

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, 陕西, 西安); 2. 陕西省交通新能源开发、应用与汽车节能重点实验室(710064, 陕西, 西安); 3. 陕西汽车重型有限公司(710299, 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理论的故障诊断方法。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(extended kalman filter, 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, 该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 20s 内; 根据荷电状态(state of charge, SOC)残差检测所需诊断时间在 100s 内; 电流故障时根据端电压残差检测所需诊断时间在 20s 内; 根据 SOC 残差检测所需诊断时间在 400s 内。上述测试条件下, 采用传统的累积和方法(CUSUM)的诊断时间分别是 20s 内、445s 以上、150s 以上和 1000s 以上, 可见本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值 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

文章编号: XXXX-XXXX(XXXX)XX-0001-15

Automotive Lithium-ion Battery Sensor Fault Diagnosis Method Based on Likelihood Ratio Test

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

(1. School of Energy and Electrical Engineering, Chang'an University, Xi'an, Shaanxi 710064, China; 2. Key Laboratory of Shaanxi Provincial Development and Application of New Transportation Energy, Chang'an University, Xi'an, Shaanxi 710064, China)

Abstract: In order to reduce the impact of sensor faults in battery management system(BMS) on the performance of electric vehicles, a fault diagnosis method using the likelihood ratio detection theory was designed. Firstly, establish the equivalent circuit model of the battery and conduct parameter identification. Use the extended kalman filter (EKF) algorithm to estimate the state of the established battery model. Then, the terminal voltage residual of the battery is calculated based on estimated states. Next, the residual data is processed using the likelihood ratio detection method to diagnose the faults of the battery sensor. Finally, the validity and adaptability of the algorithm are verified using experimental data. The results show that, this method can detect two types of sensor faults in a timely. For the given test conditions, when there is a voltage fault, the diagnosis time is within 20 seconds based on the terminal voltage residual, and it is within 100 seconds based on the SOC residual. When there is a current fault, the diagnosis time is within 20 seconds based on the terminal voltage residual, and the diagnosis time based on the state of charge(SOC) residual is within 400 seconds. While under the same test conditions, the diagnostic times using cumulative sum(CUSUM) method are within 20s, over 445s, over 150s and over 1000s respectively. This method can significantly shorten the diagnostic time. Meanwhile, this method can detect minor faults of the sensor. Fault detection can still be achieved when the voltage fault signal is 1% of the normal voltage value. In addition, when multiple faults occur sensors, this method can still achieve the fault detection goal.

Key words: 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, 这些都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。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(state of charge, SOC)、健康状态(state of health, SOH)、能量状态和剩余使用寿命(remaining useful Life, 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、温度三个参数。因此人们提

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,研究方法可分为三类: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。它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]。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监测,发现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]提出了对电池组传感器故障检测与定位的方法,采用自适应扩展卡尔曼滤波(adaptive extended kalman filter, 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,以确定故障的存在。最后,在城市动态驾驶循环工况(urban dynamometer driving schedule, UDDS)下,用串联电池组实验验证了所提传感器故障检测方案的有效性。Xiong等人^[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等人^[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(unscented kalman filter, 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。故障诊断方法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(voltage input current output, 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, proportional integral observe)的方法,完成对电流传感器故障的检测方法,并给出了电流传感器故障的补偿方法。文献[10]基于电池等效电路模型和径向等效热模型,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。Zhao等人[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。

根据仿真结果分析这些算法都可以准确地检测故障情况,但是这些算法的响应时间较长,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。另外在阈值设置时,通常都采用的是固定阈值方法,不能随着用户对误报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诊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率的要求变化而变化,在保障误报率的尽可能不变时,最大化检测概率。

最后,采用马里兰大学公开电池数据集,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模型的离线参数辨识^[14]。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,可以检测小幅度、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,在尽可能短的时间内得知传感器故障情况。下面进行详细说明。

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模型。其中, U_{oc} 代表电源的开路电压, R_0 代表电池的欧姆内阻, R_1, R_2 代表极化内阻, U_1 和 U_2 分别代表极化内阻 R_1 和 R_2 上的端电压, C_1 和 C_2 为极化电容。 I 代表流经电池的电流, 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:

$$\begin{aligned}\dot{U}_1 &= -\frac{1}{C_1 R_1} U_1 + \frac{1}{C_1} I \\ \dot{U}_2 &= -\frac{1}{C_2 R_2} U_2 + \frac{1}{C_2} I\end{aligned}\quad (1)$$

$$U_t(t) = U_{oc}(t) - I R_0 - U_1 - U_2$$

SOC理论值可以通过安时积分法来确定:

$$S_{oc}(t) = S_{oc}(t_0) + \int_{t_0}^t \frac{\xi i(\tau)}{Q} d\tau \times 100\% \quad (2)$$

其中, $S_{oc}(t)$ 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。它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, 但雅可比矩阵的引入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(3)式:

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

其中 $\mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_{k-1})$ 为(1)式的离散化形式, $\mathbf{g}(\mathbf{x}_k, \mathbf{u}_k)$ 为(2)式的离散化形式。

令

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

由式(3)可得到方程(4)式:

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

其中 k 为第 k 个离散采样时间, $\tau_k = C_k R_k$ 为第 k 个RC环路的时间常数 ($k=1, 2$), T 为采样周期, $\mathbf{w}(k)$ 为符合高斯分布的过程噪声, 其均值为0, 方差为 $\mathbf{Q}(k)$ 。 $\mathbf{w}(k)$ 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_i 为系统输出, 可得系统的离散输出方程为:

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

其中 $v(k)$ 为符合高斯分布的量测噪声, 其均值为 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

基于上述状态空间表达式(4)-(5), 扩展卡尔曼滤波过程如图 2 所示。




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, 电流和电压传感器的输出可以建模为(6)式:

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

其中上标 m 表示电流和电压的实测值与其故障值的偏差; 上标 r 表示电流和电压的实测值; I_f 和 U_f 分别为对应传感器故障引起的电流和电压。

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用于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(7)式:

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

其中, U_{fe} 和 U_{re} 分别为无故障时电池端电压值和故障时电池端电压 EKF 估计值。 S_{fe} 和 S_{re} 分别为安时积分法和 EKF 算法估计的 SOC 值。其中安时积分法计算 SOC 见第二部分(2)式, EKF 估计 SOC 步骤见第三部分。

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_{fe} ; 在电流故障诊断模块中, 通过 EKF 估计电池的故障端电压 U_{re} 。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_{re} 偏离




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

U_{fe} , 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 (cell average - constant false alarm rate) 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。因为其误差变化数据可以拟合为高斯分布, 定义误差的对数似然比函数^[18]如(8)式:

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

式中, r 为状态参数误差, $s(\cdot)$ 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。其中 $s(r)$ 为似然比函数, 是一个常用的检验器, 其门限值为 T , 其大小由实用准则来确定。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 (即误报概率) $P_{FA} = \alpha$, 门限 T 可由(9)式确定, 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 小节式(10)-式(11):




图4 端电压误差分布拟合

Fig. 4 Fitting of terminal voltage error distribution

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

3.3 恒虚警率(constant false alarm rate, CFAR)检测

恒虚警率检测方法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(即误报概率)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,而且能将误报概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]。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。

进行检测过程时,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(cell average, CA)、最大选择平均CFAR(greatest of cell average, GOCA)、最小选择平均CFAR(smallest of cell average, SOCA),有序统计类(OS, ordered statistic)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和测试,以便在各种条件下获得最佳性能。CFAR检测器将窗口分为三类:参考单元、保护单元和检测单元。

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(10)式:

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

其中 x_i 是平方律检测器的输出,门限因子 β 计算方法见(11)式:

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

N 是检测量左右两侧相邻参考单元的数量, P_{FA} 是误报概率。检测过程如图5所示。本文实验中 N 取值10,误报概率是 $P_{FA} = 10^{-3}$ 。按照上式(11)计算得到 $\beta=8.25$,将其代入(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 。

4 故障检测策略验证分析

为了验证所提出的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(Pulse Power Characterization, HPPC)工况^[21]数据提取电池的RC参数。第二步结合扩展卡尔曼滤波方法,利用动态压力测试(Dynamic Stress Test, DST)工况和完全城市驾驶循环(Federal Urban Driving Schedule, FUDS)工况下的数据集^[22-23]对所提出




图5 CA-CFAR检测原理

Fig.5 CA-CFAR detection principle

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。本文，为了更好地验证所提出策略的有效性，在此考虑了上述5个性能指标。另外，本文中采用了多次重复实验（即多次模拟）蒙特卡罗仿真实验方法，进行随机抽样，根据统计试验求近似解，来计算算法的性能指标。每种故障测试1000次，而且发生时间是随机选取。

4.1 电压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，本文设置了不同的电压传感器故障幅值、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 $N=20$ 。

首先对电压传感器在4000 s - 4100 s 分别注入+0.1 V和+0.04 V的信号偏差。

接着，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。由图中可以看出，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，可以及时地检测到故障。基于DST工况实验数据时，在故障电压为+0.1V和+0.04V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，其诊断耗时平均分别为7s和11s。相比基于累积和的残差评价方法^[24-26]（对残差和直接用报警阈值评价），两种方法都能较快地发现故障。

实验过程中发现，窗口的长度 N 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进行调整检测窗口的大小。

然后，图10给出了DST工况时电压传感器+0.1V故障发生在4000S-4100S、4200S-4300S、4400S-4500S、4800S-4900S时，该算法的检测结果。将当注入的电压故障信号为+0.04V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+0.04V发生在上述4个时间段，其对应的仿真结果。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时，且信号幅值较小时，该方法能够及时准确追




图6 +0.1V信号偏差单次故障检测(DST工况)

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




图7 +0.04V的信号偏差单次故障检测(DST工况)

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




图8 +0.1V信号偏差单次故障检测(FUDS工况)

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

踪到故障情况。

两种工况下,指定故障时,其检测性能指标见表1和表2。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。

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 ,见式(12)。考虑三个指标的重要性确定权重系数, $\alpha=0.4, \beta=0.3, r=0.3$ 。结合表1和表2中各指标平均值,计算得0.63。

$$\eta = \alpha \times \frac{1}{T} + \beta \times (1 - P_D) + r \times (1 - P_M) \quad (12)$$

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0.1V,其中 S_{je} 为故障时EKF方法估计的SOC值, S_{re} 是在无故障时得到的SOC值。仿真中设置电压故障持续时间为500s,电池SOC估计结果见图12,SOC残差见图13。由图12-13




图9 +0.04V 信号偏差单次故障检测(FUDS 工况)
Fig. 9 Single fault detection under +0.04V signal deviation (FUDS)




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




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

表1 DST 工况电压故障时检测性能指标

	0.1V 故障		0.04V 故障	
	1 组故障	4 组故障	1 组故障	4 组故障
检测率	1	1	1	0.0960
误报率	0.0033	0.0020	0.0042	0.0050
漏报率	0	0	0	0.0040

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,其诊断耗时为

表2 FUDS 工况电压故障时检测性能指标

Tab.1 Detection performance indicators under voltage faults (FUDS)

	0.1V 故障		0.04V 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	0.0077	0.0120	0.0125	0.0156
漏报率	0	0	0	0

445s。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,其检测结果与此类似。另外,实验中还测试了故障持续时间为 1000s 时,电池 SOC 变化情况,与故障持续时间 500s 所需检测时间接近,变化趋势也相似。




图 12 电压故障下 DST 工况电池 SOC 估计结果

Fig. 12 SOC estimation of EKF under voltage faults (DST)




图 13 电压故障下 DST 工况电池 SOC 残差

Fig. 13 SOC estimation error of EKF under voltage faults (DST)

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 14-15。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,本小节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 $N=20$ 。

首先对电流传感器在 4000s- 4100s 分别注入 +0.2A 和 +0.008A 的信号偏差。图 16-17 给出了基于 DST 工况实验数据的故障检测结果。由图中可以看出,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 +0.2A 和 +0.008A 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,其诊断耗时平均分别为 159s 和 187s。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的生成是通过电压的测量与估计之间差值所得。

接着,继续仿真了多次故障发生时,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,该方法能够及时准确追踪到故障情况。




图 16 0.2A 信号偏差单次故障检测(DST 工况)

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

同时,与电压故障分析情况一样,图 19-20 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,该方法同样可以及时地检测到故障。

再次,在相同的实验故障设置条件下,本文再以电池 SOC 残差作为故障判定指标对该方法的有效性进行验证。FUDS 工况下,在 4000s 注入 +0.2A 的信号偏差,结果见图 21-22,其诊断时间为 336s。在相同实验条件下,采用累积和的残差评价方法,其诊断耗时平均分别为 1006s。故障信号幅值为 0.008A 时,两种方法检测时间分别为 355s 和 1514s。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。

同时,仿真结果给出了两种工况下,指定故障时,其检测性能指标,详见表 3 和表 4。可以看出其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。可以看出电流故障幅值减小时,其误报率有一定增大




图 17 0.08A 信号偏差单次故障检测(DST 工况)

Fig. 17 Single fault detection under +0.08A signal deviation (DST)

表 3 DST 工况电流故障时检测性能指标

Tab.3 Detection performance indicators under current faults (FUDS)

	0.2A 故障		0.08A 故障	
	1 组故障	4 组故障	1 组故障	4 组故障
检测率	1	1	1	0.9200
误报率	0.0050	0.0060	0.0230	0.0350
漏报率	0	0	0.	0.0800

表 4 FUDS 工况电流故障时检测性能指标

Tab.3 Detection performance indicators under current faults (FUDS)

	0.2A 故障		0.08A 故障	
	1 组故障	4 组故障	1 组故障	4 组故障
检测率	1	1	1	0.9600
误报率	0.0034	0.0029	0.0540	0.0900
漏报率	0	0	0	0.0400

的趋势。




图 18 0.2A 的信号偏差多次故障检测(DST 工况)

Fig. 18 Multi-fault detection under +0.2A signal deviation (DST)

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:首先,采用 CA-CFAR 检测方法估计阈值,可以根据残差的




图 19 0.2A的信号偏差单次故障检测(FUDS 工况)

Fig. 19 Multi-fault detection under +0.2A signal deviation (FUDS)




图 20 0.4A的信号偏差多次故障检测(FUDS 工况)

Fig. 20 Multi-fault detection under +0.4A signal deviation (FUDS)




图 21 电流故障下FUDS 工况电池SOC估计

Fig. 21 SOC estimation of EKF under current faults (FUDS)




图 22 电流故障下FUDS 工况电池SOC残差

Fig. 22 SOC estimation error of EKF under current faults (FUDS)

变化动态地给出阈值,在保障误报概率的不变时,最大化检测概率。同时,仿真结果表明,不同实验工况和故障幅值下,该方法都能有效地检测到故障。同传统累积和方法相比,该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,该方法仍能有效检测到故障。

同时,该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,本研究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]. Ann Rev Control 2005, 29(1): 71 - 85.
- [2] Kang Y, Duan B, Zhou Z, Shang Y, Zhang C. Online multi-fault detection and diagnosis for battery packs in electric vehicles[J]. Applied Energy 2020, 259: 1-16. <https://doi.org/10.1016/j.apenergy.2019.114170>.
- [3] Liu Z, He H. Model-based sensor fault diagnosis of a lithium-ion battery in electric vehicles[J]. Energies 2015, 8(7): 9 - 27.
- [4] Liu Z, He H. Sensor fault detection and isolation for a lithium-ion battery pack in electric vehicles using adaptive extended kalman filter[J]. Applied Energy 2017, 185: 2033 - 2044.
- [5] Xiong R, Yu Q, Shen W, Lin C, Sun F. A sensor fault diagnosis method for a lithium-ion battery pack in electric vehicles [J]. IEEE Trans Power Electron 2019,34(10): 9709 - 9718.
- [6] Yu Q, Wan C, Li J, Xiong R, Chen Z. A model-based sensor fault diagnosis scheme for batteries in electric vehicles[J]. Energies 2021, 14(4):1-15.
- [7] Yu Quanqing, Dai Lei, Xiong Rui, Chen Zeyu, Zhang Xin, Shen Weixiang. Current sensor fault diagnosis method based on an improved equivalent circuit battery model[J]. Applied Energy. 2022, 310:1-15.
- [8] He Hongwen, Liu Zhentong, Hua Yin. Adaptive Extended Kalman Filter Based Fault Detection and Isolation for a Lithium-Ion Battery Pack [C]. 7th International Conference on Applied Energy, ICAE 2015, 2015, 75: 1950-1955.
- [9] XU Jun, WANG Jing, LI Shiyin, 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):13-28.
- [10] TIAN Jiaqiang, ANG 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,2020,121:1-13.
- [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+37.
SUN Lizhen, ZHAO Lele. Comparison of Nonlinear Curve Fitting Based on MATLAB and 1stOpt[J]. SmartTech Innovations, 2020, (31): 28-30+37.
- [12] 李春, 刘泽民, 陈恒杰, 薛善增. 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 (05): 117-123.
LI Chun, LIU Zemin, CHEN Hengji, XUE Shan-zeng. Application of PeakFit and 1stOpt in Data Processing of the Frank-Hertz Experiment[J]. Physical Experiment of College, 2018, 31 (05): 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 (05): 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 (05): 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]. 西安理工大学, 2019.
QIU Xinyu. Robust parameter identification for equivalent circuit models and soc estimation of lithium batteries[D]. Xi'an University of Technology, 2019.
- [15] 胡雯博. 储能锂电池荷电状态估计算法研究[D]. 长安大学, 2023.
Hu Wenbo. Research on State of Charge estimation Algorithm of Lithium-ion Battery[D]. Chang'an University, 2023.
- [16] 陈晓飞, 蒋淑霞, 崔祥波, 赵文卓, 王思思. 基于融合 EKF 与改进 DELM 的锂电池 SOC 实时估计[J]. 电源学报, 2024: 1-14.

- Chen Xiaofei, Jiang Shuxia, Cui Xiangbo, Zhao Wenzhuo, Wang Sisi. Real-time SOC estimation for lithium batteries based on fusing EKF and improved DELM[J]. Journal of Power Supply, 2024:1-14.
- [17] 代磊. 车用动力电池电流传感器故障诊断方法研究[D]. 哈尔滨工业大学, 2022.
- DAI Lei. Research on Fault Diagnosis Methods of for Vehicle Power Batteries Current Sensors[D]. Harbin Institute of Technology, 2022.
- [18] 闫林杰,郝程鹏,殷超然,孙苇轩,侯朝焕. 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 (03): 443-452.
- YAN Linjie, HAO Chengpeng, YIN Chaoran, SUN Weixuan, HOU Chaohuan. Modified Generalized Likelihood Ratio Test Detection Based on a Symmetrically Spaced Linear Array in Partially Homogeneous Environments[J]. Journal of Radars, 2021, 10 (03): 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, 2024,2906(1): 1-13.
- [20] Liang Zhihuan, Jin Yanghao, Liang Buge, Mo Jinjun. A Modified CA-CFAR Multi-human Detection Algorithm in Complex Environment Using Radar[C]. 2024 International Conference on Electronic Engineering and Information Systems, EEISS 2024, 2024: 93-97.
- [21] Fangdan Zheng, Yinjiao Xing, Jiuchun Jiang, Bingxiang Sun, Jonghoon Kim, Michael Pecht. Influence of different open circuit voltage tests on state of charge online estimation for lithium-ion batteries. Applied Energy, 2016, 183: 513 - 525.
- [22] Yinjiao Xing, Wei He, Michael Pecht, Kwok Leung Tsui. State of Charge Estimation of Lithium-Ion Batteries Using the Open-Circuit Voltage at Various Ambient Temperatures. Applied Energy, 2014, 113: 106-115.
- [23] Wei He, Nicholas Williard, Chaochao Chen, Michael Pecht. State of Charge Estimation for Li-Ion Batteries Using Neural Network Modeling and Unscented Kalman Filter-based Error Cancellation. 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.
- ZHAO Hua. Research on anomaly detection algorithm for industrial control system[D]. Beijing: Metallurgical Automation Research and Design Institute, 2013.
- [25] BASSEVILLE M, NIKIFOROV I. V. Detection of Abrupt Changes: Theory and Application [M]. New Jersey, 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 UNIVER -SITY (Natural Science Edition), 2012,42(S1): 55-59.