文章编号:1671-4598(2026)05-0063-08 DOI:10.16526/j.cnki.11-4762/tp.2026.05.008 中图分类号:TP3 文献标识码:A

基于 PC-MR-TCN 的卫星遥测数据异常检测方法

杨佳林，陈志杰，阳 凯，李学仕，周 彬
（西南电子设备研究所，成都 610036）

摘要：随着航天技术的发展，卫星遥测参数呈现出高维、耦合与非线性特征，传统统计方法难以满足精细化健康监测需求；针对当前遥测数据异常检测的深度学习中多关注单变量时序建模，忽略了参数间的耦合关系与物理一致性约束的问题，提出了一种物理一致性多关系时序卷积网络模型；该方法以时序卷积网络为主干，引入关系编码器对时间依赖和变量依赖建模参数间的多关系耦合，并通过门控机制融合，同时构建通信链路一致性与电流守恒一致性等弱物理约束损失项，将领域知识以可微形式注入训练过程；在检测阶段，基于重构误差、预测误差和物理一致性偏差构造综合异常评分；当前方法在某卫星平台与公开数据集上均取得更优的 F_1 分数，为在轨安全健康检测提供方法支撑。

关键词：遥测数据；时序卷积网络；多任务学习；关系建模；物理一致性约束

Anomaly Detection Method for Satellite Telemetry Data Based on PC-MR-TCN Modeling

YANG Jialin, CHEN Zhijie, YANG Kai, LI Xueshi, ZHOU Bin
(Southwest China Research Institute of Electronic Equipment, Chengdu 610036, China)

Abstract: With the development of space technology, satellite telemetry parameters show high-dimensional, coupled, and nonlinear characteristics. Traditional statistical methods can hardly meet the needs of fine-grained health monitoring. Current deep-learning methods for telemetry anomaly detection mainly focus on univariate time-series modeling. They ignore the coupling among parameters and physical consistency constraints. To solve this problem, this paper proposes a Physics-Consistency Multi-Relation Temporal Convolutional Network (PC-MR-TCN). The model uses a Temporal Convolutional Network (TCN) as the backbone. It introduces a relation encoder to model temporal dependencies and inter-variable dependencies. The encoder captures the multi-relation coupling among telemetry parameters. A gating mechanism is used to fuse these representations. In addition, the model constructs weak physical-constraint loss terms, such as communication-link consistency and current-conservation consistency. These terms inject domain knowledge into the training process in a differentiable way. In the detection stage, a comprehensive anomaly score is constructed based on reconstruction error, prediction error, and physical consistency deviation. The proposed method achieves better F_1 scores on both a certain satellite platform and public datasets, providing methodological support for on-orbit safety and health detection.

Keywords: Telemetry Data; Temporal Convolutional Network; Multi-task Learning; Relationship Model; Physical Consistency Constraint

0 引言

卫星是提供定位、导航、通信等服务的核心载体，在现代高科技战争中承担着关键角色。卫星平台在轨运行期间可能面临平台设备失效、载荷功能异常等突发故障，同时需应对宇宙辐射、空间碎片撞击、恶意电磁干扰等多重外部威胁。这些风险可能导致卫星性能衰退甚至完全失效，严重影响任务的连续性和可靠性[1]。随着卫星系统复杂度不断提升，遥测参数呈现出高维、耦合和非线性的特点，传统依赖固定门限、专家规则和单一统计量的方法，已难以满足当下异常检测的需求。

从研究现状来看，国内外在航天器异常检测方面大

收稿日期:2026-02-13； **修回日期**:2026-04-07。
作者简介:杨佳林(2001-),男,硕士。
通讯作者:周 彬(1968-),男,硕士,正高级工程师。
引用格式:杨佳林,陈志杰,阳 凯,等.基于 PC-MR-TCN 的卫星遥测数据异常检测方法[J].计算机测量与控制,2026,34(5):63-70.

致经历了由规则方法、统计方法向深度时序建模与关系建模发展的过程。国外研究相对起步较早，Yairi 等很早将机器学习与数据挖掘思想引入航天器遥测异常检测与故障诊断[2]，美国国家航天局艾姆斯研究中心建立了归纳监控系统[3-4]。在国内，异常检测规则与统计方面的研究主要采用主成分分析（PCA，principal component analysis）[5]、相关分析[6]和一类支持向量机[7]等统计与传统机器学习方法。这些方法大多基于规则、聚类、统计偏移量，忽略了遥测数据的时序性，对遥测数据时序建模能力有限。

随着深度学习方法的发展，国内外研究逐渐开始将自编码器（AE，auto-encoder）[8]、长短期记忆网络（LSTM，long short-term memory）[9]和注意力机制[10]等引入航天器遥测异常检测[11-12]。这些模型虽然使用了 LSTM 进行了时序建模，但是 LSTM 仅考虑当前时刻的输入和前一时刻的隐藏层特征，因此难以捕捉到较远采样时刻的变量之间的长期依赖关系[13]。同时，这些方法大多侧重时间特征提取，变量关系间的显式关系建模不足。

为了进一步建模卫星变量间关系，闵祥渊[14]和朱野等[15]使用基于图学习的方法，对遥测数据进行异常检测，这为现有多变量关联异常提供了有效思路。这些方法侧重统计关联与时空依赖建模，但是统计相关不等同于工程上的真实约束。

综上所述，卫星遥测数据异常检测不仅需要刻画长时序依赖特征，还需要显式建模变量间的耦合关系，并将物理一致性先验融入检测过程。针对上述问题，本文提出一种物理一致性多关系时序卷积网络（PC-MR-TCN），该方法通过引入多关系编码模块改进 TCN[16]的特征表示能力，使模型同时关注时间特征和变量特征信息，可以对数据长时依赖和特征关系进行建模，同时基于通信链路关系和电流守恒公式构建物理一致性约束，并以可微软惩罚形式融入模型训练过程。实验结果表明，所提方法能够提高卫星遥测异常检测的综合性能。

1 任务定义与数据说明

1.1 问题描述

设卫星在 $t=1,2,\cdots,T$ 的采集到的遥测数据为 $X=[x_1,x_2,\cdots,x_T]^T$，$X\in R^{T\times D}$，D 表示遥测数据特征维数。对于任意 t 时刻，构造长度为 L 的滑动时间窗，如公式（1）所示：

$$W_t=[x_{t-L+1},x_{t-L+2},\cdots,x_t]\in R^{L\times D} \tag{1}$$

本文的目标是使用数据驱动的方法，利用 PC-MR-TCN 学习一个由正常样本驱动的异常检测函数如公式（2）所示：

$$f:R^{L\times D}\rightarrow R \tag{2}$$

其输出异常分数 $s_t=f(W_t)$，当 s_t 超过由校准集确定的阈值判定方式时[17]，判定对应时刻或时间段为异常。由于卫星在实际运行中异常事件发生概率低且异常事件通常具有持续性。使用点级判断容易误报，因此本文在点级判断基础上，将 W 时间内连续的告警点聚合为异常段，进行事件级异常判定。若该异常段成功与异常事件相交，则视为正例，否则判定该事件为误报。

1.2 数据说明

本研究遥测数据集来自于某卫星平台的遥测参数构建的多维遥测序列，采样频率 1 Hz，时间序列总长度约为 50 000 条，共 68 维。数据同时覆盖系统级状态量、链路质量、支路电流量以及模块温度量等参数，能够较为完整的表征卫星平台在通信、热控等方面的运行状态。

由于实际在轨遥测样本稀缺且类型有限，本文在真实遥测背景基础上，通过仿真异常注入方式构建多维遥测实验数据集，共注入了 14 个互不相交异常，异常类型如图 1 所示。

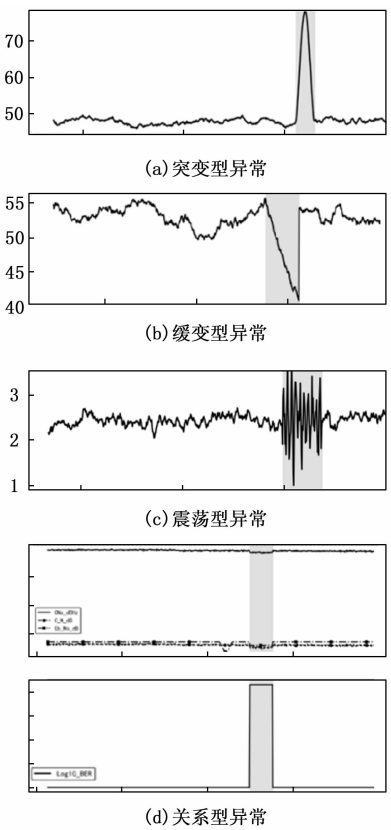

图 1 各种异常类型

突变型异常是指遥测数据突然间跳变，表现为数值瞬时偏离正常范围。缓变型异常表现为数据在一段时间内持续、缓慢地偏移正常状态。震荡型异常指表现参数在异常期间持续波动、往复震荡。关系型异常通常因为传感器漂移、采样不同步以及局部部件性能退化等因素

引起的。该类异常单个变量赋值变化不一定很大，但多个遥测参数间的耦合关系被破坏。比如当前关系型异常中，误码率升高，但是载噪比等参数几乎不变化。

此外，为验证所提方法的泛化能力，本文进一步在公开数据集 NASA MSL 上进行了泛化实验[18]。该实验数据来自于美国航天局好奇号火星车，并由 NASA 专家进行了异常数据标注。

2　PC-MR-TCN 设计

本文所提出的 PC-MR-TCN 的异常检测方法训练总体流程图如图 2 所示，主要包括数据预处理，时序－关系编码，门控融合，多任务解码，物理一致性约束建模以及异常评分判别等步骤。首先对原始遥测数据序列进行缺失值填充、平滑去噪和稳健标准化处理，并引入缺失掩码。利用 TCN 提取时间维度特征，在此基础上利用关系编码器进一步增强时间依赖与变量依赖。随后，采用门控融合机制自适应融合关系编码器和时序编码器的输出，并通过多任务解码器同时完成输入重构和单步预测。最后，将重构误差、预测误差以及物理一致性偏差进行联合建模，用于学习正常运行模式，并实现异常检测。

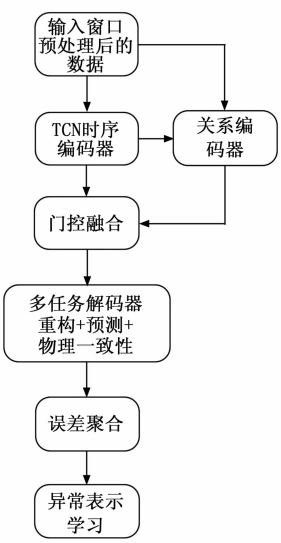

图 2　PC-MR-TCN 异常检测总体流程图

2.1　数据预处理

数据清洗：采用先前向填充再后向填充的方法对遥测数据序列进行缺失值填充，使用五点三次平滑算法[19]对数据进行清洗，引入缺失掩码向量标记原始缺失位置，设时间窗输入序列为 $X\in R^{L\times D}$，缺失掩码为 $M\in\{0,1\}^{L\times D}$，其中 L 为时间窗长度，$M_{t,d}=1$ 表示该位置缺失，$M_{t,d}=0$ 表示在该位置观测有效。缺失掩码在模型训练阶段作为辅助信息输入，以降低填充值对模型学习的干扰。采用稳健标准化方法，基于中位数和四分位数范围进行缩放，Q_3 和 Q_1 是百分之七十五和百分之二十五分数，如式（3）所示。与标准差标准化相比，稳健标准化方法对异常值更加不敏感，更适合遥测数据场景。

$$x_{\text{scaled}}=\frac{x^{(3)}-median(x)}{Q_3-Q_1} \tag{3}$$

2.2　时序－关系编码器

遥测数据具有明显的时序性，也存在多变量间的相关关系，仅从时间维度难以对遥测数据进行充分建模。因此，本文在 TCN 的基础上引入关系编码器，联合刻画时间关系和变量关系。

2.2.1　TCN 设计

TCN 是一种基于卷积的神经网络，具有并行计算效率高、感受野可扩展等优点，比 LSTM 更适合进行长时依赖关系建模。TCN 通过因果膨胀卷积保证当前时刻的输出仅依赖于当前及历史输入，避免未来信息泄露，还通过向卷积核插入空洞扩大感受野，从而捕获长时依赖关系，如图 3 所示。

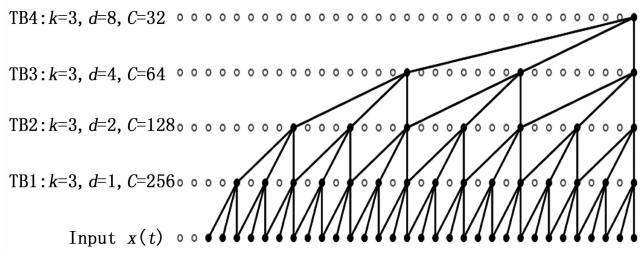

图 3　因果膨胀卷积

设时间输入序列为 $x=\{x_1,x_2,\cdots,x_T\}$，卷积核大小为 K，权重为 w_i，膨胀率为 d 的一维膨胀因果卷积输出公式如式所示：

$$y_t=\sum_{i=0}^{K-1}w_i x_{t-di} \tag{4}$$

TCN 一般由多个 Temporal Block 单元组成，每个单元结构如图 4 所示。假设第 l 个 Temporal Block 输入为 h_{l-1}，$F(h_{l-1})$ 表示经过膨胀因果卷积、非线性变换、随机失活后的输出，可定义为：

$$\begin{cases} z_t^{(l,1)}=\sigma\left(\sum_{i=0}^{K-1}w_i^{(l,1)}h_{t-di}^{l-1}+b^{(l,1)}\right) \\ F(h_{l-1})=\sigma\left(\sum_{i=0}^{K-1}w_i^{(l,2)}z_{t-di}^{(l,1)}+b^{(l,2)}\right) \end{cases} \tag{5}$$

o 表示残差支路输出，当输入与输出通道数不一致时，可通过 1×1 卷积模块将输入 h_{l-1} 与 $F(h_{l-1})$ 维度进行匹配后再相加。第 l 个 Temporal Block 输出为 $h_l=F(h_{l-1})+o$。

2.2.2　关系编码模块

TCN 虽然能够建模时间维上的长时依赖，但对变量间的耦合关系刻画不足。为此，本文在 TCN 的基础上引入关系编码模块，从时间依赖和变量依赖两个层面

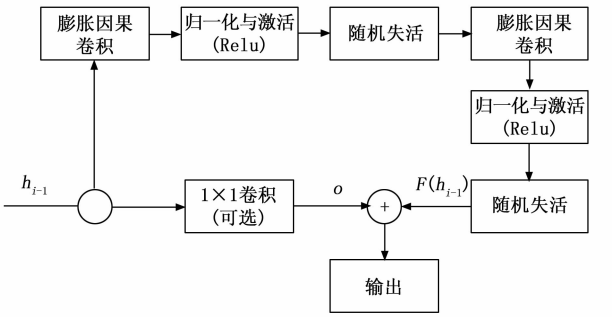

图 4 Temporal Block 单元结构

增强特征表达能力，具体结构如图 5 所示。

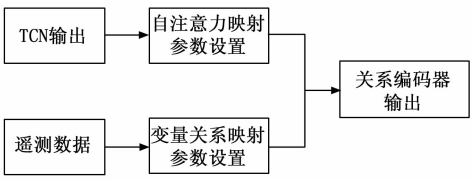

图 5 关系编码器模块架构

1）时间关系建模：

TCN 的时间依赖主要通过固定卷积核进行时间特征提取，难以刻画窗口内不同时间步对当前判别的重要性差异。因此，关系编码模块在 TCN 输出特征基础上引入多头自注意力机制。设 TCN 的逐时间步输出为 $F_{\text{tcn}} \in R^{B\times L\times C}$，$B$ 为批大小，C 为时序特征维数。首先通过线性映射将特征从 C 投射至关系维度 Re，得到 $F_{\text{tcn(Re)}}$。随后采用多头自注意力对投影后的序列特征进行建模，注意力内部的 Q,K,V 投影参数由多头注意力机制模块自动学习，对于第 h 个头的公式（6）所示：

$$\begin{cases} Q^{(h)} = F_{tcn(R)} W_Q^{(h)}, K^{(h)} = F_{tcn(R)} W_K^{(h)} \\ V^{(h)} = F_{tcn(R)} W_V^{(h)}, d_k = \dfrac{R}{H} \\ head^{(h)} = soft\max\left(\dfrac{Q^{(h)}(K^{(h)})^T}{\sqrt{d_k}}\right)V^{(h)} \end{cases} \tag{6}$$

R 为 TCN 最终输出通道参数，$H=4$。该分支输出逐时间步的时间关系特征，最终时间特征的最终结果如公式（7）所示，$\boldsymbol{W}_0$ 为多头注意力里的输出投影矩阵，用于对各注意力头拼接后的特征进行线性变换与信息重组：

$$\begin{cases} F_{\text{time}} = Concat(head^{(1)}, \cdots, head^{(H)}) W_0 \\ \boldsymbol{W}_0 \in R^{R\times R} \end{cases} \tag{7}$$

2）变量关系映射参数设置：

为刻画变量间的潜在耦合关系，本文并不预设人工关系图，而是引入一个可学习的变量关系映射矩阵：$\boldsymbol{A} \in R^{C\times C}$，$\boldsymbol{A}$ 的数值随着训练过程与模型其余参数一起优化，并通过 Softmax 归一化得到关系权重矩阵 $\boldsymbol{W} = soft\max(\boldsymbol{A})$。矩阵 $\boldsymbol{W}$ 反映的是训练数据分布下变量间的统计依赖强弱，而非严格意义上的物理因果关系，因此后续需要物理一致性建模。在变量关系分支中，首先对窗口内变量序列进行掩码加权聚合，得到窗口级变量表示 $\boldsymbol{S} \in R^C$，再通过关系映射得到 $\boldsymbol{S}_{\text{rel}} = \boldsymbol{SA}$，并经过线性变换至 R 维，最终将该变量关系特征在窗口内广播至各时间步，得到变量关系特征 $\boldsymbol{F}_{\text{var}} \in \boldsymbol{R}^{B\times L\times R}$。

3）关系特征融合与输出：

将时间关系特征 F_{time} 和变量关系特征 F_{var} 在特征维度上进行拼接，得到关系编码器的输出，如公式（8）所示：

$$\boldsymbol{F}_{\text{rel}} = Contact(F_{\text{time}}, F_{\text{var}}) \tag{8}$$

该关系特征保留时序动态信息的同时，融入了变量之间的关系，增加了对数据异常的检测能力。

2.3 门控融合机制

门控机制能够利用关系编码器的输出来调节时序通道，避免在弱耦合或强噪声场景下关系建模对异常判断产生干扰。本文在窗口末端提取 TCN 时序特征输出 F_{tcn} 和关系编码器的关系特征输出 F_{rel} 进行拼接成联合输入向量，并通过线性映射与 sigmoid 函数得到门控权重 g，最终将门控特征作用于时序特征，实现时序特征的增强，得到融合特征 $\widetilde{F}$，如公式（9）所示：

$$\begin{cases} g = \sigma[Linear(F_{\text{tcn}}, F_{\text{rel}})] \\ \widetilde{F} = g \odot F_{\text{tcn}} \end{cases} \tag{9}$$

2.4 掩码感知多任务损失

为实现稳定有效的异常表示学习，本文构建了一种掩码感知的多任务联合损失函数，综合考虑数据重构误差、预测误差以及物理一致性约束[20]。通过在预处理步骤得到的缺失掩码 M，仅在有效数据处进行误差计算，从而避免缺失值对训练目标造成干扰。

2.4.1 多任务数据损失

为统一描述不同任务的误差计算方式，本文首先定义掩码感知均方误差，如公式（10）所示：

$$L_{\text{mse}}^{\text{mask}}(\hat{Z}, Z, M) = \frac{\sum_{t,d}(\hat{Z}_{t,d} - Z_{t,d})^2 \cdot (1 - M_{t,d})}{\sum_{t,d}(1 - M_{t,d}) + \varepsilon} \tag{10}$$

其中：$\hat{Z}$ 为模型输出，Z 为真实值，ε 为数值稳定项。

本文采用多任务解码器同时输出重构与单步预测的结果，分别为 L_{recon}，L_{next}。重构损失 $L_{\text{recon}} = L_{\text{mse}}^{\text{mask}}(\hat{X}_{\text{recon}}, X_{\text{recon}}, M)$，单步预测误差同理 $L_{\text{next}} = L_{\text{mse}}^{\text{mask}}(\hat{X}_{\text{next}}, X_{\text{next}}, M)$。

2.4.2 物理一致性约束损失

除了数据驱动的误差外，一些遥测变量之间往往满足一定的物理一致性关系，但是由于实际在轨工况复杂、调制方式与载荷状态可能变化。因此，在本文中不采用严格的数值物理建模，而是引入弱物理趋势

一致性约束，仅要求关键物理量的变化趋势满足一致性关系。

1）链路一致性：在通信链路理论中，载噪比 C/N、比特能量噪声比 E_b/N_0 与载噪密度比 C/N_0 之间关系可以通过物理公式计算，如所示，B 表示信号带宽，R_b 表示比特率：

$$\begin{cases}\dfrac{C}{N_0}=\dfrac{C}{N}+10\cdot 1g(B)\\ \dfrac{E_b}{N_0}=\dfrac{C}{N_0}+10\cdot 1g(R_b)\end{cases}\tag{11}$$

以卫星中常用的调制方式为 QPSK 为例，误码率 BER 可由 E_b/N_0 近似表示为可微函数，该调制方式的误码率计算公式如式（12）所示：

$$BER\approx\frac{1}{2}erfc\left(\sqrt{\frac{E_b}{N_0}}\right)\tag{12}$$

由于实际通信过程中，卫星的调制方式多样，受到多种因素的影响。本文使用一种近似方案，即 C/N_0 与 C/N，C/N_0 与 E_b/N_0 同向变化，E_b/N_0 和 BER 反向变化。为避免噪声导致的微小波动产生不必要的惩罚，当 $|\Delta x(t)|<\varepsilon$ 时不计算该时刻的约束。由上述式子可以得到链路趋势的残差损失，如式（14）所示。φ 和 ψ 分别为同向和反向变化约束项：

$$\begin{cases}a(t)=C/N(t),b(t)=C/N_0(t)\\ c(t)=E_b/N_0(t),d(t)=BER(t)\\ \Delta x(t)=x(t)-x(t-1),|\Delta x(t)|<\varepsilon\end{cases}\tag{13}$$

$$\begin{cases}L_{\text{link}}=\dfrac{1}{3}[\varphi(\Delta a(t),\Delta b(t))+\varphi(\Delta b(t),\Delta c(t))+\\ \qquad\psi(\Delta c(t),\Delta d(t))]\\ \varphi(a,b)=max(0,-ab)\\ \psi(a,b)=\max(ab,0)\end{cases}\tag{14}$$

2）电流约束：系统总电流与各支路电流之和满足守恒关系。考虑温度、工作模式切换等因素影响，该关系实际情况中往往并非严格等式，本文构造带有比例项、偏置项和容忍区间的一致性损失。设第 t 时刻的总电流预测值为 $\hat{I}_{\text{sys}}(t)$，各支路电流预测之和为 $\hat{I}_{\text{sum}}(t)$，则定义电流一致性残差为式（15）：

$$r_I(t)=\hat{I}_{\text{sys}}(t)-\alpha\hat{I}_{\text{sum}}(t)-b\tag{15}$$

α 和 b 为可学习参数，分别表示支路和总电流之间的比例映射与偏置修正。为避免对小幅度偏差进行过度惩罚，引入容忍区间 tol，仅对超出容忍范围的残差部分进行约束，如公式（16）所示：

$$\tilde{r}_I(t)=\text{ReLU}(|\tilde{r}_I(t)|-tol)\tag{16}$$

物理一致性损失可写为式（17）：

$$L_{\text{cur}}=\frac{1}{T}\sum_t SmoothL1(\tilde{r}_I(t),0)\tag{17}$$

联合链路一致性和电流约束，可得到物理约束一致性残差（18），β_1 和 β_2 为常数：

$$L_{\text{pc}}=\beta_1 L_{\text{link}}+\beta_2 L_{\text{cur}}\tag{18}$$

2.4.3　联合损失函数

综合重构误差、单步预测误差与物理一致性损失，本文训练阶段的总目标函数由公式（19）所示：

$$L_{\text{multi}}=\alpha_1 L_{\text{recon}}+\alpha_2 L_{\text{next}}+\lambda(e)L_{\text{pc}}\tag{19}$$

α_1，α_2 为各任务权重。$\lambda(e)$ 代表训练中对物理约束采用线性预热机制，如公式（20）所示，早期权重较小，随着训练轮次增大后逐渐增大权重，以避免早期梯度主导导致训练不稳定。E 为总训练轮次，e 是训练轮次，e_w 为预热轮次：

$$\lambda(e)=\lambda_{\max}\min(1,\frac{e}{e_w})\tag{20}$$

在该联合损失的引导下，模型能够学习到对异常高度敏感、且满足物理一致性的表示，为后续异常评分与报警决策提供可靠基础。

3　实验设计

3.1　实验设置

实验在 Python 3.11.5 环境下进行，主要依赖 Numpy 2.3.4、Pandas 2.3.3 及 PyTorch 2.9.1 框架实现，所有实验均在相同的软件环境与随机种子设置下完成。

实验数据来自某卫星平台 50 000 余条多维遥测数据。本文使用无监督的训练方式划分 60％用于模型训练，用于学习遥测序列的正常演化模式。再划分后续 20％作为校准集，用于统计正常工况下异常的分布特征，并确定检测阈值，其中高分位数阈值 τ_{tau} 在 98.5％～99.9％分位区间内搜索，平滑阈值 τ_{ewma} 在 95％～99.9％分位区间内搜索，并以点级误报率不超过 0.3％作为约束条件进行选取。最后使用含有多种异常类型的 20％测试集进行检测性能评估。本文构建的 PC-MR-TCN 的主要参数如表 1 所示。

表 1　PC-MR-TCN 主要参数设置

类别	名称	参数
输入设置	输入时间窗	$L=180$
TCN 结构	Temporal Block 层数	4
TCN 结构	TCN 卷积核大小	$K=3$
TCN 结构	扩张率	1、2、4、8
关系建模	关系特征维度	$R=64$
关系建模	多头注意力头数	$H=4$
损失权重	重构误差权重	$\alpha_1=0.15$
损失权重	预测误差权重	$\alpha_2=0.70$
损失权重	物理一致性权重	$\lambda(e)=0.15$
训练策略	物理约束预热轮次	$e_w=5$
训练策略	训练轮次	120
评分策略	Top-K	6
阈值策略	目标点误报率	0.3％

卫星在轨资源受限，部署模型需要考虑模型的复杂度。在输入窗口大小 $L=180$，批大小为 1 的统计口径下，对模型的复杂度与推理效率进行测试，如表 2 所示。结果表明，PC-MR-TCN 的可训练参数量为 0.670 M，单窗口前向传播计算量为 27.10 MFLOPs，在 CUDA 环境下的单窗口平均推理延迟为 2.27 ms，P95 延迟为 2.81 ms。结果说明，该模型参数规模较小、推理速度较快，能够较好满足遥测检测任务的需求

表 2 PC-MR-TCN 模型复杂度与推理效率

模型	参数量/M	FLOPs	平均推理延迟/ms	P95 延迟/ms
PC-MR-TCN	0.670	27.10	2.27	2.81

3.2 评价方式

本文采用事件级聚合评价策略对异常检测结果进行评估。首先，根据由 $L_{\text{multi}}=\alpha_1 L_{\text{recon}}+\alpha_2 L_{\text{next}}+e_w L_{\text{pc}}$ 得到的综合异常分数与校准集得到的检测阈值进行比较得到点级告警序列，为保证实验设置的一致性，本文在训练阶段和测试阶段采用相同的损失权重；随后，对时间上连续的告警点进行聚合，并将长度少于 3 个采样点的短片段剔除，同时对间隔不超过 1 个采样点的相邻告警片段进行填补，以降低孤立噪声点带来的误报影响。之后，将得到的连续告警区间作为候选异常事件段，并对相邻间隔不超过 100 个采样点的预测事件进一步合并。最后，以异常事件为基本单位，将预测事件段与真实异常区间进行匹配。若异常事件段与真实异常区间存在交集，则记为一次正确检测；若真实异常区间未被任何异常事件段命中，则记为漏报；若预测事件段未与任何真实异常区间相交，则记为误报。

研究采用异常检测领域内广泛认可的评价指标[18]，包括精确率（Precision）、召回率（Recall）以及 F_1 分数，这些指标能从多个维度综合反映算法在异常检测任务中的综合表现。

3.3 对比实验结果

为验证 PC-MR-TCN 的检测性能，本文在某卫星平台遥测数据集上与 PCA、KNN、LSTM-AE 和深度支持向量数据描述（Deep-SVDD，deep support vector data description）[21] 作为对比方法进行实验。其中，PCA 和 KNN 代表传统统计与距离度量方法，LSTM-AE 代表深度重构型异常检测方法，Deep-SVDD 代表一类分类方法。各方法均采用相同的数据划分、相同的校准策略和相同的事件级评价准则，以保证实验结果的公平性，对比结果如表 3 所示。

由表 3 可以看出 PCA 的表现优于多数基线方法，Precision 和 Recall 分别达到 0.889 和 0.857，说明 PCA 对于当前数据中幅值偏离较明显、统计分布变化较突出

表 3 遥测数据检测结果对比

模型	PCA	KNN	LSTM-AE	Deep-SVDD	PC-MR-TCN
Precision	0.889	0.667	0.700	0.394	0.909
Recall	0.857	0.357	0.714	0.788	0.929
F_1	0.873	0.465	0.707	0.525	0.919

的异常较为敏感。KNN 基于邻域距离的判别方式在当前遥测场景下的稳定性较差，最终使 Precision 和 Recall 偏低。LSTM-AE 的 F_1 分数较好，说明该模型已经能够学习到遥测序列动态模式。Deep-SVDD 呈现出高 Recall 和低 Precision，是因为 Deep-SVDD 对边界条件较为敏感，容易出现误报，因此 F_1 分数仅为 0.525。相比之下 PC-MR-TCN 不仅用 TCN 建模遥测数据长时依赖，还刻画了变量间的关系特征，并进一步引入了物理一致性约束。因此，PC-MR-TCN 在 Precision、Recall 和 F_1 三项指标上均取得了最优的结果，其中 Precision 为 0.909，Recall 为 0.929，F_1 达到 0.919。这表明本文方法不仅能够较充分地检出真实异常，而且能够较好地抑制误报，整体检测性能最为均衡。

图 6 展示了 PC-MR-TCN 模型检测出对数据集上的整体异常检测结果。黑色实线代表异常分数，该异常分数经过校准集的中位数和尺度进行了居中归一化。灰色框图代表用模型检测到的异常段，深灰色代表实际异常区间。从图中结果分析可以得知，当前模型检测到的大部分异常区间与真实异常区间在时间位置上具有较好的一致性，说明所提出的方法能够较为有效地捕捉异常发生的真实时间段，对事件级异常整体的覆盖效果较好。

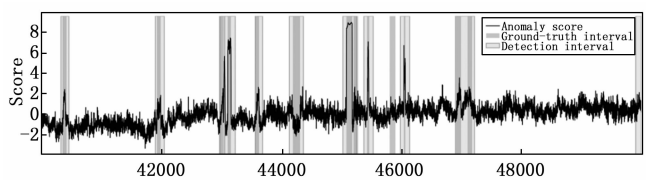

图 6 异常检测结果

3.4 消融实验

为了验证本方法变量关系建模和趋势一致性约束的有效性，设计了几种不同的实验，分别是时序模型 TCN、在 TCN 中加入关系编码器模块的 MR-TCN 以及 PC-MR-TCN，结果如表 4 所示。

表 4 消融实验对比结果

模型	TCN	MR-TCN	PC-MR-TCN
Precision	0.612	0.875	0.909
Recall	0.708	0.714	0.929
F_1	0.657	0.786	0.919

TCN 具备较强的时序建模能力，MR-TCN 引入关系编码器相对于 TCN 进行了变量关系建模并深化了时序依赖，并建模变量关系，F_1 提升至 0.786。实验结果证明对变量间关系进行建模的关系编码器可以有效提升异常检测效果。

3.5　泛化实验

由于 MSL 数据标签按照通道提供，常用于单通道验证，当前数据集下物理约束不可用，本小节采用不含物理约束分支的 MR-TCN 的方法在 MSL 数据集单通道上进行泛化性验证，实验结果如表 5 所示。为 MSL 其中 3 个通道的异常检测结果。

表 5　MSL 数据对比结果

模型	PCA	KNN	MR-TCN
Precision	0.540	0.655	0.612
Recall	0.630	0.667	0.824
F_1	0.582	0.661	0.702

从实验结果上来看，本方法在公开数据集上具有较好的泛化性。图 7 是 MSL 数据中的 3 个通道的检测结果，GT 代表 MSL 上由专家标注的异常区间，Pred 代表算法检测到的异常段。从检测结果可以看出，MR-TCN 检测方法成功在上述通道上命中了各个异常区间，

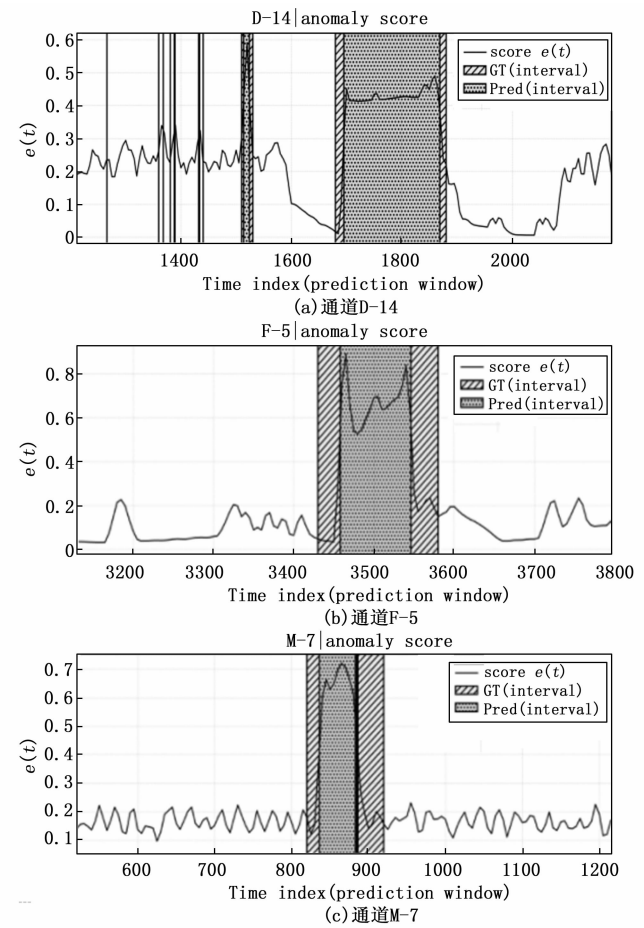

图 7　MSL 的通道异常检测结果

D-14 通道中有少许误报，在 F-5 中，尽管部分区间未表现为持续异常评分高峰，但是模型仍能成功捕捉异常模式，验证了本方法的泛化性。

3.6　实验结论分析

综合某卫星平台与公开数据集的对比实验、消融实验及其异常案例分析结果可以得出，PC-MR-TCN 相较于传统方法 PCA、KNN 与典型深度学习异常检测方法 LSTM-AE、Deep-SVDD 在当前场景下表现出更好的效果。PC-MR-TCN 在 TCN 时序幅值偏离建模的基础上，将异常判别扩展到变量关系偏离与物理逻辑偏离，因此可以对多种类型异常问题进行检测。本方法的 Recall 为 0.929，精确率为 0.909，在保证低误报的同时对异常事件有着良好的检出率。最后，使用了去除物理一致性约束的 MR-TCN 在 MSL 公开数据集进行泛化性验证，实验结果表明，对于变量关系进行建模的多关系编码模块在不同数据分布下仍具有有效性，从而侧面验证了本方法核心结构的工程上的可迁移性。

4　结束语

本文针对卫星遥测数据异常检测，提出了一种深度学习模型 PC-MR-TCN。该模型融合了 TCN，注意力机制和物理一致性约束等，实现了对遥测参数长时序依赖和变量依赖的联合表征，引导模型学习符合物理系统的正常运行模式，从而提高异常检测结果的稳定性与可靠性。在某卫星平台遥测数据集上有效解决了遥测数据耦合性，时序性以及异常模式复杂等问题，与 PCA 等传统统计方法以及 Deep-SVDD 等深度学习方法进行了对比取得了最高的 F_1 分数，为后续卫星在轨健康管理提供了技术支持。后续工作将进一步研究物理约束的自动化构建方法以及模型在在线检测与早期故障预测场景下的应用。

参考文献：

[1] 刘大禹，徐二宝. 数据驱动的卫星关键部件剩余寿命预测模型 [J]. 航天器环境工程，2022，39 (2)：148－152.

[2] YAIRI T，KAWAHARA Y，FUJIMAKI R，et al. Telemetry-mining：a machine learning approach to anomaly detection and fault diagnosis for space systems [C] //Proceedings of the 2nd IEEE International Conference on Space Mission Challenges for Information Technology (SMC-IT 2006)，IEEE，2006：466－476.

[3] IVERSON D L. Inductive system health monitoring [C] //International Conference on Artificial Intelligence，2004：605－611.

[4] IVERSON D L，MARTIN R，SCHWABACHER M，et al. General purpose data-driven monitoring for space operations [J]. Journal of Aerospace Computing，Informa-

tion, and Communication, 2012, 9 (2): 26 - 44.
[5] 钱 威, 周 军, 张国勇, 等. 基于主成分分析的卫星遥测回归方法 [P]. 中国: 发明专利, CN105590026A, 2016 - 05 - 18.
[6] 孙宇豪, 李国通, 张 鸽. 一种基于相关概率模型的卫星异常检测方法 [J]. 中国科学院大学学报, 2021, 38 (3): 409 - 416.
[7] 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.
[8] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313 (5786): 504 - 507.
[9] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9 (8): 1735 - 1780.
[10] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30.
[11] XU Z, CHENG Z, GUO B. A multivariate anomaly detector for satellite telemetry data using temporal attention-based LSTM autoencoder [J]. IEEE Transactions on Instrumentation and Measurement, 2023 (72): 1 - 13.
[12] 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.
[13] GENG Z, CHEN Z, MENG Q, et al. Novel transformer based on gated convolutional neural network for dynamic soft sensor modeling of industrial processes [J]. IEEE Transactions on Industrial Informatics, 2021, 18 (3): 1521 - 1529.
[14] 闵祥渊, 王 辉, 胡晨烨, 等. 基于双流异构图注意力网络的天基遥测数据异常检测方法 [J]. 上海航天 (中英文), 2025, 42 (5): 158 - 166.
[15] 朱 野, 赖 毅, 李 立, 等. 基于图学习的卫星遥测数据异常检测方法及系统 [P]. 中国: 发明专利, CN120337068A, 2025 - 07 - 18.
[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] ZAMANZADEH DARBAN Z, WEBB G I, PAN S, et al. Deep learning for time series anomaly detection: a survey [J]. ACM Computing Surveys, 2024, 57 (1): 1 - 42.
[18] 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.
[19] 吕 武, 耿建宁. 基于 53H 滤波的船舶综导信息在线平滑方法 [J]. 舰船科学技术, 2019, 41 (1): 121 - 124.
[20] AREVALO J, SOLORIO T, MONTES-Y-GÓMEZ M, et al. Gated multimodal units for information fusion [J]. ArXiv Preprint ArXiv: 1702.01992, 2017.
[21] RUFF L, VANDERMEULEN R, GÖRNITZ N, et al. Deep one-class classification [C] //International Conference on Machine Learning, PMLR, 2018: 4393 - 4402.

(上接第 62 页)

[9] 李依玲, 邓孺孺, 郭 昱, 等. 基于无人机多光谱数据的水体有机污染高分辨率反演——以珠江三角洲为例 [J]. 地理与地理信息科学, 2025, 41 (1): 33 - 39.
[10] 朱 凯, 李 鹏. 基于开源物联网技术的温室环境监测系统设计 [J]. 农机化研究, 2024, 46 (12): 204 - 207.
[11] 王琦华, 陈 城, 洪 岚, 等. 数字赋能大气环境智能化“监、采、控”一体化系统设计与实现 [J]. 电子器件, 2023, 46 (5): 1236 - 1241.
[12] 毛正君, 石硕杰, 王贵荣, 等. 基于无人机遥感的区域黄土滑坡识别及发育特征分析 [J]. 灾害学, 2023, 38 (1): 63 - 71.
[13] 姚文琳. 无人机遥感系统在环境保护中的应用 [J]. 工程抗震与加固改造, 2023, 45 (5): 204.
[14] 蒋 鹏. 基于 LoRa 无线通信的煤矿矿井环境智能监测系统设计 [J]. 煤炭技术, 2023, 42 (7): 206 - 208.
[15] 刘绍民, 徐自为, 黄晓东, 等. 极端生态环境水循环关键参量监测设备与物联网监测系统研制和示范 [J]. 生态学报, 2025, 45 (3): 1251 - 1260.
[16] 黄宜帆, 贺 岩, 朱小磊, 等. 一种适用于不同水质机载激光测深的深度学习方法 [J]. 中国激光, 2025, 52 (1): 222 - 228.
[17] 王嘉芃, 徐建国, 沈家晓, 等. 德兴铜矿矿山重金属污染修复效果高光谱遥感评价 [J]. 自然资源遥感, 2023, 35 (3): 284 - 291.
[18] 朱 丽, 刘冬皓, 谈嫣蓉, 等. 黄河源区 (玛曲) 近 20 年生态环境质量动态评价 [J]. 西北林学院学报, 2025, 40 (1): 209 - 217.
[19] 徐克立, 吕伟才, 汤连盟. 基于改进遥感生态指数 (MRSEI) 的淮河流域生态环境质量评价 [J]. 中国环境监测, 2025, 41 (1): 225 - 234.
[20] 郑彩之, 边 振, 桑国庆. 基于遥感生态指数的济南市生态环境质量动态监测 [J]. 生态科学, 2024, 43 (5): 175 - 182.
[21] 施蕾蕾, 吴 跃, 王 拓, 等. 基于 Geohash 与行政区划双层嵌套格网的生态环境监测数据组织管理与软件实现 [J]. 遥感技术与应用, 2024, 39 (5): 1095 - 1105.