

DOI: 10.19650/j.cnki.cjsi.J1904832

集成 LSTM 的航天器遥测数据异常检测方法*

董静怡, 庞景月, 彭宇, 刘大同

(哈尔滨工业大学电子与信息工程学院 哈尔滨 150080)

摘要:航天器作为一类集合结构、热控、电源、姿轨控等的复杂系统,遥测数据是地面判断其在轨性能的唯一依据,而有效的异常检测是保证航天器在轨可靠运行的基础要素。针对遥测数据连续、离散样本混合且样本变化高度关联于指令的数据异常检测问题,提出一种基于集成长短期记忆网络(LSTM)的航天器遥测数据异常检测方法。利用 LSTM 强大的非线性建模能力,结合矩阵范数实现对遥控指令的多模式挖掘,并通过多 LSTM 预测模型的构建以及有效集成,提升模型对于航天器复杂工况的适应性,进而有效标记遥测数据中的异常。通过对 NASA 公布的 2 个类型航天器的遥测数据进行实验验证,结果表明,与基于 LSTM 的遥测数据异常检测方法相比,所提出的方法异常检测率提升明显,尤其适合检测上下文类型异常。测试结果验证了方法的可行性,可为航天器地面运控提供有效的数据判读能力。

关键词: 卫星;遥测;异常检测;LSTM;上下文异常

中图分类号: TP206+.3/TH165+.3

文献标识码: A

国家标准学科分类代码: 510.4030

Spacecraft telemetry data anomaly detection method based on ensemble LSTM

Dong Jingyi, Pang Jingyue, Peng Yu, Liu Datong

(School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150080, China)

Abstract: Spacecraft is a kind of extraordinary complex systems consisting of integrating structure, thermal control, power, attitude, orbit, and so on. Telemetry data is the only basis to judge the on-orbit spacecraft performance on ground. The effective anomaly detection is a fundamental element to ensure the reliable operation of the spacecraft. In this paper, aiming at the data anomaly detection problems that the telemetry data are the mixture of continuous and discrete samples, and the sample variation is highly correlated with the instructions, a spacecraft telemetry data anomaly detection method is proposed based on ensemble long-short term memory (LSTM) network. The strong nonlinear modeling ability of LSTM is utilized; with matrix norm, the multiple mode mining of tele-control instruction is achieved; through the construction and effective ensemble of the multiple LSTM prediction model, the adaptability of the model to the complicated spacecraft operating condition is improved; then, the anomaly in the telemetry data is effectively labeled. The telemetry data of two kinds of spacecraft from NASA are detected in experiment. The result indicates that the anomaly detection rate of the proposed method is promoted obviously compared with the telemetry data anomaly detection method based on LSTM, the proposed method is especially suitable for contextual anomaly discovery. The test results verify the feasibility of the proposed method, and the study provides an effective data interpretation ability for the ground operation and control of spacecraft.

Keywords: satellite; telemetry; anomaly detection; LSTM; contextual anomaly

0 引言

随着航天器设计复杂程度以及功能性的逐步提升,卫星研发周期逐渐缩短,且发射数目增加,仅仅通过传统

可靠性工程方法和手段已无法满足卫星安全可靠运行对数据处理和分析的苛刻要求。目前,大多数卫星都是采用地面遥测遥控的方式进行控制,卫星在轨运行期间,地面运控中心需接收并处理在轨卫星的遥测数据,对在轨卫星的状态监测参数进行自动判断和报警等操作,同时

收稿日期:2019-03-11 Received Date:2019-03-11

* 基金项目:国家自然科学基金(61571160, 61771157, 61701131)资助项目

将获取的遥测数据存入数据库供事后分析^[1]。航天器遥测数据异常检测的研究已经引起国内外研究机构的广泛关注^[2-8]。目前遥测数据异常检测方法主要分为 3 类:基于统计、基于距离以及基于偏差方法。基于统计方法通常假设数据服从已知的分布模型,对不符合该分布或统计量特征不一致的数据进行异常标记^[9],但实际的数据很难用预设的分布进行刻画。基于距离的方法则通过衡量不同数据之间的距离,对距离较远以及密度较小的数据点进行异常标记。文献[10]利用基于密度的方法,以距离测量为辅助,实现了时间序列高准确率异常检测。文献[11]面向卫星遥测数据的时间序列开展相似性度量方法研究,消除了参量之间的相关性影响,实现了异步度量。基于偏差的方法则通过对正常数据建模,对实测数据与模型输出值的偏差进行统计,超出预设偏差的数据被标记为异常^[12-13],基于偏差的方法中基于预测的方法解释性强,且具有较强的在线应用能力,检测速度较快,更适用于需要对遥测数据进行在线监测的场景。然而,遥测与遥控互相影响,没有遥测的遥控是盲目的,没有遥控的遥测是被动的。因此,如何有效结合遥控指令实现遥测数据的异常检测是提升遥测数据异常检测能力的必需途径。

近年来随着深度学习的快速发展,很多深度学习模型被应用于异常检测^[14-17]。其中长短期记忆(Long-short term memory, LSTM)网络模型,作为递归神经网络(recurrent neural network, RNN)的一种特殊类型,保留了标准 RNN 的优势,能够利用历史数据对时间序列进行推演预测,在时间序列异常检测领域得到广泛关注^[16,18]。文献[19]中 NASA 结合 LSTM 强大的非线性建模能力及特征自动提取能力,将遥控指令与遥测数据同时作为输入,构建 LSTM 模型,实现了对遥测数据的有效标记。由于其对所有指令的控制模式构建了统一的 LSTM 模型,导致整体预测误差均值以及方差增大,LSTM 模型对于上下文(contextual anomaly)以及聚集异常的检测能力尚需提升。

鉴于上述分析,针对全局 LSTM 建模预测准确性下降的问题,提出基于集成 LSTM 的航天器遥测数据异常检测方法,利用聚类方法有效挖掘高维遥控指令间不同的控制模式,对于每种控制模式分别建立 LSTM 预测模型,通过对预测结果的集成以及预测误差的阈值生成实现航天器遥测数据的异常检测,提升模型的预测能力,进而增强模型对点异常(point anomaly)以及上下文异常的检测能力。

1 基于 LSTM 的时间序列预测方法

LSTM 作为 RNN 的一种变体,保留了标准 RNN 的优势,能够利用历史数据对时间序列进行推演预测,同时有

别于标准 RNN 的模型结构有效解决了 RNN 对历史信息利用不足的弊端^[20]。

LSTM 的结构主要分为 3 层:输入层(input layer),隐藏层(hidden layer)和输出层(output layer),其中隐藏层可为单层或多层。每个隐藏层中含有多个记忆块(memory block),每个记忆块中有若干个记忆细胞(memory cell)。针对本文要解决的异常检测问题,为了更好地挖掘遥控指令控制模式对遥测指令的影响,采用模型类型为双层同步多对多 LSTM 模型,如图 1 所示。测试数据以矩阵的形式作为输入,经过隐藏层后,同步输出预测矩阵。单个记忆块中的记忆细胞会通过一种链式结构连接在一起。在标准 RNN 的基础上,LSTM 中的 1 个记忆细胞包含 1 个细胞(Cell)和 3 个“门(Gate)”。细胞中的信息被称为细胞状态,细胞状态会根据历史输出以及实时输入而更新。3 个“门”分别为:“输入门(input gate)”,“遗忘门(forget gate)”和“输出门(output gate)”^[20-21]。

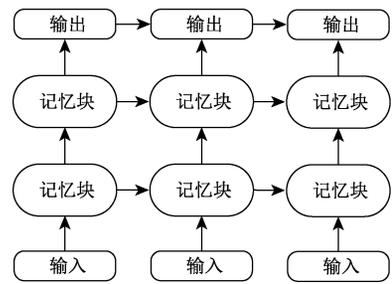


图 1 双层同步多对多 LSTM 结构模型

Fig.1 The structure of two-layer synchronous multiple-to-multiple LSTM model

LSTM 模型预测结果通过选择适合的损失函数比较其与真实值的偏差,优化函数基于偏差值对各个权重进行更新直至 LSTM 预测模型的性能满足需求。选择合适的损失函数以及优化函数能帮助模型计算相应的最优的权重矩阵,从而提高预测的准确性,减少预测值与真实值的偏差,实现 LSTM 对时间序列的预测。

2 基于集成 LSTM 预测的遥测数据异常检测方法

航天器在轨运行时,对于航天器遥测数据异常检测问题,LSTM 针对遥控指令全局建模忽略了不同遥控指令下遥测数据的不同模式特征,会降低预测准确性,影响对航天器遥测参数异常的检测能力。

因此本文提出的基于集成 LSTM 的异常检测方法主要分为 3 个部分:1)控制指令模式挖掘;2)多 LSTM 模型训练;3)遥测数据异常检测模型。基于集成 LSTM 预测模型的遥测数据异常检测方法如图 2 所示。

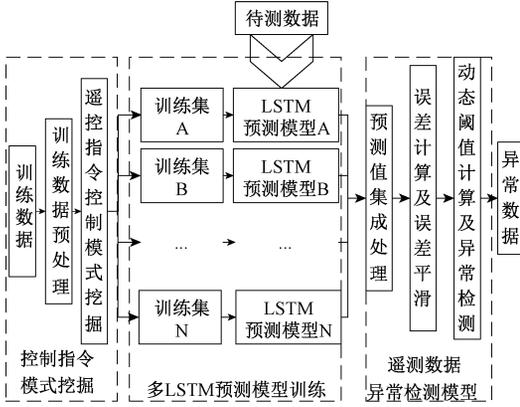


图2 基于集成 LSTM 预测模型遥测数据异常检测方法

Fig.2 Telemetry data anomaly detection method based on ensemble LSTM prediction model

2.1 控制指令模式挖掘

本方法在 LSTM 预测模型开始训练之前,先将训练数据进行预处理,在对其进行固定单位时间分割的基础上,利用聚类将其划分为不同类别,主要包括:训练数据预处理以及遥控指令控制模式挖掘。

1) 训练数据预处理

以某训练集 \mathbf{S} 为例,其在 t 时刻,可视为一组 m 维的向量, $\mathbf{s}^t = \{s_1^t, s_2^t, \dots, s_m^t\}$,其中 $\{s_1^t, s_2^t, \dots, s_{m-1}^t\}$ 为 t 时刻的多维遥控指令, $\{s_m^t\}$ 为 t 时刻的遥测数据,则包含某子系统的遥测数据训练集 \mathbf{S} 为:

$$\mathbf{S} = \left\{ \begin{bmatrix} s_1^1 \\ \vdots \\ s_{m-1}^1 \\ s_m^1 \end{bmatrix}, \begin{bmatrix} s_1^2 \\ \vdots \\ s_{m-1}^2 \\ s_m^2 \end{bmatrix}, \dots, \begin{bmatrix} s_1^t \\ \vdots \\ s_{m-1}^t \\ s_m^t \end{bmatrix}, \dots \right\} \quad (1)$$

之后将 \mathbf{S} 进行重构,因为下一时刻的遥测数据与下一时刻的遥控指令和之前一段时间的遥测数据与相应的遥控指令有关,故在构建输入时,将 \mathbf{S} 拆分成多个包含连续时间向量的次矩阵 \mathbf{S}_n^* 。每个次矩阵中包含 l_i 个时刻内的遥测数据和全局遥控指令,重构的输入 $\tilde{\mathbf{S}}$ 为:

$$\tilde{\mathbf{S}} = \{ \{ \mathbf{S}_1^* \}, \{ \mathbf{S}_2^* \}, \dots, \{ \mathbf{S}_n^* \}, \dots \} \quad (2)$$

其中:

$$\mathbf{S}_n^* = \left\{ \begin{bmatrix} s_1^n \\ s_2^n \\ \vdots \\ s_m^n \end{bmatrix}, \begin{bmatrix} s_1^{n+2} \\ s_2^{n+2} \\ \vdots \\ s_m^{n+2} \end{bmatrix}, \dots, \begin{bmatrix} s_1^{l+n} \\ s_2^{l+n} \\ \vdots \\ s_m^{l+n} \end{bmatrix} \right\} \quad (3)$$

2) 遥控指令控制模式挖掘

针对航天器遥控指令的无序性,将总训练集中的遥测数据根据一段时间内的控制模式,进行分类,以实现有针对性的训练。但为了防止过拟合或欠拟合,子训练集中的数据总量不宜过少,具体子训练集的数量应结合总

训练集数量而定。本文以两个聚类类别为例对根据控制模式聚类方法进行描述,过程如下。

以输入 $\tilde{\mathbf{S}}$ 为例,提取其每个次矩阵 \mathbf{S}_n^* 中的遥控指令 \mathbf{C}_n^* ,得到 $\tilde{\mathbf{S}}$ 对应的控制指令矩阵 \mathbf{C}^* ,其中:

$$\mathbf{C}_n^* = \left\{ \begin{bmatrix} s_1^n \\ s_2^n \\ \vdots \\ s_{m-1}^n \end{bmatrix}, \begin{bmatrix} s_1^{n+1} \\ s_2^{n+1} \\ \vdots \\ s_{m-1}^{n+1} \end{bmatrix}, \dots, \begin{bmatrix} s_1^{l+n} \\ s_2^{l+n} \\ \vdots \\ s_{m-1}^{l+n} \end{bmatrix} \right\} \quad (4)$$

通过计算 \mathbf{C}^* 个次矩阵的 L_2 范数,得到一组控制模式特征向量 $\|\mathbf{C}^*\|_2$,

$$\|\mathbf{C}^*\|_2 = \{ \|\mathbf{C}_1^*\|_2, \|\mathbf{C}_2^*\|_2, \dots, \|\mathbf{C}_n^*\|_2, \dots \} \quad (5)$$

$$\|\mathbf{C}_n^*\|_2 = \sqrt{\lambda_{\max}(\mathbf{C}_n^{*T} \mathbf{C}_n^*)} \quad (6)$$

将控制模式特征向量 $\|\mathbf{C}^*\|_2$ 中的数值重新排序,以分成 2 个子训练集为例,取 $\|\mathbf{C}^*\|_2$ 中的中位数作为阈值,集中遥控指令相似的序列,使训练集分成 2 类。

2.2 多 LSTM 预测模型训练

遥控指令通过模式挖掘和聚类后,得到的 2 个子训练集分别通过 LSTM 预测模型进行训练。以遥测数据预测为例,重构后的训练矩阵 \mathbf{S} 作为输入,其中以每一个次矩阵 \mathbf{S}_n^* 中所包含的 l_i 个时刻内的遥测数据及其相对应的全局遥控指令为依据,预测出下一时刻的遥测数据,令 $t = l_i$,预测过程如下:

$$\mathbf{S}_n^* = \left\{ \begin{bmatrix} s_1^n \\ s_2^n \\ \vdots \\ s_m^n \end{bmatrix}, \dots, \begin{bmatrix} s_1^{n+t} \\ s_2^{n+t} \\ \vdots \\ s_m^{n+t} \end{bmatrix} \right\} \rightarrow \begin{bmatrix} s_2^{n+t+1} \\ s_2^{n+t+1} \\ \vdots \\ \hat{y}^{n+t+1} \end{bmatrix} \quad (7)$$

式中: \hat{y}^{n+t+1} 为 $n+t+1$ 时刻的预测值。在构建预测模型时,绝对值误差函数 (mean absolute error, MAE) 为 LSTM 预测模型的损失函数:

$$MAE(y, \hat{y}) = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (8)$$

式中: n 为总的预测值的个数; y_i 为第 i 个真实值。

LSTM 预测模型优化函数为 Adam (adaptive moment estimation),每个子训练集通过多次迭代学习,更新优化权重矩阵,使模型的预测性能有所提升,提高模型对非常规控制模式有一定的敏感度。为了防止过拟合,会在每个隐藏层中阻止一定比例的记忆模块参与 LSTM 的学习过程,这个过程又称作 dropout。所有子训练集训练结束后,得到 LSTM 预测模型 A 与 LSTM 预测模型 B。

2.3 遥测数据异常检测模型

LSTM 预测模型 A 与 LSTM 预测模型 B 训练结束后,测试数据将分别通过各预测模型,得到 2 组预测序列,将

2组预测序列按照一定权重集成得到最终的预测序列。本模型主要分为预测值集成处理,误差计算及误差平滑以及动态阈值计算及异常检测3个步骤,如下所示。

1) 预测值集成处理

将测试数据以训练集 \mathbf{S} 为例重组,将重构后的测试集同时通过 LSTM 预测模型 A 与 LSTM 预测模型 B 进行遥测数据预测,得到2组预测序列,分别为遥测数据预测集 A, $\hat{y}_A = \{\hat{y}_A^1, \hat{y}_A^2, \dots, \hat{y}_A^t, \dots\}$, 以及遥测数据预测集 B, $\hat{y}_B = \{\hat{y}_B^1, \hat{y}_B^2, \dots, \hat{y}_B^t, \dots\}$ 。将其通过权重矩阵 δ 集成得到预测序列 \hat{Y} 。其中,令:

$$\hat{y} = \begin{Bmatrix} \hat{y}_A^1 & \hat{y}_A^2 & \dots & \hat{y}_A^t & \dots \\ \hat{y}_B^1 & \hat{y}_B^2 & \dots & \hat{y}_B^t & \dots \end{Bmatrix} \quad (9)$$

以 t 时刻为例, \mathbf{S}_t^* 作为 t 时刻的某一个输入,对应的遥控指令矩阵 \mathbf{C}_t^* 通过预测模型 A 得到 $t + l_i + 1$ 时刻的预测值 $\hat{y}_A^{t+l_i+1}$;同理, \mathbf{C}_t^* 通过预测模型 B 得到 $t + l_i + 1$ 时刻的预测值 $\hat{y}_B^{t+l_i+1}$ 。若 \mathbf{C}_t^* 对应 L2 范数 $\|\mathbf{C}_t^*\|_2$ 属于训练集 A,则:

$$\hat{y}^{t+l_i+1} = \delta^{t+l_i+1} \hat{y}_A^{t+l_i+1} + (1 - \delta^{t+l_i+1}) \hat{y}_B^{t+l_i+1} \quad (10)$$

若 \mathbf{C}_t^* 对应 L2 范数 $\|\mathbf{C}_t^*\|_2$ 属于训练集 B:

$$\hat{y}^{t+l_i+1} = (1 - \delta^{t+l_i+1}) \hat{y}_A^{t+l_i+1} + \delta^{t+l_i+1} \hat{y}_B^{t+l_i+1} \quad (11)$$

通过获取某一时刻的预测值对应的遥控指令矩阵,动态分配权重矩阵,最后得出一组预测序列 \hat{Y} 。

2) 误差计算及误差平滑

将实际遥测值与预测的遥测值做差,得到一组误差序列 $e(e_t = \hat{y}_t - y_t)$,由于误差的变化很不稳定,无法判断某时刻遥测数据的预测误差是遥测数据出现异常或 LSTM 预测模型本身造成的误差。因此需要对误差 e 进行平滑处理,削弱 LSTM 预测模型在数据预测上出现预测偏差对异常检测模型性能的影响。

本文利用指数加权移动平均法 (exponentially weighted moved averages, EWMA),对误差值进行平滑处理,得到平滑误差,以避免因预测值与正常值差异较大而造成的误差值突变的现象。而平滑之后的误差数值若出现在一段时间内异常高或异常低才有去判断数据是否异常的意义。得到的平滑误差为:

$$e_s = \{e_s^1, e_s^2, \dots, e_s^t, \dots\} \quad (12)$$

$$e_s^t = \beta e_s^{t-1} + (1 - \beta) e^t \quad (13)$$

e_s^t 为 t 时刻的平滑误差值。误差经过平滑处理后,我们得到一组平滑误差序列, $e_s = \{e_s^1, e_s^2, \dots, e_s^t, \dots\}$ 。

3) 动态阈值计算及异常判断

本文中基于集成 LSTM 预测模型的异常检测方法的性能在很大程度上取决于对平滑误差 e_s^t 的分析和处理。在获得一组平滑后的误差 e_s 后,以滑窗的方式采集窗内的平滑误差值 e_s^* ,并通过计算得出适用于该窗口的误差

阈值 ε_{th}^* 。设滑窗宽度为 l_e ,以 l_h 步长步近滑动,其中 $l_h < l_e$ 。窗内阈值会随着窗口的滑动而重新计算。

$$e_s^* = \{(e_s^*)^1, (e_s^*)^2, \dots, (e_s^*)^t, \dots\} \quad (14)$$

$$(e_s^*)^t = \{e_s^{(t-1)l_e+1}, e_s^{(t-1)l_e+2}, \dots, e_s^{(t-1)l_e+l_e}\} \quad (15)$$

式中: $(e_s^*)^t$ 为第 t 组滑窗内的平滑误差。

窗内阈值的计算将基于每窗内所有平滑误差的均值和方差,以 $(e_s^*)^t$ 为例,其对应阈值 $(\varepsilon_{th}^*)^n$ 为:

$$(\varepsilon_{th}^*)^n = \mu((e_s^*)^t) + z \cdot \delta((e_s^*)^t) \quad (16)$$

式中: $\mu((e_s^*)^t)$ 为 $(e_s^*)^t$ 的均值, $\delta((e_s^*)^t)$ 为 $(e_s^*)^t$ 的方差, z 为数值在 0.1 ~ 0.5 之间的系数。

因为异常发生在平滑误差发生突变的时刻,因此不能简单的将超过动态阈值 $(\varepsilon_{th}^*)^n$ 的点统一认定为异常点。平滑后的误差超出阈值的同时,还要计算一个误差冗余值 p ,将同一窗组内的超出阈值的点与之前时刻没有超出阈值的最大平滑误差进行比较,如果2点的差距小于 p ,则视其为正常点。通过误差冗余值 p 对是否异常进行判断的原理如图3所示, $e_s^{(1)}$ 与 $e_s^{(3)}$ 均超出阈值,但 $e_s^{(1)}$ 与 $e_s^{(2)}$ 的差距小于 p ,故 $e_s^{(1)}$ 仍是正常点,同理 $e_s^{(3)}$ 视为异常。因为异常并不是只在某一时刻出现,而是会持续一段时间,所有还要考虑一段异常时间冗余 q ,故若平滑误差 e_s^t 经过异常检测模型被判定为异常,则认定 $e_s^{(t-0.5q)} \sim e_s^{(t+0.5q)}$ 对应的时刻,该段遥测数据发生异常。

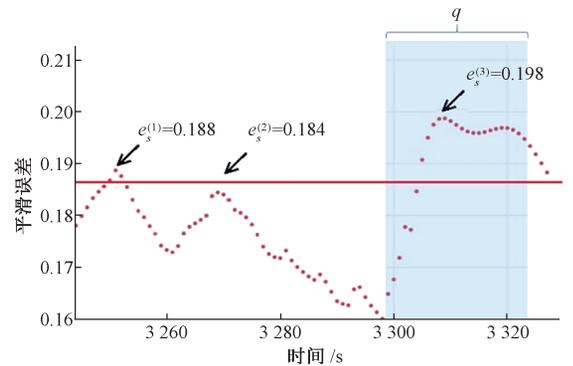


图3 异常点的判断

Fig.3 Anomaly point judgement

3 实验验证与结果分析

本文的验证数据来源于 NASA 公布的 Incident Surprise, Anomaly (ISA) reports 中收集的数据集,其涉及2个航天器类型,包括 SMAP (soil moisture active and passive) 以及 MSL (mars science laboratory) [19]。通过与基于 LSTM 的异常检测方法相比,检验基于集成 LSTM 的遥测数据异常检测方法在点异常与上下文异常检测方面的性能。

3.1 实验设置

1) 实验数据

训练数据及验证数据包括 SMAP 与 MSL 中 12 个子系统各信道的遥测数据及对应的遥测指令,共 82 组数据,其中属于 SMAP 的共有 55 组(67%),属于 MSL 的共有 27 组(33%)。每组训练集包含不同数量的遥测数据及 24 组遥控指令,每组遥测值总数在 300~4 000 点不等^[19]。详细的训练数据总量、异常序列总数、测试遥测信道总数及检测数据总量如表 1 所示。

表 1 实验数据

Table 1 Experiment data

	SMAP	MSL	总计
异常序列总数	69	36	105
点异常序列总数	43(63%)	19(53%)	62(59%)
上下文异常总数	26(38%)	17(47%)	43(41%)
遥测信道总数	55	27	47
检测的遥测数据总量	429 735	66 709	496 444

2) LSTM 模型参数

因各组遥测数据总量在 300~4 000 点不等,经实验发现子训练集所包含的遥测数据在 1 500~2 200 之内效果最好,模型相关参数如表 2 所示。由于训练数据数量有限,训练数据将根据遥控指令控制模式的挖掘聚成 2 个子训练集,预测模型 A 和预测模型 B,进行 LSTM 预测模型训练。

表 2 实验相关参数

Table 2 The experiment relevant parameters

训练数据重构参数	
次矩阵遥测序列长度(l_t)	180
LSTM 模型参数	
隐藏层总层数	2
每层隐藏层中记忆块个数	80
批尺寸(Batch Size)	70
训练迭代次数(每子训练集)	15
验证拆分比例(Validation Split)	0.2
Dropout	0.3
损失函数	MAE
优化函数	Adam
每个记忆块处理的矩阵长度	64
融合矩阵参数 δ	0.7
异常检测模型参数	
窗尺寸(l_e)	40
误差冗余(ρ)	0.013
异常时间冗余(q)	100

3) 实验性能指标

本文结合全局遥控指令,通过基于集成 LSTM 的预测模型对 SMAP 和 MSL 进行异常检测,需检测的异常类型包含点异常以及上下文异常。与实际数据进行比对,遥测数据异常检测的结果分为异常检测成功(true positive),虚警(false positive)和漏检(false negative)。

假设某遥测数据异常片段持续时间为 (t_p, t_q) ,当检测出的异常片段持续时间 $(\tilde{t}_p, \tilde{t}_q)$ 满足以下任一情况时视该异常片段被成功检测:

$$\tilde{t}_p \leq t_p; \tilde{t}_q \leq t_q \quad (17)$$

$$\tilde{t}_p \leq t_p; \tilde{t}_q \geq t_q \quad (18)$$

当 $\tilde{t}_p \leq t_p; \tilde{t}_q \leq t_q$ 或 $\tilde{t}_p \leq t_p; \tilde{t}_q \geq t_q$ 时,若满足式(19),亦视其异常成功被检验。

$$|\tilde{t}_p - t_p| + |\tilde{t}_q - t_q| \leq 200 \quad (19)$$

若 (t_p, t_q) 与 $(\tilde{t}_p, \tilde{t}_q)$ 并无交集时,或实际并无异常却检测出异常,则认定为虚警误检;若实际遥测值存在异常 (t_p, t_q) ,而异常检测方法未能成功将其检测,则视为漏检。

基于集成 LSTM 的异常检测方法的性能从检测率(precision rate)和虚警率(false positive rate)2 方面体现:

$$\text{precision rate} = \frac{\text{Num}(\text{TP})}{\text{Num}(\text{Total Anomalies})} \quad (20)$$

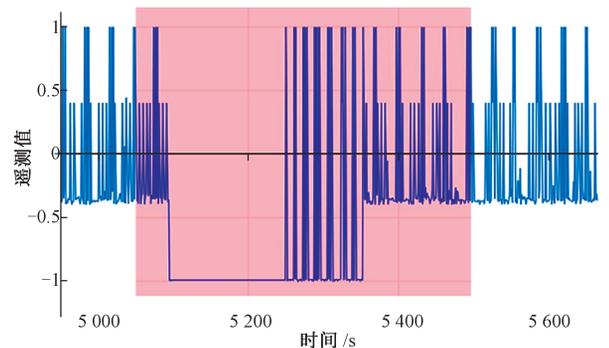
$$\text{false positive rate} = \frac{\text{Num}(\text{TP})}{\text{Num}(\text{TP}) + \text{Num}(\text{FP})} \quad (21)$$

式中:TP 为 true positive; FP 为 false positive。

3.2 基于集成 LSTM 的遥测数据异常检测方法验证

通过对检测出的异常片段及实际异常片段进行比对,异常检测部分结果示例如图 4~6 所示。

由图 4(b)可知,在 t 为 5 400 左右时检测出异常的出现,异常一直持续到 t 为 5 900 左右。同实际遥测数据对应的时刻片段作对比,由图 4 可知,检测出的异常与标注的异常能做到基本重合。因为误差冗余 q 的存在($q=100$),本文异常检测的结果与实际异常点的个数差在 ± 100 左右。



(a) 实际异常序列
(a) The actual anomaly sequence

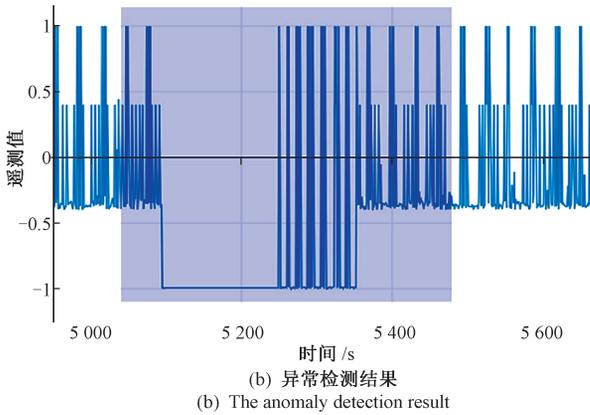


图 4 实际异常序列与异常检测结果的对比

Fig.4 Comparison between the actual anomaly sequence and anomaly detection result

在某种情况下会出现虚警的状况,实验结果出现虚警时,会将某段正常序列认定为异常序列。而出现这种状况的时候多数为原序列的遥测值规律性较大,当原序列某一时刻遥测值的变化受遥控指令的影响较小,遥测值出现较大波动时易被判定为异常,如图 5 所示。通过对漏检的结果分析,出现漏检大多因为异常持续时间过短所致。

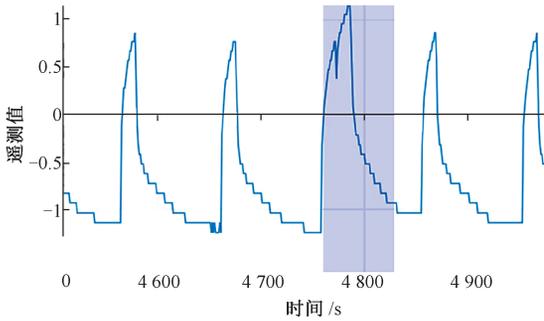


图 5 虚警时的检测结果

Fig.5 The detection result for false positive

通过对实验结果进行分析发现,虚警的主要原因在于,随着 LSTM 预测水平得提升,对异常检测模型的敏感度也随之提升,在检测率有所提升的同时,对于一些遥测数据变化规律性较大且遥测数据受遥控指令影响较小的数据,因此之后仍需对异常检测模型针对此类问题进行改进。

通过对 10 次实验结果的分析,综合考虑了基于集成 LSTM 航天器遥测数据异常检测方法对 2 种航天器遥测数据中的异常和上下文异常的平均检测率及平均虚警率。图 6 所示为某次基于集成 LSTM 的异常检测方法方法与基于 LSTM 的异常检测方法在针对 SMAP 和 MSL 2 种航天器,对点异常及上下文异常的检测性能对比。

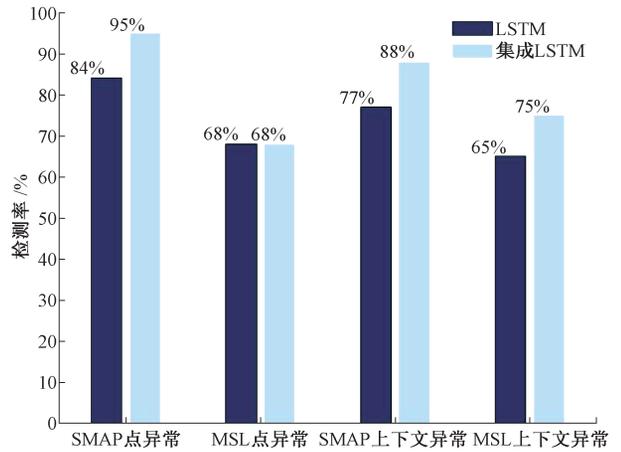


图 6 2 种方法对不同异常的检测率

Fig.6 The detection rates of different anomalies for two methods

通过图 6 可以看出,本文基于集成 LSTM 的航天器遥测数据异常检测方法中的一组实验结果,与基于 LSTM 的异常检测方法相比,对 SMAP 的点异常检测率从 84% 提升到 95%,对 SMAP 的上下文异常检测率从 77% 提升到 88%;对 MSL 的上下文异常检测率从 65% 提升到 76%。由此可看出,通过控制模式挖掘建立多模 LSTM 训练能更好地提升 LSTM 对遥测数据的预测能力,从而提升异常检测的检测率。具体实验结果相关数值如表 3 所示。通过表 3 数据可发现,本文方案与基于 LSTM 的异常检测方法相比,总体点异常检测率从 71% 增长到 78%,总体上下文异常检测率从 72% 增长到 81%。

表 3 2 种遥测数据异常检测方法性能对比
Table 3 Performance comparison between two telemetry data anomaly detection methods

	SMAP			
	点异常		上下文异常	
	检测率	虚警率	检测率	虚警率
LSTM	36/43 (84%)	4/40 (10%)	20/26 (77%)	15/35 (43%)
集成 LSTM	41/43 (95%)	27/68 (39%)	23/26 (88%)	32/55 (58%)
	MSL			
	点异常		上下文异常	
	检测率	虚警率	检测率	虚警率
LSTM	13/19 (68%)	2/15 (13%)	11/17 (65%)	0/11 (0%)
集成 LSTM	13/19 (68%)	2/15 (13%)	13/17 (76%)	2/15 (13%)
	总计			
	点异常		上下文异常	
	检测率	虚警率	检测率	虚警率
LSTM	49/69 (71%)	6/55 (11%)	31/43 (72%)	15/46 (33%)
集成 LSTM	54/69 (78%)	29/83 (35%)	35/43 (81%)	34/67 (51%)

基于集成 LSTM 航天器遥测数据异常检测方法稳定性的分析结果如表 4 所示,本文方法对 SMAP 的点异常的检测基本稳定在 95% 左右,上下文异常基本稳定在 86% 左右。对 MSL 的点异常的检测基本稳定在 73% 左右,上下文异常基本稳定在 74% 左右。2 种航天器的点异常的检测基本稳定在 79% 左右,上下文异常基本稳定在 82% 左右。可以看出在点异常和上下文异常检测率都有一定程度的提升,上下文异常检测率的提升更为明显。

表 4 基于集成 LSTM 航天器遥测数据异常检测方法稳定性

Table 4 The stability of the spacecraft telemetry data anomaly detection method based on ensemble LSTM

航天器 类型	点异常		上下文异常	
	平均准确率	平均虚警率	平均准确率	平均虚警率
SMAP	95	40	86	57
MSL	73	17	74	14
综合	79	36	82	47

综上所述,通过基于集成 LSTM 的航天器遥测数据异常检测方法与基于 LSTM 的异常检测方法相比,本文方法对点异常和上下文异常的检测率都有不同程度的提升。但对 MSL 的遥测数据异常检测性能仍不如对 SMAP 的遥测数据异常检测,通过数据比对发现,测试集中 MSL 遥测数据异常发生的时间段远小于 SMAP,一些异常少于 200 个样本点,导致此类异常很难被发现。与此同时,该方法通过对遥控指令控制模式的不同,有针对性的训练 LSTM 预测模型,相应地提升了异常检测模型的敏感度,导致虚警率也有所增加,因此在之后的工作中会对异常检测模型进行优化进一步解决异常发生的时长过短及降低虚警率等问题。

4 结 论

本文针对基于 LSTM 的航天器遥测数据异常检测方法受遥控指令多控制模式的影响,对遥测数据全局预测能力会有所下降的问题,提出了基于集成 LSTM 模型的航天器遥测数据异常检测方法。本文主要通过对全局遥控指令控制模式的类别挖掘,构建了多个 LSTM 子模型,并将各子模型的预测输出按一定权重集成,通过基于动态阈值的异常检测模型利用预测结果与实际值的偏差分析实现了异常检测。通过对国内外基于 LSTM 的航天器遥测数据异常检测方法现状的研究,对 NASA 公开的 2 个航天器 (SMAP 以及 MSL) 的遥测数据结合遥测指令进行分析实验,与基于 LSTM 的遥测数据异常检测方法相比,利用遥控指令控制模式挖掘将遥测数据按控制模

式聚类别训练,提升了基于 LSTM 模型的遥测数据预测能力,对点异常以及上下文异常的检测率都有明显提升,其中上下文异常的检测率提升更为明显,这为地面航天器性能判断提供了更有效的检测手段。

本文提出的异常检测方法仍存在不足,对 MSL 的遥测数据的异常检测的性能仍需要提升,整体的异常虚警率过大。后续研究将考虑针对不同飞行器对异常检测的方法进行完善,并对误差的判断方式进行优化,以达到进一步提高异常检测率及降低误判率的要求,使其能满足多种检测需求。

参考文献

- [1] 谭维炽. 我国航天器遥测遥控技术发展的台阶[J]. 遥测遥控, 2016, 37(6): 14-17.
TAN W ZH. The development steps for telemetry and command technology of Chinese spacecraft[J]. Journal of Telemetry, Tracking and Command, 2016, 37(6): 14-17.
- [2] BAY S D, SCHWABACHER M. Mining distance-based outliers in near linear time with randomization and a simple pruning rule [C]. ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2003: 29-38.
- [3] MARTÍNEZ-HERAS J A, DONATI A, KIRSCH M G F, et al. New telemetry monitoring paradigm with novelty detection [C]. International Conference on Space Operations, 2012: 11-15.
- [4] QU ZH W, SU L, WANG X R, et al. A unsupervised learning method of anomaly detection using GRU [C]. IEEE International Conference on Big Data and Smart Computing, 2018: 685-688.
- [5] DU Y, WANG F, SUN CH, et al. Anomaly detection of orbit satellite telemetry sequence based on two-window mode [C]. Chinese Control and Decision Conference, 2018: 1064-1068.
- [6] DU Y, LIANG X, WANG F, et al. Anomaly detection of satellite telemetry in orbit based on sequence and point feature combination [C]. IEEE Data Driven Control and Learning Systems Conference, 2018: 872-878.
- [7] FERNÁNDEZ M M, YUE Y, WEBER R. Telemetry anomaly detection system using machine learning to streamline mission operations [C]. International Conference on Space Mission Challenges for Information Technology, 2017: 70-75.
- [8] 彭宇, 何永福, 王少军, 等. 飞行数据异常检测技术综

- 述[J]. 仪器仪表学报, 2019, 40(3): 1-13.
- PENG Y, HE Y F, WANG SH J, et al. Flight data anomaly detection: A survey [J]. Chinese Journal of Scientific Instrument, 2019, 40(3): 1-13.
- [9] MARTINEZ J. DrMUST-a data mining approach for anomaly investigation [C]. International Conference on Space Operations, 2012: 186-187.
- [10] 孙梅玉. 基于距离和密度的时间序列异常检测方法研究[J]. 计算机工程与应用, 2012, 48(20): 11-17, 22. SUN M Y. Research on discords detect on time series based on distance and density[J]. Computer Engineering and Applications, 2012, 48(20): 11-17, 22.
- [11] 陈静. 卫星遥测数据的时间序列相似性度量方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2015. CHEN J. Similarity measure of time series for satellite telemetry data [D]. Harbin Institute of Technology, Harbin, 2015.
- [12] O'MEARA C, SCHLAG L, FALTENBACHER L, et al. ATHMoS: automated telemetry health monitoring system at GSOC using outlier detection and supervised machine learning [C]. International Conference on Space Operations, 2016: 2347.
- [13] 史欣田, 庞景月, 张新, 等. 基于集成极限学习机的卫星大数据分析[J]. 仪器仪表学报, 2018, 39(12): 81-91. SHI X T, PANG J Y, ZHANG X, et al. Satellite big data analysis based on bagging extreme learning machine[J]. Chinese Journal of Scientific Instrument, 2018, 39(12): 81-91.
- [14] KANARACHOS S, CHRISTOPOULOS S R G, CHRONEOS A, et al. Detecting anomalies in time series data via a deep learning algorithm combining wavelets, neural networks and Hilbert transform [J]. Expert Systems with Applications, 2017, 85(1): 292-304.
- [15] MALHOTRA P, VIG L, SHROFF G, et al. Long short term memory networks for anomaly detection in time series [C]. ESANN 2015 Proceedings, 2015: 89-94.
- [16] CHAUHAN S, VIG L. Anomaly detection in ECG time signals via deep long short-term memory networks [C]. IEEE International Conference on Data Science and Advanced Analytics, 2015: 1-7.
- [17] DU M, LI F F, ZHENG G N, et al. Deeplog: anomaly detection and diagnosis from system logs through deep learning [C]. ACM SIGSAC Conference on Computer and Communications Security, 2017: 1285-1298.
- [18] CHENG M, XU Q, LV J M, et al. MS-LSTM: A multi-scale LSTM model for BGP anomaly detection [C]. IEEE International Conference on Network Protocols, 2016: 1-6.
- [19] HUNDMAN K, CONSTANTINOU V, LAPORTE C, et al. Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding [C]. ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2018: 387-395.
- [20] IAN G, YOSHUA B, AARON C, et al. Deep learning [M]. London: The MIT Press, 2016.
- [21] SEPP H, JURGEN S. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.

作者简介



董静怡, 2015年毕业于哈尔滨理工大学获得学士学位, 2018年毕业于新南威尔士大学, 获得工学硕士学位。现为哈尔滨工业大学电子与信息工程学院博士研究生。现主要研究方向为遥测数据分析与挖掘、故障预测处理以及智能信息处理等。

E-mail: jennied_jiyue@163.com

Dong Jingyi received her B.S. degree from Harbin University of Science and Technology (HUST) in 2015 and M.S. degree from University of New South Wales (UNSW), Australia in 2018. She is currently a Ph. D. candidate in School of Electronics and Information Engineering, Harbin Institute of Technology. Her research interests includes telemetry data analysis and data mining, fault prognosis and intelligent information processing, etc.



刘大同 (通信作者), 分别在 2003 年 2005 年和 2010 年于哈尔滨工业大学获得学士学位、硕士学位和博士学位, 现为哈尔滨工业大学教授、博士生导师, 主要研究方向为自动测试技术、系统状态监测、工业大数据、数据驱动的故障预测和健康管理、锂离子电池管理等。

E-mail: liudatong@hit.edu.cn

Liu Datong (Corresponding author) received his B. Sc., M. Sc. and Ph. D. degrees all from Harbin Institute of Technology in 2003, 2005 and 2010, respectively. He is currently a professor and Ph. D. supervisor in Harbin Institute of Technology. His main research interests include automatic test technology, system condition monitoring, industrial big data, data-driven prognostics and health management, lithium-ion battery management, etc.