

DOI: 10.19650/j.cnki.cjsi.J2413247

Feen-LSTM: 一种优化的多遥测参数 在线无监督异常检测方法*

张金垒¹, 庞景月¹, 卢晓伟², 宋宇晨³

(1. 重庆工商大学人工智能学院 重庆 400067; 2. 上海卫星工程研究所 上海 201100;
3. 哈尔滨工业大学 哈尔滨 150080)

摘 要:随着我国航天事业由航天大国向航天强国迈进,航天器发射数量以及密度屡创新高,保障航天器在轨正常运行成为非常重要的任务。航天器遥测数据是地面长管判断其正常运行的重要依据,增强遥测数据的异常检测能力是目前地面长管提升保障能力的关键。目前工程上遥测数据异常检测主要依赖于专家经验和固定阈值,虽高效可靠,但难以应对复杂多变的在轨运行环境,且检测准确性有待提高。而传统的机器学习方法随着遥测数据量增加,模型的性能与有效性不足。近年来,深度学习方法在异常检测领域展现出巨大潜力,然而现有基于深度学习的航天器遥测数据异常检测仍面临较大挑战:一方面,对异常模式标记的准确性与完整性依赖较强,而实际工程中获取大量准确的异常标记数据较为困难;另一方面,现有方法在线异常检测能力不足,难以满足航天器的在轨监测需求。针对上述问题,提出了一种在线且无监督的异常检测模型 Feen-LSTM,其基于 Transformer 结构提取多维遥测数据的全局时空特征,并结合 LSTM 来建模局部时间依赖性,从而实现了特征增强的优化结构。通过在 NASA 公开的两个航天器遥测数据集上的实验,表明 Feen-LSTM 能够有效地提高异常检测的精度,尤其是在面对复杂数据和未知异常模式时,表现出比其他方法更优的性能。

关键词: 遥测数据;长短时记忆网络;特征增强;在线异常检测

中图分类号: TH165+.3 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Feen-LSTM: An optimized online unsupervised anomaly detection method for multi-telemetry parameters

Zhang Jinlei¹, Pang Jingyue¹, Lu Xiaowei², Song Yuchen³

(1. School of Artificial Intelligence, Chongqing Technology and Business University, Chongqing 400067, China; 2. Shanghai Satellite Engineering Research Institute, Shanghai 201100, China; 3. Harbin Institute of Technology, Harbin 150080, China)

Abstract: As China's space industry advances from being a space power to a space strong nation, the number and density of spacecraft launches have reached new heights. Ensuring the normal operation of spacecraft in orbit has become a crucial task. Spacecraft telemetry data is an important basis for ground control to determine normal operation, and enhancing the anomaly detection capability of telemetry data is key to improving ground control's support capabilities. Currently, anomaly detection of telemetry data mainly relies on expert experience and fixed thresholds. While these methods are efficient and reliable, they struggle to cope with the complex and dynamic operating environment in orbit, and the detection accuracy still needs improvement. Traditional machine learning methods show limited performance and effectiveness as the volume of telemetry data increases. In recent years, deep learning methods have shown great potential in the field of anomaly detection. However, existing deep learning-based anomaly detection methods for spacecraft telemetry data still face significant challenges. On the one hand, they heavily rely on the accuracy and completeness of anomaly labels, while obtaining a large amount of accurate anomaly-labeled data in practical engineering is difficult. On the other hand, existing methods lack the ability for online anomaly detection, which is essential for meeting the real-time monitoring needs of spacecraft in orbit. To address these issues, this paper proposes an online and unsupervised anomaly detection model, Feen-LSTM. This model extracts global spatiotemporal features from multidimensional telemetry data using a Transformer structure and combines LSTM to model local temporal

收稿日期:2024-09-04 Received Date: 2024-09-04

* 基金项目:国家自然科学基金项目(62001069)、重庆市教委科学技术研究项目(KJQN202300841, KJQN202100821)、高层次人次科研启动项目(2056009)、重庆市博士“直通车”科研项目(CSTB2022BSXM-JSX0008)资助

dependencies, thereby achieving an optimized structure for feature enhancement. Experiments on two spacecraft telemetry data sets published by NASA show that Feen-LSTM can effectively improve the accuracy of anomaly detection, especially in the face of complex data and unknown anomaly patterns, and show better performance than other methods.

Keywords: telemetry data; long short-term memory network; feature enhanced; online anomaly detection

0 引言

自2016年以来,我国航天事业的发展进入“快车道”,2022年我国发射卫星次数达64次,2023年更是达到了67次。据UCS卫星数据库统计,目前我国在轨卫星数量已有628颗,约占全球总量的1/12。2021年1月28日颁布的第5部航天白皮书——《2021中国的航天》指出^[1]:“研究制定商业航天发展指导意见,促进商业航天快速发展。扩大政府采购商业航天产品和服务范围,推动重大科研设施设备向商业航天企业开放共享,支持商业航天企业参与航天重大工程项目研制”,其推动了我国商业航天的蓬勃发展。据《中国航天科技活动蓝皮书(2023年)》数据显示^[2],2023年我国实施67次航天发射,其中有26次商业发射,发射成功率达96%。

随着我国航天事业的飞速发展,设计的卫星结构和功能复杂性增加。加之卫星在轨运行时会受到极端空间环境、设计验证不充分、生产加工工艺风险、运行寿命等影响,每颗航天器在轨运行时都会面临严重程度不同的异常事件,例如平台故障、载荷故障等^[3-4]。因此对地面长管检测与处理航天器异常的能力提出了更高要求。

通过天地通信链路传输至地面长管的遥测数据是判断航天器运行状态的重要依据^[4-6]。一颗卫星通常具有数千个遥测通道,不同的遥测通道代表卫星对应模块的性能和工作状态,例如:电源系统充放电状态、姿轨控系统的姿态、推进系统温度状态等。及时检测遥测数据中的异常,以降低航天器在运行过程中的潜在风险^[7],是延长航天器在轨运行寿命的主要手段之一。

目前航天器遥测数据常检测方法主要涉及阈值、专家经验模型、知识系统与数据驱动的方法^[8]。其中阈值、专家经验模型以及基于知识系统的方法通常依赖专家知识、需耗费大量人力、无法实时更新以及缺乏自动学习能力,并且在面对复杂且未知的异常模式时检测能力不足^[9-11]。而数据驱动的方法则是通过统计、机器学习、深度学习等技术对遥测数据进行建模和异常检测,其能够更好地建模关系复杂、高维度的遥测数据,是目前国内外研究的主要方向^[12]。

数据驱动的方法中基于距离、密度、以及聚类方法可以充分利用数据进行建模^[13-14],但在面对大规模数据集时,其扩展性和泛化能力受限,且非线性关系处理能力较

弱。近年来随着深度学习在多元时间序列数据异常检测领域的广泛探索以及应用拓展^[15-18],许多深度学习模型也被用于实现航天器遥测数据异常检测。其中变分自编码器(variational autoencoder, VAE)^[19]、阶梯变分自编码器(ladder variational autoencoder, LadderVAE)^[20]、无监督异常检测(unsupervised anomaly detection, USAD)^[21]属于性能较优的非动态方法,其将遥测数据映射到潜在空间以捕捉更复杂的分布特征,可以处理不平衡数据,但面对大规模数据时训练和推理速度缓慢,且对于时序数据的关联性不够敏感,无法检测长期异常;长短时记忆网络与非参数动态阈值(long short-term memory and nonparametric dynamic thresholding, LSTM-NDT)^[22]、OmniAnomaly^[23]与深度卷积自动编码记忆网络(deep convolutional autoencoding memory network, CAE-M)^[24]属于主流的动态方法,能有效对时序数据之间的依赖关系进行建模,但其捕获更长时序数据特征的能力还有待提升;图神经网络(graph neural network, GNN)^[25]与InterFusion^[26]属于典型的关系方法,该类方法擅长捕捉时序数据之间的复杂依赖关系,能够处理多维度的时序数据,然而,由于其计算复杂度较高,难以满足在线检测或实时处理的需求。

上述方法中,尽管非动态方法和关系方法在特定场景下展现了其优势,但它们在应对在线检测和实时监测需求时存在显著不足。相比之下,基于长短时记忆网络(long short-term memory, LSTM)的动态方法能够有效捕捉数据间的长短期依赖关系,并且具备较快的处理速度和实时响应能力,这使得其在实时监测场景中展现明显优势。但随着航天器功能与结构的复杂化提升,遥测数据量与维度的增长,以及时间序列的长时依赖性,该网络的特征提取能力和预测值生成的准确性都受到了明显限制,最终导致异常检测效果不佳。并且,卫星传感器产生的高维遥测数据间也存在互相依赖的复杂关联关系,亟需通过空间特征建模来理解数据的内在结构,而LSTM网络并不具备对空间特征建模的能力。因此,提出一种特征增强型LSTM模型(feature enhanced LSTM, Feen-LSTM),该模型通过编码器中的多头自注意力机制增强对输入数据的时序特征提取能力,并且融合Transformer编码器捕获空间依赖关系进而提升建模准确性,该模型能够实现在线高可靠的异常监测,其异常检测性能通过NASA公开数据集进行验证。

1 Feen-LSTM 模型

1.1 Feen-LSTM 模型的整体结构

Feen-LSTM 模型整体结构如图 1 所示。图 1 中,该模型首先通过位置编码对输入的遥测序列进行编码,以保留原始数据的时序信息。位置编码为每个时间步嵌入独特的位置向量,从而增强模型对时间序列位置依赖性的理解。其次,融合 Transformer 编码器和 LSTM 的混合结构,以提取遥测数据中更全面和更丰富的时空特征。




图 1 网络整体结构

Fig. 1 Overall network structure

该结构在训练过程中均无需用到样本的标签,仅需要利用原始数据即可实现对模型参数的寻优,且在测试过程中异常检测的动态阈值也是依据遥测数据的预测均值以及方差的统计特征确定,无需用到测试数据的标签进行异常样本的排序,因此在训练和测试的全过程均具备无监督特性,更适用于实际的航天器遥测数据异常样本不足且异常标签不精确的场景。而且本文提出的方法在检测时可随着数据的到达进行标记,对于未来数据的标签不具有依赖性,可更好应用于在线检测。

1.2 时序特征提取

Transformer 编码器中的自注意力机制层对于输入的序列进行并行处理,是无序的。但时序信息又是遥测数据中至关重要的特征,因此本文通过位置编码 (positional encoding, PE) 来为遥测数据显式的添加时序信息,通过保留时序信息这一特征可以大大提高模型预测准确率。Transformer 提供了两种位置编码的方法,其原理都是通过将编码后的数据与原始数据相加并求和以嵌入位置信息。本文使用的是静态位置编码,这种方法使用正弦和余弦函数来生成位置编码,频率随位置和维度变化。其计算公式具体如式 (1) 和 (2) 所示。

$$PE_{(pos, 2i)} = \sin\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right) \quad (1)$$

$$PE_{(pos, 2i+1)} = \cos\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right) \quad (2)$$

式中: pos 表示序列中的位置; i 表示位置编码的维度索引; d_{model} 表示位置编码的维度总数。

具体而言,利用多头自注意力机制和前馈神经网络有效捕捉时序数据中的全局时空依赖关系,以实现特征增强。通过将增强后的特征输入到 LSTM 网络,实现更加精确的局部时间依赖建模。最后,通过全连接层,将特征映射到预测值空间,生成最终的预测结果。本模型的结构设计充分考虑了多维遥测参数的特性,并融合了位置编码、Transformer 以及 LSTM 的特征变换优势,实现了全局时空特征建模以及局部时序特征建模,以充分捕获多维遥测参数的长时依赖性、短期波动性以及复杂的空间关联,提升预测精度以及异常检测能力。

1.3 全局时空特征建模

Transformer^[27] 最初被设计用于自然语言处理领域,但因其灵活性和强大的建模能力,其同样适用于时间序列数据的预测任务。通过其独特的结构可以捕获到时序数据中的复杂依赖关系和多尺度特征。它主要由编码器 (Encoder) 和解码器 (Decoder) 两部分组成,其中编码器在处理输入数据和提取特征方面起着至关重要的作用。Transformer 编码器结构如图 2 所示。




图 2 编码器结构

Fig. 2 Encoder structure

由图 2 可知,此编码器包含 3 部分:多头自注意力机制、前馈神经网络、残差连接和层归一化。

1) 多头自注意力机制

多头自注意力机制是 Transformer 编码器的核心之一,它通过并行计算多个自注意力来捕捉不同子空间中

的特征,从而增强模型对输入序列的表示能力,其主要计算过程分为以下几个步骤。

(1) 输入投影:将输入的序列 X 通过多个不同的线性变换投影到不同的查询 (Query)、键 (Key) 和值 (Value) 空间,对于第 i 个头:

$$Q_i = XW_i^Q, K_i = XW_i^K, V_i = XW_i^V \quad (3)$$

式中: W_i^Q, W_i^K, W_i^V 是第 i 个头的可训练权重矩阵。

(2) 并行计算注意力:对于每个头,计算其自注意力输出:

$$head_i = Att(QW_i^Q, KW_i^K, VW_i^V) \quad (4)$$

$$Att(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (5)$$

(3) 拼接和线性变换:将所有头的输出拼接在一起,并通过线性变换得到最终的多头自注意力输出。

$$Z = [Z_1; Z_2; \dots; Z_h]W^O \quad (6)$$

式中: W^O 是用于线性变换的可训练权重矩阵。

综合上述步骤,多头自注意力机制可表示为:

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_h)W^O \quad (7)$$

在航天器遥测数据预测任务中,多头自注意力机制能够捕捉到序列中的长短期依赖,并且其可从不同的子空间提取特征以实现空间特征的建模,对不同注意力头的输出进行拼接和线性变换可提高特征的表达能力。这些特性使得 Transformer 编码器在遥测数据预测中能够更有效地提取关键特征,捕捉复杂的时空关系,从而提高预测的性能。

2) 前馈神经网络

Transformer 编码器中的前馈神经网络 (feed-forward neural network, FFN) 在每个编码器层中起着关键的作用,它是由两个线性变换和一个非线性激活函数组成,其对每个时间步的特征进行独立处理,以进一步提取和变换特征,提高模型的表达能力。

前馈神经网络的计算公式如式(8)所示。

$$FFN(x) = \max(0, xW_1 + b_1)W_2 + b_2 \quad (8)$$

式中: $x \in \mathbf{R}^{d_{\text{model}}}$ 是输入特征向量; $W_1 \in \mathbf{R}^{d_{\text{model}} \times d_{\text{ff}}}$ 是第1层的权重矩阵; $b_1 \in \mathbf{R}^{d_{\text{ff}}}$ 是第1层的偏置向量; $W_2 \in \mathbf{R}^{d_{\text{ff}} \times d_{\text{model}}}$ 是第2层的权重矩阵; $b_2 \in \mathbf{R}^{d_{\text{model}}}$ 是第2层的偏置向量; $\max(0, \cdot)$ 表示 ReLU 激活函数。

3) 残差连接和层归一化

残差连接的主要目的是缓解深层网络中的梯度消失问题,并加速模型的收敛。通过在子层与其输入之间添加跳跃连接,残差连接能够让信息更直接地传递,从而保留输入信息并改进特征提取效果。具体来说,残差连接将输入直接添加到子层的输出,而层归一化则是对每个输入的样本在特征维度上进行归一化操

作。公式表示如式(9)所示。

$$z_{\text{res}} = x + \text{SubLayer}(x) \quad (9)$$

式中: x 是子层的输入; $\text{SubLayer}(x)$ 是子层的输出; z_{res} 是经过残差连接后的输出。

$$z_{\text{norm}} = \frac{z - E[z]}{\sqrt{\text{Var}[z] + \epsilon}}\gamma + \beta \quad (10)$$

式中: z 是残差连接后的输出 z_{res} ; $E[z]$ 是 z 的均值, $\text{Var}[z]$ 是 z 的方差; ϵ 是一个小值,防止分母为0; γ 和 β 是可训练的缩放和偏移参数。

1.4 局部时序特征建模

遥测数据 x_t 经过位置编码和 Transformer 编码器处理后会获得一个含有丰富时空特征的矩阵 W_x , 将其与输入数据 x_t 进行相乘后得到 X_t , 作为 LSTM 的输入, 实现特征增强。其网络整体结构如图3所示。




图3 LSTM 网络结构

Fig. 3 LSTM network structure

1) 遗忘门

由图3可知,特征增强的 LSTM 网络的第1步是通过“遗忘门”,将从上一个时间点的状态 C_{t-1} 中丢弃某些信息,具体来说,输入 C_{t-1} ,会根据上一个时间点的隐藏状态 h_{t-1} 和根据特征矩阵 W_x 加权后的 X_t , 通过 Sigmoid 激活函数的输出结果 f_t 来确定遗忘信息的多少,如果结果为1则表示保留 C_{t-1} 较多的权重,如果为0则表示完全忘记 C_{t-1} 的信息。具体计算公式为:

$$X_t = W_x \cdot x_t \quad (11)$$

$$f_t = \text{Sigmoid}(W_f \cdot [h_{t-1}, X_t] + b_f) \quad (12)$$

式中: W_f 表示的是遗忘门的权重矩阵; W_x 表示特征矩阵; h_{t-1} 表示上一个时间步的隐藏状态; x_t 表示原始遥测数据; X_t 表示当前时间步的输入数据; b_f 表示遗忘门的偏置项,用于调整激活函数的输出。

2) 输入门

根据上一个时间点的输出 h_{t-1} 和当前时间点的输入 X_t 生成两部分信息 i_t 及 $\bar{C}_t$, 通过 Sigmoid 输出 i_t , 用 tanh 输出 $\bar{C}_t$. 之后 i_t 及 $\bar{C}_t$ 两个部分相乘,共同决定新的时序数据特征被保留,具体计算公式如式(13)~(15)所示。

$$i_t = \text{Sigmoid}(\mathbf{W}_i \cdot [h_{t-1}, X_t] + b_i) \quad (13)$$

$$\tilde{C}_t = \tanh(\mathbf{W}_c \cdot [h_{t-1}, X_t] + b_c) \quad (14)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (15)$$

式中: i_t 表示输入门的输出; $\mathbf{W}_i$ 表示输入门权重; b_i 表示输入门偏置项; $\tilde{C}_t$ 表示包含新信息的候选记忆细胞; $\mathbf{W}_c$ 表示记忆细胞权重; b_c 记忆细胞偏置项。

3) 输出门

最后,根据上一个时间点的输出 h_{t-1} 和当前时间点的输入 X_t 通过 Sigmoid 输出 o_t ,再根据 o_t 与 $\tanh$ 控制的当前时间点状态信息 C_t 相乘作为该门控的输出,最后经过线性激活函数对 h_t 进行线性变换得到预测的遥测值,其计算公式如式(16)~(18)所示。

$$o_t = \text{Sigmoid}(\mathbf{W}_o[h_{t-1}, x_t] + b_o) \quad (16)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (17)$$

$$\hat{y}_t = \text{Linear}(h_t) \quad (18)$$

式中: o_t 表示输出门的输出; $\mathbf{W}_o$ 表示输出门的权重; b_o 表示输出门的偏置项; $\hat{y}_t$ 表示预测值。

通过 LSTM 网络特殊的门控机制实现了对航天器遥测数据局部时间依赖关系的有效建模。

2 基于 Feen-LSTM 的遥测数据在线异常检测

遥测数据是由航天器上部署的多个传感器在线采集并传回地面的多种物理量组成的,这些物理量涵盖了温度、压力、电流、电压、加速度、姿态角、速度、位置等,遥测数据具有实时性、高维度、复杂性等特点。遥测数据是地面判断卫星运行状态的重要依据,对其进行实时监测是保障航天器在轨正常运行的重要手段。

传统的异常检测方法对于这些复杂、高维的遥测数据建模能力有限,在线实时监测效果较差,本文基于第1章提出的 Feen-LSTM 结构,实现了无监督、在线的遥测数据异常检测,其流程如图4所示。

由图4可知,本文提出的方法首先经过位置编码来保留遥测数据时序信息这一特征,然后通过 Transformer 编码器实现时空特征的建模,最后经过 LSTM 网络实现滑动窗口内的遥测数据局部时序特征建模。最终,模型输出预测值,将其与实际值进行比较,通过动态阈值的方法完成异常的标记。

在实际的应用中,该混合结构的数量可通过多次实验验证后选择出最适合完成在线异常检测任务的最佳数量。在推理及检测时间上3层结构>2层结构>1层结构,单层混合结构推理时间最短,但本文设计的2层结构经过分析,其检测时间低于0.1s,小于快遥测的采样间隔(快遥测为0.5s左右),满足在线检测的时间要求;而关于检测率,通过验证,检测准确率2层结构>1层结构>




图4 基于 Feen-LSTM 异常检测流程

Fig. 4 Feen-LSTM based anomaly detection process

3层结构,因此经过综合分析并结合实际的验证情况, N 建议设置为2。

本文提出的异常检测方法中,异常标记采用动态阈值技术,每个时间步 t 计算预测误差 $e^{(t)}$,其公式为:

$$e^{(t)} = |y^{(t)} - \hat{y}^{(t)}| \quad (19)$$

式中: $y^{(t)} = x_i^{(t+1)}$, i 代表的是真实遥测值的维度。

每个时间步的预测误差 $e^{(t)}$ 形成一维误差向量 $\mathbf{e}$ 。

$$\mathbf{e} = [e^{(t-h)}, \dots, e^{(t-l_s)}, \dots, e^{(t-1)}, e^{(t)}] \quad (20)$$

式中: h 是用于评估当前误差的历史误差值的数量。

为了减小由模型预测导致的误差尖峰,使用了指数加权平均(exponentially weighted moving average, EWMA)对误差 $\mathbf{e}$ 进行了误差平滑处理,以此避免因预测值与实际值相差较大而造成误差值骤变的现象^[28],经过处理后生成平滑误差向量 $\mathbf{e}_s$ 。

$$\mathbf{e}_s = [e_s^{(t-h)}, \dots, e_s^{(t-l_s)}, \dots, e_s^{(t-1)}, e_s^{(t)}] \quad (21)$$

为了判断遥测值是否正常,为平滑后的预测误差设定了一个阈值 ϵ ,如果平滑误差超过阈值则标记为异常。

阈值 ϵ 是根据平滑误差的均值和标准差计算,根据式(22)确定初步阈值。

$$\epsilon = \mu(\mathbf{e}_s) + z\sigma(\mathbf{e}_s) \quad (22)$$

式中: $\mu(\mathbf{e}_s)$ 是平滑误差的均值; $\sigma(\mathbf{e}_s)$ 是平滑误差的标

准差; z 是一组正值,表示标准差的倍数(通常在 2~10 之间)。根据式(23)计算出最优阈值以区分正异常值:

$$\epsilon = \operatorname{argmax} \left(\frac{(\Delta \mu(e_s) / \mu(e_s)) + (\Delta \sigma(e_s) / \sigma(e_s))}{|e_a| + |E_{seq}|^2} \right)$$

(23)

式中: $\Delta \mu(e_s)$ 和 $\Delta \sigma(e_s)$ 表示如果移除高于初步阈值 ϵ 的值后,平滑误差的均值和标准差的变化; e_a 表示的是高于 ϵ 的值的集合; E_{seq} 表示的是这些异常值序列的数量。

根据上述过程可以确保阈值随着数据的变化而调整,其具有非常高的灵活性和适应性,不依赖于固定的阈值,从而提高异常检测的准确性和可靠性。

3 实验设置和结果

3.1 实验设置

1) 数据集

由于航天器的遥测数据具有领域特性,公开的数据集较少。本文实验中所用到的数据集是 NASA 公开的遥测数据集 SMAP (Soil Moisture Active Passive satellite) 以及 MSL (Mars Science Laboratory rover),其中 SMAP 是用来采集地球表面土壤湿度和冻结状态的卫星,MSL 是用来探测火星的气候和地质的卫星。数据集的详细情况如表 1 所示。

表 1 实验数据

Table 1 Experiment data

数据集信息	MSL	SMAP
维度	27×55	55×25
时间粒度/s	60	60
训练集大小	58 317	135 181
测试集大小	73 729	427 617
异常率/%	10.72	13.13

表 1 中 MSL 有 27 个通道,每个通道维度是 55,SMAP 则有 55 个通道,每个通道维度是 25,每个通道的第 1 维数据是遥测值,其他维度均是指令量,遥测数据的采集间隔都是 1 min。

该公开数据集由航天领域专家进行标记,训练集和测试集被分别放在不同文件中,其中训练数据集具有类别标签,测试数据无类别标签,两个数据集在现研究工作中均被直接使用,无需在验证中进行训练集与测试集的二次划分,可用于客观地评价不同算法的异常检测性能。

2) 模型参数设置

本文基于 Pytorch1.12.0+cu116 框架搭建的模型,使用了 1 个 NVIDIA RTX4060 GPU 进行训练,系统为 Windows11,CPU 为 Intel Core i5-13650HX。实验中模型使用的所有参数具体如表 2 所示。

表 2 实验相关参数

Table 2 Relevant experimental parameters

参数名称	参数值
LSTM 隐藏层数	2
Transformer 编码器个数	2
注意力头数	5
隐藏层及编码器神经元尺寸	40
批尺寸	64
训练轮次	35
验证集拆分比例	0.2
Dropout	0.3
损失函数	MSE
优化函数	Adam

3) 评价指标

本文使用 F1 分数作为主要评价指标,以衡量模型在预测任务中的性能。F1 分数综合了精确率(Precision)和召回率(Recall),通过它们的调和平均数来平衡二者之间的权重。准确率、召回率以及 F1 分数的具体计算公式如式(24)~(26)所示。

$$Precision = \frac{TP}{TP + FP}$$

(24)

$$Recall = \frac{TP}{TP + FN}$$

(25)

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

(26)

3.2 异常检测结果与分析

1) 基线实验

根据对航天器遥测数据异常检测领域的调研,本文提出的异常检测算法与目前 3 类主流深度学习方法中性能较优的模型进行了对比。(1)非动态方法,包括 VAE^[19],一种基本的概率生成模型;LadderVAE^[20],一种深层 VAE 结构模型;USAD^[21],一种基于逆向训练的自动编码器模型。(2)动态方法,包括 LSTM-NDT^[22],一种确定性递归自编码模型;LSTM^[29]一种利用长短期记忆网络处理序列数据的方法;CAE-M^[24],一种结合了深度卷积自编码器和双向 LSTM 网络的模型。(3)关系方法中 GNN^[25],一种用于异常检测的图神经网络。

以上提到的方法和本文提出的 Feen-LSTM 方法分别在 MSL 和 SMAP 数据集上做了对比实验,详细异常检测结果如表 3 所示。

表 3 实验结果

Table 3 Experiment results

	MSL			SMAP		
	Precision	Recall	F1-score	Precision	Recall	F1-score
VAE	0.781	0.813	0.797	0.755	0.737	0.746
LadderVAE	0.842	0.823	0.832	0.792	0.775	0.783
USAD	0.794	0.991	0.882	0.748	0.962	0.841
LSTM	0.883	0.679	0.765	0.821	0.790	0.802
LSTM-NDT	0.926	0.694	0.794	0.855	0.855	0.855
CAE-M	0.775	1.00	0.873	0.819	0.956	0.882
GNN	0.881	0.889	0.885	0.812	0.944	0.873
Feen-LSTM (本文)	0.893	0.879	0.886	0.915	0.875	0.898

由表 3 的实验结果可知,VAE 以及 LadderVAE 在两个数据集上的表现较为不错,LadderVAE 是在 VAE 结构上进行了优化,加深了网络层次增强了特征提取的能力,其性能相对 VAE 有一定程度的提升,USAD 通过逆向训练的方式进一步提升了自动编码器的建模效果,检测性能也得到了一定的提升。这 3 种方法都是通过学习数据的概率分布,然后生成与原始样本相似的样本,以此识别偏离正常分布的异常数据。它们都因为结构简单、计算效率高、无需标签数据即可识别异常等优点在该领域取得了很好的效果,但其无法处理时序数据中的时序信息,因此存在一定缺陷。LSTM、LSTM-NDT 和 CAE-M 这 3 种方法都是基于 LSTM 网络而实现的异常检测方法,它们都能够有效的捕获时序数据中的时间依赖特征以提高异常检测的能力,但它们在具有更高维度的 MSL 数据集上表现却不佳,随着维度增加数据中所包含的空间特征信息就会越丰富,而 LSTM 网络不具备建模空间特征的能力,因此随着数据变复杂检测效果也随之下降。GNN 在近两年被逐渐应用并且取得了非常不错效果,它通过将时序数据转换为图结构来捕获时间步之间以及特征间的依赖,实现了非常充分的特征建模。在线异常检测任务对模型要求要快而精确,但因 GNN 网络结构复杂导致推理时间较长,所以在线检测的时效性无法保证。本文提出的 Feen-LSTM 模型在这些方面要优于 GNN,其首先通过位置编码来保留时序性以便 LSTM 网络后续进行特征提取,并通过 Transformer 编码器来弥补 LSTM 对于高维度时序数据特征提取能力差的缺陷,最后再结合 LSTM 网络捕获时序数据长短期依赖关系以及推理速度快这些优点。根据实验结果来看本文提出的模型相对于其他对比模型具有一定优势。

由于篇幅有限,本节仅给出 SMAP 数据集和 MSL 数据集的其中各一个传感器的遥测数据作为检测样

例,并且考虑结果对比的清晰性,主要将除本文提出方法外的最优对比方法进行同步呈现,如图 5 所示。




图 5 异常检测结果

Fig. 5 Detection results

图 5(a)中所用的数据集来自于 SMAP 数据集的某一设备,其实际异常序列出现的位置索引在 [4 550,4 660],本文提出的方法异常检测的索引位置为 [4 540,4 655] 覆盖了整个异常模式区间,除本文方法外也对比了在 SMAP 数据集上检测效果最好的方法 CAE-M,其检出索引位置为[4 537,4 652]。

图 5(b)中所用的数据集来自于 MSL 数据集的某一设备,其实际异常序列出现的位置索引在[630,750],本文提出的方法异常检测的索引位置为[605,757],除本文方法外也对比了在 MSL 数据集上检测效果最好的方法 GNN,其检出索引位置为[569,792],这两种方法都检测出了全部异常序列但 GNN 的误检区域远大于 Feen-LSTM 的误检区域。

考虑到本文面向在线异常检测场景,在线检测应用时检测到此片段为异常即可进行后续异常排查,而检出索引更适合于事后异常片段的精准定位,而且考虑到现有在线异常检测方法中均通过检出索引计算 F1 分数来评估算法性能,而未把单独的检出索引设计为评价指标,为保证比较的客观性,本文也仅对单独的检出索引进行分析,以提供参考。

在实际应用时,卫星遥测数据中快遥测的采样间隔约为 0.5 s,本文使用 NVIDIA RTX4060(8 G)显卡进行训练与检测时,针对不同数据集所用的测试总耗时及平均耗时为:MSL 数据集测试总耗时 540 s,平均每个样本异常检测的耗时为 0.007 s,SMAP 数据集测试总耗时为 1 440 s,平均每个样本异常检测耗时为 0.003 s,通过测试与分析,本文提出的模型推理平均耗时均低于采样率,可以满足在线检测的需求。

2) 消融研究

为深入理解模型中各个组件对整体性能的贡献,本文进行了系统的消融研究。由于本文是基于 LSTM 网络的一种优化算法,因此将未与 Transformer 编码器融合前的 LSTM-NDT 模型,作为基础模型,进行对比。通过不断移除模型中的不同部分以计算结果,最终在 SMAP 数据集和 MSL 数据集上准确率、召回率及 F1 分数的变化情况分别如图 6(a)和(b)所示。

图 6 中对比模型分别为:LSTM-NDT、Feen-LSTM 无位置编码、Feen-LSTM 无编码器、位置编码-Transformer 编码器。由图 6 可知,移除位置编码模块后,Feen-LSTM 无位置编码模型的召回率和准确率均有不同程度的下降。位置编码的主要功能是保留输入数据的时序信息,





图 6 消融实验结果
Fig.6 Ablation study results

使模型能够学习到数据的时序关系。当移除该模块时,模型在进行异常检测时缺乏时序信息的指导,导致其标记异常的过程变得无序化,从而无法准确识别出所有异常数据。这表明位置编码在捕捉和利用时序关系方面对异常检测任务具有重要作用。引入 Transformer 编码器的目的是提高特征提取能力,移除它后对于 SMAP 数据集和 MSL 数据集来说整体性能都有些许下降。并且可以看到 MSL 数据集的 F1 分数下降更加明显,因为该数据集的维度要高于 SMAP 数据集,所以对模型的特征提取能力就有更高的要求,而移除该模块后导致特征提取能力下降,所以对于 MSL 数据集的影响则会更加明显。综合以上分析,验证了对于遥测数据异常检测,本文设计的优化结构的有效性与必要性。

4 结 论

面向航天器遥测数据异常样本标签不充分情况下的在线异常检测的需求与挑战,本文提出了 Feen-LSTM 模型,该模型结构主要由时序特征提取,全局时空特征建模和局部时序特征建模 3 个部分组成。首先,遥测数据经过位置编码保留输入数据的时序信息,再通过 Transformer 编码器和 LSTM 的混合结构进行特征提取以及生成预测值。本文提出的模型在航天器遥测数据的特征挖掘以及捕获长序列依赖关系的能力上有明显提升。在 NASA 公开的遥测数据集上的实验表明,与其他主流的异常检测算法相比,本文所提出的模型性能更优。

在后续研究工作中将通过数据处理手段或选择对噪声鲁棒性强的结构组合到网络中以进一步降低误检率,使其能够更好的满足异常检测任务的需求,并结合更多的遥测数据验证方法的实际应用能力。



参考文献

- [1] 中华人民共和国国务院新闻办公室. 白皮书:2021 中国的航天[R/OL]. (2022-01-28)[2024-08-25]. State Council Information Office(SCIO). White Paper: China's Aerospace in 2021[R/OL]. (2022-01-28)[2024-08-25].
- [2] 中国航天科技集团. 中国航天科技活动蓝皮书(2023年)[EB/OL]. (2024-02-26)[2024-08-25]. China Aerospace Science and Technology Corporation. China Aerospace Science and Technology Activities Blue Book(2023)[EB/OL]. (2024-02-26)[2024-08-25].
- [3] 田思维,朱爱军,贾树泽,等. 基于遥测数据频域特征的气象卫星故障诊断方法[J]. 电子测量技术,2021,44(14):158-162. TIAN S W, ZHU A I J, JIA S H Z, et al. Fault diagnosis method for meteorological satellites based on frequency domain features of telemetry data[J]. Electronic Measurement Technology, 2021,44(14):158-162.
- [4] 宁顺成. 基于遥测时序数据的航天器异常检测技术应用研究[D]. 哈尔滨:哈尔滨工业大学,2019. NING S H C H. Based on remote sensing the time-series data of anomaly detection technology of spacecraft[D]. Harbin: Harbin Institute of Technology, 2019.
- [5] 彭喜元,庞景月,彭宇,等. 航天器遥测数据异常检测综述[J]. 仪器仪表学报,2016,37(9):1929-1945. PENG X Y, PANG J Y, PENG Y, et al. Review on anomaly detection of spacecraft telemetry data[J]. Chinese Journal of Scientific Instrument, 2016,37(9):1929-1945.
- [6] YU J S, SONG Y, TANG D Y, et al. Telemetry data-based spacecraft anomaly detection with spatial-temporal generative adversarial networks[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 3515209.
- [7] 李桢煜,宋宇晨,彭喜元,等. 基于对比序列重构的卫星遥测数据异常检测方法[J]. 仪器仪表学报,2024,45(4):17-26. LI Z H Y, SONG Y C H, PENG X Y, et al. Contrastive time-series reconstruction method for satellite anomaly detection[J]. Chinese Journal of Scientific Instrument, 2024,45(4):17-26.
- [8] YANG K F, WANG Y K, HAN X D, et al. Unsupervised anomaly detection for time series data of spacecraft using multi-task learning[J]. Applied Sciences, 2022, 12(13):6296.
- [9] 何家辉,程志君,郭波. 联合字典学习与 OCSVM 的遥测数据异常检测方法[J]. 航空学报, 2023,44(13):207-219. HE J H, CHENG Z H J, GUO B. Anomaly detection method of telemetry data based on combined dictionary learning and OCSVM[J]. Acta Aeronautica et Astronautica Sinica, 2023,44(13):207-219.
- [10] 董静怡,庞景月,彭宇,等. 集成 LSTM 的航天器遥测数据异常检测方法[J]. 仪器仪表学报,2019,40(7):22-29. DONG J Y, PANG J Y, PENG Y, et al. Spacecraft telemetry data anomaly detection method based on ensemble LSTM[J]. Chinese Journal of Scientific Instrument, 2019,40(7):22-29.
- [11] 苏鹏,高燕,董婷婷,等. 多星遥测联合判断实时故障分析模型设计及应用[J]. 国外电子测量技术,2020,39(9):128-131. SU P, GAO Y, DONG T T, et al. Design and application of a multi-satellite telemetry joint judgment real-time fault analysis model[J]. Foreign Electronic Measurement Technology, 2020,39(9):128-131.
- [12] 庞景月,赵光权. 数字孪生驱动多算法自适应选择的空间电源系统故障检测[J]. 电子测量与仪器学报, 2022,36(6):91-99. PANG J Y, ZHAO G Q. Digital twin-driven adaptive multi-algorithm selection for space power system fault detection[J]. Journal of Electronic Measurement and Instrumentation, 2022,36(6):91-99.
- [13] CHANDOLA V, BANERJEE A, KUMAR V. Anomaly detection: A survey[J]. ACM Computing Surveys (CSUR), 2009, 41(3):1-58.
- [14] 杨挺,王媛,王瑛琪,等. 基于时空关联的飞控传感器数据异常检测[J]. 仪器仪表学报,2024,45(8):21-31. YANG T, WANG Y, WANG Y Q, et al. A spatio-temporal correlation method for flight control sensor data anomaly detection[J]. Chinese Journal of Scientific Instrument, 2024,45(8):21-31.
- [15] CHEN W C H, TIAN L, CHEN B, et al. Deep variational graph convolutional recurrent network for

- multivariate time series anomaly detection[C]. International Conference on Machine Learning. PMLR, 2022: 3621-3633.
- [16] KANG SH Q, GAO Y J, SONG Y CH, et al. Parameter probabilistic prediction for satellite power system based on unsupervised multi-dimensional sequence segmentation[J]. Aerospace Science and Technology, 2024, 146:108933.
- [17] CHEN Z K, CHEN D SH, ZHANG X, et al. Learning graph structures with transformer for multivariate time-series anomaly detection in IoT[J]. IEEE Internet of Things Journal, 2021, 9(12):9179-9189.
- [18] LI J B, IZAKIAN H, PEDRYCZ W, et al. Clustering-based anomaly detection in multivariate time series data[J]. Applied Soft Computing, 2021, 100:106919.
- [19] KINGMA D P, WELING M. Auto-encoding variational bayes[J]. ArXiv preprint arXiv:1312.6114, 2013.
- [20] SØNDERBY C K, RAIKO T, MAALØE L, et al. Ladder variational autoencoders[C]. Advances in Neural Information Processing Systems, 2016:3745-3753.
- [21] AUDIBERT J, MICHIARDI P, GUYARD F, et al. Usad: Unsupervised anomaly detection on multivariate time series[C]. Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2020:3395-3404.
- [22] HUNDMAN K, CONSTANTINOU V, LAPORTE C, et al. Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding[C]. Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2018:387-395.
- [23] SU Y, ZHAO Y J, NIU CH H, et al. Robust anomaly detection for multivariate time series through stochastic recurrent neural network[C]. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2019:2828-2837.
- [24] ZHANG Y X, CHEN Y Q, WANG J D, et al. Unsupervised deep anomaly detection for multi-sensor time-series signals[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 35(2):2118-2132.
- [25] DENG A, HOOI B. Graph neural network-based anomaly detection in multivariate time series[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(5):4027-4035.
- [26] LI ZH H, ZHAO Y J, HAN J Q, et al. Multivariate time series anomaly detection and interpretation using hierarchical inter-metric and temporal embedding[C]. Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining, 2021: 3220-3230.
- [27] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]. Advances in Neural Information Processing Systems, 2017:6000-6010.
- [28] SHIPMON D T, GUREVITCH J M, PISELLI P M, et al. Time series anomaly detection; detection of anomalous drops with limited features and sparse examples in noisy highly periodic data[J]. ArXiv preprint arXiv:1708.03665, 2017.
- [29] ERGEN T, KOZAT S S. Unsupervised anomaly detection with LSTM neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 31(8): 3127-3141.

作者简介



张金垒, 2023 年于新疆财经大学获得学士学位, 现为重庆工商大学软件工程专业研究生, 主要研究方向为航天器遥测数据在线异常检测。

E-mail: 2023313019@ctbu.edu.cn

Zhang Jinlei received his B. Sc. from Xinjiang University of Finance and Economics in 2023. Now he is a graduate student in Software Engineering at Chongqing Technology and Business University. His main research interest is online anomaly detection of spacecraft telemetry data.



庞景月 (通信作者), 2011 年于重庆理工大学获得学士学位, 2013 年于哈尔滨工业大学获得硕士学位, 2020 年于哈尔滨工业大学获得博士学位, 现为重庆工商大学副教授, 主要研究方向为工程测试与信息处理, 航天器遥测数据分析, 航天器电源系统异常检测以及工业大数据分析。

E-mail: jypang2019@ctbu.edu.cn

Pang Jingyue (Corresponding author) received her B. Sc. degree from Chongqing University of Technology in 2011, M. Sc. degree from Harbin Institute of Technology in 2013, and Ph. D. degree from Harbin Institute of Technology in 2020, respectively. Now she is an associate professor in Chongqing Technology and Business University. Her main research interests include engineering testing & signal processing, spacecraft telemetry data

analysis, anomaly detection for spacecraft power subsystems, and analysis on industrial big data analysis.



卢晓伟,2010 年于哈尔滨工业大学大学获得学士学位,2013 年于哈尔滨工业大学获得硕士学位,现为上海卫星工程研究所高级工程师,主要研究方向为卫星综合测试,航天器遥测数据分析。

E-mail:hitlxw@126.com

Lu Xiaowei received his B.Sc. from Harbin Institute of Technology in 2010 and his M.Sc. from Harbin Institute of Technology in 2013. He is currently a senior engineer at Shanghai Satellite Engineering Research Institute. His main research interests include specializing in satellite comprehensive testing and spacecraft telemetry data analysis.



宋宇晨,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助理教授,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 received his B.Sc. degree in 2015 from the University of Electronic Science and Technology of China, received his Ph.D. degree in 2022 from Harbin Institute of Technology. Now he is an assistant 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.