

胡龙娇, 陈庆奎. 基于数据驱动的故障诊断协同模型[J]. 智能计算机与应用, 2025, 15(11): 39-44. DOI: 10.20169/j.issn.2095-2163.251106

基于数据驱动的故障诊断协同模型

胡龙娇, 陈庆奎

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要: 作为物联网数据获取的边缘终端, 传感器状态对于数据采集的准确性和时效性至关重要, 然而传感器数量大且各自运行系统封闭, 传输机制多样, 长期处于恶劣环境, 受干扰因素影响传感器输出常常失真, 从而影响系统测量的可靠性。此外, 传统的物联网传感器状态通常需要人工检查, 特别是在传感器发生漂移故障的情况下, 由于漂移幅度一开始非常微小且稳定, 相较于其他故障更具隐蔽性。本文提出了一种数据驱动的故障诊断协同模型, 从周期分析故障诊断、图像视觉故障诊断以及数据分析故障诊断3个方面对公共交通环境的传感设备状态进行分析。实验证明, 本文的协同模型诊断能力优于传统模型, 能够缩短传感设备状态诊断时间, 为传感器相关工作提供有力支持。

关键词: 传感器状态; 故障诊断; 边缘; 协同模型

中图分类号: TP277; TP315

文献标志码: A

文章编号: 2095-2163(2025)11-0039-06

Collaborative model of fault diagnosis based on data driven

HU Longjiao, CHEN Qingkui

(School of Optical-electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: As the edge terminal of Internet of Things data acquisition, the status of sensors is crucial to the accuracy and timeliness of data acquisition. However, the number of sensors is large, their operating systems are closed, transmission mechanisms are diverse, and they are in a harsh environment for a long time. The sensor output is often distorted by interference factors, thus affecting the reliability of system measurement. In addition, the status of traditional Internet of Things sensors often requires manual inspection, especially in the case of sensor drift failures, because the drift amplitude is very small and stable at the beginning, compared to other faults more hidden. Against this background, this paper proposes a data-driven collaborative model for fault diagnosis to analyze the status of sensing devices in the public transportation environment from three aspects: periodic analysis fault diagnosis, image visual fault diagnosis, and data analysis fault diagnosis, to achieve comprehensive monitoring of the status of sensing devices. Experiments have proved that the collaborative model in this paper has a superior diagnostic ability than the traditional model, can shorten the diagnosis time, and provide strong support for sensor-related work.

Key words: sensor status; fault diagnosis; edge; collaborative model

0 引言

城市交通的日益发展, 利用公共交通工具也可以享受舒适的出行环境, 所以实时关注公共交通情况显得尤为重要。以上海轨道交通为例, 其运营时间已有数年, 随着使用时间的增加, 监控传感器系统故障的次数也随之递增, 由于公共交通监控传感器分布广泛且结构复杂, 设备故障的监测难度大大增加^[1-2]。传统解决方案采用定期离线人工检查的方

式, 耗时费力, 目前已将研究重点转向故障的在线诊断方面。2018年, Sultani等^[3]以弱监督学习的方式对监控里的异常情况进行训练, 实现对监控传感器中异常画面的诊断; Bakhtiaridoust等^[4]利用深度神经网络结构形成非线性系统的库普曼预测器, 将得到的线性模型用于故障检测; Gao等^[5]提出了一种基于改进深度卷积生成对抗网络(DCGAN)的新型图像诊断方法, 用于机械传感器故障分类; 王炜俊^[6]用Relim算法对监控设备状态监测数据进行挖

基金项目: 国家自然科学基金(61572325); 上海重点科技攻关项目(19DZ1208903)。

作者简介: 胡龙娇(1998—), 女, 硕士, 主要研究方向: 计算机视觉, 深度学习。

通信作者: 陈庆奎(1966—), 男, 博士, 教授, 博士生导师, 主要研究方向: 计算机集群, 并行计算, 人工智能等。Email: chenqingkui@usst.edu.cn。

收稿日期: 2024-02-26

哈尔滨工业大学主办 ◆ 学术研究与应用

掘,生成监控设备的故障关联规则,对监控设备故障进行分析;Gao 等^[7]设计了一种自适应心跳机制,使得双方的主机可以通过交换心跳数据包来检测服务通信状态;Yan 等^[8]设计了一种通信负荷优化的故障检测算法,用来检测建筑 SHM (Structural Health Monitoring) 系统的传感器故障;何天放等^[9]基于边云协同的温度仪表漂移故障诊断方法,利用系统内与待诊断仪表相关的仪表测量值进行漂移故障诊断;Long 等^[10]提出了一种基于深度双向长短期记忆递归神经网络的模型,该模型能够自动提取制冷系统运行数据,利用累积残差矢量法来提高传感器漂移故障的可检测性。虽然传感器故障诊断方法在各个领域得到了广泛应用,但目前仍存在问题。首先,故障分类时,测试方法依据单一,难以适应环境的变化;其次,传感器故障类别较多,单一方法判断故障,无法保证准确性。为解决上述问题,本文利用传感器的特性,提出了一种传感器故障诊断协同模型,通过此模型中的多个诊断模块实现对传感器资源状态监测和异常诊断,能更迅速地发现问题。

此模型主要由 3 个部分构成:

(1)数据输入:边缘部件采集监控数据,对数据进行格式转换,再由中间部件拉取监控数据并推送数据,实现对传感器各指标的实时监控,如内存利用率、通信数据、监控视频图像数据等;

(2)故障诊断:利用自定义传输协议将监控信息传输到模型诊断中心,进行传感器的状态分析;

(3)故障决策:当指标结果达到指标预设阈值,通过决策模块计算评估传感器状态。

1 模型概述

1.1 模型结构

物联网传感器状态监测系统建设基于一系列的标准规范体系以及安全防护体系。在安全防护框架下,本文所提出的协同模型可与传感器进行数据传输,协同模型结构如图 1 所示。

1) 传感器设备

系统的设备主要由监控传感器、压力传感器、电流传感器等多种感知设备组成,为数据采集服务提供了可靠的硬件支持。

2) 缓冲传输区

为控制数据流,将收集的不同类型数据通过发送接口(send)暂存至缓冲区,经传输中间件处理后传到汇集接口(collect),接口根据任务周期再进行数据任务分配,其中数据传输中间件包括数据格式

转换器(DFT)和数据传输器(DT),该缓冲区的数据将用于后续设备的诊断服务。




图 1 协同模型结构

Fig. 1 Distribution structure of sensor and model components

3) 配置表与转发表

在协同模型结构中,配置表用于存放系统的配置信息,包括服务器类别、服务器 IP、缓冲区数量等。服务器端口分为数据接收端口和数据转发端口,接收端口根据配置表的信息获取接收端口号,并循环扫描端口接收数据;转发端口通过查询配置表中的转发端口号,将数据发送至对应的诊断模块;诊断模块基于接收到的数据完成状态诊断,并将结果反馈至故障决策模块。

4) 故障决策模块

决策模块将根据状态诊断结果对传感器的工作状态进行评估,将评估结果反馈给设备的管理中心,进行动态调整和修复。

1.2 模型工作过程

为提升监测体系整体处理能力,协同监测模型依托数据采集层获取的多源数据(通信/图像/资源信息),经特征提取与处理生成远程监视结果。模型基于该结果,判断传感器设备的运行状态,完整的协同模型监测流程如图 2 所示。

1)初始化:启动设备后基于中间件获取到边缘设备的软硬件资源,将数据流以相应的元组形式输入缓冲区,缓冲区存储数据后,服务器再按照转发表的要求进行传输。

2)处理:数据传输至数据驱动模块后,数据驱动模块根据数据类型将数据依次传输给相应故障诊断模块进行信息处理,诊断模块再将收集的监视结

果反馈给故障决策模块,决策模块针对故障类型建立故障临时存储队列。

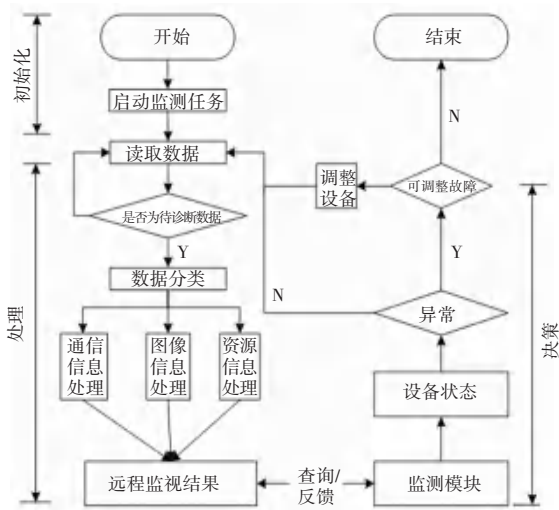


图 2 协同模型监测流程

Fig. 2 Collaborative model monitoring process

3) 决策:本模型中设置的故障队列有通信故障队列、图片采集异常队列和硬件资源漂移队列。根据结果队列再进行以下两步处理:

(1) 故障优先级

通信故障会直接导致整个系统数据交互链路中断,硬件故障会直接影响整个系统的传输效率下降,因此在模型决策阶段需要给不同故障赋予不同的优先级,如:p0 为最严重故障-通信故障,p1 为较严重-硬件漂移故障,p2 为严重故障-图片采集故障,确保模型能够自动识别并优先处理影响范围大的故障。

(2) 设备状态队列评估

在决策阶段,会为每个节点保存一个固定长度的历史状态队列和故障计数器,历史队列中保存着每个节点最近的状态信息,以在一个较长的时间维度上做出更精准的判断^[11-12]。中间件通过模型获取状态后,生成状态标志status。0:通信故障,1:硬

件设备故障,2:数据采集故障,放入相应节点的状态队列中,故障程度越高则对故障期望的影响越大。将故障标志累加后取平均作为故障期望 E,即

$$E = \sum_{i=1}^T \text{status} / T \tag{1}$$

其中, T 为评估周期。

2 模型诊断功能

2.1 周期分析故障诊断

在现代工程和科学领域中,传感器可能会出现各种故障,可能导致数据失真、系统异常。本文基于协同模型中的周期分析故障诊断来监测传感器的通信情况,鉴于传感器数量大,为方便协同模型的通信管理,该诊断模块使用如图 3 所示的分级通信结构实现对传感器通信数据的传输管理。各级通信模块负责汇集下级通信中所有的传感器通信情况,以便后续故障分析。除此之外,考虑到需要面对不同类型的传感通信数据,通用的字符流会增加待传输数据的开销。为此,本文故障诊断模块基于如图 4 所示的通信数据包格式记录通信信息,通过格式中的数据类型以及设备号可快速区分不同传感器的通信信息。




图 3 分级通信技术

Fig. 3 Hierarchical communication technology

消息 id	发送设备号	接收方(主)	接收方(分)	时间戳	心跳数	数据类型
-------	-------	--------	--------	-----	-----	------

图 4 数据包格式

Fig. 4 Packet format

当传感设备正常运行时,每个发送端的传感器节点需按图 5 所示方式与接收端的主系统建立通信数据链路,通过发送通信数据包汇报工作状态。发送方设置重传定时器,若未在有效期内收到确认报文则触发重传机制。当接收端存储的超时异常记录

达到临界值时,周期故障诊断模块需基于分级通信数据链路的汇总的交互信息分析是否存在通信故障,并将诊断结果传回模型中的决策模块,同时按图 6 的通信异常存储格式记录异常信息以便定位传感器通信故障。

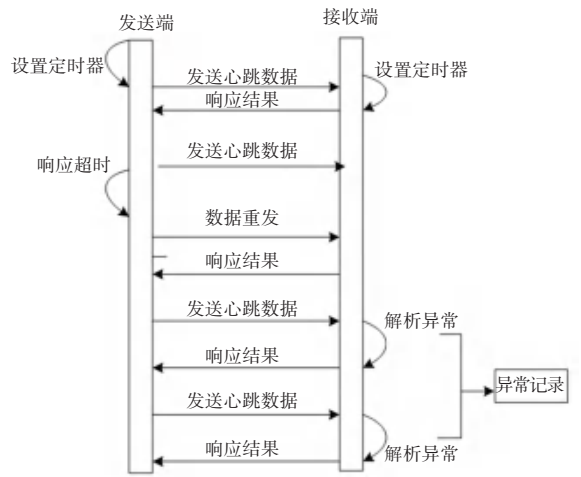


图 5 通信交互图

Fig. 5 Communication interaction diagram

数据 id	设备 ID	警告名称	时间戳	报警描述	报警状态
-------	-------	------	-----	------	------

图 6 通信异常存储格式

Fig. 6 Communication exception storage format

应用层通过中间件及时获取存储数据中报警状态(0:新异常,1:修正后异常)以及异常类型来感知传感器的工作通信状态。在进行周期性监测时,要考虑到传感器的工作寿命和消耗,避免过于频繁地询问导致传感器寿命缩短。

2.2 图像视觉故障诊断

基于模型的周期分析能够保障传感器在通信层面的正常运行。然而,大多数监控传感器处于露天环境,不可避免会受到周围环境因素的影响,容易出现拍摄角度变化的情况,而传感器传输图片的质量优劣会直接或间接地对后续相关工作产生影响^[13]。因此,本文将基于协同模型的图像视觉故障诊断方法,针对监控传感器的角度偏移故障进行分析。为了方便统计,数据在传输以(设备编号,图片存储地址,时间戳,图片状态,数据类型)元组的形式进行传输,公交车站台传感器监测的实时图像如图 7 所示。



图 7 传感器实时图像

Fig. 7 Real-time image of the sensor

将图像数据传入模型,模型再将数据发送到相应诊断模块,在诊断模块中采用图 8 所示的 SIFT (Scale-Invariant Feature Transform) 算法来提取图像

的边缘特征点,提取过程如图 8 所示。通过对比实时图像与参考图像的特征点匹配情况,能够准确判断监控点是否发生了偏移。




图 8 SIFT 特征提取过程

Fig. 8 SIFT feature extraction process

最终的偏移诊断结果如图 9 所示,可以看出当前的站台的视频角度处于正常范围内。借助模型中的图像视觉故障诊断,可以有效解决摄像机位置偏移带来的问题。



图 9 偏移诊断结果

Fig. 9 Offset diagnosis result

2.3 数据分析故障诊断

公交车台视频传感器分布复杂且需 24 小时连续运行,这种特性容易引发传感器漂移(Drift)。而传感器的漂移状态难以从外部直接判断。为及时诊断并处理该问题,本文在基于数据驱动的故障诊断协同模型中设置了数据分析故障诊断模块,通过对系统传回的元组数据(数据 ID,设备 ID,待监测指标值,时间戳,设备服务类型)进行分析,实现对传感器漂移状态的有效诊断,具体处理过程如图 10 所示。




图 10 数据分析故障诊断模块处理过程

Fig. 10 Processing procedure of the data analysis fault diagnosis module

假设传感器运行至稳定状态时间是 t_b , 模型正常运行观测时刻为 t_c , T 为采样周期, t_c 时刻可获取数据的组数 n :

$$n = \frac{t_c - t_b}{T}$$

(2)

若传感器发生故障, 动态调节时间周期为 t_a , 每个 t_a 时间段内可获取数据的组数 n 的计算方式更新为:

$$n = \frac{t_a}{T} \quad (3)$$

根据组数 n , 从监测数据中获取数据 $x = \{x_1, x_2, x_3, \dots, x_i, x_{i+1}, x_{i+2}, \dots, x_n\}$, 将 x 输入至模型的数据分析故障诊断模块, 完成对传感器漂移问题的分析, 输出值 \bar{x} 计算如下式:

$$\bar{x} = \sum_{i=1}^k w_i f_i(x) \quad (4)$$

其中, k 为集成诊断模块中子模块的个数; w_i 为每个子模块在故障预估时的权重; $f_i(x)$ 为诊断模块内部各个子模块的预测值。

考虑不同类型的传感器待监测指标的数据范围不同, 需构造反映传感器状态的综合指数, 根据综合指数分析传感器的漂移故障问题^[14]。综合指数计算方式如下式:

$$R = \left| \frac{A - \bar{x}}{A - \mu} \right| \quad (5)$$

其中, A 为传感器的各待监测指标的报警限值, μ 为传感器的日常监测均值。


借助综合指数 R 即可分析出传感器的漂移故障问题, 传感器漂移故障异常记录存储格式如图 11 所示。

数据 ID	设备 ID	待监测指标状态	时间戳	设备服务类型
-------	-------	---------	-----	--------


图 11 漂移故障异常记录存储格式

Fig. 11 Storage format for drift fault anomaly records

在传感器运行中, 应当对各自待监测指标给予足够的关注。因为待监测指标持续的高负载可能会引发系统性能的降低、响应时间的延长, 甚至导致系统崩溃。本文以内存使用率指标为例, 模型分析结果如图 12 所示。



(a) 内存使用率



(b) 内存使用率指标

图 12 指标分析结果图

Fig. 12 Index analysis result chart

3 模型评价

3.1 评价指标

为了证明协同模型的可用性, 本文利用处理能力和准确对模型进行评估。

1) 为验证协同模型在实际应用中的可用性, 硬件处理能力 (Ability) 是关键评估维度。通过选取数据吞吐量、处理速度、任务处理规模等在内的 n 个核心硬件指标, 组成指标集合 $R = \{R_1, R_2, R_3, \dots, R_n\}$ 进行加权运算, 处理能力计算如下式:

$$\text{Ability} = \sum_{i=1}^n R_i k_i \quad (6)$$

其中, R_i 为硬件处理能力指标的实际测量值, k_i 为指标在总处理能力中的重要程度占比。

2) 模型诊断准确率 (Accuracy) 计算公式如下式:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \quad (7)$$

其中, TP、TN、FP、FN 分别代表被模型预测为正类的正样本数、预测为负类的负样本数、预测为正类的负样本数、预测为负类的正样本数。

3.2 评价结果

为了检测模型的有效性, 本文对协同模型 (Cooperative model) 和非协同模型 (Non-cooperative model) 在处理能力上做对比分析实验, 实验结果如图 13 所示。可见与非协同模型相比, 本文提出的协同模型在处理传感器数据时具有更高的效率, 传感器间的信息共享和协同工作更加充分, 能够更全面分析数据, 尤其处理样本数量比较多时更能体现其模型的优势。

尽管在故障诊断领域已有多种优化策略以提升诊断成功率, 但由于系统复杂性与数据不确定性, 误

诊现象仍难以完全消除。本文的模型通过协同多源信息,构建融合式诊断框架,充分整合不同数据源与算法的优势,有效缩小故障诊断范围,规避单一方法的局限性。经实践验证,该策略显著提升了诊断成功率。模型在训练后的准确率对比如图 14 所示,体现了协同诊断策略的有效性与可靠性。

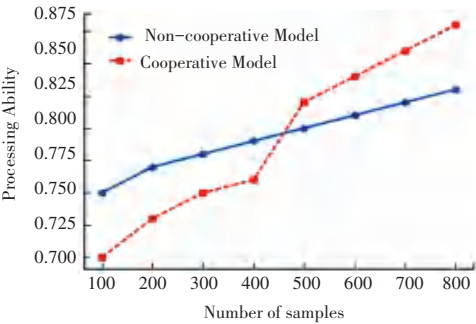


图 13 处理能力结果对比

Fig. 13 Comparison of average processing capacity results




图 14 模型诊断准确率对比

Fig. 14 Comparison of model diagnostic accuracy

4 结束语

本文提出了一种基于数据驱动的故障诊断协同模型,用于边缘智能传感器故障诊断。实验结果表明,引入边云协同方式应用于故障诊断中,在边缘完成对数据的预处理,提高了后续诊断效率;模型通过协同多源信息,构建融合式诊断框架,充分整合不同算法的优势,有效缩小故障诊断范围,规避单一方法的局限性。但该协同模型还存在一些不足,在应对大规模边缘监控传感器的诊断场景时,其数据处理效率与跨节点协同能力呈现一些短板。

参考文献

[1] 汤俊儿. 视频监控系統常見異常检测技术研究及应用[D]. 广州:华南理工大学, 2020.

[2] HU Z X, WANG Y, GE M F, et al. Data-driven fault diagnosis method based on compressed sensing and improved multiscale network[J]. IEEE Transactions on Industrial Electronics, 2019, 67(4): 3216-3225.

[3] SULTANI W, CHEN C, SHAH M. Real-world anomaly detection in surveillance videos[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ:IEEE, 2018: 6479-6488.

[4] BAKHTIARIDOUST M, IRANI F N, YADEGAR M, et al. Data-driven sensor fault detection and isolation of nonlinear systems: Deep neural-network Koopman operator[J]. IET Control Theory & Applications, 2023, 17(2): 123-132.

[5] GAO Y, PILTAN F, KIM J M. A novel image-based diagnosis method using improved DCGAN for rotating machinery [J]. Sensors, 2022, 22(19): 7534.

[6] 王伟俊. 融入故障诊断技术的监控设备状态监测平台的研究和实现[D]. 泉州:华侨大学, 2021.

[7] GAO C, DU J. Adaptive heartbeat mechanism for meteorology operation command system based on GPRS[C]//Proceedings of 2009 First International Conference on Information Science and Engineering. Piscataway, NJ: IEEE, 2009: 2522-2525.

[8] YAN K, ZHANG Y, YAN Y, et al. Fault diagnosis method of sensors in building structural health monitoring system based on communication load optimization[J]. Computer Communications, 2020, 159:310-316.

[9] 何天放, 王锴, 徐皓冬, 等. 基于边云协同的温度仪表漂移故障诊断方法[J]. 仪表技术与传感器, 2022 (6):88-94.

[10] LONG G, LI D H, YU L L, et al. Sensor drift fault diagnosis for chiller system using deep recurrent canonical correlation analysis and k-nearest neighbor classifier[J]. ISA Transactions, 2021, 122:232-246.

[11] 陈文强, 刘阳, 丁晓喜, 等. 轴承云边协同监测系统[J]. 轴承, 2022 (12):66-73.

[12] 段倩, 周华春, 刘颖, 等. 协同式网络监测模型的研究与设计[C]//全国网络与信息安全技术研讨会论文集(上册). 2007: 215-221.

[13] SUN K H, HUH H, TAMA B A, et al. Vision-based fault diagnostics using explainable deep learning with class activation maps[J]. IEEE Access, 2020, 8: 129169-129179.

[14] 谢润桦, 王滨, 张蕴明, 等. 面向智慧城市的物联网传感器状态监测与可视化应用[J]. 物联网技术, 2018, 8(3):18-20.