [J/OL]. Journal of Power Supply. (2024-08-23) [2025-04-25]. <https://link.cnki.net/urlid/12.1420.TM.20240822.1755.006>.
- [17] 代磊. 车用动力电池电流传感器故障诊断方法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2022.
- [18] 闫林杰, 郝程鹏, 殷超然, 等. 部分均匀环境下适用于空间对称线阵的修正广义似然比检测方法 [J]. 雷达学报, 2021, 10(3): 443-452.
- YAN Linjie, HAO Chengpeng, YIN Chaoran, et al. Modified generalized likelihood ratio test detection based on a symmetrically spaced linear array in partially homogeneous environments [J]. Journal of Radars, 2021, 10(3): 443-452.
- [19] LIU Boxuan, CUI Zhongma, LU Zhen. Marine target CFAR detection method based on superpixel difference degree [C]//Journal of Physics: Conference Series. Bristol, United Kingdom: IOP Publishing, 2024: 012020.
- [20] LIANG Zhihuan, JIN Yanghao, LIANG Buge, et al. A modified CA-CFAR multi-human detection algorithm in complex environment using radar [C]//2024 International Conference on Electronic Engineering and Information Systems (EEISS). Piscataway, NJ, USA: IEEE, 2024: 93-97.
- [21] ZHENG Fangdan, XING Yinjiao, JIANG Jiuchun, et al. Influence of different open circuit voltage tests on state of charge online estimation for lithium-ion batteries [J]. Applied Energy, 2016, 183: 513-525.
- [22] XING Yinjiao, HE Wei, PECHT M, et al. State of charge estimation of lithium-ion batteries using the open-circuit voltage at various ambient temperatures [J]. Applied Energy, 2014, 113: 106-115.
- [23] HE Wei, WILLIARD N, CHEN Chaochao, et al. State of charge estimation for Li-Ion batteries using neural network modeling and unscented Kalman filter-based error cancellation [J]. International Journal of Electrical Power & Energy Systems, 2014, 62: 783-791.
- [24] 赵华. 工业控制系统异常检测算法研究 [D]. 北京: 冶金自动化研究设计院, 2013.
- [25] BASSEVILLE M, NIKIFOROV I V. Detection of abrupt changes: theory and application [M]. Upper Saddle River, NJ, USA: Prentice Hall, 1993.
- [26] 张云贵, 赵华, 王丽娜. 基于工业控制模型的非参数CUSUM入侵检测方法 [J]. 东南大学学报(自然科学版), 2012, 42(S1): 55-59.
- ZHANG Yungui, ZHAO Hua, WANG Lina. A non-parametric CUSUM intrusion detection method based on industrial control model [J]. Journal of Southeast University(Natural Science Edition), 2012, 42(S1): 55-59.
- (编辑 杜秀杰)

(上接第210页)

- 电机电磁噪声的削弱影响 [J]. 浙江大学学报(工学版), 2019, 53(11): 2248-2254.
- XU Ke, YING Hongliang, HUANG Surong, et al. Electromagnetic noise reduction of permanent magnet synchronous motor by step-skewed rotor [J]. Journal of Zhejiang University(Engineering Science), 2019, 53(11): 2248-2254.
- [23] 谢颖, 刘海松, 吕森, 等. 计及转子斜槽时笼型感应电机电磁振动变化规律的研究 [J]. 中国电机工程学报, 2015, 35(15): 3948-3955.
- XIE Ying, LIU Haisong, LÜ Sen, et al. Study on the variation laws of electromagnetic vibration considered the skewed rotor in a squirrel-cage induction motor [J]. Proceedings of the CSEE, 2015, 35(15): 3948-3955.
- [24] MAO Yanxin, LIU Guohai, ZHAO Wenxiang, et al. Vibration prediction in fault-tolerant flux-switching permanent-magnet machine under healthy and faulty conditions [J]. IET Electric Power Applications, 2017, 11(1): 19-28.
- [25] 王道涵, 彭晨, 王柄东, 等. 电动汽车新型转子内置式永磁同步电动机转矩脉动与电磁振动抑制研究 [J]. 中国电机工程学报, 2022, 42(14): 5289-5299.
- WANG Daohan, PENG Chen, WANG Bingdong, et al. Research on a novel interior permanent magnet machine with segmented rotor to mitigate torque ripple and electromagnetic vibration [J]. Proceedings of the CSEE, 2022, 42(14): 5289-5299.
- (编辑 武红江)