

基于线性-解码器组合的卫星遥测参数预测

姜辉^{1, 2}, 刘玉荣¹

1(中国科学院国家空间科学中心 北京 100190)

2(中国科学院大学 北京 100049)

摘要 在轨卫星状态监测、运行分析与异常检测是保障卫星安全可靠运行的重要环节。遥测参数能够反映卫星分系统和关键部件的工作状态，对其进行趋势预测有助于发现潜在异常并支持运行管理。随着卫星系统复杂度提高，遥测数据规模和维度不断增加，传统基于经验规则或简单统计模型的方法难以充分建模复杂时序变化。针对遥测参数周期性不显著、非平稳性较强等特点，本文提出一种基于线性-解码器组合的预测模型。该模型通过时间序列分解提取趋势项和季节项，并在解码器中引入不同粒度的嵌入策略，以捕捉局部与全局时序特征。实验结果表明，所提方法在实际卫星遥测数据和公开时序预测数据集上均取得了较好的预测效果，验证了其可行性与有效性。

关键词 时间序列分解，卫星遥测参数，数据预测，深度学习

Satellite Telemetry Parameter Prediction Based on a Linear-Decoder Combination

JIANG Hui^{1, 2}, LIU Yurong¹

1(*National Space Science Center, Chinese Academy of Sciences, Beijing 100190*)

2(*University of Chinese Academy of Sciences, Beijing 100049*)

Abstract The status monitoring, operational analysis, and anomaly detection of on-orbit satellites are important tasks for ensuring their safe and reliable operation. They also play an important role in improving the efficiency of satellite operation management. As telemetry parameters directly reflect the working states of satellite subsystems and key components, trend prediction of telemetry data is of great significance for identifying potential anomalies and supporting safe satellite operation. With the increasing complexity of satellite systems and the diversification of space missions, telemetry data have grown rapidly in both scale and dimensionality. Satellite telemetry time series usually contain multiple variables and complex coupling relationships, and often show non-stationary characteristics, long-term trends, and local fluctuations. Traditional prediction and detection methods based on empirical rules or simple statistical models are often unable to fully describe these complex temporal patterns. Therefore, they can hardly meet the current requirements for efficient data analysis and rapid operational response. In particular, telemetry parameters usually do not have obvious or stable periodic characteristics, which makes it difficult for conventional models to capture their dynamic changes effectively and leads to limited prediction accuracy. To address this problem, this paper proposes a prediction model based on a linear-decoder combination. The proposed model first uses time series decomposition to divide the original telemetry sequence into a trend component and a seasonal component. The trend component is modeled by a linear model to capture relatively stable long-term variations, while the seasonal component is modeled by a decoder-based structure to describe local fluctuations and nonlinear temporal dependencies. In addition, embedding strategies with different granularities are introduced into the decoder to capture local and global temporal features more effectively, thereby improving the model's ability to represent complex telemetry sequences. In the experimental part, the proposed deep learning-based method is applied to real telemetry data from an on-orbit satellite. Public time series forecasting datasets are also used for comparative experiments. The experimental results show that the proposed method achieves good prediction performance, which verifies its feasibility and effectiveness in satellite telemetry parameter prediction.

Key words Time series decomposition, Satellite telemetry parameters, Trend prediction, Deep learning

0. 引言

近年来，我国航天事业快速发展，卫星在轨运行的数量稳步增加[1]。与此同时，随着航天技术的快速进步，卫星系统的复杂性显著提升。卫星在轨运行过程中需长期应对极其复杂和恶劣的空间环境，这对其稳定运行提出了严峻挑战。由于元器件老化及环境因素影响，卫星在轨运行中易出现异常，进而影响其正常工作[2]。与此同时，卫星在轨运行过程中会产生遥测数据，这些数据能够客观反映各部件的工作状态，蕴含丰富的运行信息，是

评估卫星状态与性能的重要参考，也是地面测控中心进行运行监控与决策的重要依据[3]。为提高遥测参数预测精度，研究者提出了包括数据统计模型和机器学习等方法在内的多种遥测参数预测手段。通过对比预测值与真实观测值，运控人员能够提前识别潜在异常，从而实现了对卫星运行状态的预判与保障。

卫星遥测参数具有高维度、时序性、大规模数据量以及伪周期等特征[4]。卫星遥测参数受空间环境和载荷工作状态等多重因素影响，呈现出多种变化趋势。这些趋势通常由缓慢的长期变化与不规则的短期波动叠加而成。针对遥测数据的预测方法的发展大致与时间序列预测方法的发展相同，其主要分为基于随机过程的预测方法和基于数据驱动的预测方法。

基于随机过程的预测方法，如卡尔曼滤波和马尔科夫链等，在卫星状态预测领域具有重要应用。卡尔曼滤波通过构建状态空间模型，结合上一时刻的估计结果与当前观测数据，对状态变量进行更新和优化，适用于实时处理和计算机运算，但其假设系统模型和噪声统计特性已知且系统为线性或近似线性，对于非线性系统或模型参数未知的情况，预测精度受限[5]。马尔科夫链用以刻画系统状态之间的随机变化和转移过程，具有无记忆性，适用于状态转移具有无记忆性的系统[6]，如卫星故障预测，但对于具有趋势性和周期性的卫星遥测参数，其预测效果不佳。卫星遥测参数往往存在长期趋势变化和周期性波动[7]，如电池电压随时间逐渐下降，表面温度随轨道位置变化呈现周期性波动，这些特点使得基于随机过程的预测方法在卫星遥测参数预测中的应用受到一定限制，因为这些方法的前提是时间序列数据具备无后效性，也就是说，未来的状态只由当前状态决定，而不受更早历史信息的影响，而具有趋势性和周期性的遥测参数并不满足这一前提。

基于数据驱动的预测技术主要依赖于采集的历史数据，通过数据处理方法分析其中的隐含信息，并据此进行趋势预测[8]。尽管传统方法因可解释性和计算效率被广泛采用，但在处理非线性和复杂模式的数据时仍存在局限性，导致模型构建困难，泛化能力有限。近年来，深度学习技术的发展为数据预测提供了更高效、快速、准确的方法。基于改进的 LSTM 模型，山梦娜[9]在改进的 LSTM 模型中引入注意力机制，使模型在利用数据自身特征的同时，也能结合描述其变化规律的参数，从而提高了预测精度。然而，该方法虽然在温度类参数数据集上表现较好，但在电流、电压等其他类型的参数数据上检测效果相对不足。姜改新等人[10]提出了一种结合 LSTM 的改进预测模型，专门用于处理卫星遥测参数序列。该模型通过全局模块提取序列的趋势特征，同时利用局部模块捕捉短期波动特征，并通过改进的注意力机制增强对多维参数间相关性的建模能力；Xu 等人[11]采用 Transformer 模型预测未来交通流量，结果显示该模型在长时间预测任务中比传统方法（如 ARIMA 和 LSTM）更为准确，且能够处理复杂的时空依赖关系。深度学习模型通过端到端学习策略自动提取数据特征和模式，尤其适用于卫星这种大规模、复杂和多变量序列的预测。近些年，随着研究的深入，卫星遥测参数预测领域迅速发展，基于 LSTM、RNN 及注意力机制的多种创新方法相继出现，并取得了显著进展。同时，为增强模型在时间维度上的特征捕捉能力，许多研究开始引入注意力机制，但这一机制往往仅关注单个序列在不同时间步上的信息，缺乏对于特征之间关系的提取能力[10]。然而，对于卫星遥测参数而言，其周期性特征不明显且趋势变化频繁，传统单一的时序建模方法难以有效刻画其多尺度动态特征。

本文利用解码器结构开展卫星遥测数据的预测研究，针对在轨卫星遥测参数中趋势性与周期性特征随运行时间频繁变化的特点，引入分解模型对遥测数据进行特征分解，以更全面地提取多尺度特征；进一步地，采用线性-解码器组合预测模型，对分解后的不同成分分别建模与预测，从而提升整体预测的精度与稳定性，实现对在轨卫星遥测参数的高精度预测。

1. 定义

在时间序列预测任务中，明确时间序列、子序列以及预测窗口的定义具有重要意义。时间序列的定义奠定了研究对象的范围，是整个建模过程中的出发点；子序列的划分则将

冗长的序列分解为若干样本片段，既降低了模型训练的复杂度，又有助于模型捕捉局部时序规律；预测窗口的设定进一步明确了模型的预测时间跨度，为评估模型性能提供了明确依据。

1.1 时间序列

维度为 n 的时间序列数据集 X 可以表示为

$$X = (T_1, T_2, \dots, T_{n-1}, T_n) \quad (1)$$

其中， T_i 表示第 i 维时间序列数据。序列长度为 m 的时间序列数据可以表示为

$$T_i = (t_{i1}, t_{i2}, \dots, t_{i(m-1)}, t_{in}) \quad (2)$$

其中， t_{ij} 表示数据集中第 i 维参数在时刻 j 的参数值。时刻为 k 的多维参数向量表示为：

$$t_k = (t_{1k}, t_{2k}, \dots, t_{(n-1)k}, t_{nk}) \quad (3)$$

1.2 子序列

使用窗口大小为 l 的滑动窗口进行子序列获取，每次移动步长为 p 。可表示为

$$S_i(X, l, p) = \{S_1, S_2, \dots, S_N\} \quad (4)$$

其中， $N = \lfloor (m-l)/p \rfloor + 1$ 每个子序列可以表示为

$$S_i = \begin{cases} (t_{1+(i-1) \times p}, t_{2+(i-1) \times p}, \dots, t_{l+(i-1) \times p}), \wedge 1 \leq i \leq N \\ (t_{1+(i-1) \times p}, t_{2+(i-1) \times p}, \dots, t_m), \wedge i = N+1 \end{cases} \quad (5)$$

当窗口超过尾部时，最后的子序列包含至序列末尾的全部数据。

1.3 预测窗口

使用窗口大小为 $pred_len$ 的预测窗口，卫星遥测参数预测的函数可表述为

$$F: (S_i) \rightarrow \hat{Z}_{i:i+pred_len} \quad (6)$$

其中， S_i 表示范围 $[i-l, i]$ 时刻的历史数据， $\hat{Z}_i$ 代表在 i 时刻的点预测结果， $\hat{Z}_{i:i+pred_len}$ 表示未来时刻 i 到 $i+pred_len$ 的预测结果数据。

2. 预测框架与模型

预测框架是时间序列预测任务的整体设计思路与执行流程的抽象化描述，它涵盖了数据源、数据处理、模型构建以及训练与验证环节，构成了实现预测的逻辑框架。

2.1 预测框架




图 1 卫星遥测参数预测模型框架

Fig. 1 Framework of satellite telemetry parameter prediction model

本文中的预测模型框架如图 1 所示，其详细的步骤如下：

步骤 1：对原始的卫星遥测参数进行预处理，主要包括基于时间序列的线性插值方法填充缺失值、异常值以及归一化处理，得到模型输入数据。

步骤 2：模型采用时间序列分解方法提取输入数据的趋势项和季节项。

步骤 3：对于步骤 2 所得到的趋势项，使用线性模型进行预测。对于步骤 2 所得到的季节项，使用季节项预测模型进行预测，该模块基于 Transformer 的解码器结构，通过不同的嵌入方式提取局部与全局特征，并利用交叉注意力实现信息融合。

步骤 4：组合步骤 3 所得到的预测值，得到遥测参数最终的预测值。

在上述流程中，步骤 2 采用移动平均对序列进行分解。相比小波分解等复杂方法，该方法结构简单、计算开销低（复杂度为 $O(N)$ ），能够较为稳定地提取趋势成分，更适合遥测场景对实时性的要求。同时，本文也尝试了小波分解，但其预测效果不如移动平均，且计算复杂度更高，综合预测精度与计算成本，本文最终选择移动平均作为时序分解模块。分解后的趋势项通常较为平稳、呈单向变化特征，因此本文使用线性层对其建模，可直接由历史序列推断未来趋势。季节项则具有显著的周期波动特征，同时遥测参数之间存在变量依赖关系。针对季节项，本文采用 Transformer 解码器，通过不同嵌入策略获取局部特征与全局特征，并利用自注意力与交叉注意力分别建模时间依赖与变量依赖。

最终，框架对趋势项与季节项分别预测，并将两者结果叠加得到最终预测值。该方法基于“分治”思想，将复杂序列拆解为相对简单的成分分别学习，从而提升对卫星遥测参数等复杂序列的预测能力。

2.2 时间序列分解

时间序列分解是预测模型框架中重要的组成部分，其主要用于对原始时间序列进行分解。根据时间序列相关理论，时间序列数据可以分解为若干相互正交的成分[1]，即趋势项(X_t)、季节项(X_s)、随机噪声(X_i)和循环项(X_c)。其中，季节项表现出相对明确的周期性波动，而循环项的周期较长且规律性较弱，因此在大多数研究中将其合并到季节项中。常用的分解模型包括加法模型和乘法模型，本文选用加法模型进行趋势分解。由于随机噪声与趋势项对本研究结果的影响较小，本文将随机噪声和循环项合并到季节项，以简化分析过程。给定输入 X ，原始序列可表示为 $X = X_t + X_s$ ，分解过程如下：

$$X_t = \text{mean} \left(\sum_{i=1}^n \text{MovingAvg}(\text{Padding}(X))_i \right) \quad (7)$$

$$X_s = X - X_t \quad (8)$$

2.3 线性预测模型

线性预测模型是预测框架中用于预测趋势项的部分。在长期预测任务中，由于数据可能表现出明显的非线性特征，并可能在某些时刻出现突变，目前尚无可靠的长期预测方法可供广泛应用。相比之下，短期预测更接近于线性问题。趋势项反映了时间序列中的长期变化方向，通常表现为整体的上升、下降或平稳趋势[12]。它能够捕捉时间序列的全局规律，并保持平滑性，从而帮助模型理解数据的宏观变化。因此，趋势项可视为平滑且低频的序列，其预测可近似视为线性回归问题。线性问题可视为一种非参数拟合问题，线性预测模型能够减少异常点对预测结果的干扰，有助于提取有效的趋势特征。线性层被表达为：

$$Y = \text{Linear}(X) = WX + b \quad (9)$$

X 表示输入数据，通过线性层变换得到输出数据 Y 。

2.4 季节项预测模型

季节项预测模型是预测框架中用于预测季节项的部分，季节项描述了时间序列中周期性重复的波动模式，能够捕捉数据的短期规律，从而帮助模型更好地理解其周期性特征[13]。传统的季节性建模方法由于仅关注单一时间维度，且难以适应动态变化，因此在处理多变量协同效应时表现有限。为解决这一问题，本文采用基于Transformer的解码器结构，通过多种嵌入策略获取局部与全局特征，并利用自注意力机制和交叉注意力机制分别建模时间依赖和变量依赖。




图 2 季节项预测模型框架

Fig. 2 Framework of seasonal component forecast model

现有基于Transformer的预测模型通常将单个时间点或时间序列片段作为时间标记嵌入，通过自注意力机制学习时间依赖关系。为了精细捕捉变量内部的时间变化，将输入变量分割成不重叠的子块，并通过卷积层将每个子块卷积到一个时间标记上。鉴于局部特征与全局特征在预测中的作用不同，本文以多粒度方式对其进行嵌入。因此，若直接将局部特征和全局特征进行组合，容易导致信息错位。为此，本文为每个局部特征引入一个可学习的

token 字段，作为与全局特征交互的宏观表示。这种设计有助于进行局部特征和全局特征信息的融合。整体的局部特征被表达为：

$$\begin{aligned} \{y_1, y_2, \dots, y_N\} &= \text{Path}(x) \\ P_{de} &= \text{PatchEmbed}(s_1, s_2, \dots, s_N) \\ & \quad (10) \\ \text{Token} &= \text{Learnable}(x) \end{aligned}$$

P 表示数据块长度， T 表示数据长度， $N=\lfloor T/P \rfloor$ 表示从序列中分割出来的数据块数， s_i 表示第 i 个数据块。PatchEmbed 通过可训练的卷积层将每个长度为 P 的数据块通过位置嵌入映射到一个 D 维向量中。总的来说， N 个块级别的时间令牌嵌入 P_{de} 和一个序列级别的Token被输入到Transformer解码器中。

全局特征的引入主要是为了提升局部特征的预测精度。不同变量之间的交互关系能够通过变量级别的表示更自然地捕捉，并可适应多种不规则情况，如缺失值、不一致的时间戳、不同的采样频率或不一致的回溯长度[14]。相比之下，数据块级别的表示对全局特征而言过于细粒度，不仅会增加计算复杂度，还会引入了不必要的噪声信息。针对上述问题本文设计了一种方案，即每个全局序列被嵌入到一个序列变量中，该序列变量被形式化为：

$$z = \text{Learnable}(t) + \text{token} \quad (11)$$

为了实现准确的时间序列预测，识别局部特征内部的时间依赖关系以及其与全局特征的变量级表示之间的交互作用至关重要。除了对局部时间标记应用自注意力机制外，可学习的全局标记在局部特征与全局特征之间建立了桥梁。整个过程可以简化为局部自注意力的计算：

$$\widehat{P_{de}^l}, \widehat{\text{Token}_{de}^l} = \text{LayerNorm}\left(\left[P_{de}^l, \text{Token}_{de}^l\right] + \text{Self-Attention}\left(\left[P_{de}^l, \text{Token}_{de}^l\right]\right)\right) \quad (12)$$

其中 $l \in \{0, \dots, L-1\}$ 表示第 l 个块的输出， $P_{de}^0 = P_{de}$ ， $\text{Token}_{de}^0 = \text{Token}$ 。这里， $[\cdot, \cdot]$ 表示局部特征的分块符号和全局符号沿序列维度的串联。通过在序列的串联标记 $\left[P_{de}^l, \text{Token}_{de}^l\right]$ 上采用自注意力层，可以同时捕获补丁之间的时间依赖关系以及每个补丁到整个序列的关系。

交叉注意力在多模态学习中被广泛应用，用于捕捉不同模态之间的自适应词级依赖关系[15]。在交叉注意力层中，局部特征作为查询，全局特征作为键和值，从而建立两类变量之间的联系。上述过程可以形式化表示为：

$$\widehat{P_{de}^l} = \text{LayerNorm}\left(\left[P_{de}^l, \text{Token}_{de}^l\right] + \text{Cross-Attention}\left(\left[P_{de}^l, \text{Token}_{de}^l\right], Z\right)\right) \quad (13)$$

最后，通过前馈层进行转换，形式上表示为：

$$P_{de}^{l+1} = \text{Feed-Forward}\left(\widehat{P_{de}^l}\right) \quad (14)$$

多元预测可以看作是对多变量数据中的每个变量进行预测，而将其他变量视为上下文信息，通过捕捉变量间的相关性来提高整体预测精度。

3.实验验证

为了验证模型的有效性，本文在多元时间序列预测任务下设计了对比实验。实验选取

了多个真实的卫星遥测数据集作为研究对象，通过对比不同模型在相同数据集和参数设置下的预测表现，以评估模型的能力。对比模型包括：PatchTST、Dlinear、iTransformer 以及 FEDformer。通过与上述模型的性能对比，能够验证模型在卫星遥测数据多变量预测任务中的准确性。

3.1 实验数据集

鉴于电源系统与热控系统是卫星平台的关键组成部分，直接影响载荷的稳定运行，本文选取两者的遥测参数作为研究对象。实验数据来自我国两颗空间科学卫星的延时遥测数据，覆盖电源分系统（DY）与热控分系统（RK）的关键遥测数据。对原始数据进行整理后，形成四个卫星数据集：卫星 1 的 DY_1、RK_1，以及卫星 2 的 DY_2、RK_2。

其中，DY 系列数据(DY_1、DY_2)用于表征电源系统在 2024 年 11 月 1 日至 2024 年 11 月 30 日的电压、电流等变化，包含电池电压、电流、母线电压及充放电状态等关键参数，原始数据量均为 2,592,000 条，经 4 分钟间隔的平均池化下采样后得到 10,800 条样本，两者特征维度一致，均为 27。RK 系列数据(RK_1、RK_2)用于描述热控系统在 2024 年 11 月 1 日至 2024 年 11 月 30 日的温度变化特征，包含应答机温度、蓄电池温度等参数，其原始数据量同样为 2,592,000 条，采用相同下采样方式得到 10,800 条样本，其中 RK_1 含 24 个特征维度，RK_2 含 32 个特征维度。

此外，还选取了两个公开的数据集（ETTm2 及 ECL），ETTm2 数据集记录了 2016 年 7 月至 2018 年 7 月电力变压器在实际工业场景中运行状态的数据，包含高使用负载、中使用负载、油温等参数，共计 69680 条数据、7 个特征维度。ECL 数据集包含了 320 位用户在 2016 年 7 月至 2019 年 7 月的每小时用电数据，包含用电功率、电压等参数，共计 26304 条数据。各数据集详细信息如表 1 所示。

表 1 数据详情

Table 1 Dataset Details					
Dataset	Dimensions	Timesteps	Frequency	Information	Data class
DY_1	27	10800	4 min	Electricity	Satellite
RK_1	24	10800	4 min	Temperature	Satellite
DY_2	27	10800	4 min	Electricity	Satellite
RK_2	32	10800	4 min	Temperature	Satellite
ETTm2	7	69680	15 min	Electricity	Public
ECL	321	26304	Hourly	Electricity	Public

3.2 移动平均窗口尺度影响分析

在实验中，对趋势分解中的移动平均窗口长度进行了对比分析，分别将窗口尺度设置为 3、5、7、11、13、15、17、19。具体实验结果见表 2。

表 2 窗口尺度参数对比实验结果

Table 2 Comparative experimental results of window scale parameters								
窗口尺度	3	5	7	11	13	15	17	19
MSE	0.053	0.051	0.050	0.048	0.047	0.048	0.048	0.048
MAE	0.097	0.096	0.094	0.095	0.096	0.095	0.098	0.099

由表 2 可知，移动平均窗口尺度对模型预测性能具有一定的影响，但整体变化趋势较为平稳。当窗口尺度从 3 增大至 13 时，MSE、MAE 整体保持下降或小幅波动趋势，说明在一定范围内适当增大窗口尺度有助于提升预测精度。当窗口尺度过大时，MSE、MAE 出现轻微回升，表明过大的窗口会导致趋势项过度平滑，使部分有效的短期变化被错误地划

分至季节项，从而影响模型对数据变化的刻画能力。综合实验结果可知，窗口尺度为 13 时模型取得了较优的性能，因此在后续实验中选取窗口尺度 13 作为趋势分解的默认参数。需要说明的是，不同数据集的采样频率、变化周期和噪声水平不同，适合的移动平均窗口尺度可能存在差异，因此该取值仅作为本文数据实验中的参数选择。

3.3 时间序列分解

按照时间序列分解的流程，依次求取卫星遥测数据集以及公开数据集的趋势项和季节项，其结果如图 3 所示。




图 3 时序分解后的趋势项和季节项

Fig. 3 Trend component and seasonal component after time series decomposition

图 3 展示了六个数据集的某一维度在时序分解后的趋势项和季节项。可以看到，趋势项整体走势与原始数据基本一致，反映了数据的长期变化趋势，但其变化更加平滑，波动性较低；而季节项则表现出明显的周期性波动特征，能够揭示数据在短期内的重复模式。由于将随机噪声与循环项合并为季节成分，因此季节项中包含短期波动与噪声。通过对数据进行这样的分解，不仅能够在保留主要趋势信息的同时，有效分离出周期性变化特征，还可以降低原始序列的复杂度。

从图 3 中可以进一步观察到，趋势项的变化情况较为平稳，说明其规律性较强、随机扰动较少，因此可采用相对简单的线性模型进行趋势预测。而对于周期性更强、变化幅度较大的季节项部分，则可采用相对复杂的解码器结构进行建模，从而提升整体预测的准确性与稳定性。

3.4 参数预测

根据上述趋势项和季节项的特征，按照算法框架进行预测，最后叠加两者的结果。在实验中，我们在实验数据集上对模型进行训练与预测，设置解码器输入维度为 512，并将多层感知机 (MLP) 的隐藏层维度设置为 1024，以增强特征表示的非线性映射能力。训练过程中，各模型的输入步长设为 96，预测步长设为 [96, 192, 336, 720]，步长设置与 PatchTST 工作保持一致，便于对比；训练的批量大小 (batch_size) 设为 16，以兼顾计算效率与模型收敛速度。原始特征经线性投影映射到与解码器保持一致的特征空间。在训练过程中，采用早停策略，并在 20 个训练轮次后取验证集上的平均评价指标。

为定量评估所提算法的性能，本文选取多种方法 (PatchTST, iTransformer, DLinear, FEDformer) 进行对比实验。评价指标采用 PatchTST 工作中使用的均方误差 (MSE) 和平均绝对误差 (MAE) [16]。

表 3 各数据集对应算法实验结果

Table 3 Each dataset corresponds to the results of algorithms

模型		Our		PatchTST		iTransformer		DLinear		FEDformer	
指标		MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
DY_1	96	0.048	0.098	0.058	0.136	0.049	0.096	0.076	0.158	0.053	0.113
	192	0.052	0.102	0.062	0.14	0.058	0.113	0.081	0.164	0.056	0.111
	336	0.056	0.109	0.072	0.156	0.06	0.112	0.085	0.169	0.066	0.146
	720	0.061	0.12	0.082	0.167	0.07	0.126	0.094	0.18	0.067	0.125
	Avg	0.054	0.107	0.069	0.150	0.059	0.112	0.084	0.168	0.061	0.124
RK_1	96	0.344	0.406	0.359	0.427	0.448	0.438	0.368	0.432	0.43	0.455
	192	0.555	0.526	0.576	0.525	0.663	0.566	0.6	0.552	0.652	0.567
	336	0.728	0.598	0.739	0.608	0.768	0.612	0.783	0.635	0.803	0.64
	720	0.838	0.662	0.958	0.687	0.989	0.712	0.953	0.711	0.986	0.711
	Avg	0.616	0.548	0.658	0.562	0.717	0.582	0.676	0.583	0.718	0.593
DY_2	96	0.037	0.094	0.044	0.123	0.051	0.111	0.082	0.153	0.064	0.153
	192	0.048	0.109	0.055	0.138	0.071	0.141	0.092	0.165	0.074	0.171
	336	0.049	0.111	0.056	0.134	0.072	0.143	0.101	0.174	0.099	0.21
	720	0.054	0.121	0.063	0.141	0.077	0.149	0.104	0.18	0.117	0.238
	Avg	0.047	0.109	0.055	0.134	0.068	0.136	0.095	0.168	0.089	0.193
RK_2	96	0.153	0.242	0.181	0.26	0.173	0.254	0.175	0.279	0.213	0.311
	192	0.213	0.306	0.249	0.33	0.238	0.318	0.227	0.338	0.304	0.39
	336	0.271	0.354	0.325	0.387	0.323	0.384	0.278	0.387	0.347	0.424
	720	0.429	0.479	0.485	0.492	0.478	0.494	0.373	0.468	0.455	0.503
	Avg	0.267	0.345	0.310	0.367	0.303	0.363	0.263	0.368	0.330	0.407
ETM2	96	0.175	0.257	0.176	0.260	0.186	0.266	0.193	0.292	0.193	0.282
	192	0.239	0.301	0.253	0.313	0.248	0.307	0.284	0.362	0.264	0.324
	336	0.298	0.340	0.318	0.354	0.310	0.348	0.385	0.428	0.330	0.368
	720	0.393	0.398	0.414	0.410	0.412	0.407	0.556	0.523	0.425	0.421
	Avg	0.276	0.324	0.290	0.334	0.289	0.332	0.354	0.401	0.303	0.348
ECL	96	0.154	0.248	0.180	0.273	0.160	0.252	0.200	0.287	0.194	0.307
	192	0.167	0.259	0.187	0.279	0.172	0.262	0.200	0.291	0.208	0.323
	336	0.186	0.278	0.203	0.295	0.190	0.279	0.213	0.306	0.233	0.346
	720	0.228	0.312	0.245	0.327	0.229	0.313	0.248	0.338	0.265	0.369
	Avg	0.169	0.261	0.203	0.293	0.187	0.276	0.215	0.305	0.225	0.336

从表3的结果可以发现，本文所提出的模型在预测结果上优于其他对比算法。这表明，所采用的时序分解结构能够分别捕获序列的趋势项和季节项，并通过不同的预测模块提高了遥测数据的预测精度。在公开数据集上的实验结果显示，本模型在大多数情况下同样取得了较好表现，说明该方法在其他领域的预测任务中依然保持较高的准确度。进一步分析可以发现，随着预测步长增加，单一模型难以同时刻画趋势与周期变化，预测误差易在长时预测中累积放大。本文通过分解实现趋势与周期信息的解耦建模，有效抑制误差传播，因此在长预测区间下优势更加明显。

综上所述，本模型在点预测任务中相较于其他模型取得了更优的结果，主要原因在于，所提模型通过趋势—季节分解模块分离遥测序列中的长期趋势与短期波动，并分别采用线性结构和注意力机制进行建模，从而提升了对复杂时序变化的表达能力。同时，RK数据较DY数据更易受到姿态变化、日照条件及设备启停影响，非平稳性更强，虽提升幅度相对有限，但模型仍保持整体领先，体现了良好的鲁棒性。

3.5 消融实验

为评估时序分解模块及不同嵌入向量组合在模型中的作用，本文设计并实施了相应的消融实验。在DY_1、RK_1、DY_2、RK_2、ETM2、ECL数据集上进行预测未来[96,192,336,720]时刻数据的实验，表4展示了平均MSE以及平均MAE，其中

MSE*、MAE*表示去掉时序分解，MSE+、MAE+表示季节项预测结构为线性模型，MSE、MAE 表示本文完整模型。

表 4 消融实验结果

Table 4 Results of ablation experiment

Dataset	MSE*	MSE+	MSE	MAE*	MAE+	MAE
DY_1	0.062	0.065	0.054	0.116	0.126	0.107
RK_1	0.667	0.670	0.616	0.694	0.572	0.548
DY_2	0.053	0.069	0.047	0.132	0.127	0.109
RK_2	0.347	0.267	0.267	0.432	0.371	0.345
ETTm2	0.905	0.348	0.276	0.605	0.398	0.324
ECL	0.181	0.211	0.169	0.380	0.298	0.261

从表 4 中实验评价指标结果可以看出，时序分解结构与不同嵌入策略的组合对算法性能的贡献存在差异，当两者同时使用时预测效果最佳。引入解码器结构后，对预测性能的有所提升，说明该结构能够抓取参数之间的关联特征，并为预测过程提供额外的权重信息，从而有效提高模型的准确度。同时，时间序列分解模块也进一步增强了预测效果，说明对序列进行成分分离能够更好地提取不同特征模式，尤其在处理周期性不明显的遥测序列时表现尤为显著。

3.6 趋势项与季节项预测误差贡献分析

为进一步验证时序分解与建模策略的有效性，本文在 DY_1 数据集上分析了趋势项与季节项对最终预测误差的相对贡献，其中预测步长为 96。考虑到两者量纲和尺度不一样，为消除量纲差异的影响，采用基于方差归一化的方法计算贡献程度。具体步骤为：先对趋势项与季节项的预测误差计算标准化均方误差，再依据其相对于整体预测误差的比例，量化各分量对总误差的贡献。实验结果如表 5 所示。

表 5 误差贡献实验结果

Table 5 Error contribution experiment results

	MSE	Var	NMSE	Contribution
Trend	0.267	0.229	1.161	64.80%
Seasonal	0.271	0.429	0.631	35.20%

实验结果表明，趋势项对长预测步长误差的主导作用明显，而季节项在捕捉短期波动中贡献突出。该结果验证了本文采用趋势-季节分解建模的必要性，通过分别建模趋势与周期信息，模型能够在保证长期变化刻画能力的同时有效捕获短期波动，从而提升整体预测性能。

4 结论

对于周期特征不显著的遥测参数序列，本文构建了一种由线性模块与解码器组成的组合预测模型。该方法通过时序分解结构将原始数据序列分解成趋势项和季节项，以充分捕捉序列中长期变化趋势与潜在的周期性波动特征。随后，针对不同成分分别采用合适的预测策略：趋势项采用高效的线性预测模型进行建模，能够稳健地捕捉整体变化趋势；季节项则通过解码器结构进行预测，以挖掘局部非线性波动和潜在复杂模式。最终，将两个模型的预测结果进行叠加，得到完整的时间序列预测值，从而有效提升对周期性不明显序列的预测精度。

最终实验结果表明，该方法在遥测数据集及公开数据集上的点预测任务中表现出较好的精度。相比传统方法，线性-解码器组合模型能够更好地适应多变量遥测序列的复杂特征，实现趋势与季节性成分的协同预测。此外，该方法可集成到卫星地面系统中，为在轨卫星的参数监控提供参考信息。

最新录用

参考文献

- [1] ZHOU Feng, PI Dechang. Prediction algorithm for seasonal satellite parameters based on time series decomposition[J]. *Computer Science*, 2016, **43**(2): 9-12 (周枫, 皮德常. 一种时间序列分解的卫星周期性参数预测方法[J]. 计算机科学, 2016, **43**(2): 9-12)
- [2] LIU Enyu. Research on Fault Diagnosis Method and Health Management of Satellite Attitude Control System[D]. Shenyang: Shenyang Ligong University, 2023 (刘恩雨. 卫星姿态控制系统故障诊断及健康管理研究[D]. 沈阳: 沈阳理工大学, 2023)
- [3] DU Xiaolong, BAI Meng. Anomaly detection method for satellite telemetry parameters based on time-series imputation generative adversarial networks[J]. *Chinese Journal of Space Science*, 2025, **45**(4): 1087-1097 (杜晓龙, 白萌. 基于时序插补生成式对抗网络的卫星遥测参数异常检测方法[J]. 空间科学学报, 2025, **45**(4): 1087-1097)
- [4] ZHAO Yuwei, SU Ju. Satellite anomaly detection method based on parameter adaptive optimization clustering[J]. *Chinese Journal of Space Science*, 2023, **43**(5): 927-937 (赵玉炜, 苏举. 基于参数自适应优化聚类的卫星状态异常检测方法[J]. 空间科学学报, 2023, **43**(5): 927-937)
- [5] BAI Y T, YAN B, ZHOU C G, *et al.* State of art on state estimation: Kalman filter driven by machine learning[J]. *Annual Reviews in Control*, 2023, **56**: 100909
- [6] SHAO Chuanyong. Family Load Forecasting Method Based on Markov Chains[D]. Guangzhou: South China University of Technology, 2020 (邵传雍. 基于马尔科夫链的家庭负荷预测方法[D]. 广州: 华南理工大学, 2020)
- [7] FANG H Z, XING Y, LUO K, *et al.* Study of the long-term performance prediction methods using the spacecraft telemetry data[C]//Proceedings of the IEEE 2012 Prognostics and System Health Management. Beijing: IEEE, 2012
- [8] XU Zhaoping, GUO Bo. A research review on fault prognostic techniques for complex equipments[J]. *Journal of Changsha University of Science & Technology (Natural Science)*, 2023, **20**(2): 10-26 (徐兆平, 郭波. 复杂装备故障预测方法研究综述[J]. 长沙理工大学学报(自然科学版), 2023, **20**(2): 10-26)
- [9] SHAN Mengna. Anomaly Detection of Telemetry Data Based on Deep Learning[D]. Xi'an: Xi'an Technological University, 2020 (山梦娜. 基于深度学习的遥测数据异常检测[D]. 西安: 西安工业大学, 2020)
- [10] JIA Gaixin, LIU Yurong. Satellite telemetry parameter prediction based on improved combinatorial machine learning[J]. *Chinese Journal of Space Science*, 2023, **43**(4): 786-792 (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)
- [11] XU M X, DAI W R, LIU C M, *et al.* Spatial-temporal transformer networks for traffic flow forecasting[OL]. arXiv preprint arXiv: 2001.02908, 2021
- [12] SONG Ci, PEI Tao. Research progress in time series clustering methods based on characteristics[J]. *Progress in Geography*, 2012, **31**(10): 1307-1317 (宋辞, 裴韬. 基于特征的时间序列聚类方法研究进展[J]. 地理科学进展, 2012, **31**(10): 1307-1317)
- [13] ZHANG Y F, WU R, DASCALU S M, *et al.* Multi-scale transformer pyramid networks for multivariate time series forecasting[J]. *IEEE Access*, 2024, **12**: 14731-14741
- [14] DONG J X, LIU Y, LONG M S, *et al.* TimeXer: empowering transformers for time series forecasting with exogenous variables[C]//Proceedings of the 38th Annual Conference on Neural Information Processing Systems. Vancouver: Neural Information Processing Systems Foundation, Inc., 2024
- [15] LI J N, SELVARAJU R R, GOTMARE A D, *et al.* Align before fuse: vision and language representation learning with momentum distillation. *Advances in neural information processing systems*, 2021, **34**: 9694-9705.
- [16] NIE Y Q, NGUYEN N H, SINTHONG P, *et al.* A time series is worth 64 words: long-term forecasting with transformers[C]//Proceedings of the 11th International Conference on Learning Representations. Kigali, Rwanda: OpenReview.net, 2023

作者简介



姜辉 男, 2001 年 4 月出生于山东省菏泽市, 现为中国科学院国家空间科学中心在读硕士研究生, 主要研究方向为卫星智能运控技术等. E-mail: jianghui231@mailsucas.ac.cn



刘玉荣 女, 1971 年 2 月出生于北京市, 现为中国科学院国家空间科学中心正高级工程师, 主要研究方向为卫星运控技术和航天地面系统技术。

最新录用