

DOI: 10.19650/j.cnki.cjsi.J2412830

基于时空关联的飞控传感器数据异常检测*

杨挺, 王媛, 王瑛琪, 宋宇晨, 刘大同

(哈尔滨工业大学电子与信息工程学院 哈尔滨 150080)

摘要: 飞控传感器数据的异常检测对保证飞行器安全稳定运行有重要意义。然而, 现有的异常检测方法大多仅从传感器数据之间的关联性 or 不同传感器间数据的相关性变化角度出发, 当飞行器运行工况动态变化时, 可能会由于对传感器数据的特征提取不充分而导致异常检测结果的准确率偏低且虚警率偏高。对此, 本文提出一种基于时空关联的飞控传感器数据异常检测方法, 实现对传感器数据时间与空间 2 个维度变化规律的融合建模。首先, 同时构建时序演化与空间相关性特征提取模块来对传感器数据进行时间与空间两个维度特征的并行提取。其次, 对 2 个模块的预测输出进行时空关联融合, 得到时空关联的预测飞控传感器数据。最后, 基于预测数据与实际数据残差的统计量进行阈值选取并对传感器数据进行异常检测。在无人机惯性测量单元仿真与实测数据集上对本文方法进行验证, 结果表明相较于相关向量机等典型的异常检测方法, 本文方法的异常检测准确率至少提高 0.4% 且虚警率至少降低 1.8%。

关键词: 飞控传感器数据; 特征提取模块; 时空关联; 异常检测

中图分类号: TP311 TH701 **文献标识码:** A **国家标准学科分类代码:** 510.4030

A spatio-temporal correlation method for flight control sensor data anomaly detection

Yang Ting, Wang Yuan, Wang Yingqi, Song Yuchen, Liu Datong

(School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150080, China)

Abstract: The normal operation of flight control sensors is the key of the safety and stability of the aircraft. However, most of the anomaly detection methods only consider the correlation between sensors data or the correlation change of data between different sensors. When the operating conditions of aircraft change dynamically, the accuracy of anomaly detection results may be low and the false alarm rate is high due to insufficient feature extraction. In this article, a flight control sensor data anomaly detection method based on spatio-temporal correlation is proposed to achieve the fusion modeling of sensor data changes in time and space. Firstly, the feature extraction module of temporal evolution and spatial correlation is formulated to extract the features in time and space in parallel. Secondly, the spatio-temporal correlation fusion is carried out to obtain spatio-temporal correlation predictive data. Finally, based on the statistic of the residual between the predicted data and the actual data, the threshold is selected and the sensor data is detected. Through the verification of simulation and measurement data, compared with typical anomaly detection methods such as RVM, the anomaly detection accuracy rate of the proposed method is at least 0.4% higher and the false alarm rate is at least 1.8% lower.

Keywords: flight control sensor data; feature extraction module; spatio-temporal correlation; anomaly detection

0 引言

飞控传感器用于测量飞行器的各种运动参数, 描述飞行器的运动状态及其在空间的位置, 是飞行控制系统

的首要环节, 飞控传感器的正常运行是保证飞行器安全、稳定运行的关键^[1]。典型的飞控传感器包括惯性测量单元 (inertial measurement unit, IMU)、全球卫星定位导航系统 (global navigation satellite system, GNSS)、磁力计等。由于飞行器飞行任务的不确定性与传感器自身可

能出现的各类故障,飞控传感器可能在飞行过程中产生非预期的异常数据,从而导致飞行器的运行模式异常甚至影响飞行安全。例如,埃塞俄比亚航空的波音 737MAX 客机坠毁的一个重要原因是其机动特性增强系统中的迎角传感器错误感知飞机姿态导致飞行控制系统做出了向下俯冲的决策,从而发生了坠机^[2]。此外,无人机飞控系统发生的故障的 70% 为传感器故障所导致^[3]。因此,为了保证作为飞行器核心部分的飞行控制系统的可靠性,进而使飞行器能够安全稳定运行,需要对飞控传感器数据中可能存在的异常进行实时检测,为异常源识别和可靠决策提供信息支撑,从而进一步提升其运行安全。

飞控传感器数据异常是指,飞控系统测量部件出现了预期功能缺失或性能显著下降从而表现出状态或输出数据的异常变化^[4]。而飞控传感器数据的异常检测,即在飞控系统传感器输出数据出现异常时,能够准确辨别出这种异常变化的发生。

目前飞控传感器数据异常检测方法通常分为基于知识的方法、基于模型的方法和数据驱动的方法^[5]。基于知识的方法^[6]通常需要研究领域的专家总结出异常检测的经验知识或者构造异常检测相关的专家知识系统。例如,美国航空航天局(national aeronautics and space administration, NASA)开发了基于专家经验的航天器自主故障诊断系统 Livingstone^[7],成功对星上搭载的成像仪和数据记录装置进行故障诊断。然而,基于知识的方法严重依赖于先验知识,导致这类方法的异常检测能力较差。

基于模型的方法^[8]通常需要建立精确的物理模型,计算估计值与实际测量值之间的残差,以确定是否发生异常。如 Hansen 等^[9]提出一种基于扩展卡尔曼滤波器的自适应观测器来产生分析冗余并创建残差,实现了对无人机空速计传感器的异常检测。然而,建立一个完整、准确的飞行器物理模型是非常困难的,导致这类方法的性能受到了限制。数据驱动方法直接利用飞控传感器运行状态下的监测数据进行故障诊断,可有效解决无人机结构复杂和任务场景不确定特性下的系统建模难题以及专家先验知识不足问题。随着飞行器系统日益复杂,需要监测的传感器数据也呈膨胀式发展,利用以监测数据为基础,基于机器学习与深度学习理论的数据驱动方法对飞控传感器数据进行异常检测成为国内外研究的热点所在^[10-11]。

在机器学习异常检测领域,Brnz 等^[12]将多维传感器数据作为支持向量机(support vector machine, SVM)的输入来提取传感器的时序关联特征与空间相关性特征,实现对陀螺仪和加速度计等参数的异常检测。Wang 等^[13]提出一种基于相关向量机(relevance vector

machine, RVM)的异常检测方法,通过对导航高度等传感器数据空间相关性特征的提取,实现了对气压传感器的异常检测。随着深度学习理论的日益成熟,基于深度学习的飞控传感器数据异常检测方法也取得了令人瞩目的进展。Wang 等^[14]提出了一种递归神经网络的变体模型,即长短期记忆网络(long short-term memory, LSTM)来提取传感器历史数据的时序特征,实现了对向北速度和气动升力速度的异常检测。Hundman 等^[15]将多维航天器遥测数据作为 LSTM 网络的输入进行时序演化与空间相关性两个维度的特征提取,实现对飞控传感器数据的异常检测。然而,上述方法大多仅考虑飞控传感器数据的时序演化特征或者不同传感器之间的空间相关性特征进行异常检测。当飞行器的任务模式和运行状态呈动态变化趋势时,同一传感器数据前后的关联性特征与不同传感器数据之间的相关性特征可能不显著,仅通过时间维度的时序演化建模或者空间维度的数据相关性建模易由于难以全面表达数据的变化趋势,导致异常检测结果存在准确率偏低且虚警率偏高的问题。

此外,从方法采用的模型角度出发,上述方法大多基于 RVM、LSTM 模型进行设计。然而这类方法由于网络层数有限,容易造成过拟合,且尽管 LSTM 等网络引入了选择性记忆和遗忘机制,但其在对前后变化复杂的数据进行时序演化或者空间变化相关的特征进行提取时仍可能遗漏历史数据信息的问题。而时域卷积网络(temporal convolution network, TCN)^[16]由于引入了残差块结构,因此得以更好的训练深度网络;同时,TCN 网络引入了空洞卷积架构,其灵活的感受野使网络可以较好地提取全局的信息,因此可以灵活高效地提取复杂飞控传感器数据的时序演化特征或者传感器之间的数据相关性特征,目前是异常检测领域一大热点。You 等^[17]提出了一种改进 TCN 网络的飞控传感器数据异常检测方法,该方法通过提取飞控传感器数据的时序演化特征来实现异常检测。Li 等^[18]提出利用一种具有可解释性的飞行器异常检测方法,其利用 TCN 网络提取了不同维度传感器序列的时序演化特征。然而,这些方法大多仅从传感器数据之间的关联性或者不同传感器间数据的相关性变化角度出发,在飞行器的工况呈动态变化趋势时会导致模型对数据的特征提取不够充分^[19],这可能导致飞行器在动态飞行过程中进行异常检测时结果存在准确率偏低且虚警率偏高的问题。

针对上述问题,本文提出了一种基于时空关联的飞控传感器数据的异常检测方法,通过 TCN 网络对传感器数据的时序演化特征与空间变化特征分别提取后基于一定权重对 2 个维度的特征进行关联融合,解决异常检测时对传感器数据信息利用不充分问题,提升了异常检测方法对飞行器动态运行过程中的特征提取能力。该方法

通过同时构建时序演化特征提取模块与空间相关性特征提取模块来建立特征提取模型,实现对传感器数据时间和空间2个维度特征的并行提取。在此基础上,进一步构建飞控传感器数据的时空关联融合模型,通过特征提取模块的历史性能表现设计权重融合策略,对2个模块的预测输出基于一定权重进行关联融合得到新的预测飞控传感器数据,实现对飞控传感器数据的时空关联融合。最后,计算传感器正常数据与故障数据残差的均值与标准差从而确定异常检测的阈值,并利用观测到的真实飞控传感器数据与时空关联融合后飞控传感器预测数据之间的残差来实现对飞控传感器数据异常的检测与识别。

1 时空关联的异常检测方法

为充分利用飞行任务中飞控传感器数据的时空关联性,本文提出了基于时空关联的飞控传感器数据异常检测方法,其原理框图如图1所示。




图1 基于时空关联预测的异常检测方案框架

Fig. 1 Anomaly detection scheme framework based on spatiotemporal correlation prediction

其中,飞控传感器特征提取模块的时序演化特征提取模块与空间相关性特征提取模块分别对历史传感器数据之间的关联性 or 不同传感器间数据的相关性特征进行学习,并对新的传感器数据进行预测。时空关联融合模块对2个模块的输出进行时空关联融合。在异常检测模块中,用实际数据与预测数据的残差与阈值进行比较,从而实现对飞控传感器数据的异常判别。

对于某一飞控传感器,其数据序列为记录值和记录

时间组成的元素的有序集合。在本文中将飞控传感器*i*的数据序列简记为式(1)所示:

$$S_i = [s_{i1}, s_{i2}, \dots, s_{it}] \quad (1)$$

其中, s_{it} 表示飞控传感器*i*在*t*时刻的传感器值。

对飞控传感器数据进行异常检测时,其异常时间点通常由极值组成,因此检测异常的基本方法是预测或估计某个时间步的值,然后计算该值与真实数据之间的差异^[20],若差异大于设定阈值即判定为异常。

现有的异常检测方法进行预测时大多仅考虑如式(2)所示的传感器数据之间的关联性^[14,17]或式(3)所示的不同传感器间数据的空间关联性^[13]:

$$\hat{s}_{it} = F_t([s_{i1}, s_{i2}, \dots, s_{it-1}]) \quad (2)$$

$$\hat{s}_{it} = F_s([s_{j1}, s_{j2}, \dots, s_{ji-1}])|_{j \neq i} \quad (3)$$

式中: $\hat{s}_{it}$ 为传感器在时间步*t*的预测值; s_{it} 为传感器在时间步*t*的实际值; F_t, F_s 分别表示单独从时序演化特征或空间相关性特征出发建立的预测模型。以下将分别对所提出方法的各个单元模块进行介绍。

1.1 飞控传感器特征提取模块

本文采用TCN网络分别设计时序演化特征提取模块与空间相关性特征提取模块。

1) 时序演化相关性特征提取模块

在时序相关性特征提取模块中,TCN网络的卷积部分采用如图2所示的空洞卷积架构。




图2 TCN网络因果空洞卷积示意图

Fig. 2 Diagram of dilated causal convolution in TCN network

每一层TCN网络的感受野都可以进行灵活的调整。若定义模型输入传感器序列 $S_i = [s_{i1}, s_{i2}, \dots, s_{it}]$, 扩张卷积的输出一般形式如式(4)所示:

$$C(S_i) = \sum_{j=0}^{k-1} f(j) \times s_{i(t-d \times j)} \quad (4)$$

式中: f 是卷积滤波器; k 是核大小; d 是膨胀因子, 表示卷积核每个元素的间隔数; $t - d \times i$ 表示仅使用 S_i 过去时间状态进行卷积。卷积中, 时间*t*的输出仅与时间*t*和前一层中更早的元素卷积有关。卷积层越深, 窗口越大, 卷积窗口中的空洞越多, 感受野越大, 从而可以感受范围更广的历史信息, 便于更好的提取飞控传感器数据的时序

演化特征。

对于多层的 TCN 网络而言,相邻两层的 TCN 网络之间使用残差结构进行如图 3 所示的跳跃连接。




图 3 TCN 网络跳跃连接示意图

Fig. 3 Diagram of causal skip connection

为了使得跳跃连接层两侧的特征图通道数相匹配,引入 1×1 卷积来使相加的特征图通道数一致。

由于线性整流函数(rectified linear unit, ReLU)具有收敛速度快,计算量小的优点,因此 TCN 网络中通常选用如(5)所示的 ReLU 函数来作为激活函数。

$$ReLU(s) = \max(0, s) \quad (5)$$

综上所述,在时序演化特征提取模块中,对于待预测维度为 m 的飞控传感器数据 S_m , 特征提取模块每一层的输出如式(6)所示:

$$\hat{S}_{time} = TCN(S_m) = ReLU(F(S_m)) + C_{1 \times 1}(S_m) \quad (6)$$

其中, $\hat{S}_{time} = [\hat{s}_{time_1}, \hat{s}_{time_2}, \dots, \hat{s}_{time_f}]$ 表示特征提取模块每一层预测得到的待测维度飞控传感器输出, $TCN(S_m)$ 表示对 S_m 利用 TCN 网络进行前向推理得到的特征输出; $F(S_m)$ 表示对 S_m 进行空洞卷积与激活函数操作; $C_{1 \times 1}(S_m)$ 表示对 S_m 进行 1×1 卷积。

2) 空间相关性特征提取模块

空间相关性特征提取模块采用 TCN 网络进行回归分析。本文将其余维度的飞控传感器数据 S_n 作为回归分析的自变量,它可以是多维度的变量,也可以是单一维度的变量;将待预测维度的数据 S_m 作为回归分析的因变量,利用 TCN 网络来进行回归分析,以便提取各维度飞控传感器数据之间的相关性特征。

对于输入传感器序列 $S_n = [s_{n1}, s_{n2}, \dots, s_{nt}]$, 其经过 TCN 网络卷积层后的输出如式(7)所示:

$$C(S_n) = \sum_{j=0}^{k-1} f(i) \times s_{n(t-d \times i)} \quad (7)$$

式中: f 是卷积滤波器; k 是核大小; d 是膨胀因子; i 表示卷积核每个元素的间隔数; $t - d \times i$ 表示仅使用 S_n 过去时间

状态进行卷积。

与时序演化特征提取模块类似,进行回归分析时网络的激活函数仍选用 ReLU 函数。

综上所述,在空间相关性特征提取模块中,对于相关维度为 n 的飞控传感器数据 S_n , 对其进行空间相关性特征提取后,模块的每一层输出如式(8)所示:

$$\hat{S}_{space} = TCN(S_n) = ReLU(F(S_n)) + C_{1 \times 1}(S_n) \big|_{n \neq m} \quad (8)$$

其中, $\hat{S}_{space} = [\hat{s}_{space_1}, \hat{s}_{space_2}, \dots, \hat{s}_{space_f}]$ 表示空间变化相关性特征提取模块预测得到的待测维度飞控传感器输出, $TCN(S_n)$ 表示对 S_n 利用 TCN 网络前向推理得到的特征输出; $F(S_n)$ 表示对 S_n 进行空洞卷积与激活函数操作; $C_{1 \times 1}(S_n)$ 表示对 S_n 进行 1×1 卷积。

1.2 飞控传感器数据的时空关联融合

得到时间步 t 的预测飞控传感器数据 $\hat{s}_{time_t}, \hat{s}_{space_t}$ 后,基于一定的权重对飞控传感器数据进行如式(9)所示的时空关联融合:

$$\hat{s}_t = w_1 \hat{s}_{time_t} + w_2 \hat{s}_{space_t} \quad (9)$$

其中, w_1 与 w_2 为基于时间与空间模块历史训练过程得到的最优损失函数值进行设计得到的权重。

飞控传感器数据的时空关联时应当考虑每个特征提取模块对于数据预测能力的优劣。由于 2 个模块的损失函数值 $loss_{time}, loss_{space}$ 反映了训练好的模型对于飞控传感器数据的拟合效果的优劣,即损失函数值越大,特征提取效果越差,若采用损失函数的反比来设计权重,则权重的变化趋势与模块占据优势的程度一致。例如,若 $w_2 = loss_{time}/loss_{space} > 1$, 则说明当前占据优势地位的模块为空间变化相关性特征提取模块,其所占据的权重也应越大,与该模块的权重值变化一致,说明了采用损失函数比设计权重较合理。同时为了防止某个模块占据绝对优势可能导致的过拟合现象,最终采用损失函数反比求根的形式作为权重。因此基于最优损失函数值的权重如式(10)、(11)所示:

$$w_1 = \frac{\sqrt{loss_{space}/loss_{time}}}{\sqrt{loss_{space}/loss_{time}} + \sqrt{loss_{time}/loss_{space}}} \quad (10)$$

$$w_2 = \frac{\sqrt{loss_{time}/loss_{space}}}{\sqrt{loss_{space}/loss_{time}} + \sqrt{loss_{time}/loss_{space}}} \quad (11)$$

若训练过程中的损失函数定义为预测数据与实际数据的均方误差,则对传感器序列 S_i 而言,两个特征提取模块的损失函数分别如式(12)与(13)所示:

$$loss_{time} = \frac{1}{n} \sum_{k=1}^n (s_{ik} - \hat{s}_{time_k})^2 \quad (12)$$

$$loss_{space} = \frac{1}{n} \sum_{k=1}^n (s_{ik} - \hat{s}_{space_k})^2 \quad (13)$$

1.3 基于时空关联的飞控传感器数据异常检测

异常检测的流程分为以下 3 个阶段:

1) 数据预处理阶段: 由于飞行器各维度的数据有不同的测量单位, 因此在数据预处理环节中, 需要将数据进行归一化处理, 本文对飞行参数进行式(14)所示 $[0, 1]$ 范围内的最大-最小归一化处理:

$$S_i^o = \frac{S_i - S_{\min}}{S_{\max} - S_{\min}} \quad (14)$$

式中: S_i 是飞控传感器 i 维度的原始数据序列; $S_{\min}$ 和 $S_{\max}$ 分别是 S_i 的最小值和最大值。接着, 归一化后的数据被分成长度为 t 的时间窗口并进入待检测窗口以便于特征提取模块对数据进行处理。

2) 飞控传感器数据的时空关联融合阶段: 将待检测窗口的数据分别输入 2 个模块进行特征提取, 得到当前时间步 t 的预测飞控传感器数据 $\hat{s}_{\text{time}_t}$ 、 $\hat{s}_{\text{space}_t}$ 。其次将 2 个模块的飞控传感器预测输出进行式(9)所示的时空关联融合。

3) 异常检测阶段

在异常检测阶段, 首先进行异常检测阈值的选取; 其次根据设定的阈值对飞控传感器数据进行异常检测。

(1) 异常检测阈值选取

由于原始数据不稳定, 不适合采用静态阈值的方法确定阈值, 而正常数据与预测数据之间的残差通常服从某一统计分布^[21], 因此具有一定的稳定性。因此本文基于模型训练时的正常数据与预测数据残差的统计量均值 μ 与标准差 σ 进行阈值的选择, 将超过一定标准差倍数的残差定义为异常阈值。本文选择简单有效的 3σ 原则来设定异常阈值, 阈值上界 λ_{up} 与阈值下界 λ_{low} 如式(15)与(16)所示:

$$\lambda_{\text{up}} = \mu + 3\sigma \quad (15)$$

$$\lambda_{\text{low}} = \mu - 3\sigma \quad (16)$$

(2) 飞控传感器数据异常检测

在进行异常检测时, 使用第 2 阶段得到的时空融合输出进行异常检测, 计算 t 时间步待测维度 m 的飞控传感器数据的异常得分 γ_t :

$$\gamma_t = s_{mt} - \hat{s}_t \quad (17)$$

设定一异常标签集 $\xi = [\xi_1, \xi_2, \dots, \xi_t]$, 如果时间步 t 的异常分数 γ_t 偏离异常阈值, 则该时间步的飞控传感器数据被判定为异常数据, 相应的, 时间步 t 对应的异常标签 ξ_t 标记为 1, 否则标记为 0。

综上, 基于时空关联的异常检测算法如表 1 所示。

2 实验分析

2.1 实验设置

1) 实验数据

无人机含有 IMU、GNSS 等多种类型的飞控传感器,

表 1 基于时空关联融合预测的异常检测算法

Table 1 Algorithm of anomaly detection based on spatiotemporal correlation fusion

算法 基于时空关联的飞控传感器数据异常检测算法

Input 待预测维度的数据 $S_m = [s_{m1}, s_{m2}, \dots, s_{mT}]$, 其余相关维度的数据 $S_n = [s_{n1}, s_{n2}, \dots, s_{nT}]$, 异常判决门限上限 λ_{up} 与下限 λ_{low}

Output 异常标签 $\xi = [\xi_1, \xi_2, \dots, \xi_T]$

For $t = 1$ to T **do**

$\hat{s}_{\text{time}_t} \leftarrow \text{TCN}([s_{m0}, s_{m1}, \dots, s_{mt-1}])$

$\hat{s}_{\text{space}_t} \leftarrow \text{TCN}([x_{n0}, x_{n1}, \dots, x_{nt-1}])$

$\hat{s}_t \leftarrow w_1 \hat{s}_{\text{time}_t} + w_2 \hat{s}_{\text{space}_t}$

$\gamma_t \leftarrow s_{mt} - \hat{s}_t$

If $\gamma_t > \lambda_{\text{up}}$ or $\lambda_t < \lambda_{\text{low}}$ **then**

$\xi_t \leftarrow 1$

else

$\xi_t \leftarrow 0$

End if

End for

且无人机的运行环境包括开阔空域、山区丘陵等多种类型的环境, 基本涵盖了其它各种飞行器飞控传感器的种类与飞行器运行的环境特征, 因此以无人机飞控传感器为代表进行研究具有一定的典型性。此外, 实际应用本文方法时, 需要传感器具有较高的采样率, 才能接近实时地检测出单点时间步是否存在异常, 因此适合于 IMU 等采样率较高的飞控传感器。

综上所述, 本文选择无人机 IMU 飞控传感器的仿真与实测数据对所提方法的异常检测性能进行验证。

(1) 仿真 IMU 飞控传感器数据简介

本文采用开源飞控软件 PIXHAWK 进行软件在环仿真^[22]。在进行仿真时, 仿真器中无人机物理模型组成的整体框图如图 4 所示。




图 4 无人机物理模型组成框图

Fig. 4 Physical model of UAV

如上图所示, 无人机物理模型可分为空气动力学模

块与反馈控制模块。在空气动力学模块中,无人机的电机系统由反馈控制反馈的脉冲宽度调制波形进行驱动并产生力与力矩来驱动无人机执行相关任务。无人机的状态参量由传感模块进行感知并输出到反馈控制模块进行反馈控制。在反馈控制模块中,测量转换模块将对飞控传感器测量的传感参数进行坐标变换与校准,校准得到的相对于惯性系下的状态量,接着将此状态量输入至控制器进行控制并产生反馈量。

在进行飞控传感器故障注入以及数据的获取时,通过传感器模块中与反馈控制系统之间的数据接口对 IMU 进行读写来完成。

通过上述方式,按照表 2 所示的飞行任务信息进行任务规划,并对三轴加速度计中的 x 轴加速度与三轴陀螺仪中的滚转角速率 2 个维度的数据按照表 3 所示的信息注入卡死故障与恒偏差故障^[23]。

表 2 不同采样点区间飞行任务工况信息

Table 2 Flight mission operating condition information in different sampling point intervals

飞行任务	采样点区间
起飞	0~800
转弯	800~2 200
直行	2 200~3 000
转弯	3 000~5 000
降落	5 000 以后

表 3 故障注入设置信息

Table 3 Details of fault injection settings

数据类型	故障类型	故障值	故障持续区间
x 轴加速度	卡死	-0.3 m/s^2	(1 800~2 050), (2 250~2 500)
x 轴加速度	恒偏差	0.2 m/s^2	(1 800~2 050), (2 500~2 750)
滚转角速率	卡死	0.3 rad/s	(1 535~1 700), (4 300~4 500)
滚转角速率	恒偏差	0.2 rad/s	(1 000~1 100), (2 600~2 700)

对飞控传感器 IMU 进行采集,以 x 轴加速度为例,得到 5 000 组 x 轴加速度传感器正常以及异常模式数据如图 5、6 所示。





图 5 x 轴加速度含卡死故障的异常数据
Fig. 5 Anomaly data of x -axis acceleration with stuck fault





图 6 x 轴加速度含恒偏差故障的异常数据
Fig. 6 Anomaly data of x -axis acceleration with constant deviation fault


为了验证故障注入的真实性,本文还对 x 轴加速度传感器故障注入前后无人机姿态角前后变化进行观测。如图 5(b)、6(b) 所示,在大约 1 800 采样点处进行故障注入后,姿态角也随即产生了一定程度的偏差,因此可以说明仿真数据具有真实性。

(2) 实测 IMU 飞控传感器数据简介


本文使用的实测 IMU 飞控传感器数据为一架旋翼无人机在执行某次任务的过程中所产生。该数据集包含了无人机执行任务全过程产生的 IMU 实测数据。以其中滚转角速率为例,其正常以及含有故障的异常模式的数据如图 7 所示。

2) 异常检测指标

本文使用异常检测领域最为常用的几种指标如准确率(accuracy, ACC)、虚警率(false alarm rate, FAR)以及 F1 分数(F1 score, F1)来评估异常检测方法在的异常检



(a) 翻滚角速率含偏差故障
(a) Measured data of roll rate with const fault



(b) 翻滚角速率含卡死故障
(b) Measured data of roll rate with stuck fault

图7 滚转角速率实测数据

Fig. 7 Measured data of roll rate

测性能^[24-25]。这几种指标如下式:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (18)$$

$$FAR = 1 - \frac{TP}{TP + FN} = \frac{FN}{TP + FN} \quad (19)$$

$$F1 = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (20)$$

其中, TP 为真阳性数量, TN 为真阴性数量, FP 为假阳性数量, FN 为假阴性数量。上述指标中, ACC 表示分类正确的样本数占总样本数的比例, 其值越高, 说明对数据进行分类的准确率也越高; FAR 则反映了模型的虚警率, 其值越低, 说明模型的虚警率越低; $F1$ 分数综合考虑模型的精确率与虚警率, 一般 $F1$ 分数越接近 1, 说明模型的整体性能越好。


2.2 时空关联的异常检测方法性能评估

对本文提出的方法进行性能评估时, 分别对比基于仅考虑时序演化特征的 RVM^[13]、LSTM^[14]、TCN^[17] 模型所构建的异常检测方法以及本文方法对不同类型飞控传感器的不同种类的故障的异常检测性能。


1) 仿真数据异常检测实验结果分析

首先, 应用基于时空关联的飞控传感器数据异常检测方法对 2 个维度故障注入之后的数据进行异常检测, 其结果如残差图 8、9 所示。

故障类型设置与表 2 中故障注入的信息一致。由于时间步长设置为 200, 因此对于 5 000 个采样数据而言, 实际的异常检测区间为 200~5 000。观察残差图可知,




(a) 卡死故障预测值与实际值残差
(a) Residual between predicted and actual value of stuck fault




(b) 恒偏差故障预测值与实际值残差
(b) Residual between predicted and actual value of const fault

图8 基于时空关联的加速度异常检测残差

Fig. 8 Residual of a_x anomaly detection based on spatio-temporal correlation



(a) 卡死故障预测值与实际值残差
(a) Residual between predicted and actual value of stuck fault



(b) 卡死故障预测值与实际值残差
(b) Residual between predicted and actual value of const fault

图9 基于时空关联的滚转角速率异常检测残差

Fig. 9 Residual of roll rate anomaly detection based on spatio-temporal correlation

在每个故障注入的采样点间隔内, 初始时故障值可以准确反映在残差图中; 此外, 对于持续一段时间的故障而言, 故障的区间特征也可以很好的反映在图中, 这说明, 这说明本文方法不仅可以精准识别点异常, 且具有对连续异常的检测能力。

其次, 基于仅考虑时序演化特征的 RVM、LSTM 模型

构建异常检测方法,并对两个维度故障注入之后的数据进行异常检测。以滚转角速率为例,检测结果如残差图 10、11 所示。




图 10 RVM 对滚转角速率异常检测残差
Fig. 10 Residual of roll rate anomaly detection based on RVM




图 11 LSTM 对滚转角速率异常检测残差
Fig. 11 Residual of roll rate anomaly detection based on LSTM

观察残差图可知,以恒偏差故障为例,相较于基于 TCN 网络的异常检测方法,本文方法在采样点 1 200 以及 3 200 附

近将大量非故障滚转角速率数据判定为异常,这可能是由于这两类方法的特征提取能力较弱,导致前向推理时对原始数据的特征输出产生畸变,进而影响其异常检测的性能。

为直观体现本文方法在飞控传感器数据异常检测方面带来的优势,将本文方法与上述基于 RVM、LSTM 以及 TCN 模型的典型异常检测方法的指标性能进行对比,结果如表 4 所示。

表 4 不同方法对仿真数据的异常检测性能
Table 4 Performance of different methods for anomaly detection in simulation data

数据类型	评价指标	RVM	LSTM	TCN	本文方法
x 轴加速度卡死	ACC	0.942	0.972	0.990	0.995
	FAR	0.030	0.017	0.020	0.010
	F1	0.864	0.933	0.980	0.990
x 轴加速度恒偏差	ACC	0.956	0.972	0.990	0.995
	FAR	0.080	0.130	0.020	0.020
	F1	0.852	0.838	0.980	0.980
滚转角速率卡死	ACC	0.983	0.976	0.998	0.997
	FAR	0.026	0.078	0.020	0.010
	F1	0.970	0.938	0.980	0.990
滚转角速率恒偏差	ACC	0.951	0.954	0.990	0.996
	FAR	0.040	0.050	0.040	0.020
	F1	0.856	0.862	0.968	0.980
指标均值	ACC	0.958	0.968	0.992	0.996
	FAR	0.044	0.069	0.033	0.015
	F1	0.913	0.900	0.977	0.985

通过对比基于 RVM、LSTM、TCN 模型所构建的异常检测方法,对于准确率指标而言,TCN 网络的异常检测方法较另外两类方法平均高 2%;对于虚警率指标而言,较另外两类方法至少平均降低 3%;在 F1 分数指标方面,较另外两类异常检测方法至少提高 6%;这说明由于 TCN 网络对于飞控传感器数据具有更好的特征提取能力,基于 TCN 网络的异常检测方法往往具有较好的异常检测能力,这与对残差图 10、11 进行分析所得出的结论一致。

此外,通过对比利用仅从时序演化特征出发进行建模的 TCN 模型所构建的异常检测方法,与本文方法可知,对于准确率指标,本文方法至少提升了 0.4%;对于虚警率指标,本文方法至少降低 1.8%,说明本文所提出的方法在保证准确率较高的同时也能显著降低虚警率;对于 F1 指标,本文方法至少提升 0.8%,说明方法对不同传感器类型的不同故障类型进行异常检测时具有较高的泛化

能力。对比异常检测性能的 3 个指标,说明通过融合不同传感器数据之间的关联性,可以进一步提升方法对飞控传感器数据的异常检测能力。

2) 实测数据异常检测实验结果分析

为进一步验证本文方法是否具有一定的实际应用价值,利用实测 IMU 数据对所提方法进行验证。不同方法进行异常检测的结果如表 5 所示。

表 5 不同方法对实测数据的异常检测性能
Table 5 Performance of different methods for anomaly detection in real data

数据类型	评价指标	RVM	LSTM	TCN	本文方法
x 轴加速度 卡死	ACC	0.922	0.946	0.970	0.978
	FAR	0.052	0.040	0.042	0.038
	F1	0.834	0.896	0.920	0.931
x 轴加速度 恒偏差	ACC	0.936	0.952	0.972	0.976
	FAR	0.088	0.158	0.038	0.030
	F1	0.848	0.816	0.923	0.928
滚转角速 率卡死	ACC	0.957	0.938	0.963	0.975
	FAR	0.066	0.084	0.048	0.028
	F1	0.913	0.908	0.915	0.933
滚转角速 率恒偏差	ACC	0.931	0.949	0.969	0.980
	FAR	0.070	0.068	0.044	0.030
	F1	0.902	0.858	0.920	0.939
指标均值	ACC	0.936	0.946	0.968	0.977
	FAR	0.069	0.087	0.043	0.031
	F1	0.899	0.869	0.920	0.933

观察上表可知,相较于仿真数据的异常检测结果而言,本文方法的异常检测性能有所下降,这可能是由于实测传感器数据存在有较大的噪声,从而对方法的异常检测性能有一定影响。然而,相较于基于 RVM、LSTM 以及 TCN 模型的异常检测方法,本文方法的 ACC 保持仍在 97% 以上,而 FAR 仍保持在 96% 以上,分别至少提升了 0.9%、1.2%,说明本文方法具有一定的工程应用价值。

3 结 论

对飞控传感器数据进行异常检测对飞行器安全稳定运行有重要意义。针对现有的模型大多仅考虑传感器数据前后的关联性或不同传感器间数据的相关性,从而在飞行器运行工况动态变化过程中进行异常检测时可能存在准确率偏低而虚警率偏高的问题,本文提

出了一种基于时空关联的飞控传感器数据异常检测方法。该方法构建时序演化特征提取模块与空间相关性特征提取模块来对飞控传感器数据进行时间与空间 2 个维度特征的并行提取并基于一定的权重进行关联融合,实现了对飞控传感器数据在时间与空间两个维度变化规律的融合建模。经过实验验证,所提出方法在提升准确率的同时降低了虚警率,这表明通过融合传感器自身的时序演化关联性和空间变化相关性,能够进一步提升在工况动态变化时对不同类型飞控传感器数据的异常检测能力。

然而,本文所提出的方法对实测数据进行验证时,会受到传感器数据噪声的影响;此外,本文所提出的方法目前仅对累积的历史数据进行离线异常检测时有效。因此,下一步开展研究工作时,首先,优化已有的异常检测算法来削弱实测数据中噪声的影响;其次,开展对模型计算流程的并行化设计并进行模型的嵌入式设备部署工作,完成对传感器数据的在线异常检测。

参考文献

[1] GUO K, YE ZH SH, LIU D T, et al. UAV flight control sensing enhancement with a data-driven adaptive fusion model[J]. Reliability Engineering & System Safety, 2021, 213:107654.

[2] ETHIOPLAN A. Investigation report on the B737-MAX8 REG. ER-AVJ operated [R]. Aircraft Accident Investigation Bureau, 2022.

[3] 安雪,李少波,张仪宗,等. 无人机飞控系统故障诊断技术研究综述[J]. 计算机工程与应用, 2023, 59(24):1-15.

AN X, LI SH B, ZHANG Y Z, et al. Review of fault diagnosis techniques for UAV flight control systems[J]. Computer Engineering and Applications, 2023, 59(24): 1-15.

[4] 陈亚锋. 无人机飞行数据实时异常检测系统研制[D]. 哈尔滨: 哈尔滨工业大学, 2017.

CHEN Y F. Real-time anomaly detection system for unmanned aerial vehicle flight data[D]. Harbin: Harbin Institute of Technology, 2017.

[5] ZHONG J, ZHANG Y J, WANG J Y, et al. Unmanned aerial vehicle flight data anomaly detection and recovery prediction based on spatio-temporal correlation[J]. IEEE Transactions on Reliability, 2021, 71(1):457-468.

[6] LEONI J, GELMINI S, PANZAN G, et al. A derivative,

- integral, and proportional features extractor for fault detection in dynamic processes [J]. *Engineering Applications of Artificial Intelligence*, 2023, 128: 107510.
- [7] KURIEN J, NAYAK P P. Back to the future for consistency-based trajectory tracking[C]. 17th National Conference on Artificial Intelligence and the 12th Innovative Applications of Artificial Intelligence Conference, 2000:370-377.
- [8] YANG L, LI SH B, ZHU C CH, et al. Spatio-temporal correlation-based multiple regression for anomaly detection and recovery of unmanned aerial vehicle flight data[J]. *Advanced Engineering Informatics*, 2024, 60: 102440.
- [9] HANSEN S, BLANKE M. Diagnosis of airspeed measurement faults for unmanned aerial vehicles[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2014, 50(1):224-239.
- [10] 彭宇,刘大同. 数据驱动故障预测和健康管理综述[J]. *仪器仪表学报*, 2014, 35(3):481-495.
- PENG Y, LIU D T. Data-driven prognostics and healthmanagement: A review of recent advances[J]. *Chinese Journal of Scientific Instrument*, 2014, 35(3): 481-495.
- [11] 赵光权,王盟,刘大同,等. 航天器电源建模仿真综述与展望[J]. *仪器仪表学报*, 2023, 44(4):1-18.
- ZHAO G Q, WANG M, LIU D T, et al. Review and perspective survey on spacecraft power supply modeling and simulation [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(4):1-18.
- [12] BRONZ M, BASKAYA E, DELAHAYE D, et al. Real-time fault detection on small fixed-wing UAVs using machine learning [C]. 2020 AIAA/IEEE 39th Digital Avionics Systems Conference, 2020:1-10.
- [13] WANG B K, LIU D T, PENG X Y, et al. Data-driven anomaly detection of UAV based on multimodal regression model[C]. 2019 IEEE International Instrumentation and Measurement Technology Conference, 2019:1-6.
- [14] WANG B K, WANG Z Y, LIU L SH, et al. Data-driven anomaly detection for UAV sensor data based on deep learning prediction model [C]. 2019 Prognostics and System Health Management Conference, 2019:286-290.
- [15] HUNDMAN K, CONSTANTINOU V, LAPORTE C, et al. Detecting spacecraft anomalies using LSTMs and nonparametric dynamic thresholding [C]. *SIGKDD Explorations*, 2018:382-390.
- [16] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. *ArXiv preprint arXiv:1803.01271*, 2018.
- [17] YOU J T, LIANG J, LIU D T. An adaptable UAV sensor data anomaly detection method based on TCN model transferring [C]. 2022 Prognostics and Health Management Conference, 2022:73-76.
- [18] LI X, SHANG J X, ZHENG L J, et al. IMTCN: An interpretable flight safety analysis and prediction model based on multi-scale temporal convolutional networks[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(1):289-302.
- [19] WANG S ZH, CAO J N, YU P S. Deep learning for spatio-temporal data mining: A survey [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(8):3681-3700.
- [20] LI G, JUNG J J. Deep learning for anomaly detection in multivariate time series: Approaches, applications, and challenges[J]. *Information Fusion*, 2023, 91:93-102.
- [21] HYNDMAN R, ATHANASOPOULOS G. *Forecasting: Principles and practice*[M]. OTexts: Melbourne, 2018.
- [22] XAVIER F C S, SANTOS S R B D, GIVIGI S N. A multifixed-wing-UAV software-in-the-loop simulation platform for system design[J]. *IEEE Systems Journal*, 2023, 17(4):6724-6735.
- [23] 彭宇,史书慧,郭凯,等. 无人机飞控系统故障仿真及数据生成[J]. *仪器仪表学报*, 2019, 40(7):13-21.
- PENG Y, SHI SH H, GUO K, et al. Fault simulation and data generation of UAV flight control system[J]. *Chinese Journal of Scientific Instrument*, 2019, 40(7): 13-21.
- [24] WANG Y Q, MENG SH W, SONG Y CH, et al. Time series fragmental variation trend anomaly detection method based on a temporal sequential modeling approach[C]. *IEEE International Instrumentation and Measurement Technology Conference*, 2023:910-915.

[25] WANG Y Q, MENG SH W, SONG Y CH, et al. Fault detection for large scale indoor distributed antenna system based on time series similarity[C]. 2022 Prognostics and Health Management Conference, 2022:269-275.

作者简介



杨挺,2024 年于哈尔滨工业大学获得学士学位,现为哈尔滨工业大学自动化测试与控制研究所博士研究生,主要研究方向为复杂系统异常检测等。

E-mail: 1756174983@qq. com

Yang Ting received his B. Sc. degree from Harbin Institute of Technology in 2024. He is currently pursuing his Ph. D. degree in Automatic Test and Control Institute at Harbin Institute of Technology. His main research interest is complex system anomaly detection.



宋宇晨(通信作者),2015 年于电子科技大学获得学士学位,2022 年于哈尔滨工业大学获得博士学位,现为哈尔滨工业大学副教授,主要研究方向为复杂系统智能感知与评估、智能测试信息处理、卫星星座状态监

测与运维等。

E-mail: songyuchen@hit. edu. cn

Song Yuchen (Corresponding author) received his B. Sc. degree from University of Electronic Science and Technology of China in 2015, and received his Ph. D. degree from Harbin Institute of Technology in 2022. He is currently an associate professor at Harbin Institute of Technology. His main research interests include complex system intelligent sensing and evaluation, intelligent testing information processing, satellite constellation state monitoring and operating.