

DOI: 10.13382/j.jemi.B2508136

多粒度时频域特征融合的温度遥测概率性预测*

曹杨锁¹ 卢晓伟² 庞景月¹

(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)

摘要: 卫星温度遥测数据预测对于地面运维系统监测卫星状态及故障预警具有重要的研究与应用价值。但传统预测方法存在精度低、鲁棒性不足且无法提供概率区间表达的局限性。为此,提出了一种针对卫星温度遥测序列的多元时序概率性预测模型 TFM-Diff。首先,构建了一种基于门控循环单元与离散余弦变换的混合架构,以更准确地识别遥测数据中的时频域动态模式。然后通过融合多粒度特征实现对温度遥测数据短期波动与长期趋势的复杂建模,以有效解析卫星温度数据的多尺度特性。最后,结合去噪扩散模型全面分析数据的潜在分布模式,实现预测结果的概率区间表达。基于 4 组真实卫星温度数据集的实验验证表明,针对概率性预测的连续排序概率评分总和指标,相对于其他主流方法,所提出模型的预测性能提升 6.26% ~ 27.77%,验证了其在空间应用场景下具有优越的预测性能、良好的适用性和通用性。

关键词: 卫星温度遥测序列; 概率性预测; 时频特征提取; 去噪扩散模型

中图分类号: V557+.3; TN06 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Probabilistic prediction of temperature telemetry based on multi-granularity time-frequency domain feature fusion

Cao Yangsuo¹ Lu Xiaowei² Pang Jingyue¹

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

Abstract: The prediction of satellite temperature telemetry data has important research and application value for monitoring satellite status and fault warning in ground operation and maintenance systems. However, traditional prediction methods have limitations such as low accuracy, insufficient robustness, and inability to provide probabilistic interval expressions. Therefore, this study proposes a multivariate temporal probabilistic prediction model TFM Diff for satellite temperature telemetry sequences. Firstly, a hybrid architecture based on gated recurrent units and discrete cosine transform was constructed to more accurately identify time-frequency domain dynamic patterns in telemetry data. Next, by integrating multi granularity features, complex modeling of short-term fluctuations and long-term trends in temperature telemetry data can be achieved, effectively analyzing the multi-scale characteristics of satellite temperature data. Finally, by combining the denoising diffusion model to comprehensively analyze the potential distribution patterns of the data, the probability interval expression of the prediction results can be achieved. Experimental verification based on four sets of real satellite temperature datasets shows that the continuous ranking probability score sum index for probabilistic prediction has improved the predictive performance of the proposed model by 6.26% to 27.77% compared to other mainstream methods, verifying its superior predictive performance, good applicability, and universality in space application scenarios.

Keywords: satellite temperature telemetry sequence; probabilistic prediction; time frequency feature extraction; denoising diffusion model

收稿日期: 2025-01-21 Received Date: 2025-01-21

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

0 引言

自 2016 年以来,我国航天事业的发展进入“快车道”。据 UCS 卫星数据库统计,目前我国在轨卫星数量已达 628 颗,约占全球总量的 $1/12$ ^[1-2]。随着我国航天事业的快速发展,卫星技术的研究与应用也日益深入。卫星在轨运行过程中长期受到外热流、光照、辐射等多种因素的影响,其在轨运行状态可能发生与预期不符的情况,引发异常和故障,直接影响关键部件甚至卫星整机的性能及寿命^[3-6]。卫星是一个复杂庞大的力、热、电综合系统。其中,温度是星上热学环境的重要衡量指标,它为众多需求各异的单机和器件提供适宜的工作条件和生存环境。其对应的温度遥测序列则是反映在轨卫星关键部件性能、单机状态、分系统乃至整星健康水平的重要指标。在此背景下,对卫星温度遥测序列进行准确的预测,不仅能够实现卫星异常检测与预警,还有助于工程师优化卫星热控系统的设计,提高卫星在轨运行的可靠性和稳定性^[7-9]。

实际工程应用中,传统的卫星温度预测方法通常基于有限元、有限差分等理论建立卫星热控数学模型,并根据卫星在轨的典型工况完成热控系统仿真^[8]。尽管传统热控系统仿真方法能够在一定程度上解决温度预测问题,但面向不同卫星型号、分系统和单机部件进行温度预测时通常需要根据相应机理构建不同的模型,模型的通用性和拓展性较差,难以满足全卫星平台乃至多卫星平台的温度监测需求。因此,在应对现代航天工程的复杂环境和快速响应需求时,传统方法具有较大的局限性^[9]。考虑到在轨卫星不同部件的温度变化受到多种因素的影响,包括外热流、热涂层材料、热敏安装位置、单机开关机状态以及控温策略等,这些因素使得不同数据变化表现形式中蕴含一定的共性规律。因此,从数据驱动的角度建模关系复杂、高维度的遥测数据,是目前国内外研究的主要方向^[9-11]。

目前基于数据驱动的预测包括点预测(预测某一时刻序列的具体数值)和概率性预测(某一时刻序列预测结果的波动范围)两个方面。遥测数据参数间关系复杂,数据波动性较大,外部环境变化频繁,单一点预测仅提供直观的预测结果,无法体现预测结果的不确定性。对比而言,概率性预测方法不仅能提供一个预测值,还可为每个预测值生成不确定性区间,即预测结果的可能波动范围^[12],更适宜于卫星温度遥测序列的预测场景。

概率性预测方法中高斯过程回归(Gaussian process regression, GPR)^[13]、隐马尔科夫模型(hidden Markov model, HMM)^[14]、贝叶斯回归(Bayesian regression)^[15]和稀疏回归模型(relevance vector machine, RVM)^[16]等基于

统计机器学习的模型在针对遥测参数的小样本概率性预测方面具有一定优势,但面对大规模复杂数据时所需计算代价昂贵,且非线性建模能力受限,预测效果不佳。

随着深度学习技术的发展与计算资源的突破,基于深度学习的概率性预测在近几年得到了持续关注。其中 DeepVar(deep variational model)^[17]基于传统的向量自回归模型(vector autoregressive model, VAR)与循环神经网络结合,可以有效捕捉复杂的非线性动态关系,但面对大规模数据时难以有效捕捉所有时间点的依赖性;LSTNet^[18]基于长短期记忆网络(long short-term memory, LSTM)能够有效提取时间序列中的局部特征,但参数较多,需要大量的训练数据来避免过拟合^[19-20];Transformer-MAF(Transformer-based masked autoregressive flow)^[21]能够在建模时充分考虑数据的长距离依赖关系,通过多头自注意力机制,可以同时关注多个时间点的信息,提高预测的准确性,但对于某些局部异常或突变点的预测能力尚有待提升;TACTIS-2 基于连接函数(Copula)以及注意力机制,能够有效地建模多变量时间序列的联合分布,但该模型计算复杂度较高且对于局部异常值的处理能力相对较弱,可能导致预测结果的不稳定^[22];TimeGrad^[23]、ScoreGrad^[24]和 MG-TSD^[25]基于扩散模型,能够通过生成式过程逐步学习数据的真实概率分布,可有效捕捉复杂时间序列的长期趋势与短期波动,保证预测的稳定性与准确性。

上述方法中,DeepVar、LSTNet 和 Transformer-MAF 虽然在特定场景下展现了其优势,但都存在一定局限性。相比之下基于扩散模型的方法不仅能够捕捉复杂的时间依赖性,还能够有效降噪,同时保持稳定性和灵活性,适应不同的预测任务和数据特征,这使得其能在时间序列预测中充分发挥优势。然而,与传统时间序列相比,卫星温度遥测序列具有更强的不确定性,其复杂性来源于外部空间环境扰动(如太阳辐射、地球阴影效应)以及内部系统噪声(如热力学波动、电池充放电等)。此外,尽管温度序列中可能存在一定的隐藏周期性(如轨道周期或运行模式),但受噪声影响周期性呈现波动性与多周期特性,传统的时序建模方法难以有效提取关键特征。而且在噪声水平较高或分布复杂的情况下,基础的扩散模型难以准确地将噪声从信号中分离,有时甚至会抑制一些有用的信号特征,导致重要的动态信息被忽视,从而影响预测精度。

因此,针对以上问题与挑战,本研究提出一种基于多粒度时频域特征融合的扩散概率模型(TFM-Diff)以降低噪声干扰,增强趋势建模,该模型通过离散余弦变换(discrete cosine transform, DCT)提高对遥测数据中频域变化的敏感度,补充时域特征的不足,并且融合多粒度模块从多尺度捕捉长期、局部动态变化模式,进而实现对

温度遥测序列的可靠预测,其预测性能通过实际航天器在轨温度数据进行了实验验证与分析。

1 TFM-Diff 原理与结构

1.1 TFM-Diff 模型的整体结构

本文提出的 TFM-Diff 模型整体结构如图 1 所示。图 1 中,遥测序列作为输入,首先通过多粒度分解以捕捉数据在不同时间尺度上的特征。多粒度分解将输入序列划分为短期、中期和长期等不同粒度的子序列,从而增强模型对多层次时间依赖关系的理解。其次,融合门控循环单元(gated recurrent unit, GRU)以及 DCT 的混合结构,

以更准确地识别遥测数据中的时频域动态模式。具体而言,每个粒度的子序列分别通过独立的 GRU 单元进行处理,模型能够同时捕捉短期波动和长期趋势。通过将提取到的特征输入 DCT 模块,提升模型对周期性变化的捕捉能力,以更准确地描述遥测数据的潜在模式。最终,利用扩散模型的生成式特性,模型逐步还原出原始数据的真实分布,生成最终的预测结果。本文模型的结构设计充分考虑了多维遥测参数的特性,并融合了多粒度分解、扩散模型、GRU 以及 DCT 的特征变换优势,实现了多尺度特征融合的时频域特征建模,以充分捕捉多维遥测参数的长时间依赖性、短期波动性以及复杂的潜在频域变化,为提升概率性预测的精度奠定优质的模型基础。

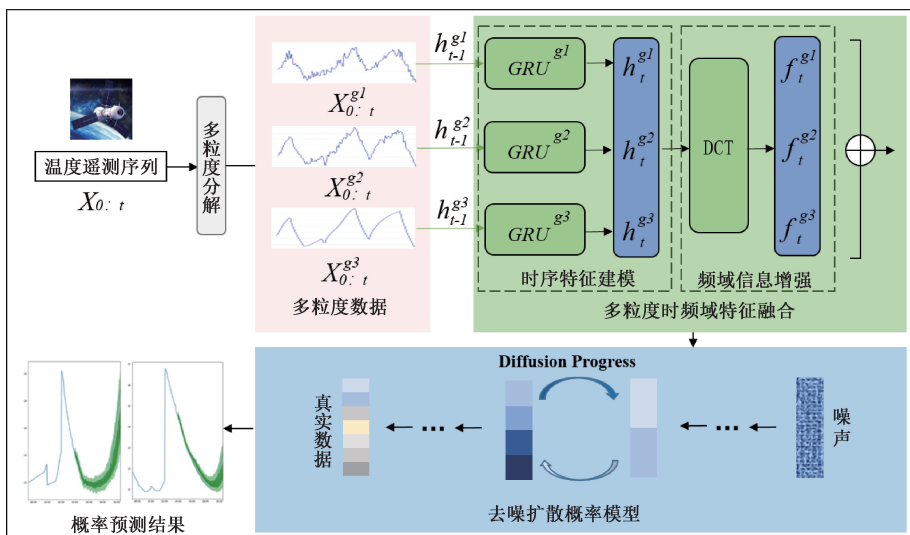


图 1 卫星温度遥测序列预测模型框架

Fig. 1 Framework of satellite temperature telemetry sequence prediction model

1.2 多粒度分解与时频域特征融合

1) 多粒度分解

不同时间粒度数据反映的信息变化趋势不同,细粒度的时间序列可以保留更详细的信息,而较大粒度的序列可以捕捉长期变化的趋势。因此本文从粒度计算的角度,引入下采样方法,使用不同尺寸的历史滑动窗口平滑细粒度数据,将原始遥测数据划分为多粒度数据,进而从不同粒度序列中获取多元复杂的动态关系。假设 f 是预定义的下采样平滑方法, s^g 是粒度级别,其中 g 为预定义滑动窗口大小, $X^{(1)}$ 为细粒度的原始序列,则 $X^{(g)} = f(X^{(1)}, s^g)$,其中 $X^{(g)}$ 表示经过下采样后粒度为 g 的序列。滑动窗口是非重叠的,并且所获得的粒度 g 的粗粒度数据被复制 s^g 次从而能够在时间线 $[1, T]$ 上对齐。

2) 时序特征提取

遥测数据 X_t 经多粒度分解后会获得不同粒度的数据,将其分别作为 GRU 的输入,实现多粒度时序特征提

取。GRU 的网络整体结构如图 2 所示。




图 2 GRU 网络结构

Fig. 2 GRU network architecture

(1) 重置门

由图 2 可知,各粒度的数据输入首先通过“重置门”控制遗忘或保留某些信息。具体来说,某一粒度的当前时间点输入会根据上一时间点的隐藏状态 h_{t-1} 以及重置门的权重 W_r 和 U_r ,通过 Sigmoid 激活函数的输出结果 r_t

来确定上一时间步的信息遗忘程度,当 r_t 结果接近 0 时,表示遗忘大部分历史信息;当 r_t 结果接近 1 时,表示几乎完全保留上一时间步的状态。计算公式如下:

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (1)$$

式中: W_r 表示当前输入对重置门的贡献的权重矩阵; U_r 表示上一时间步对重置门的贡献的权重矩阵; x_t 表示某单一粒度的遥测数据; h_{t-1} 表示上一个时间步的隐藏状态; b_r 表示重置门的偏置项。

(2) 候选隐藏状态

根据上一时间点的隐藏状态 h_{t-1} 、当前粒度的输入 x_t 和重置门 r_t ,通过 \tanh 生成候选隐藏状态 \tilde{h}_t ,作为当前时间步的潜在特征。计算公式如下:

$$\tilde{h}_t = \tanh(W x_t + r_t \odot (U h_{t-1}) + b) \quad (2)$$

式中: W 和 U 表示候选隐藏状态的权重矩阵; x_t 表示某单一粒度的遥测数据输入; b 表示候选隐藏状态的偏置项。

(3) 更新门及隐藏状态更新

根据上一时间点的隐藏状态 h_{t-1} 、当前粒度的输入 x_t 以及更新门的权重矩阵 W_z 和 U_z ,通过 Sigmoid 输出 z_t 来控制当前隐藏状态中新旧信息的融合比例,再根据 z_t 和候选隐藏状态 \tilde{h}_t 的点积结果获得当前时间步的隐藏状态 h_t ,其计算公式如下:

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (3)$$

$$h_t = (1 - z_t) \odot \tilde{h}_t + z_t \odot h_{t-1} \quad (4)$$

式中: W_z 、 U_z 和 b_z 表示更新门的权重矩阵及偏置项; z_t 表示更新门的输出; h_t 表示更新后的当前时间步隐藏状态。

通过 GRU 网络特殊的门控机制,可以实现对时间依赖关系的有效建模。

3) 频域信息增强

时间序列的频率信息揭示了隐藏在遥测数据中的重要模式和特征。与传统时域特征提取方法不同,频域增强方法通过扰动数据的频率分量来捕捉原始数据中未被稳定时域特征所揭示的动态信息。

遥测数据经过多粒度分解和 GRU 时序特征提取后会获得包含丰富时序特征的隐藏状态序列 $[h_1, h_2, \dots, h_L]$,将其作为 DCT 的输入,实现频域特征增强^[26]。该编码方法能够深入挖掘和分析遥测数据中的周期性变化特征,从而提高模型的预测性能和稳定性。

对于隐藏状态序列 X ,DCT 的基函数定义如下:

$$B_i(l) = \cos\left(\frac{\pi l}{L}\left(i + \frac{1}{2}\right)\right) \quad (5)$$

式中: $l \in \{0, 1, \dots, L-1\}$ 表示时间步; i 表示频率索引; L 表示隐藏状态序列的长度。

基于上述基函数,DCT 可以表示为:

$$f_i = \sum_{l=0}^{L-1} h_l \cdot B_i(l) \quad (6)$$

式中: f_i 是变换后的频域表示,包含了输入序列 x 中各频率分量的幅值信息。对应的逆 DCT 可以表示为:

$$h_l = \sum_{i=0}^{L-1} f_i \cdot B_i(l) \quad (7)$$

通过对频域特征的使用,DCT 能够自然地分离出信号的主要成分和低频噪声成分,以用于提升模型的整体性能。

4) 多粒度特征融合

遥测数据经过 TFM 时频域特征提取模块后会获得具有丰富时频域特征的隐藏状态 f_i ,将其作为 SENet(squeeze-and-excitation network)层的输入,以完成特征融合,主要步骤如下:

(1) 将 TFM 提取到的多粒度特征向量进行拼接操作,一个粒度作为一个特征通道,共 3 个特征通道。

$$T = F_{concat}(x_l, x_m, x_s) \quad (8)$$

式中: T 为 $H \times W \times C$ 的三维张量, C 设置为 3; x_l, x_m, x_s 分别表示长期、中期、短期粒度特征。

(2) 对 T 进行 Squeeze 操作,即对 T 中每个通道的粒度特征进行全局平均池化,在单粒度的空间维度 $H \times W$ 上进行压缩,获得每个粒度特征对应的全局信息。

$$z_c = F_{sq}(t_c) = \frac{1}{W \times H} \sum_{i=1}^W \sum_{j=1}^H t_c(i, j) \quad (9)$$

式中: t_c 为 T 中通道 C 上的特征值; z_c 表示得到的全局特征值。

(3) 进行 Excitation 操作,将上一步得到的 z 通过一个全连接层,再将得到结果输入到 ReLU 激活函数中,最后再通过一个全连接层,最后再通过 Sigmoid 激活函数生成的 s 即为多粒度特征的权重向量。

$$s = F_{ex}(z, W) = \sigma(W_2 \delta(W_1 z)) \quad (10)$$

式中: δ 表示 ReLU 激活函数; σ 表示 Sigmoid 激活函数; W_1 的维度为 $(C \times r) \times C$; W_2 的维度为 $C \times (C \times r)$; r 表示缩放参数,本文设置为 3。

(4) 将单粒度特征的权重和单粒度特征向量按通道逐元素相乘得到加权后的 \tilde{t}_c 。

$$\tilde{t}_c = F_{scale}(u_c, s_c) = s_c u_c \quad (11)$$

式中: s_c 为 c 粒度特征的权重向量; u_c 为 c 粒度的特征向量。

(5) 将分配权重后的多粒度特征进行拼接,最终得到按通道加权的输出 \tilde{T} 。

$$\tilde{T} = [\tilde{t}_1, \tilde{t}_2, \tilde{t}_3] \quad (12)$$

通过上述步骤,SENet 可较好地识别出 T 中需重点关注的粒度特征,并进行自适应加权融合,可实现短期波动与长期趋势的有效建模。

1.3 去噪扩散概率模型

多维序列经过多粒度特征融合后会获得具有丰富时频域特征的隐藏状态序列 f_i ,作为扩散模型的输入,利用

其反向过程生成未来时刻遥测温度的条件概率分布,如式(13)所示。

$$q_x(x_{t_0:T}^0 | x_{1:t_0-1}^0, c_{1:T}) = \prod_{t=t_0}^T q_x(x_t^0 | x_{1:t-1}^0, c_{1:T}) \quad (13)$$

式中: $x_{1:t_0-1}^0$ 为区间 $[1, t_0-1]$ 的原始温度遥测数据; $c_{1:T}$ 表示时间戳 $1:T$ 的协变量,其由时间依赖信息以及训练集时间频率的滞后特征组成,在整个编码过程中均是已知的。

作为新兴的生成模型,扩散模型包含前向扩散与反向扩散两个过程,如图3所示。

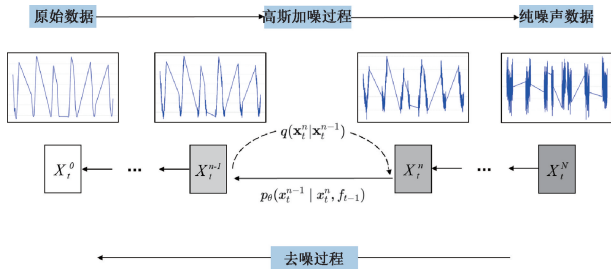


图3 前向扩散及反向扩散过程

Fig. 3 Forward and backward diffusion processes

图3中,在前向扩散过程中,模型逐步对输入数据添加高斯噪声,逐渐破坏原始数据;反向扩散过程中,隐藏状态 f_i 作为条件信息用来建模未来时刻每一步的条件概率分布 $p_\theta(x_{t_0:T}^{n-1} | x_{t_0:T}^n, f_{t-1})$,并通过反方向的不断迭代采样求得目标数据 $x_{t_0:T}^0$ 的概率分布 $p_\theta(x_{t_0:T}^0)$ 。因此经训练后的扩散模型在反向过程中能够指导性地从噪声中生成符合目标数据的概率分布。


网络训练完成后,结合采样噪声 $x_{T+1}^N \sim N(0,1)$ 和更新隐藏状态 f_i ,经逐步迭代后,最终可以得到下一时间戳的遥测温度 x_{T+1}^0 。此采样路径重复多次以考虑不同可能的未来场景从而估计不确定性,在每个路径结束时,获得相应的目标温度值。根据需要,可以选择不同分位数下的目标温度值作为经验分位数,以构建相应置信度下的预测区间。

2 基于 TFM-Diff 的温度遥测概率性预测

本文使用 E 来表示原始观测数据。遥测时序数据表示为 $E = [e_1^d, \dots, e_t^d, \dots, e_T^d]$, t 来表示时间戳 $t \in [1, T]$, 且 $e_t^d \in \mathbf{R}^D$, $d \in [1, D]$, D 表示 E 的维度。具体地说,研究任务是在给定历史上下文的固定窗口的情况下,对时间序列 $[e_1^d, \dots, e_T^d]$ 的未来时间步长的条件分布进行建模。从数学上,本文考虑的问题可以表述如下:

$$q_x(e_{t_0:T}^d | \{e_{1:t_0-1}^d\}) = \prod_{t=t_0}^T q_x(e_t^d | \{e_{1:t-1}^d\}) \quad (14)$$

预测过程以及滑动窗口机制操作如图4所示。



(a) 预测过程

(a) Prediction process

Time Series Data	1	2	3	4	5	6	...	T-1	T
Sample 1	1	2	3	...	d	d+1			
Sample 2	2	3	4	...	d+1	d+2			
Sample T-d	T-d	T-(d-1)	T-(d-2)	...	T-1	T			

(b) 滑动窗口机制

(b) Sliding window mechanism

图4 预测过程及滑动窗口机制

Fig. 4 Prediction process and sliding window mechanism

图4(a)中,遥测序列数据作为模型的输入数据,图4(b)中,序列的前 d 个点被视为输入,并且 $d+1$ 被标记为预测目标。预测值可以表示为:

$$\hat{Y}_{t+\tau} = k(e_t, e_{t-1}, \dots, e_{t-\tau}) \quad (15)$$

式中: $\hat{Y}_{t+\tau}$ 是接下来 τ 小时内的预测对象; k 表示在历史数据上训练的最终模型; e_t 表示被预测时刻的数据; $e_{t-\tau}$ 是被预测时刻之前 τ 小时内的数据。

概率性预测流程如图5所示。图5中,多维温度遥测序列首先经过多粒度分解来保留数据不同时间尺度上的特征。为了优化计算效率,长期、中期和短期粒度的分解和特征提取过程采用了并行计算策略。每个时间尺度的数据分别经过 GRU 单元以及 DCT 的混合结构,实现时频域动态模式建模,其次通过多粒度特征融合实现了对短期波动与长期趋势的有效建模,最终,模型经过多次采样路径构建预测分布,实现对预测区间的估计和不确定性的量化。

3 实验设置与结果

3.1 数据集描述

本文的实验验证数据集来源于国内实际航天器的温度遥测序列,其通过安装在卫星关键部件上的高精度温度传感器进行采集。传感器信号经星载测控单元进行数模转换,且采样周期严格遵循星上时序控制器的 16 s 基准时钟同步,并通过遥测信道下传至地面站。原始数据在地面站完成校验,并依据卫星分系统架构将 16 个温度参数划分为单/多维序列。原始数据集包含的 16 个温度遥测参数的每个维度对应一个独立的单机温度参数。由于不同设备单机属于不同的测控单元以及传感器集群,

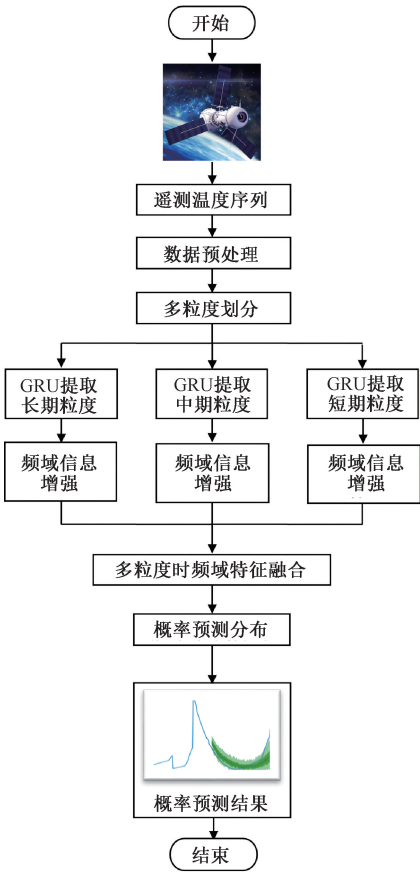


图 5 概率性预测流程
Fig. 5 Probabilistic forecasting process

时间戳并不完全同步,因此原始数据集在来源上已预先划分为单维、4 维以及 6 维,具有独立的采样逻辑。本文仅选取多维序列作为实验样本。


原始数据时间持续范围为 2.5 年,采样率为 16 s,而卫星温度遥测数据的变化较为缓慢,原始数据存在一定的数据冗余,会造成计算资源的浪费。从实际应用的角度来看,温度预测任务通常关注较长时间尺度的变化趋势而非秒级波动。加之对原始数据的分析,卫星实际的温度遥测数据的变化主要呈现分钟级别的趋势和伪周期特性。通过对比不同采样率(如 1、2、4、8 min 等)下的数据质量及可视化效果,4 min 的采样率能够在保留数据关键特征的同时,显著减少数据量并提高模型训练效率。因此,本文实验以 4 min 为单位整合建立了数据集 I、II、III、IV,详细信息如表 1 所示。各数据集内训练集和测试集均以 3 : 1 的比例进行划分。

表 1 中数据集 I、III 中数据维度为 6, II、IV 中数据维度为 4,每个数据集中样本量即包含精确时间戳的多维数据记录总数,数据间隔都是 4 分钟,数据类型统一为 float 类型。由于篇幅有限,本文仅给出卫星温度遥测数据集 I、II 的可视化图,如图 6 所示。

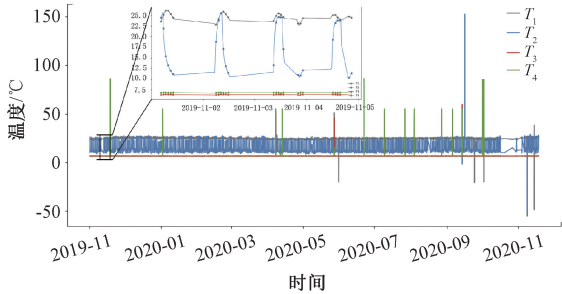
表 1 数据集统计

Table 1 Dataset statistics

数据集	维度	样本量	采样率/min	数据类型
I	6	44 360	4	float
II	4	44 352	4	float
III	6	58 132	4	float
IV	4	58 136	4	float



(a) 卫星温度遥测数据集 I
(a) Satellite temperature telemetry dataset I



(b) 卫星温度遥测数据集 II
(b) Satellite temperature telemetry dataset II

图 6 卫星温度遥测数据集可视化

Fig. 6 Satellite temperature telemetry dataset visualization

图 6 为整体的温度遥测曲线变化,为了更清晰的呈现局部特点,图 6 的两幅子图为温度遥测的细节图,并在细节图中用不同的点标记方式呈现不同的温度遥测曲线。从图 6 可以看出,该航天器的在轨温度遥测从长期趋势看,具有较为复杂的包络和趋势变化,且细节图表示温度遥测存在一定的波动性、短期数据变化连续且呈现出明显的伪周期变化。

3.2 实验环境及评估指标

(1) 实验设置,实验使用英特尔酷睿 i9 第 14 代 14900K CPU 和 NVIDIA GeForce RTX 4090 显卡进行深度学习计算和模拟训练。实验使用的软件配置环境为以“pytorch 1.11.3”、“glouns 0.9.6”为后端的“Python3.9.12”。

(2) 评估指标,为有效评估概率性预测算法的精度,本文使用的指标主要有连续排序概率评分总和(continuous ranked probability score sum, CRPS-sum)、归一化偏差总和(normalized deviation sum, ND-sum)、归

一化均方根误差总和 (normalized root mean square error sum, NRMSE-sum)。CRPS-sum 是将 CRPS 扩展到多变量时间序列,通过对各维度的样本求和并排序以获得分位数,上述指标的具体计算方式如式(16)~(19)所示。

$$CRPS(F,x)=\int_{\mathbf{R}}(F(z)-I\{x\leqslant z\})^2dz$$
 (16)

式中: $I\{x\leqslant z\}$ 为指示函数,当 $x\leqslant z$ 时值为 1,否则为 0。

$$CRPS_{-sum}=E_t[CRPS(F_{sum}^{-1},\sum_i x_i^t)]$$
 (17)

式中: F_{sum}^{-1} 是通过在各维度上求和并排序得到的分位数。

$$ND_{-sum}=\sum_{i=1}^D\frac{\sum_{t=1}^T|\hat{y}_t^i-y_t^i|}{\sum_{t=1}^T|y_t^i|}$$
 (18)

$$NRMSE_{-sum}=\frac{\sqrt{\frac{1}{T}\sum_{t=1}^T(\hat{y}_t-y_t)^2}}{\frac{1}{T}\sum_{t=1}^T|y_t|}$$
 (19)

式中: \hat{y}_t 表示第 t 个时间步的预测值; y_t 表示第 t 个时间步的实际值; T 是时间步的总数; D 表示时间序列的维度。

针对 CRPS-sum、ND-sum、NRMSE-sum 三个评价指标,其值越接近 0(但通常为非 0 正数),表明真实值与预测值之间的误差越小,模型的预测精度越高。3 个评估指标中 CRPS-sum 为评估概率性预测算法的核心指标,考核预测区间的有效性,也是目前研究领域内进行概率

性预测研究的首要指标。而 ND-sum、NRMSE-sum 则主要用于点预测算法性能的评估,仅评估预测均值与真实值的误差,本文在实验部分也同时对这两个指标进行了计算,以为研究学者提供更多的信息参考。

3.3 预测结果与分析

1) 基线实验

为验证本文提出模型的有效性,对其在 4 个卫星遥测数据集上均进行了训练和预测实验,并将预测结果与目前主流且具有优势的 DeepVAR、LSTNet、Transformer-MAF、TimeGrad 和 MG-TSD 五种深度学习时序预测方法进行对比。实验中本文提出模型所涉及的参数设置具体如表 2 所示。

表 2 模型训练超参数表

Table 2 Model training hyperparameter	
参数	数值
Epochs	30
Batch size	128
Diffusion Steps	100
Learning Rate	0.000 01
粗细粒度划分窗口大小	1 : 4
GRU-layers	4
GRU-cells	40
embedding_dimension	5

4 个数据集实验的定量结果如表 3 所示。

表 3 模型对比实验结果

Table 3 The experimental results of the model comparison

数据集	指标	本文	TACTIS-2	MG-TSD	ScoreGrad	TimeGrad	Transformer-MAF	LSTNet	DeepVAR
I	CRPS-sum	0.009 44	0.013 709	0.013 069	0.015 44	0.015 70	0.013 36	0.017 54	0.020 97
	ND-sum	0.013 17	0.014 037	0.016 705	0.018 37	0.019 42	0.018 46	0.017 87	0.027 09
	NRMSE-sum	0.017 36	0.017 583	0.017 74	0.021 72	0.023 39	0.021 16	0.019 18	0.033 90
II	CRPS-sum	0.047 07	0.067 31	0.063 043	0.055 39	0.057 51	0.083 92	0.079 25	0.069 61
	ND-sum	0.061 69	0.069 77	0.081 136	0.086 02	0.092 13	0.098 67	0.079 25	0.086 69
	NRMSE-sum	0.075 96	0.099 35	0.100 78	0.109 51	0.103 28	0.125 18	0.089 26	0.109 52
III	CRPS-sum	0.009 25	0.010 82	0.011 00	0.013 75	0.019 00	0.016 41	0.032 52	0.020 42
	ND-sum	0.008 26	0.014 02	0.015 55	0.014 93	0.023 57	0.019 99	0.032 52	0.032 26
	NRMSE-sum	0.010 99	0.015 58	0.017 98	0.025 80	0.028 37	0.026 34	0.039 38	0.039 36
IV	CRPS-sum	0.015 41	0.016 93	0.016 87	0.017 33	0.016 38	0.018 79	0.016 44	0.028 12
	ND-sum	0.018 82	0.025 39	0.024 49	0.024 97	0.023 79	0.021 74	0.024 17	0.028 12
	NRMSE-sum	0.025 33	0.026 56	0.027 09	0.026 35	0.026 91	0.029 47	0.025 95	0.030 93

由表 3 的实验结果可知,针对本文验证的主要指标 CRPS-sum,其综合反映预测均值与预测区间的性能,本文提出的模型性能均为最优。针对数据集 I、II、III、IV,相对于对比模型中的最优方法,本文提出的模型,其 CRPS-sum 指标提升分别为 27.77%、18.15%、14.51%、6.26%。

指标 ND-sum 和 NRMSE-sum 主要用于衡量预测均值的误差,其可用于评估点预测算法的性能。针对数据

集 I、II、III、IV,相对于对比模型中的最优方法,本文提出的模型 ND-sum 指标分别提升了 6.17%、11.58%、41.08%、13.43%,NRMSE-sum 指标分别提升了 2.14%、14.90%、29.46%、2.39%。

DeepVar 和 LSTNet 在 4 个数据集上的表现较为不错,DeepVar 在传统的 VAR 模型基础上进行了优化,结合循环神经网络(recurrent neural network,RNN)提升了捕捉时序数据非线性动态关系的能力;LSTNet 结合 CNN 和

LSTM,能够有效提取时序特征和局部依赖;Transformer-MAF 通过多头注意力机制进一步提升了模型对长距离依赖的建模能力,预测性能也得到了提升。这 3 种方法都是基于深度学习模型实现对多维数据长期时序依赖关系的建模,提升非线性建模能力,以此生成与原始样本相似的样本。但它们缺乏针对短期波动的建模能力,因此存在一定缺陷。TACTiS-2 近年被逐渐应用并且取得了非常不错效果,它通过 Copula 理论和 Transformer 架构,简化了分布参数的计算复杂度,使其从阶乘级降低到线性级,显著提升了模型的训练效率和性能。但其对局部异常值的处理能力较弱,所以预测结果的稳定性得不到保障。TimeGrad、ScoreGrad 和 MG-TSD 均是基于扩散模型的概率性预测方法,它们通过生成式过程逐步学习数据的真实概率分布,有效地捕捉时间序列的长期趋势与短期波动。然而在温度遥测数据集上,这两种方法的预测精度显著受限,主要原因在于遥测数据存在更强的不确定性,在噪声水平较高且分布复杂的情况下,仅考虑时域的扩散模型难以精准分离噪声与有效信号;此外,模型在去噪过程中可能会抑制有用的信号特征,导致关键动态信息丢失,从而影响预测精度。本文提出的 TFM-Diff 在这些方面要优于其他模型。其首先通过离散余弦变换提高对数据中频域变化的敏感度,补充时域特征的不足,并且融合多粒度模块从多尺度捕捉长期、局部动态变化模式,进而实现对卫星遥测数据的可靠预测。实验结果表明,本文提出的模型在预测均值与预测区间综合性能上表现更优。

本文模型对于数据集 I 的预测结果如图 7(a) 所示,考虑到结果对比的清晰性,将本文提出方法与最优对比方法进行对比,即 MG-TSD 方法,如图 7(b) 所示。

图 7 中,曲线表示预测中值,浅、深绿色部分分别表示 50% 和 90% 的预测值置信区间。其中 50% 置信区间的边界用虚线表示,90% 置信区间的边界用实线表示。图 7 中遥测参数序列不仅有长期的趋势变化,而且在局部也存在短期的不规则波动的情况。根据预测中值点所构成的曲线可知本文提出的模型对温度遥测数据的变化趋势拟合得很好,而且模型的预测区间更接近真实值,能够在覆盖宽度尽量小的情况下保证区间覆盖率。

而且根据《GJB 2703A-2006 卫星热控系统通用规范》等专业文件,卫星温度遥测序列预测的实际精度需求主要取决于以下两个方面。

(1) 卫星任务的安全性及可靠性要求

卫星在轨运行期间,温度是影响单机、分系统乃至整星性能的关键因素。预测精度直接关系到对异常情况的检测能力和故障预警的及时性。例如,某些关键部件(如蓄电池、推进器、有效载荷等)对温度的敏感度较高,预测误差过大可能导致误判或漏判,进而影响卫星任务的执

行。因此,在涉及卫星安全性和可靠性的场景中,预测精度通常要求较高,误差范围需控制在 2℃ 以内,以确保对潜在风险的精准识别。

(2) 热控系统优化设计的工程需求

在卫星热控系统的优化设计中,温度预测不仅用于异常检测,还需要为热控策略的调整提供数据支撑。预测误差过大会导致热控策略的设计过于保守,增加系统能耗;或过于激进,影响卫星在复杂环境下的稳定性。因此,在热控系统优化场景中,预测误差通常希望控制在 3℃ 以内,以在保证系统稳定性的同时实现能耗的优化。

综上所述,实际应用中对预测精度的要求:点预测误差控制在 3℃ 以内,具体需求根据部件敏感度和任务类型而定。本研究提出模型的预测精度不仅可满足工程领域的要求,且对于模型研究,其预测性能(连续排序概率评分总和指标提升 6.26%~27.77%)达到了更高的要求,95% 置信区间的概率性预测结果显示误差大概控制在 3℃ 以内(图 7(a)),为卫星温度遥测预测提供了更为精确和可靠的解决方案。

2) 消融实验

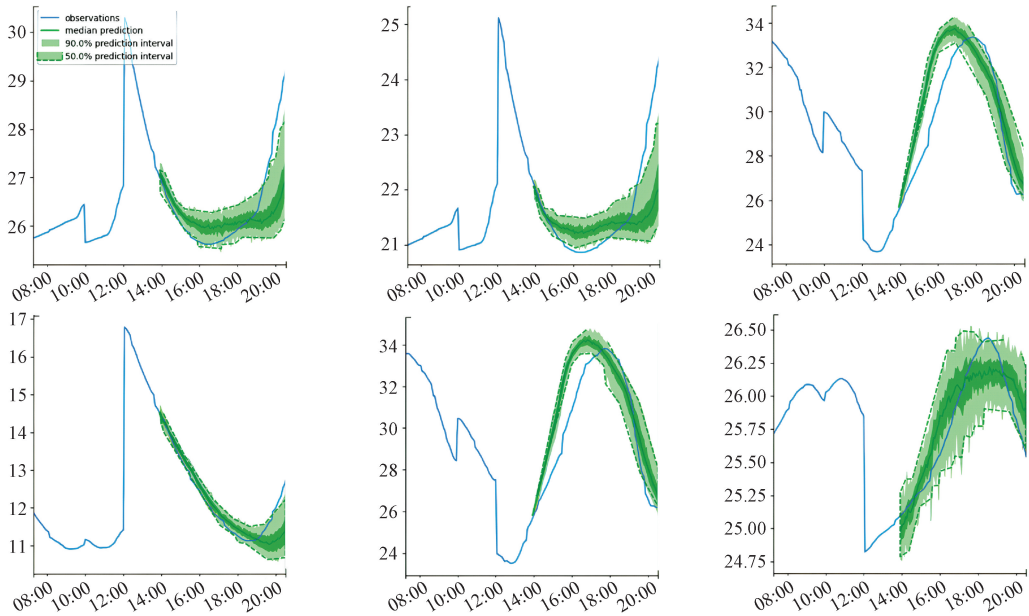
为了深入理解模型中各个组件对整体性能的贡献,进行了消融实验。限于篇幅,以数据集 I 为例对未来 90 个时刻的数据进行预测,其他数据集的实验结果类似,不再一一列举。数据集 I 具备典型的时序特征和噪声特性,能够有效验证模型在不同结构下的性能差异。通过不断移除模型中的不同部分以进行结果的计算,用于验证的模型分别为去掉多粒度结构、去掉时频域融合结构、GRU+Diffusion 以及本文模型。

表 4 为不同评价指标 CRPS-sum、ND-sum 和 NRMSE-sum 评估不同模型结构的预测性能。

表 4 消融实验结果
Table 4 Ablation test results

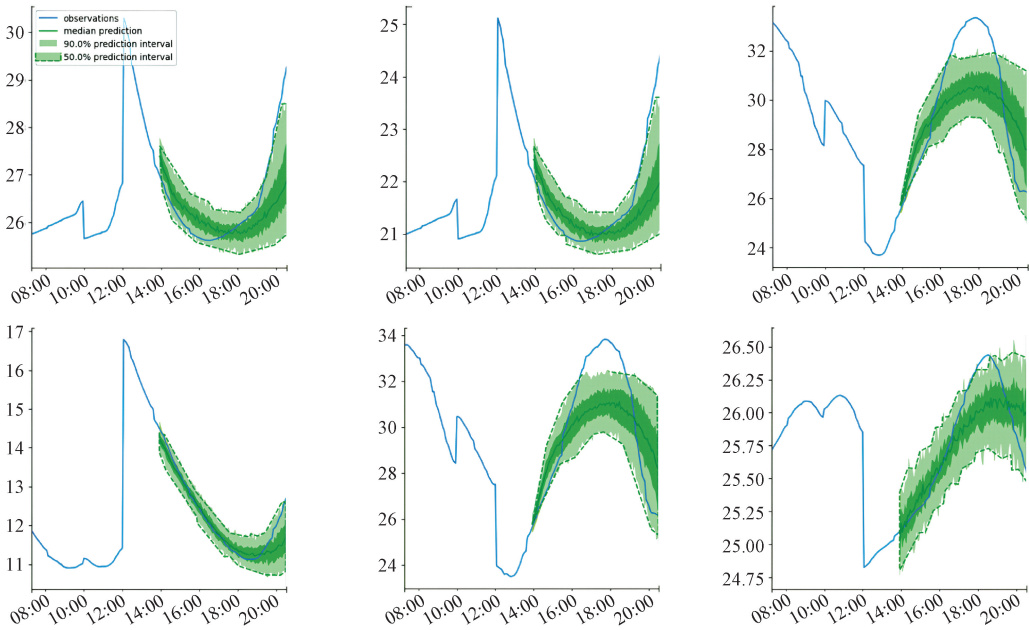
采样频率	CRPS-sum	ND-sum	NRMSE-sum
去掉多粒度结构	0.011 4	0.015 7	0.017 6
去掉时频域融合结构	0.012 8	0.016 1	0.019 8
GRU+Diffusion	0.018 2	0.024 7	0.029 9
本文模型	0.009 4	0.013 7	0.017 3

由表 4 可知,多粒度结构和时频域融合模块对算法带来的贡献程度不同,两者结合的时候预测效果最好。移除多粒度结构后,模型在所有指标上的性能都有所下降。多粒度结构的主要功能是使模型能够进行多尺度的特征提取,兼顾长期以及短期的动态时间依赖关系。移除该模块后,模型在对遥测数据进行预测时难以准确捕获短期波动的变化模式,导致其预测结果倾向于长期趋势,误差增大。引入时频域融合结构的目的是使模型能够同时捕捉数据的时域和频域特征,增强其对复杂数据模式的识别能力,改善其对噪声和异常的鲁棒性,同时提



(a) 本文模型预测结果

(a) Prediction result based on TFM-Diff



(b) MG-TSD预测结果

(b) Prediction result based on MG-TSD

图 7 数据集 I 预测结果

Fig. 7 Prediction result of dataset I

高预测准确性和模型的泛化能力。去除该模块后,可以看到模型整体性能相比移除多粒度结构有明显下降,说明时频域融合模块通过捕捉复杂的潜在频域变换,改进了时序分析的不足,对于温度遥测序列的预测效果更优。综合以上实验结果与分析,验证了对于温度遥测序列的概率性预测,本文设计的优化结构的有效性与优势。

4 结 论

针对卫星多维温度序列受复杂噪声干扰且呈现长短期趋势变化情况下的概率性预测的需求与挑战,本文提出了 TFM-Diff 模型,多维温度序列经过多粒度分解划分为子序列,再通过 GRU 单元和 DCT 的混合结构实现时

频域特征提取,并由多粒度融合模块进行特征融合,最终通过去噪扩散模型挖掘潜在分布模式,构建预测区间。本文提出的模型在卫星温度遥测数据的特征挖掘以及捕获复杂的潜在频域变化的能力上有明显提升。通过在国内航天器真实遥测数据集上的实验,验证了本文提出的模型在概率性预测任务上具有更优的表现,可为卫星故障预警、健康管理提供重要的信息支撑。

在后续研究工作中将考虑不确定区间的自适应调整策略以进一步提高不确定性建模能力,使其能够更好地满足概率性预测任务的需求,并结合更多的温度遥测序列验证方法的实际应用能力。

参考文献

- [1] 中国航天科技集团. 中国航天科技活动蓝皮书(2023年)[EB/OL]. 北京:中国航天科技集团,2023.
CHINA AEROSPACE SCIENCE AND TECHNOLOGY CORPORATION. China Aerospace Science and Technology Activities Blue Book (2023) [EB/OL]. Beijing: China Aerospace Science and Technology Corporation, 2023.
- [2] 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.
STATE COUNCIL INFORMATION OFFICE (SCIO). White Paper: China's Aerospace in 2021 [R/OL]. 2022-01-28.
- [3] 谭春林, 胡太彬, 王大鹏, 等. 国外航天器在轨故障统计与分析[J]. 航天器工程, 2011, 20(4): 130-136.
TAN CH L, HU T B, WANG D P, et al. Analysis on foreign spacecraft in-orbit failures [J]. Spacecraft Engineering, 2011, 20(4): 130-136.
- [4] KANG S, YANG L, SONG Y, et al. Satellite power system state prediction based on online learning with parameter association rules[J]. IEEE Transactions on Instrumentation and Measurement, 2023, DOI: 10.1109/TIM.2023.3291798.
- [5] PENG Y, JIA S, XIE L, et al. Accurate satellite operation predictions using attention-BiLSTM model with telemetry correlation[J]. Aerospace, 2024, 11(5): 398.
- [6] 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 ZH Y, SONG Y CH, 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.
- [7] 纪泽源, 许晓凡, 孙伟, 等. 融合多传感器的飞行器电缆网状态在线监测系统[J]. 电子测量与仪器学报, 2024, 38(3): 77-85.
- [8] 夏青, 邱实, 刘新颖, 等. 基于数据驱动方法的在轨卫星智能温度预测[J]. 系统工程与电子技术, 2024, 46(5): 1619-1627.
JI Z Y, XU X F, SUN W, et al. Multi-sensor monitoring system and health status classification for air-craft cable networks [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(3): 77-85.
- [9] 杨加春, 王彦明, 李庆军, 等. 探空温度传感器误差预测技术研究[J]. 电子测量与仪器学报, 2021, 35(12): 24-36.
YANG J CH, WANG Y M, LI Q J, et al. Research on error prediction technology of radiosonde temperature sensor [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(12): 24-36.
- [10] 陈义鹏, 徐志强, 钟杰, 等. 基于时空自注意力的航天器电源系统故障诊断[J]. 电子测量技术, 2024, 47(7): 184-191.
CHEN Y P, XU ZH Q, ZHONG J, et al. Spacecraft power system fault diagnosis based on spatio-temporal self-attention[J]. Electronic Measurement Technology, 2024, 47(7): 184-191.
- [11] 姜海旭. 基于数据驱动的在轨航天器状态预测与诊断关键技术研究[D]. 西安:西北工业大学, 2020.
JIANG H X. Research on key technologies of in-orbit spacecraft state prediction and diagnosis based on data driven method [D]. Xi'an: Northwestern Polytechnical University, 2020.
- [12] 姜改新, 刘玉荣. 基于改进组合机器学习的卫星遥测参数预测[J]. 空间科学学报, 2023, 43(4): 786-792.
JIANG G X, LIU Y R. Satellite telemetry parameter prediction based on improved combinatorial machine learning[J]. Chinese Journal of Space Science, 2023, 43(4): 786-792.
- [13] LIU L, LIU D, ZHANG Y, et al. Effective sensor selection and data anomaly detection for condition monitoring of aircraft engines[J]. Sensors, 2016, 16(5): 1-17.
- [14] MASTRANTONIO G. A Bayesian hidden Markov model for telemetry data [J]. ArXiv preprint arXiv: 1512.00487, 2015.
- [15] BAHOOTOROODY A, DE CARLO F, PALTRINIERI N, et al. Bayesian regression based condition monitoring approach for effective reliability prediction of random

- processes in autonomous energy supply operation [J]. Reliability Engineering & System Safety, 2020, 201: 106966.
- [16] YAIRI T, KAWAHARA Y, FUJIMAKI R, et al. Telemetry-mining: A machine learning approach to anomaly detection and fault diagnosis for space systems [C]. IEEE International Conference on Space Mission Challenges for Information Technology, 2006: 468-476.
- [17] SALINAS D, FLUNKERT V, GASTHAUS J, et al. DeepAR: Probabilistic forecasting with autoregressive recurrent networks [J]. International Journal of Forecasting, 2020, 36(3): 1181-1191.
- [18] LAI G, CHANG W C, YANG Y, et al. Modeling long-and short-term temporal patterns with deep neural networks [C]. The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval, 2018: 95-104.
- [19] 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. Anomaly detection method for spacecraft telemetry data with integrated LSTM [J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 22-29.
- [20] 张羽飞, 孟凡勇, 王永千, 等. 基于改进型 LSTM 的电力设备温度预测方法研究 [J]. 电子测量与仪器学报, 2021, 35(12): 167-173.
- ZHANG Y F, MENG F Y, WANG Y Q, et al. Research on temperature prediction method of power equipment based on improved LSTM [J]. Journal of Electronic Measurement and Instrumentation, 2023, 35(12): 167-173.
- [21] RASUL K, SHEIKH A S, SCHUSTER I, et al. Multivariate probabilistic time series forecasting via conditioned normalizing flows [C]. International Conference on Learning Representations, 2021.
- [22] YAN T, ZHANG H, ZHOU T, et al. Scoregrad: Multivariate probabilistic time series forecasting with continuous energy-based generative models [J]. ArXiv preprint arXiv:2106.10121, 2021.
- [23] RASUL K, SEWARD C, SCHUSTER I, et al. Autoregressive denoising diffusion models for multivariate probabilistic time series forecasting [C]. International Conference on Machine Learning. PMLR, 2021: 8857-8868.
- [24] ASHOK A, MARCOTTE É, ZANTEDESCHI V, et al. Tactis-2: Better, faster, simpler attentional copulas for multivariate time series [J]. ArXiv preprint arXiv:2310.

01327, 2023.

- [25] FAN X, WU Y, XU C, et al. MG-TSD: Multi-granularity time series diffusion models with guided learning process [J]. ArXiv preprint arXiv:2403.05751, 2024.
- [26] JIANG M, ZENG P, WANG K, et al. FECAM: Frequency enhanced channel attention mechanism for time series forecasting [J]. Advanced Engineering Informatics, 2023, 58: 102158.

作者简介



曹杨锁, 2023 年于徐州工程学院获得学士学位, 现为重庆工商大学硕士研究生, 主要研究方向为航天器遥测数据概率性预测。

E-mail: jscys6991@163.com

Cao Yangsuo received his B. Sc. degree from Xuzhou University of Technology in 2023. Now he is a M. Sc. candidate at Chongqing Technology and Business University. His main research interest includes Probabilistic prediction of spacecraft telemetry data.



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. Now he is a senior engineer at Shanghai Satellite Engineering Research Institute. His main research interests include satellite comprehensive testing and spacecraft telemetry data analysis.



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 at 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.