

基于改进组合机器学习的卫星遥测参数预测*

姜改新^{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 对在轨卫星的运行状态进行监测、分析以及异常检测是卫星在轨运行管理的重要内容。预测卫星遥测参数序列的变化趋势,对卫星异常检测与处置、保障安全运行非常必要。针对目前对于周期性不明显且具有多种变化特征的遥测参数预测精确度不够的问题,本文引入对遥测参数的预测有辅助作用的因素作为协变量,提出了基于改进组合机器学习的预测模型。该模型使用全局模型和局部模型分别获取遥测参数序列的趋势特征和局部不规则波动特征,并采用改进的注意力机制捕获多维参数之间的关联关系,提高了预测精度。此模型可以提供点预测和区间预测的结果,为在轨卫星处置决策提供了更多输入。在科学卫星真实遥测数据集和时间序列公开数据集上验证了本文方法的有效性。

关键词 卫星遥测参数, 预测模型, 机器学习, 注意力机制

中图分类号 V557.3

Satellite Telemetry Parameter Prediction Based on Improved Combinatorial Machine Learning

JIANG Gaixin^{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 monitoring, analysis and anomaly detection of the operational status of satellites in orbit are important contents of satellite operational management. It is very necessary to predict the changing trend of satellite telemetry parameter data series for detecting, dealing with satellite anomalies and ensuring the safe operation of satellites. Aiming at the problem that the current prediction research is not accurate enough for telemetry parameters with insignificant periodicity and multiple changing characteristics, this paper introduces covariates that are helpful for telemetry parameter sequence prediction, and proposes a prediction model based on improved combined machine learning, using the global model

* 空间科学先导专项科学卫星任务运控技术(XDA15040100)和科学卫星在轨运行维护项目(E02215A01S)共同资助

2022-10-09 收到原稿, 2023-02-08 收到修定稿

E-mail: jianggaixin20@mailsucas.ac.cn

and the local model to obtain the trend characteristics and local irregular fluctuation characteristics of the telemetry parameter sequence respectively, and the improved Attention mechanism is used to capture the correlation between multi-dimensional parameters to improve the prediction accuracy. At the same time, this model can provide point prediction and interval prediction results for the telemetry data sequence, providing more input for the decision-making of on-orbit satellite disposal. The validity of the proposed method is verified on the real telemetry data set of scientific satellites and the public time series data sets.

Key words Satellite telemetry parameters, Prediction model, Machine learning, Attention mechanism

0 引言

卫星由于自身系统的复杂性,以及在轨运行过程中长期受到光照、辐射、太阳粒子等多种因素的影响,其在轨运行状态可能发生与预期不符的情况,甚至发生异常和故障^[1]。通过预测卫星遥测参数序列的变化趋势,可以使操作人员对卫星的异常情况进行预判,从而增加异常处置的准备时间。遥测数据包含着丰富的卫星在轨运行状态的信息,是预测卫星运行状态变化趋势的重要输入。由于卫星在轨状态受到空间环境、载荷工作模式和任务规划等多种因素的影响,遥测参数序列呈现不同的变化规律,是缓慢的趋势变化、不规则波动变化等统计特征的叠加,不具备明显的周期性^[2]。

目前在遥测参数序列的预测方面有点预测(预测某一时刻序列的具体数值)和区间预测(某一时刻序列预测结果的波动范围)。点预测可以提供直观的预测结果,但是无法体现预测结果的不确定性;区间预测可以对预测的不确定性进行评估,提供预测结果可能波动的范围,提高预测可信度。基于数理统计的自回归模型(AR)、自回归滑动平均模型(ARMA)、自回归综合移动平均模型(ARIMA)^[3]和指数平滑^[4]等在遥测参数单一序列点预测方面都取得了不错的效果。在深度学习方面,Roman D^[5]通过深度神经网络(DNN)、贝叶斯岭回归(BRR)等深度学习模型把卫星锂电池的电容量作为健康指标来预测锂电池的剩余寿命;O'MEARA^[6]使用自编码器和长短时记忆网络(LSTM)进行自动特征提取、异常检测和遥测参数预测,用迭代方式训练,进行卫星异常模式或者行为的预先警告。Li等^[7]利用HP滤波将遥测参数序列分为趋势性和波动性特征,利用全局和局部的结构独

立建模捕获,提高了预测准确性。Liu等^[8]基于最小二乘支持向量机,根据模型的估计误差服从高斯分布,利用置信区间获得了具有一定置信度的异常片段的波动范围。Fang等^[9]假设卫星电压参数数据服从高斯分布,使用ARMA时间序列预测模型来预测,获得了电压参数具有95%置信度的区间预测范围。Shi^[10]基于注意力机制(Attention)结合质量驱动的区间预测方法,对锂电池放电电流进行了多步区间预测。

近年来在遥测参数序列预测的研究中,使用基于数据驱动的组合机器学习方法已成为国内外研究的热点。根据现有知识和专家经验可知的影响因素中可以提前获得或预报的、对预测遥测参数序列变化趋势起到辅助作用的因素将之定义为协变量,例如根据卫星运行轨道计算得到的相关参数、卫星过南大西洋异常区(SAA)时段以及其他可提前预知的因素等。通过引入可提前获得的协变量数据,为遥测参数序列的预测提供更多的输入信息,提高预测准确性。基于数理统计ARIMA、支持向量回归(SVR)、高斯回归(GPR)和灰度模型(GM)的遥测参数预测方法不适用于模型输入为多维时间序列的预测;而能够处理多维输入的LSTM网络对于周期性不明显且具有多种变化特征的遥测参数序列预测精确度不够。为了进一步提升LSTM模型在时间维度上的特征提取能力,越来越多的学者引入了Attention机制,但在时间维度上注重单一序列时间步长信息的Attention缺乏对多维参数间关联特征的提取能力。根据遥测参数数据具有复杂变化规律和不明显周期性的特征,采用全局-局部融合的结构^[11-13]分别独立建模提取序列时间维度上的趋势性和波动性特征,并采用改进的Attention机制捕获多维参数之间的关联关系,提高模型的

点预测和区间预测精度。

本文在分析卫星遥测参数在轨变化规律的基础上,针对其具有非典型周期特性和多种复杂变化特征,将卫星遥测参数序列的全局趋势性和局部不规则波动性特征采用全局-局部结构分开独立建模,并用高斯耦合函数进行两个特征分量的融合,为周期性不明显且变化规律复杂的遥测参数序列提供了精确度较高的点预测和区间预测结果。采用注重捕获状态矩阵中行向量权重的 Attention 机制,捕获多维参数之间更多的关联信息,根据协变量关联性的强弱对目标序列预测施加不同的影响权重,以提高预测准确性。

1 问题定义

为了清晰描述遥测参数序列与协变量之间的关系,对各类数据进行形式化定义。

定义 1 在 t 时刻,协变量为

$$B_t = (x_{1,t}, x_{2,t}, \dots, x_{n,t}). \quad (1)$$

式中, $x_{i,t}$ 为第 i 个协变量在时刻 t 的取值, n 代表协变量的维度。

定义 2 根据 t 时刻卫星的遥测参数序列和已知的协变量 B_t 得到 t 时刻卫星的组合数据

$$X_t = (t, B_t, y_t). \quad (2)$$

其中, y_t 表示遥测参数序列在 t 时刻的取值。

定义 3 卫星在 t 时刻的遥测参数序列的预测结果为

$$Z_t = (t, d_t, s_t, \tilde{y}_t). \quad (3)$$

其中 d_t, s_t 分别表示遥测参数序列在 t 时刻的预测上限值和预测下限值, $\tilde{y}_t$ 代表在 t 时刻遥测参数序列点预测的结果。

定义 4 卫星遥测参数序列的预测问题可以抽象为

$$F : (X_{t_1:t_2}, B_{t_2+1:t_3}) \rightarrow Z_{t_2+1:t_3}. \quad (4)$$

其中 $X_{t_1:t_2}$ 代表从时刻 t_1 到 t_2 的历史组合数据, $B_{t_2+1:t_3}$ 代表未来时刻 t_2+1 到 t_3 的已经获得具体数据的协变量, $Z_{t_2+1:t_3}$ 是未来 t_2+1 到 t_3 的预测结果。

2 预测模型

2.1 预测框架

基于以上问题定义,设计卫星遥测参数序列的预

测模型框架如图 1 所示,将遥测参数和协变量数据进行剔除异常值、填充缺失值和归一化等步骤后处理成组合数据输入模型,分别经过全局模块和局部模块后获得全局分量(趋势性特征)和局部分量(波动性特征),随后利用高斯函数进行两个特征分量的融合,训练后获得预测模型。实时数据预处理后输入预测模型,其输出数据通过分位函数后得到最终的点预测和区间预测结果。

2.2 全局模型

2.2.1 初步全局分量

初步全局分量由 k 个循环神经网络(RNN)线性组合而成的 LSTM 给出,将上一时间步的组合数据 X_{t-1} 和 LSTM 的输出 g_{t-1} 以及下一时间步已知的协变量 B_t 作为下一时间步的输入,即

$$g_t = G(g_{t-1}, X_{t-1}, B_t). \quad (5)$$

其中, g 的初始状态是 LSTM 网络 $G(X, B)$ 的输出,在训练阶段和预测阶段,使用相同的网络结构,并且共享权重以减少计算量。

2.2.2 注意力机制

传统的时间序列注意力机制主要关注于改变注意力模型的网络结构来提升任务性能,选择与当前时间步相关的信息,上下文向量是当前 RNN 隐状态矩阵的列加权和,这种设计适合每个时间步包含单一序列的任务,但是只关注了几个时间步长信息,很难跨越多个时间步长获取周期性信息。LSTNet^[14]虽然加




图 1 卫星遥测参数序列预测模型框架

Fig. 1 Framework of satellite telemetry parameter sequence prediction model

入了 skip 机制和传统的 Attention, 减轻了这一问题, 但其是为具有强周期特征的序列数据设计的。由于卫星绕地球运行受多种因素的影响, 遥测参数序列不具有明显的周期性, 而且本文引入了对预测遥测参数序列有辅助作用的协变量, 形成多维的模型输入, 传统的方法难以提取在空间上多参数之间的相关信息。本文的 Attention 将更加关注隐向量矩阵中行向量的信息而非时间维度上的时间步长信息, 考虑了多维协变量对预测目标序列的影响权重因子, 适合多元时间序列。因为卷积神经网络(CNN)能够提取重要的空间特征, 因此引入了 CNN 来获取每个个体变量的隐状态重要信息。使用 g_t 作为注意力机制函数的输入, Attention 函数定义如下。

使用 CNN 获取 g_t 空间维度上重要的特征:

$$H_{i,j}^C = \sum_{l=1}^w H_{i,(t-w-1+l)} C_{j,t-w+l}. \quad (6)$$

式中, $H_{i,j}^C$ 代表第 i 行第 j 列的卷积值, $C_{j,t-w+l}$ 表示卷积权重矩阵的 j 行 $t-w+l$ 列。

给注意力加权, 可得

$$f(H_i^C, g_t) = (H_i^C)^T W_a g_t. \quad (7)$$

其中, H_i^C 是隐状态 H^C 的第 i 行, $W_a \in R^{k \times m}$ 。将权重向量通过 sigmoid 函数进行归一化, 根据多变量的重要性程度进行选择

$$A_i = \text{sigmoid}(f(H_i^C, h_t)). \quad (8)$$

根据注意力权重, 对提取了空间特征的状态向量每行进行加权求和, 得到全局分量, 有

$$h_t = \sum_{i=1}^m A_i H_i^C. \quad (9)$$

此时, 全局分量 h_t 包含了多个时间步长的 g_t 行向量的加权和, 所以它可以捕获到目标序列的长时间跨度的信息和多维协变量之间影响权重的时间信息。

2.3 局部模型

局部模型 R 可以选择任意经典概率时间序列模型, 为了有效地计算高斯似然函数 $P(Z_i | R_i)$, 根据本文数据的分析得局部分量 r_t 满足正态分布假设, $r_t \sim N(0, \sigma_t^2)$, 其中 σ_t^2 (即 l_t) 是由和全局模型相同的输入特征经过 RNN 得到的结果, 即

$$\begin{aligned} l_t &= R(X_{t-1}, B_t), \\ r_t &\sim N(0, l_t). \end{aligned} \quad (10)$$

2.4 优化目标

假设数据服从高斯分布, 使用全局分量以及局部分量 (h_t, r_t) 作为高斯似然的均值和标准差 (μ, σ) 计算结果, 即

$$y(x) = (2\pi\sigma^2)^{-\frac{1}{2}} \exp[-(x - \mu)^2 / (2\sigma^2)]. \quad (11)$$

在整体训练阶段, 利用高斯函数作为 Loss 函数, 通过求 Loss 函数的极大似然估计作为目标值进行训练得到最佳的 (μ, σ) 和模型参数, 在输出预测结果时, 采用分位函数 (Quantile function), 对于一个给定的分位数 $\rho \in (0, 1)$ 可提供点预测和区间预测的结果。

2.5 评价指标

选取回归模型常用评价指标 MAPE 和 PID 分别来验证模型点预测和区间预测的性能。

(1) 点预测: MAPE (Mean Absolute Percentage Error, 定义符号 E_{MAPE}), 范围 $[0, +\infty)$, MAPE 的值越小, 表明模型具有更好的预测精度, 有

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\tilde{y}_i - y_i}{y_i} \right|. \quad (12)$$

(2) 区间预测: PID (Prediction Interval Distance, 定义符号 D_{PI}), 均衡了区间覆盖率和平均区间宽度, 取值越小, 表明越能在较窄的上下界获得更大覆盖率, 有

$$D_{\text{PI}} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(y_i - \frac{U_i + L_i}{2} \right)^2}. \quad (13)$$

其中, y_i 为真实值, $\tilde{y}_i$ 为预测值, U_i 和 L_i 是预测结果的上下界。

3 实验验证与结果分析

3.1 实验数据集

由于电源系统是卫星平台非常重要的组成部分, 是卫星载荷正常工作的基础, 而母线电压能够直接反应电源系统的状态, 因此本文选择母线电压遥测数据作为研究数据。本实验选取某在轨科学卫星从北京时间 2021 年 9 月 1 日 00:00 LT 至 2021 年 9 月 26 日 00:00 LT 的电压系统母线电压遥测数据; 协变量包括卫星是否处于地影区标识 (0/1 状态量, 卫星处于阴影区还是太阳照射区, 影响太阳能帆板发电)、载荷工作模式 (整型数值, 代表载荷不同的工作模式, 影

响用电量)和卫星是否处于 SAA 区标识(0/1 状态量, 卫星运行至 SAA 区时载荷关机, 影响电压), 整合后的数据集为 Satellite。为了验证模型的性能还选取了时间序列预测领域公开的数据集 Solar Energy^{*}和 Electricity^{**}。各数据集详细信息描述列于表 1。

3.2 对比算法

点预测对比算法如下。

(1) ARIMA: 基于自回归多项式系数和滑动平均多项式系数的拟合预测模型。本文在运用模型前将数据进行对数平稳化处理。

(2) SVR: 寻求距离所有样本总偏差最小的一个超平面, 拟合数据来进行预测。

(3) GPR: 利用高斯先验对数据进行拟合的非参数预测模型, 本文使用 RBF 高斯核。

(4) LSTM: 特殊的 RNN 网络—长短期记忆网络, 在时间序列的预测方面具有优势。

区间预测对比算法如下。

(1) VAR: 向量自回归模型, 把系统中每一个内生变量作为系统中所有内生变量的滞后值的函数来构造模型, 可以用于时间序列区间预测。

(2) RVM: 相关向量机模型, 与 SVM 类似的稀疏概率预测模型。

(3) GPR: 利用高斯先验对数据进行拟合的非参数预测模型, 本文使用 RBF 高斯核。

3.3 实验结果

设置模型参数 LSTM cells=4, attention 机制中的 CNN cells=32, hidden layers=50, embedding_size=10。在卫星遥测数据集和两个公开数据集上, 利用本文提出的算法和 3.2 介绍过的对比算法分别进行模型训练和预测, 各个模型的训练步长设置为 120, 预测步长设置为 30 和 50, 进行 20 个轮次的验证取得评价指标的平均值。Satellite 数据集的预测结果如图 2

所示。

如图 2 所示, 遥测参数序列不仅有长期的趋势变化, 而且在局部也有短期的不规则波动的情况。母线电压值分布在 27~28 V 之间, 没有明显的随着时间变化的规律。由点预测结果可知模型对母线电压数据的变化趋势拟合得很好, 而且模型得到了有效的接近真实值的预测区间, 能够在覆盖宽度尽量小的情况下保证区间覆盖率。

在三个数据集上点预测的评价指标 MAPE 结果列于表 2。表 3 给出了区间预测的评价指标 PID 结果。

由表 2 可得在 Satellite 数据集上预测结果的评价指标 MAPE, 本文提出的模型相比 SVR 下降了 0.24。由此可以说明, 本文采用全局-局部融合的结构




图 2 预测 30 个时刻 (a) 和 50 个时刻 (b) 的结果 (P10 quantile 和 P90 quantile 分别代表区间预测的下界和上界, P50 forecast 代表点预测结果, true 代表真实数据)

Fig. 2 Result graph of 30 predictions (a) and 50 predictions (b) (P10 quantile and P90 quantile represent the lower and upper bounds of the prediction interval, P50 forecast represents point prediction results and true is the true value)

表 1 数据集统计表

Table 1 Statistics of all datasets

数据集	维度	样本量	采样率/min	数据类型
Satellite	4	55156	0.5	float
Solar energy	2	52560	5	float
Electricity	2	105215	15	float

* <https://www.nrel.gov/grid/solar-power-data.html>

** <https://archive.ics.uci.edu/ml/datasets/ElectricityLoadDiagrams20112014>

表 2 各数据集对应算法的 MAPE
Table 2 Each dataset corresponds to
the MAPE of algorithms

Model	Solar energy	Electricity	Satellite
ARIMA	0.141394	0.364261	0.43033
SVR	0.245441	0.458509	0.46821
GPR	0.126012	0.468745	0.44977
LSTM	0.121016	0.252913	0.32426
Our Model	0.110150	0.145592	0.17361

表 3 各数据集对应算法的 PID
Table 3 Each dataset corresponds to
the PID of algorithms

Model	Solar energy	Electricity	Satellite
VAR	0.36534	0.34288	0.45087
RVM	0.33673	0.32538	0.39721
GPR	0.42383	0.40293	0.42032
本文模型	0.31160	0.23165	0.20249

分别捕获序列的全局趋势性特征和局部不规则波动性特征,经过高斯耦合两个分量提高了遥测数据的预测准确率;MAPE 指标相比 LSTM 下降了 0.1,说明在加入了协变量提供更多的输入信息后,利用注重捕获参数之间相关权重的 Attention,获得了协变量对预测目标序列的影响权重,从而提高了预测准确率。在公开数据集上,本模型相比其他几个算法均取得了更好的结果,尤其是在 Electricity 数据集上的效果,相比 Solar energy 数据集相对明显,可以得出本模型在其他领域的预测依然有较高的准确性,模型具有较好的鲁棒性。

由表 3 可以看出,本文提出的模型相对于其他几个算法都取得了更好的结果,在用极大似然估计目标值函数进行模型训练之后,能够在获得较高区间覆盖率的情况下尽量减小覆盖宽度,提高了区间预测的可靠性。

综上可以看出,本模型的点预测和区间预测相比其他模型都取得了较好的结果,尤其是在 Electricity 数据集上,这是由于电力数据集受人类用电随机性影响较大,数据周期性相比 Solar Energy 数据集更加不明显,可知本文提出的模型针对这样周期性不明显的预测优势较为明显。

表 4 消融实验结果
Table 4 Results of ablation experiment

	MAPE	PID
去掉改进 Attention 结构	0.28864	0.34320
去掉全局-局部融合结构	0.30388	0.40542
LSTM	0.32426	0.42310
本文模型	0.19161	0.23744

3.4 消融实验

为了验证本文提出的模型中全局-局部融合结构和改进 Attention 的有效性,本文进行了消融实验。在 Satellite 数据集上进行预测未来 50 个时刻数据的实验,表 4 利用评价指标 MAPE 和 PID 展示了全局-局部融合的结构以及改进 Attention 对于模型的影响。

从表 4 在 Satellite 数据集上实验的 MAPE 和 PID 评价指标的结果可以得出,全局-局部融合的结构和改进 Attention 对算法带来的贡献程度不同,两者共用的时候预测效果最好。使用全局-局部融合的结构比改进 Attention 对预测结果的影响更大,说明全局-局部融合的结构分别提取序列的不同成分特征然后用高斯函数耦合得到结果,对于不具有明显周期性特征的遥测参数序列的预测效果更加明显;改进 Attention 相比 LSTM 提高了预测精度,说明此结构通过获得参数之间的相互关联信息,可以为遥测参数序列的预测提供更多协变量的影响权重信息,提高模型预测准确率。

4 结论

针对目前的预测研究对于周期性不明显且具有多种变化特征的遥测参数序列预测精确度不够的问题,本文引入了对预测遥测参数序列有辅助作用的协变量,提出了一个基于改进 Attention 组合机器学习的预测模型,通过全局和局部融合的结构对遥测参数序列的全局趋势性和局部波动性特征独立建模,并采用改进 Attention 捕获多维协变量对预测目标序列的影响权重,然后通过高斯函数耦合两个特征分量得到最终结果,实现了遥测参数序列在某时刻高准确度的点预测和区间预测。在科学卫星真实遥测数据集和公开的时间序列数据集上进行实验验证,本文提出的方法在时间序列点预测和区间预测任务上均取得

了较好的结果,可以为卫星地面操作人员提供决策支持。

参考文献

- [1] TAN Chunlin, HU Taibin, WANG Dapeng, *et al.* Analysis on foreign spacecraft in-orbit failures[J]. *Spacecraft Engineering*, 2011, **20**(4): 130-136 (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)
- [2] PANG Jingyue. Probabilistic prediction based anomaly detection method for spacecraft telemetry data[D]. Harbin: Harbin Institute of Technology, 2019 (庞景月. 基于概率性预测的航天器遥测数据异常检测方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2019)
- [3] WILSON G T. Time series analysis: forecasting and control, 5 th Edition, by George E. P. Box, Gwilym M. Jenkins, Gregory C. Reinsel and Greta M. Ljung, 2015. Published by John Wiley and Sons Inc., Hoboken, New Jersey, pp. 712. ISBN: 978-1-118-67502-1[J]. *Journal of Time Series Analysis*, 2016, **37**(5): 709-711
- [4] ÖLLER L E, STOCKHAMMAR P. Rob J. Hyndman, Anne B. Koehler, J. Keith Ord, Ralph Snyder, forecasting with exponential smoothing: the state space approach, Springer (2008), 359 pp, ISBN 978-3-540-71916-0 (paperback), €36.95, e-ISBN 978-3-540-71918-2 (online), €25/Chapter[J]. *International Journal of Forecasting*, 2010, **26**(1): 204-205
- [5] ROMAN D, SAXENA S, ROBU V, *et al.* Machine learning pipeline for battery state-of-health estimation[J]. *Nature Machine Intelligence*, 2021, **3**(5): 447-456
- [6] O'MEARA C, SCHLAG L, WICKLER M. Applications of deep learning neural networks to satellite telemetry monitoring[C]//Proceedings of the 2018 SpaceOps Conference. Marseille, France: AIAA, 2018
- [7] LI Zhiqiang, ZHANG Xiangyan, TIAN Huadong. Prediction method of satellite telemetry data using HP filter[J]. *Spacecraft Engineering*, 2021, **30**(4): 23-30 (李志强, 张香燕, 田华东. 应用HP滤波的卫星遥测数据预测方法[J]. 航天器工程, 2021, **30**(4): 23-30)
- [8] LIU D T, PANG J Y, SONG G, *et al.* Fragment anomaly detection with prediction and statistical analysis for satellite telemetry[J]. *IEEE Access*, 2017, **5**: 19269-19281
- [9] FANG H Z, ZOU K X, YI D W, *et al.* The study of spacecraft telemetry data prediction based-on SERTS model[C]//Proceedings of 2011 Prognostics and System Health Management Conference. Shenzhen, China: IEEE, 2011: 1-5
- [10] SHI Mengxin. Telemetry Data Prediction Method Based on Attention Mechanism Neural Network[D]. Beijing: The University of Chinese Academy of Science (National Space Science Center, Chinese Academy of Science), 2020 (石梦鑫. 基于注意力机制神经网络的遥测数据预测方法[D]. 北京: 中国科学院大学(中国科学院国家空间科学中心), 2020)
- [11] AHMED A, ALY M, GONZALEZ J, *et al.* Scalable inference in latent variable models[C]//Proceedings of the 5 th ACM International Conference on Web Search and Data Mining. Seattle, Washington, USA: ACM, 2012
- [12] HWANG Y, TONG A, CHOI J. Automatic construction of nonparametric relational regression models for multiple time series[C]//Proceedings of the 33 rd International Conference on International Conference on Machine Learning. New York, NY, USA: JMLR. org, 2016
- [13] JING H, SMOLA A J. Neural survival recommender [C]//Proceedings of the 10 th ACM International Conference on Web Search and Data Mining. Cambridge, United Kingdom: ACM, 2017
- [14] LAI G K, CHANG W C, YANG Y M, *et al.* Modeling long- and short-term temporal patterns with deep neural networks[C]//Proceedings of the 41 st International ACM SIGIR Conference on Research & Development in Information Retrieval. Ann Arbor, MI, USA: Association for Computing Machinery, 2018: 95-104. DOI: 10.1145/3209978.3210006