

基于数据驱动的 MEMS 加速度计 自检测自校正技术研究

薛健¹, 张博亚², 尹可³, 付杰¹, 付洪硕¹, 凤雷¹, 刘冰¹

(1. 哈尔滨工业大学 电子与信息工程学院, 哈尔滨 150001;

2. 火箭军装备部 驻哈尔滨地区军事代表室, 哈尔滨 150001;

3. 中国航发湖南动力机械研究所, 湖南 株洲 412002)

摘要: MEMS 加速度计是一种用于测量载体加速度的微型集成系统, 已被广泛应用于生产生活中; 然而 MEMS 器件在使用过程中易由内外因素影响出现故障, 若不能及时检测故障并校正故障数据, 将会使得系统无法准确感知外界环境进而导致控制出现偏差, 因此及时检测 MEMS 加速度计的故障并校正其故障数据对于提高系统的鲁棒性、测量准确性以及控制稳定性等方面具有重要意义; 现有检测校正方法大多依靠建立加速度计的物理模型或构建传感器冗余网络来实现加速度计的自检测与自校正, 但 these 方法存在建模复杂且引入额外误差或硬件资源需求高等问题; 为了避免建模不准确引入的误差并减少算法对硬件资源的需求, 基于近传感器计算的思想, 设计了一种轻量化的、基于数据驱动的 MEMS 加速度计自检测自校正算法; 测试结果表明, 算法对冲击、偏差、信号丢失、恒定输出 4 种故障的检测率均达到 90%, 校正后数据与正常数据的平均绝对误差小于 0.15 g, 并且具有在 2.54 ms 内处理加速度计数据的能力。

关键词: MEMS 加速度计; 自检测; 自校正; 近传感器计算; 数据驱动

Research on Data-driven MEMS Accelerometer Self-detection and Self-correction Technology

XUE Jian¹, ZHANG Boya², YIN Ke³, FU Jie¹, FU Hongshuo¹, FENG Lei¹, LIU Bing¹

(1. School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150001, China;

2. Military Office of Rocket Armaments Department in Harbin District, Harbin 150001, China;

3. Hunan Aviation Powerplant Research Institute, AECC, Zhuzhou 412002, China)

Abstract: A micro-electro-mechanical system (MEMS) accelerometer is miniature integrated system, which is widely used to measure carrier acceleration in various industrial and domestic applications. However, MEMS devices are susceptible to faults due to internal and external factors during operation. If the fault can not be detected and the fault data can not be corrected in time, the system will not be able to accurately perceive the external environment, resulting in control deviations. Hence, It is of great significance for the timely detection and correction of MEMS accelerometer faults to improve the robustness of the system measurement data accuracy, and control stability. Existing detection and calibration methods often rely on establishing the accelerometer physical model or constructing redundant sensor networks to achieve the self-detection and self-correction of accelerometer, but these methods have the shortages of complexities in modeling, additional errors, or high hardware resource requirements. To avoid inaccuracies introduced by modeling and reduce the demand of the algorithm on hardware resources, a lightweight, data-driven self-testing and self-calibration algorithm for the MEMS accelerometer is proposed based on the notion of proximal sensor computation. Test results demonstrate that the algorithm achieves a detection rate of 90% for four types of faults: shock, bias, signal loss, and constant output. The average absolute error between the calibrated data and the normal data is less than 0.15 g, with the ability to process the accelerometer response data within 2.54 ms.

Keywords: MEMS accelerometer; self-detection; self-calibration; near-sensor computing; data-driven

收稿日期: 2024-03-25; 修回日期: 2024-04-29。

基金项目: 国家重点研发计划(2022YFB3207504)。

作者简介: 薛健(2000-), 男, 硕士研究生。

通讯作者: 刘冰(1982-), 男, 博士, 教授。

引用格式: 薛健, 张博亚, 尹可, 等. 基于数据驱动的 MEMS 加速度计自检测自校正技术研究[J]. 计算机测量与控制, 2024, 32(10):

53-61.

0 引言

MEMS 加速度计是一种利用微机电系统 (MEMS, micro-electro-mechanical system) 技术制成的、用于测量载体加速度的惯性传感器^[1]。相较于传统加速度计, MEMS 加速度计具有体积小、功耗低、成本低^[2]等优势, 目前已被广泛应用于振动测量^[3]、惯性制导^[4-5]、形变监测^[6]、人体行为识别^[7]等领域。同时, 在智能汽车、无人机、智能可穿戴设备等智能终端中发挥着重要作用^[8]。

在上述应用领域中, MEMS 传感器可能因机械结构损坏、电子元件性能退化、环境干扰、过度振动等因素影响而导致输出故障数据^[9], 进而影响应用效果。因此, 如果 MEMS 加速度计出现故障而系统无法感知并及时处理故障数据, 则系统可能受故障数据影响无法准确感知外界环境进而使得控制出现偏差^[10], 严重时甚至导致设备损坏。因此, 及时检测 MEMS 加速度计的故障并校正其故障数据在提高系统的鲁棒性、测量准确性以及控制稳定性, 延长设备使用寿命等方面具有重要意义。

为了检测 MEMS 加速度计的故障并对故障数据进行校正, 目前已有许多学者针对表 1 中列出的一种或多种 MEMS 传感器常见故障开展了研究^[11-13]。在这些研究中, 一类方法是依靠对加速度计物理模型的分析, 建立特定故障的数学模型, 依靠数学模型实现对该种故障数据的校正。如文献 [14] 通过对几何抗弹簧结构的电容式 MEMS 加速度计进行分析, 构建了该类型加速度计的热漂移补偿模型, 有效降低了温度所引起的漂移。文献 [15] 根据扭摆式硅微加速度计的结构和工作原理, 从理论上分析了其温度特性, 并建立了温度补偿模型和非线性补偿模型, 有效减少了温度变化带来的误差。而另一类方法则利用多传感器之间的冗余信息实现故障的检测与数据校正。如文献 [16] 设计了一种含有 4 个 MEMS 加速度计的加速度计冗余系统, 该系统能够实现加速度计的故障检测并对故障传感器进行隔离。该方法能够保证系统在一个加速度计损坏的情况下正常运行。文献 [17] 使用加速度计网络测量结构的响应数据, 有效检测校正了偏差、增益、漂移等 7 种传感器故障的故障数据, 并能利用该传感器网络识别故障类型。

表 1 部分 MEMA 传感器常见故障

故障类型	描述
冲击	输出信号的瞬时突变
偏差	输出信号相对于真实值存在恒定偏移
缩放	也称增益故障, 信号幅度按一个因子缩放, 信号本身的形式不改变
漂移	传感器输出随着时间增加 (时变漂移) 或温度变化 (温度漂移) 缓慢改变
噪声	不可预知的随机时间序列, 为了简化分析, 常假设噪声是零均值的
信号丢失	传感器无信号输出 (输出全为 0 值)
恒定输出	传感器输出信号为某个恒定值

上述两类方法虽然能较为有效地处理加速度计故障,

但仍存在一定的局限性。具体而言, 对于依赖加速度计物理结构的模型驱动自检测自校正方法, 在使用前需要对实际选用的加速度计结构进行分析并针对不同故障进行建模。建模过程不仅会增加工作量, 也可能由于拟合模型不准确而引入误差^[18]。而部署冗余加速度计的方法在一些资源受限的场景中可能难以实现。为了解决前述方法的局限性, 本文面向单加速计应用场景, 基于近感计算的理念, 设计了一种轻量化的 MEMS 传感器自检测自校正算法。该算法从数据的角度出发, 采用数据驱动的方式进行算法设计, 避免了对加速度计物理结构进行建模。在传统的传感器故障检测与数据校正架构中, 传感器节点与计算节点距离较远, 数据需要传送到计算节点进行计算, 这一过程消耗了大量的通信资源和设备能源。而近年来提出的近传感器计算 (Near-sensor Computing) 方法通过将计算任务转移到传感设备附近执行, 能够有效降低设备的资源消耗^[19]。综上, 本文主要面向单个加速度计的应用场景, 针对冲击、偏差、信号丢失和恒定输出 4 种故障, 进行加速度计自检测自校正算法的设计。

本文首先设计了加速度计运动状态鉴别算法用于分析加速度计目前处于移动状态还是静止状态。在此基础上, 针对两种不同的状态, 本文分别设计了相应的故障诊断算法用于实现上述 4 种故障数据的检测校正。最后, 通过实验验证了本文所提方法的有效性。

1 自检测自校正算法设计

本文所提出的加速度计自检测自校正算法完整流程如图 1 所示, 主要流程单元包括运动状态鉴别, 静止/运动状态下故障检测以及静止/运动状态下故障数据校正。当 MEMS 加速度计采集到响应数据后, 运动状态鉴别算法将会判断当前加速度计所处的运动状态, 然后根据判断结果, 分别调用相应的故障检测算法来判断原始数据中是否存在故障。若原始数据中不包含故障, 则直接将原始数据输出。若检测算法判断原始响应数据中存在故障, 则采用相应的校正算法对故障数据进行重构, 并将重构校正后的数据输出。

2 运动状态鉴别算法设计

2.1 状态鉴别的设计动机

在本文所面向的单加速度计应用场景中, 由于系统中不存在冗余传感器提供直接冗余信息, 因此需要利用实际的物理约束条件提供间接冗余信息实现对故障数据的检测校正^[17]。由于加速度与物体运动状态相关, 因此通过区分运动情况, 我们能够更好地发掘出加速度计响应数据中的约束条件, 以此选用更有针对性, 更加有效的自检测自校正算法。为了更好地利用不同场景中的约束条件, 提高故障检测的准确率, 降低重构数据与真实值的偏差, 本文希望针对运动与静止两种运动状态分别选用不同的故障检测与数据校正算法。为此, 需要先判断加速度计当前所处的运动状态, 才能调用相应的算法对数据进行分析处理。

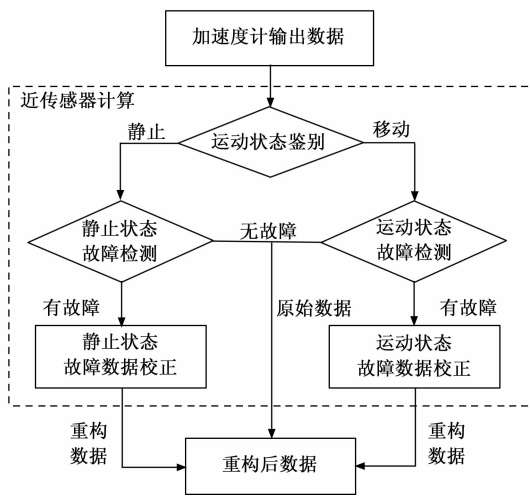


图 1 算法流程示意

2.2 算法设计

为了鉴别两种不同的运动状态, 需要找到二者响应数据之间的差异。由于本文依据静止时加速度应为重力加速度这一静态约束来划分两种状态, 因此考虑利用该条件进行鉴别。加速度计三轴矢量之和的计算公式为:

$$g_a = \sqrt{x^2 + y^2 + z^2} \quad (1)$$

其中: x 、 y 、 z 分别代表三轴加速度计的 3 个原始响应, g_a 代表三轴响应的合矢量。对于正常的加速度计, 当载体处于静止时其三轴响应的矢量和应为重力加速度 $1g$, 只要统计一段时间内 g_a 的变化情况, 便能实现加速度计当前状态的判别。但是当响应中存在故障时, 故障的干扰会使单纯利用 g_a 进行判断的方法出现误判, 因此难以直接利用矢量之和进行判断。

因此, 为了在数据中可能存在故障的前提下正确判断加速度计当前运动状态, 本文基于决策树模型设计了状态鉴别算法。

决策树是一种常用的有监督机器学习方法^[20], 其具有预测速度快、精度高且决策规则简单易理解等优点, 在分类问题中被广泛使用^[21]。由于本文面向资源受限的系统进行轻量化算法设计, 因此出于减少计算量的考虑, 选择以决策树算法中计算量较小^[21]的 CART (Classification and Regression Tree) 决策树为基础进行状态鉴别算法设计。本文首先将采集到的数据编码为特定长度的时间序列, 再计算时间窗内数据的典型特征统计量, 最后将统计量输入决策树实现状态鉴别。在输入变量的选择上, 选择以均值、方差、能量、峰峰值四个数据统计量作为决策树的划分属性, 其对应的计算公式分别如式 (2) ~ (5):

$$mean = \frac{1}{W} \sum_{i=1}^W x_i \quad (2)$$

$$var = \frac{1}{W-1} \sum_{i=1}^W (x_i - mean)^2 \quad (3)$$

$$energy = \sum_{i=1}^W x_i^2 \quad (4)$$

$$p2p = x_{max} - x_{min} \quad (5)$$

式中, W 为时间窗的长度, x_i 为时间窗内的第 i 个数据, $mean$ 为数据的均值, var 为数据的方差, $energy$ 为数据的能量, $p2p$ 为数据的峰峰值, 其值为时间窗内数据的最大值 x_{max} 与最小值 x_{min} 的差值。

针对三轴加速度计的 X、Y、Z 三轴响应数据, 分别构建 3 棵决策树用于进行状态判断, 最后根据 3 棵树的判断结果, 取得票多者为当前状态。

本文所设计的加速度计运动状态鉴别算法流程如图 2 所示。首先分别提取加速度计三轴响应数据的 4 个统计特征, 然后将其送入对应的决策树中进行状态鉴别, 由 3 棵决策树输出对应的判断结果。最后判别器将统计 3 棵决策树的输出并以其中占多数的判断结果作为加速度计的当前运动状态。

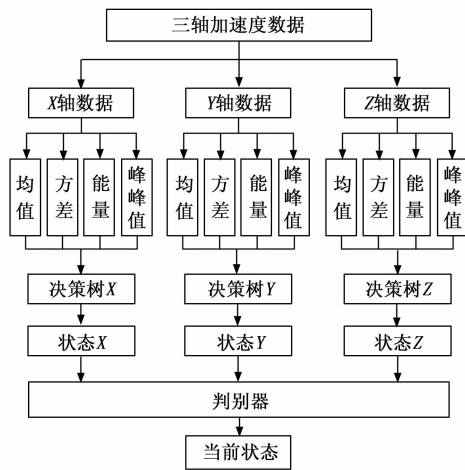


图 2 运动状态鉴别算法流程

3 故障数据自检测自校正算法

针对两种运动状况下数据的不同特点, 本文选用了几种典型的方法进行故障检测与数据校正。根据静止状态下的静态约束, 选择拉依达准则 (3σ 准则) 进行故障检测, ARMA 时间序列建模进行故障数据校正。根据运动状态下的时间相关性约束, 以均值滤波对故障数据进行处理。

3.1 静止状态下自检测自校正算法

本文首先针对静止状态下数据的特点, 对静止场景中的自检测算法和自校正算法分别进行了设计。

首先根据静态约束条件进行自检测算法的选择。出于算法轻量化的考虑, 本文没有采用故障检测中常用的主成分分析 (PCA, principal component analysis) 方法^[13,22], 而是选择了拉依达准则与矢量和作为判断故障的依据。

考虑到轻量化的设计需求, 本文选择以矢量和作为故障检测依据, 以拉依达准则作为检测方法进行故障检测。当加速度计处于静止状态时, 由公式 (1) 计算出的三轴响应的矢量和 g_a 在任意时刻都应重力加速度 $1g$, 因此我们可以以该条件作为依据实现故障检测。但是受地理位置

不同、海拔高度不一以及加速度计存在标定误差等因素影响, g_a 并不总是精确地为 1 g。此外, 由于数据中存在不可避免的噪声, 因此静止状态下由响应数据计算出的矢量和会在很小的范围内波动。综合考虑恒定偏差与噪声波动的影响, 本文以拉依达准则作为静止状态下的故障检测算法。预先计算得到不同位姿下矢量和的均值和标准差, 当 g_a 与均值的差值在三倍标准差以内时, 认为该数据正常不存在故障, 反之认为数据中存在故障。

对于被故障检测算法所检测出来的故障数据, 本文采用自回归滑动平均 (ARMA, auto-regressive and moving average) 模型对故障数据进行校正。ARMA 是一种用于弥合平稳序列的模型^[23], 其数学表达式如下:

$$x(k) = \varphi_1 x(k-1) + \varphi_2 x(k-2) \dots + \varphi_p x(k-p) + e(k) + \theta_1 e(k-1) + \theta_2 e(k-2) \dots + \theta_q e(k-q) \quad (6)$$

式中, $x(k)$ 为时间序列, $e(k)$ 为白噪声序列, φ 和 θ 为模型参数, p 和 q 为模型阶数。当 q 为 0 时, 模型退化为自回归 (AR, auto-regressive) 模型, 该模型描述了当前值与历史值之间的关系, 即用变量自身的历史数据对自身进行预测。

由于静止状态下的数据是一组平稳序列, 因此可用 ARMA 模型描述数据的统计特性。此外, 数据的采集以及故障的检测与恢复是按时间顺序进行, 可以认为前一刻的数据无故障或者已被重构。因此在静止状态下, 本文依据 AR (1) 模型, 使用历史数据对故障数据进行校正。

3.2 运动状态下自检测自校正算法

当状态鉴别算法判断加速度计当前处于运动状态时, 会执行运动状态下的自检测自校正算法对响应数据进行处理。由于运动状态与静止状态存在的约束不同, 因此本文针对运动状态下数据的表现形式, 选择以均值滤波的方式对数据进行冲击故障的检测与数据校正。

与静止状态存在合加速度等于重力加速度这一显式的强约束条件不同, 当加速度计进行变速运动时, 由于三轴数据各自独立不存在相互约束, 因此难以发掘足够的冗余信息用于故障的检测。虽然运动状态下的数据不存在显式约束条件, 但由于载体通常工作于限定的场景中, 且受限于设备硬件的限制, 其运动形式会存在一定潜在规律, 这会在数据中体现为隐式约束。通过对载体应用场景及运动形式的分析, 能够部分发掘响应数据的潜在约束, 从而在一定程度上实现故障的检测与数据校正。

当响应数据满足平稳性假设时, 可以利用相邻时刻数据之间的时间相关性对故障进行检测及数据校正, 因此本文选择采用均值滤波的方式对运动状态下的数据进行处理。计算公式如式 (7):

$$\hat{x}_i = \frac{x_{i-1} + x_{i+1}}{2} \quad (7)$$

式中, \hat{x}_i 为前一刻响应 x_{i-1} 与后一刻响应 x_{i+1} 的平均值。由于对数据的检测校正按时间顺序进行, 因此认为 x_{i-1} 已进行过处理, 不在本次的故障考虑范围内。 x_i 与 x_{i+1} 故障的判断依据由式 (8) (9) 给出:

$$x_i \in (\hat{x}_i - \theta, \hat{x}_i + \theta) \quad (8)$$

$$x_{i+1} \in (x_{i-1} - 2\theta, x_{i-1} + 2\theta) \quad (9)$$

式中, θ 为根据载体实际运动场景所设定的阈值。根据冲击故障的瞬态特性, 本文假设 x_i 与 x_{i+1} 不同时存在故障, 当响应数据 x_{i+1} 满足式 (9) 且 x_i 不满足式 (8) 时, 认为 i 时刻加速度计出现故障, 以 \hat{x}_i 作为校正值代替 x_i 。校正方法如式 (10) 所示:

$$x_i = \begin{cases} \hat{x}_i & \text{if } x_{i+1} \in (x_{i-1} - 2\theta, x_{i-1} + 2\theta) \\ \& x_i \notin (\hat{x}_i - \theta, \hat{x}_i + \theta) \\ x_i & \text{else} \end{cases} \quad (10)$$

式中, $\&$ 表示逻辑与。

4 实验验证

为了验证所设计的自检测自校正算法的有效性, 本章进行了算法性能分析并在近感计算单元中评估了算法的资源消耗。在 4.1 节介绍了所使用的实验平台及数据, 4.2 节通过实验评估了所设计算法的性能以及算法在近感计算单元中的资源消耗, 4.3 节对实验的结果进行了分析与讨论。

4.1 实验装置设计及数据集构建

由于收集真实的不同类型的故障数据存在一定难度, 因此本文选择采用故障诊断领域中常用故障注入的方式对故障数据进行模拟。即依据不同故障的信号特征, 通过在实际收集的正常加速度计响应数据中注入故障的方式模拟故障数据。本文所搭建的数据采集平台如图 3 所示, MEMS 加速度计通过单片机与计算机相连, 其采集的数据将通过单片机实时传输至计算机中进行保存。




图 3 实验数据采集平台

对于静止状态数据的收集, 本文参考加速度计标定中的静态六位置法^[24], 收集了地东南、天西南、西地南、东天南、南西地和东北天六组静止数据, 此外还收集了 12 组不同位姿下的静止数据。传感器输出速率设为 100 Hz, 即相邻点时间间隔为 10 ms。

所采集 18 组静止状态数据如图 4 所示, 其中每组数据长度为 100 样本点, 共计 1 800 样本点。所采集运动状态数据如图 5 所示, 数据长度为 2 700 样本点。

近感计算单元资源消耗评估中所采用的近感计算单元是 TI 的 CC1350 处理器, 它是一种低功耗嵌入式处理器, 体积和计算功耗符合近感计算的计算单元定位, 其内核为 Arm Cortex-M3, 时钟频率最高 48 MHz。




图 4 静止状态数据




图 5 运动状态数据

4.2 实验过程

在本节中, 我们通过一系列实验对所设计算法的性能进行了全面评估。具体而言, 第 4.2.1 节详细评估了本文算法对于不同故障的检测校正性能。紧接着, 本文在第 4.2.2~4.2.4 节中分别对所设计算法中状态鉴别、静止状态下自检测自校正和运动状态下自检测自校正 3 个部分的有效性进行了测试。最后, 在 4.2.5 节评估了算法在近感计算单元上的资源消耗。

4.2.1 故障数据自检测自校正

为了评估算法在设定场景中的性能, 本文使用故障注入对不同故障进行了模拟, 并测试了算法对故障的检测与数据校正效果。

本文通过故障注入的方式对故障进行了模拟, 将静止数据与运动数据进行混合用以模拟动静交替的状态, 在混合数据中注入不同故障以模拟故障数据。通过对比原始的无故障数据与算法重构后的故障数据, 可以对算法的性能进行评估。下面将分别给出性能评价方式及故障注入方式。

在算法性能评价指标的选择上, 本文以检测率 (FDR,

fault detection rate) 和误检率 (FPR, false positive rate) 作为自检测算法的评价指标, 其计算分别如式 (11) (12) 所示:

$$FDR = \frac{TP}{TP + FN} \quad (11)$$

$$FPR = \frac{FP}{TN + FP} \quad (12)$$

式中, TP 为实际故障且被检测出故障的数据数量, TN 为实际正常且被判断为正常的的数据数量, FP 为实际正常但被误判为故障的数据点数量, FN 为没有被检测出的故障点数量。

对于故障数据的校正效果, 以平均绝对误差 (MAE, mean absolute error) 作为故障重构校正的评价指标, 其计算如式 (13) 所示:

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (13)$$

式中, n 为重构数据中与原无故障数据中不相同的数据点数量, x_i 为原始数据, \hat{x}_i 为重构后的数据。

在故障注入的设置上, 本文在每一轮实验中向混合后的 2 000 个样本点中分别注入了冲击、偏差、信号丢失和恒定输出 4 种故障。其中, 每一轮故障注入的参数为: 1) 冲击故障随机注入 100 个点, 故障幅度在 0.5~0.7 g 随机, 故障极性 (正负) 随机; 2) 偏差故障在静态数据中随机注入 5 段, 每段长度 20 个连续样本点, 故障幅度 0.5 g; 3) 信号丢失故障在静态数据中随机注入 5 段, 每段长度 20 个连续样本; 4) 恒定输出故障在静态数据中随机注入 5 段, 每段长度 20 个连续样本点, 恒定值 0.5 g。

上述每种故障进行 10 轮实验, 取这 10 轮实验的平均值作为最终测试结果, 算法对 4 种故障的检测与数据校正效果如表 2 所示。

表 2 4 种故障检测校正效果

故障类型	FDR/%	FPR/%	MAE/g
冲击	94.700	1.663	0.059
偏差	95.100	1.263	0.048
信号丢失	90.000	1.052	0.132
恒定输出	90.900	1.263	0.136

由表 2 可知, 算法对冲击故障以及静止状态下的偏差故障、信号丢失故障和恒定输出故障均具有较好的检测校正效果。其中, 4 种故障的检测率均达到 90%, 误检率不到 2%, 平均绝对误差也在 0.15 g 以下。

图 6 以 X 轴混合数据为例展示了故障注入的结果以及本文所设计算法对 4 种故障检测与数据校正的可视化结果。

由于故障检测算法需要依赖阈值进行判断, 因此故障检测的准确率与故障的幅度大小具有一定的相关性。本文以冲击故障为例, 评估了故障幅度对故障检测校正效果的影响。故障注入的方式为随机在数据中注入 100 个冲击故障, 故障的幅值分别 0.1~0.7 g, 步长为 0.1 g。同样, 每

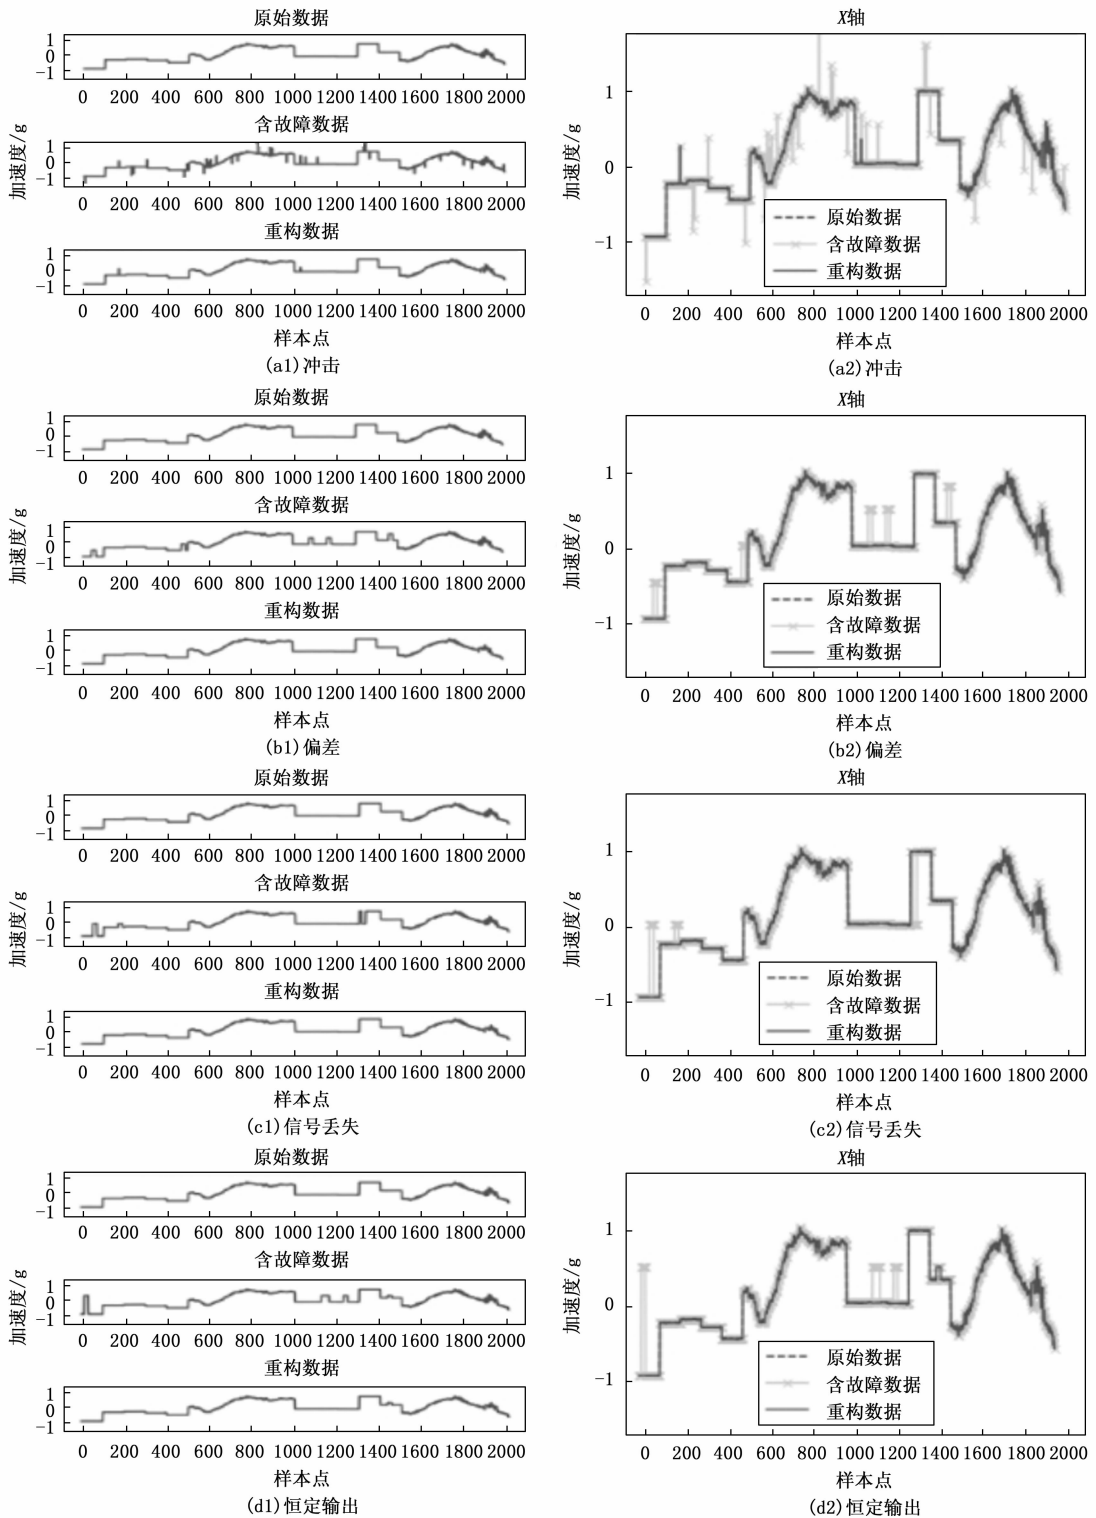


图 6 自检测自校正结果

种幅度的故障都进行了 10 轮实验，取平均值作为最终的测试结果。不同故障幅度的冲击故障下，算法性能如表 3 所示。

由表 3 可知，随着故障幅度的增大，检测率也随之上升，当幅度达到 0.5 g 后，检测准确率可达 90% 以上。其中

故障幅度在 0.3~0.5 g 范围内检测率出现较大幅度变化，其余区间内检测率变化较为平缓。误检率整体波动幅度较小。平均绝对误差在故障幅度 0.1~0.3 g 的范围内随着故障的增大而增加，在 0.3~0.6 g 的区间内随着故障的增大而减小，在 0.6~0.7 g 的范围内略有上升。

表 3 不同故障幅度下冲击故障自检测自校正效果

幅度/g	FDR/%	FPR/%	MAE/g
0.1	21.000	1.237	0.099
0.2	25.200	1.305	0.127
0.3	40.400	1.442	0.129
0.4	71.000	1.605	0.088
0.5	92.900	1.574	0.058
0.6	94.400	1.621	0.056
0.7	95.300	1.694	0.060

4.2.2 运动状态鉴别

本文通过 3 棵决策树及判别器实现加速度计运动状态鉴别。为了验证状态鉴别算法的有效性, 本文测试了状态鉴别算法的分类性能。

为了实现算法在数据中存在故障的情况下仍能准确区分两种运动状态的目的, 本文在原有的无故障数据集的基础上, 通过对原始数据注入故障的方式进行数据增强。注入的故障具体为: 1) 冲击故障, 随机注入共 400 故障样本点; 2) 偏差、信号丢失、恒定输出 3 种故障, 分别在原始数据的基础上进行故障注入, 每 100 个样本点随机选择其中 40% 连续注入。

在评价指标的选择上, 本文以正确判断的数据数量占总数据数量的百分比进行评价。在故障注入的设置上, 每一轮所注入的故障为: 1) 冲击故障, 随机在 500 个样本点中注入故障, 幅度 0.5~0.7 g 随机, 极性随机; 2) 偏差、信号丢失、恒定输出 3 种故障: 分别随机注入 10 段故障, 每段长度 50 样本点, 偏差故障和恒定输出故障的幅值均为 0.5 g。10 轮实验结果的平均值如表 4 所示。

表 4 不同故障状态鉴别效果 %

无故障	冲击	偏差	信号丢失	恒定输出
98.50	97.35	98.45	97.80	96.75

由表 4 可知, 状态鉴别算法在数据中存在故障的情况下仍保持了较高的鉴别准确率, 约为 97%。由于本文所设计的状态鉴别算法考虑了传感器存在故障的情况, 在决策树的训练数据中引入了故障数据, 因此算法能够实现对有故障数据的状态鉴别, 但对于无故障的数据, 鉴别准确率没有达到 100%。

4.2.3 静止状态下自检测自校正

本节首先通过故障注入的方式验证了所设计的静止状态自检测自校正算法的有效性。然后, 将本文所采用的基于矢量和的自检测算法与基于 PCA 的自检测算法进行了对比, 证明了所采用的自检测算法的优越性。

为了验证所设计的静止状态下故障检测与数据校正算法的有效性, 本文测试了算法对四种故障的检测及数据校正性能。所设置的故障形式及评价指标同 4.2.1 节中完整算法测试所用的一致。10 轮测试的平均结果如表 5 所示。

表 5 静止数据自检测自校正效果

故障类型	FDR/%	FPR/%	MAE/g
冲击	94.100	0	0.020
偏差	93.400	0	0.023
信号丢失	100.000	0	0.004
恒定输出	100.000	0	0.004

由表 5 可知, 算法针对四种故障的检测率均不低于 93%, 误检率为 0, 平均绝对误差在 0.03 g 以下。结果表明, 所设计的静止状态自检测自校正算法对 4 种类型的故障均具有较好的检测校正效果。

为了证明所选择的基于矢量和的故障检测算法的优越性, 本文对比了基于 PCA 的故障检测方法与基于矢量和的故障检测方法。

平方预测误差 SPE 是基于 PCA 的故障检测方法中常用的一个统计量, 通常用该统计量是否超过控制限来判断系统是否发生异常^[25]。本文通过对原始数据进行特征提取, 计算了三轴响应残差的绝对值以及信号幅度域^[26]共 4 个特征, 与原始数据及矢量和构成了八维数据, 对这组八维数据使用 PCA 进行故障检测。图 7 以一组冲击故障和一组偏差故障为例可视化展示了基于 SPE 统计量进行故障检测校正的原理。当数据点的 SPE 值超出控制限时, 判断故障发生。




图 7 基于 SPE 统计量的故障检测

为了对比两种故障检测方法的性能, 本文分别测试了两种算法对冲击故障的检测率、误检率, 并将算法移植到近感计算单元中以评估其计算资源消耗。在故障注入的设置上, 采用随机注入 100 个冲击故障的方式; 计算资源的评估方式为, 输入窗口长度为 10 的数据, 分别使用两种方法进行检测, 测量其计算所需的时间。表 6 展示了实验结

果,表中数据均为 10 轮实验的平均值。

表 6 两种检测算法的平均检测性能

	FDR/%	FPR/%	耗时/时钟周期
矢量和	95.200	0	2 649
PCA	97.600	0.692	155 979

由表 6 可知,两种算法对故障的检测性能相差不大,但从计算量的角度,基于矢量和的检测方法优于基于 PCA 的故障检测方法。针对单组数据的故障检测耗时,结合时钟频率 48 MHz 可算得,基于 PCA 的检测方法平均需要 3.250 ms,而基于矢量和的检测方法平均仅需要 0.055 ms,是基于 PCA 检测方法的 1.7%。故本文所选用的静止状态故障检测算法在检测效果接近的情况下,具有更小的计算量,更适宜在近感计算单元中运行。

4.2.4 运动状态下自检测自校正

为了测试运动状态下算法对冲击故障检测校正的效果,本文同样通过故障注入的方式对算法性能进行了评估。将 100 个 0.5 g 的冲击故障随机注入数据中,10 轮测试的平均值如表 7 所示。

表 7 运动数据自检测自校正效果

故障类型	FDR/%	FPR/%	MAE/g
冲击	97.600	0.012	0.021

由表 7 可知,所采用的运动状态自检测自校正算法对冲击故障的检测率达到 97.6%,误检率 0.012%,平均绝对误差 0.021 g。故算法能够较为准确地处理运动状态下的冲击故障。

4.2.5 近感计算单元资源消耗

最后,本文在近感计算单元中实际运行了所设计的算法以评估其资源消耗。本文分别测试了算法在 CC1350 中运行的功耗、时间以及存储资源消耗。功耗测量的结果如图 8 所示。




图 8 运行功耗测试

在 3.3 V 电压下,芯片工作电流为 0.023 A,计算可得运行功耗为 75.9 mW。

在 CC1350 的开发环境 Code Composer Studio 中,查看程序共占用 4.3 kB 的 FLASH 空间。处理 10 组数据时,程序共消耗 122 108 个时钟周期,可算得运行时间约为 2.544 ms。

4.3 实验结果分析与讨论

由上述实验,本文所提出的算法能够较为有效地检测并校正 MEMS 加速度计的 4 种故障。其中对冲击故障和偏差故障的检测及数据校正效果较好,可达 95% 的左右准确率以及 0.06 g 左右的平均绝对误差。针对信号丢失、恒定输出两种故障,检测率均达到 90%。

由表 3 可知,故障检测率在故障 0.3~0.5 g 的范围内提升速度较快。本文分析是由于运动状态故障检测与数据校正算法所设定的阈值为 0.4 g,因此在算法的实际使用中,根据载体运动状态准确分析数据并确定阈值是提高检测性能的关键因素。

由表 4 可知,本文所设计的加速度计运动状态鉴别算法即使在数据中存在故障的情况下也能较好实现状态判别。

由近感计算单元中的资源消耗评估结果可知,所设计算法仅需 4.3 kB 内存空间,处理 10 组三轴响应仅需 2.54 ms。由于传感器输出速率为 100 Hz,即采集并传输一组数据需要 10 ms,因此本文所设计的算法具有在 100 Hz 传输速率下实时检测并校正传感器响应数据的能力。

5 结束语

为了在一些配备了 MEMS 加速度计的资源受限的设备中实现加速度计自检测与自校正,本文设计了一种轻量化、低功耗、易在近感计算单元中部署的加速度计自检测自校正算法。该方法基于数据驱动,降低了对所用加速度计物理模型及测量原理的依赖,避免了对故障进行建模的过程。此外,该方法不依赖冗余传感器,可以在仅有单个加速度计的情况下运行,适用于资源受限的智能设备。实验结果表明,该算法对冲击、偏差、信号丢失、恒定输出 4 种故障的检测率均达到 90%,平均绝对误差小于 0.15 g,能够有效实现故障的检测与故障数据的校正。此外,算法在 CC1350 中运行时,内存占用仅 4.3 kB,功耗为 75.9 mW,且具有实时处理加速度计数据的能力。

目前,本文仅对上述 4 种故障进行了研究与测试,在未来的工作中,我们将会考虑对更多的故障类型进行分析。此外,由于数据驱动模型依赖丰富的数据来挖掘信息,因此对于数据数量存在要求,未来我们考虑使用数据增强等手段来减少数据采集及标注的成本。最后,目前本文所采用的均值滤波方法要求运动状态满足平稳性假设,且该方法无法处理非冲击故障,后续将选用性能更好的方法以提升所设计算法的整体性能。

参考文献:

- [1] 秦和平. 惯性技术发展动态发展方向研讨会文集——新型惯性元件与先进导航技术 [C] //北京:中国惯性技术学会, 2023: 13.
- [2] GRIMMELSMAN K A, ZOLGHADRI N. Experimental evaluation of low-cost accelerometers for dynamic characterization of bridges [C] //Proceedings of the 37th IMAC, A Conference and Exposition on Structural Dynamics 2019, Springer Interna-

- tional Publishing, 2020; 145 - 152.
- [3] MANIKANDAN K G, PANNIRSELVAM K, KENNED J, et al. Investigations on suitability of MEMS based accelerometer for vibration measurements [J]. *Materials Today: Proceedings*, 2021, 45: 6183 - 6192.
- [4] 刘 维, 王明杭, 朱志宇. 基于 MEMS 传感器的惯导系统预处理和姿态解算 [J]. *传感技术学报*, 2019, 32 (11): 1677 - 1681.
- [5] MATEJCEK M, SOSTRONEK M. The influence of inertial sensors parameters on guidance systems [C] //2020 New Trends in Signal Processing (NTSP), IEEE, 2020; 1 - 6.
- [6] 沈 楠. 基于 GNSS 与加速度计融合的建筑物形变监测关键技术研究 [D]. 武汉: 武汉大学, 2021.
- [7] 石磊鑫. 基于可穿戴设备的人体行为识别系统的研究 [D]. 济南: 山东大学, 2021.
- [8] 丁衡高. 三十年不断发展的 MEMS 惯性传感器 [J]. *导航与控制*, 2023, 22 (4): 1 - 4.
- [9] AVRAM R C, ZHANG X, MUSE J. Quadrotor sensor fault diagnosis with experimental results [J]. *Journal of Intelligent & Robotic Systems*, 2017, 86 (1): 115 - 137.
- [10] ZHU M, LI J, WANG W, et al. Self-detection and self-diagnosis methods for sensors in intelligent integrated sensing system [J]. *IEEE Sensors Journal*, 2021, 21 (17): 19247 - 19254.
- [11] 郭 俊. 无人机传感器故障诊断与容错技术研究 [D]. 兰州: 兰州理工大学, 2020.
- [12] BALABAN E, SAXENA A, BANSAL P, et al. Modeling, detection, and disambiguation of sensor faults for aerospace applications [J]. *IEEE Sensors Journal*, 2009, 9 (12): 1907 - 1917.
- [13] LIU B, ZHOU Y, FU H, et al. Lightweight self-detection and self-calibration strategy for MEMS gas sensor arrays [J]. *Sensors*, 2022, 22 (12): 4315.
- [14] 张 煜, 刘保真, 单聪森, 等. 基于 IPPG 技术的生理参数检测综述 [J]. *医疗卫生装备*, 2020, 41 (2): 91 - 95.
- [15] OBEIDAT Y M, ALQUDAH A M. An embedded system based on raspberry pi for effective electrocardiogram monitoring [J]. *Applied Sciences*, 2023, 13 (14): 8273 - 8274.
- [16] 李 园, 周 静, 莫兴燕, 等. 心电监护袖带反向缚扎法在慢性肝病患者中的应用研究 [J]. *护理学报*, 2021, 28 (17): 76 - 78.
- [17] SILVERIO A A, SUAREZ C G, SILVERIO L A, et al. An unobtrusive, wireless and wearable single-site blood pressure monitor based on an armband using electrocardiography (ECG) and reflectance Photoplethysmography (PPG) signal processing [J]. *Electronics*, 2023 12 (7): 1538 - 1539.
- [18] ZSARNOCZAY E, FINK N, SCHOEPEF U J, et al. Ultra-high resolution photon-counting coronary CT angiography improves coronary stenosis quantification over a wide range of heart rates-a dynamic phantom study [J]. *European Journal of*
- [14] ZHANG H, WEI X, GAO Y, et al. Analytical study and thermal compensation for capacitive MEMS accelerometer with anti-spring structure [J]. *Journal of Microelectromechanical Systems*, 2020, 29 (5): 1389 - 1400.
- [15] 杨志梅. 扭摆式硅微加速度计性能补偿方法研究 [D]. 苏州: 苏州大学, 2015.
- [16] SEYED M S M, MOAVENI B, MOSHIRI B, et al. Auto-calibration and fault detection and isolation of skewed redundant accelerometers in measurement while drilling systems [J]. *Sensors*, 2018, 18 (3): 702.
- [17] KULLAA J. Detection, identification, and quantification of sensor fault in a sensor network [J]. *Mechanical Systems and Signal Processing*, 2013, 40 (1): 208 - 221.
- [18] WANG S, ZHU W, SHEN Y, et al. Temperature compensation for MEMS resonant accelerometer based on genetic algorithm optimized backpropagation neural network [J]. *Sensors and Actuators A: Physical*, 2020, 316: 112393.
- [19] ZHOU F, CHAI Y. Near-sensor and in-sensor computing [J]. *Nature Electronics*, 2020, 3 (11): 664 - 671.
- [20] 周志华. 机器学习 [M]. 北京: 清华大学出版社, 2016.
- [21] 刘亚芬. 基于 GA 的 CART 决策树改进算法与应用 [D]. 广州: 广州大学, 2020.
- [22] 赵凯阳, 张家良. 基于数据变化率和重构贡献图的微小故障诊断方法 [J]. *计算机测量与控制*, 2023, 31 (12): 14 - 20.
- [23] 杜少林, 陈书钊, 陈鹏光, 等. MEMS 加速度计噪声分析与降噪方法研究 [J]. *传感器与微系统*, 2018, 37 (7): 45 - 48.
- [24] 林国鑫. MEMS 加速度计的误差补偿技术研究 [D]. 北京: 北京化工大学, 2023.
- [25] 周彦臻. 环境感知智能微系统自检测自校正技术研究 [D]. 哈尔滨: 哈尔滨工业大学, 2022.
- [26] 钟 君. 基于加速度传感器的日常行为识别的特征提取方法研究 [D]. 兰州: 兰州大学, 2016.
- [19] 孔令琴, 赵跃进, 董立泉, 等. 基于成像光电容积描记技术的非接触式生理参数检测及其应用 [J]. *光学学报*, 2023, 43 (15): 266 - 279.
- [20] 徐 杰, 胡丹峰, 张 林, 等. 基于双摄像头的心率测量系统的设计与改进 [J]. *半导体光电*, 2023, 44 (1): 115 - 121.
- [22] 张 昊, 孙 元, 王志刚, 等. 基于 ARM 和 WIFI 技术的心电信号实时检测系统设计与研究 [J]. *计算机测量与控制*, 2021, 29 (1): 54 - 58.
- [23] 饶珂萌. 基于 GPRS 和 Zigbee 的无线心电信号监测系统设计 [J]. *计算机测量与控制*, 2021, 29 (2): 20 - 24.
- [24] BI J, QIN X, HU D, et al. Fatigue driving detection method based on IPPG technology [J]. *Promet-Traffic & Transportation*, 2023, 35 (4): 540 - 551.
- [25] GARIS G, HAUPTS M, DUNING T, et al. Heart rate variability and fatigue in MS: two parallel pathways representing disseminated inflammatory processes? [J]. *Neurological Sciences*, 2023, 44 (1): 83 - 98.