

基于循环神经网络的通信卫星故障检测



刘云^{1,2} 尹传环^{1,2} 胡迪³ 赵田³ 梁宇³

1 北京交通大学计算机与信息技术学院 北京 100044

2 交通数据分析与挖掘北京市重点实验室 北京 100044

3 中国空间技术研究院 北京 100094

(17120392@bjtu.edu.cn)

摘要 随着现代航天事业的飞速发展,通信卫星的结构日益复杂,其故障也逐渐增多,通信卫星的故障检测已成为当前航天领域关注的重点问题。目前,各大航天机构对故障的检测仍以简单的上下限阈值检测为主,只能检测出少部分特定的故障。早期利用传统机器学习算法进行检测的研究也仅能检测出数量特征上的故障。针对传统的机器学习算法难以有效学习遥测数据趋势变化的问题,文中提出了基于长短时记忆(Long Short-term Memory,LSTM)网络的阈值化方法。通过 LSTM 预测模型来学习卫星遥测数据的趋势变化,同时以最大化相关系数与 F1 分数的方式为多维遥测数据的故障判定确定合适的阈值,此方式能够有效地通过卫星遥测数据的趋势变化来判断故障。实验数据采用某航天机构提供的时长为 2 年的 24 维通信卫星遥测数据,其核心模型 LSTM 网络在 NVIDIA Corporation GP102[TITAN Xp]上训练,最终整体模型的准确率为 99.34%,查准率为 81.93%,查全率为 94.62%。同时,与传统机器学习算法以及基于 LSTM 的非阈值方法进行对比,该模型的精度明显更高。实验结果表明,LSTM 网络能够高效地学习到卫星遥测数据的趋势变化特征;同时,采用合适的方法选定阈值,能够有效地检测出通信卫星发生的故障,在很大程度上成功地解决航天领域中通信卫星的故障检测难题。

关键词: 遥测数据;故障检测;机器学习;长短时记忆网络;阈值化

中图分类号 TP181

Communication Satellite Fault Detection Based on Recurrent Neural Network

LIU Yun^{1,2}, YIN Chuan-huan^{1,2}, HU Di³, ZHAO Tian³ and LIANG Yu³

1 School of Computer and Information Technology, Beijing 100044, China

2 Beijing Key Laboratory of Traffic Data Analysis and Mining, Beijing 100044, China

3 China Academy of Space Technology, Beijing 100094, China

Abstract With the rapid development of modern space industry, the structure of communication satellites is becoming more and more complex, while its faults are gradually increasing, and fault detection of communication satellites has become a key issue in the current aerospace field. At present, the detection of faults by major space agencies is still based on simple upper and lower threshold's detection. The method is too simple and can only detect a small number of specific faults. Early studies using traditional machine learning for detection can only detect faults in quantitative characteristics. Aiming at the problem that traditional machine learning algorithms are difficult to effectively learn the trend of telemetry data, this paper proposed a thresholding method based on long-short-time memory network. LSTM prediction model is used to learn the trend change of the satellite telemetry data, and at the same time to maximize the correlation coefficient and the F1 score, to determine the appropriate threshold for the fault determination of the multi-dimensional telemetry data. This method can effectively judge the fault by the trend of the satellite telemetry data. The experimental data is based on the 24D communication satellite telemetry data provided by a space agency for 2 years. The core model LSTM network is trained on NVIDIA GTX TITAN X. The final model accuracy is 99.34%, the precision is 81.93%, and the recall rate was 94.62%. At the same time, compared with the traditional machine learning algorithm and the LSTM-based non-threshold method, the accuracy of the model is significantly higher. The experimental results show that the LSTM network can efficiently learn the trend characteristics of satellite telemetry data. At the same time, using the appropriate method to select the threshold value, it can effectively detect the fault of the communication satellite which successfully solve the problem of communication satellite fault detection in the aerospace field.

收稿日期:2019-06-26 返修日期:2019-09-09 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:中央高校基本科研业务费(2018JBZ006)

This work was supported by the Fundamental Research Funds for the Central Universities of Ministry of Education of China (2018JBZ006).

通信作者:尹传环(chhyin@bjtu.edu.cn)

Keywords Telemetry data, Fault detection, Machine learning, Long short-term memory Network, Thresholding

1 引言

现代航天事业飞速发展,航天器的功能日益完善。通信卫星作为航天器的一种,对国计民生有着重要的影响。随着通信卫星结构的日益复杂,其在轨故障率也出现了明显的增加。卫星遥测数据是地面人员了解其在轨运行状态的唯一依据^[1],有着数据量大、维度高、数据关系复杂等特点。根据实时遥测数据,实现通信卫星的故障检测报警,成为了航天领域重点关注的内容。目前,各大航天机构正在使用的故障检测方法以阈值法和专家系统法为主^[2]。该方法简单易行,但缺乏灵活性,无法检测出限定范围内的故障。

为了弥补传统阈值法和专家系统法的缺点,许多相关的机器学习算法被应用于卫星故障检测领域。例如,基于正常行为聚类的 K 近邻(K-Nearest Neighbor, KNN)算法^[2]、K 均值(K-means)聚类算法和 C4.5 决策树算法^[3-4]等可以在只有无标记数据的情况下建立聚类模型,通过欧氏距离和阈值等方式进行故障检测,其缺点在于故障数据必须与正常数据存在明显的分布区别。此外,单类支持向量机(One-Class Support Vector Machine, OCSVM)^[5-6]、主成分分析(Principal Component Analysis, PCA)结合支持向量机(Support Vector Machine, SVM)^[7]等算法能够挖掘出正常数据和故障数据中的潜在特征,从而进行故障检测,但此类方法忽视了时序数据的趋势信息。近年来,深度学习逐步兴起,循环神经网络(Recurrent Neural Networks, RNNs)作为其重要分支,在语音识别、机器翻译等对序列数据处理的问题上表现出了极强的适应性。RNN 以及 RNN 的变体 LSTM 等变体也开始被应用于各个不同类型的时序问题中^[8-13]。然而,此类模型在卫星故障检测领域中仅对单维遥测数据进行研究且成果较少^[14],而目前尚无对卫星多维遥测数据故障检测的研究。

本文主要研究卫星多维时序遥测数据,对卫星系统级的故障进行检测。测试数据为某航天机构提供的通信卫星遥测数据,包含该卫星与地影监测事件相关的 24 个参数,时间长度为 2 年。通过对上述各个模型及其应用场景进行分析比较,本文引入了循环神经网络中的 LSTM 网络^[15]。具体地,本文通过 LSTM 网络来实现对遥测数据各个参数的高性能预测。以此预测模型为基础,在正常数据上进行预测,得到预测误差的高斯分布参数;然后,在带有故障样本的验证集上进行测试,以最大化预测值与真实值的相关系数为目标,为每个参数确定最佳的故障判定阈值;最后,综合判断所有维度的故障情况,通过最大化 F1 分数的方式来计算出故障数阈值,即某时刻发生故障的参数个数超过此阈值则判定为故障。文中详细介绍了实验所采用的网络结构、参数选择、阈值化方法及实验结果,并将所提方法与高斯混合模型(Gaussian Mixed Model, GMM)、K-Means、SVM、BP(Back Propagation)网络以及基于 LSTM 的非阈值化方法进行实验比较,结果展示了基于 LSTM 的阈值化方法在卫星多维遥测数据故障检测中的优异性能。

2 相关工作

在通信卫星的故障检测领域,各航天机构早期以阈值法为主,即专家根据经验对需要检测的各参数设定阈值,当某参数数值变化超过事先设置好的阈值时,便认为发生了故障。虽然阈值法存在极大的局限性,但其计算资源消耗低、适用性强、易于理解等特点,使其仍然是各个航天机构应用最多的故障检测方法^[16-18]。

随着航天领域的发展,对通信卫星的故障检测要求也在提高。基于聚类的算法^[19-20]、基于最近邻的算法^[21-23]、数据降维算法^[24-25]等机器学习算法开始被应用于该领域。这些算法虽然在各自的应用场景中表现出了良好的性能,但都存在着一定的局限性,比如参数选择、可解释性、泛化能力等都存在着问题^[14]。考虑到通信卫星的高度复杂性及可靠性要求,目前阈值法仍处于不可替代的地位。然而,随着数据量的增加以及循环神经网络在相关领域中的逐步推广,这种现象有望发生改变。

近年来,数据量的爆炸式增长与计算机算力的提高,使得深度学习成为了主流。最具有代表性的 LSTM 网络以及其他相关的 RNN 网络,相比于普通的人工神经网络,在对历史信息的保留和对未来信息的预测上实现了巨大的突破。相比于早期的 RNN 网络, LSTM 网络的遗忘门、输入门和输出门的设计使其具备了维持记忆的能力,解决了早期 RNN 网络存在的长时期依赖问题。该网络已经在自然语言处理、时间序列预测、机器翻译等多领域中得到了广泛的应用^[26-27]。

LSTM 的特点使其成为了处理时间序列数据的理想模型,已被尝试应用在多个不同的故障检测任务中^[8-13]。本文针对通信卫星的多维时序遥测数据进行研究,提出了一种基于 LSTM 网络的阈值化方法。该方法利用 LSTM 网络和相关系数的计算实现时序数据的高性能预测与单维遥测数据故障的判定;同时以最大化 F1 分数为目标确定合适的阈值,整合多维时序数据中的信息,实现多维时序遥测数据的故障判定。该方法针对通信卫星系统级的故障进行检测,实验结果良好。

3 循环神经网络在故障检测中的应用

近几年,循环神经网络在文本分类、情感分析、机器翻译^[26-27]等序列数据处理问题上获得了极大的成功,因而有研究者也开始将其运用于时间序列的处理中^[27]。

3.1 循环神经网络

循环神经网络是一种专用于处理序列数据的深度网络。相比传统的人工神经网络(Artificial Neural Network, ANN),循环神经网络加入了“记忆”的成分。例如, (x_1, x_2, \dots, x_m) 可被视作一系列随着时间不断发展的事件序列。如果使用传统的全连接网络对此数据进行处理,该网络会分别对这些输入进行计算,得到相应的 (o_1, o_2, \dots, o_m) 等一系列的输出,但是 o_1, o_2 和 o_m 之间并无关联。循环神经网络的特点在于: o_2 的值不仅仅与 x_2 相关,也依赖于 o_1 的值。循环神经网络的基本结构如图 1 所示。

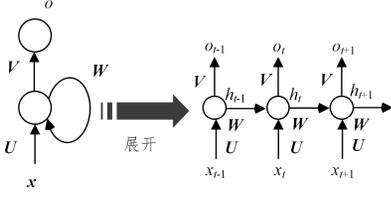


图1 循环神经网络的结构

Fig.1 Structure of RNNs

图1中左半部分为循环神经网络的折叠形式,右半部分为展开形式。其中, x 表示输入的序列数据, h 表示网络的隐藏层状态, o 表示神经元的输出向量; U 为输入层到隐藏层之间的参数矩阵, V 为隐藏层到输出层的参数矩阵, W 为不同时刻隐藏层之间的参数矩阵,所有参数矩阵为不同时间隐藏状态的共享矩阵。该网络的前向传播过程表示为:

$$a_t = b + Wh_{t-1} + Ux_t \quad (1)$$

$$h_t = \tan(a_t) \quad (2)$$

$$o_t = c + Vh_t \quad (3)$$

$$\hat{y}_t = \text{softmax}(o_t) \quad (4)$$

式(1)~式(4)中, x_t 表示输入数据在 t 时刻的输入, h_t 表示隐藏层在 t 时刻的状态, a_t 表示隐藏层在 t 时刻的输入, o_t 表示 t 时刻的输出, \hat{y}_t 表示预测值经过归一化之后的概率输出。

虽然普通的RNN网络已经能够有效地处理序列数据,但由于梯度消失与梯度爆炸的原因,其依然无法处理长时间的时间序列,而LSTM正是为了解决这个问题而产生的。相比于普通的RNN网络,LSTM主要的改进在于多了遗忘门、输入门、输出门等3个控制门的设计,其细胞结构如图2所示。

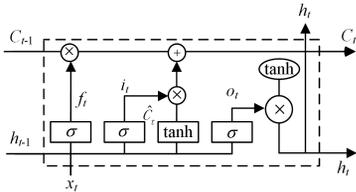


图2 LSTM的细胞结构

Fig.2 Cell structure of LSTM

此细胞结构为LSTM网络单个时刻的细胞结构图,与普通的RNN网络类似,LSTM也是以此细胞结构为单位展开,其中 x_t 表示当前时刻的输入,其前向传播过程表示为:

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (5)$$

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (6)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (7)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (8)$$

式(6)中, f_t 表示遗忘门,它由上一时刻的隐层状态 h_{t-1} 与当前时刻的输入 x_t 生成,大小在0到1之间,控制着上一时刻信息 C_t 的通过程度。式(7)中, i_t 表示输入门,控制着新记忆 \tilde{C}_t 写入长期记忆的程度。LSTM网络中这种跨层连接的设计有效地减弱了梯度消失的影响,使其对长序列的记忆预测能力大大提高。

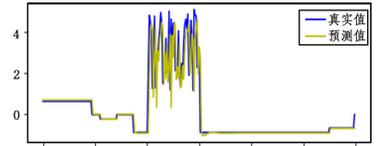
3.2 基于循环神经网络的时序数据故障检测

将时序数据符号化表示为 $X = (X_1, X_2, \dots, X_n)$,其中 X_t 表示时序数据 X 在 t 时刻的值,为一个 m 维的向量,符号化表示为:

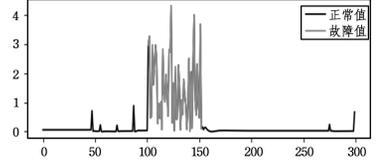
$$X_t = \{X_t^{(1)}, X_t^{(2)}, \dots, X_t^{(m)}\}, X_t \in R^m \quad (9)$$

其中, m 表示时序数据的维数,即卫星遥测数据参数的个数。本文使用LSTM网络来实现对该时序数据的预测。LSTM网络虽然可同时在多维数据上进行学习,但准确性会随着维数 m 的增加而不断降低,这也是目前大多数基于时序数据的故障检测研究仅仅停留在单维数据的原因之一^[14]。本文给多维遥测时序数据的每一个维度各训练了一个LSTM模型,但各模型也仅用于对其单独的一个维度进行预测。

针对单参数的时序数据 $X^{(m)} = (X_0^{(m)}, X_1^{(m)}, \dots, X_n^{(m)})$,其中 $X_n^{(m)}$ 表示时序数据 X 的第 m 个属性在时刻 n 的值。本文取步长 l_i 为LSTM模型的输入数据的时间长度, l_p 为LSTM模型的输出数据的时间长度,为了保证模型的精度,本文取 $l_p = 1$ 。通过对LSTM模型的训练,本文为单参数的每个实际遥测值生成了一个预测值,在有故障的单维时序遥测数据上的预测情况如图3所示。



(a) 单维时序数据的真实值与预测值的变化曲线



(b) 真实值与预测值的误差变化曲线

图3 LSTM的预测效果

Fig.3 Prediction effect of LSTM

从图3中可以明显看出,在时序数据发生故障的部分,LSTM的预测误差明显高于其他未发生故障的部分。此部分变量表示为:

$$x = \{x_0, x_1, \dots, x_t\} \quad (10)$$

$$\hat{x} = \{\hat{X}_0, \hat{X}_1, \dots, \hat{X}_t\} \quad (11)$$

$$e = \{e_0, e_1, \dots, e_t\} \quad (12)$$

$$e_t = |x_t - \hat{X}_t| \quad (13)$$

式(10)为单维时序数据的真实值,式(11)为LSTM预测模型对该数据的预测值,式(12)、式(13)分别表示LSTM模型的预测误差和误差计算方式。实际进行训练预测时,本文通过在仅有正常样本的训练集上训练,得到基于LSTM的预测模型。当用于预测的时序数据 X 都为正常数据时,预测误差必然符合高斯分布 $N(\mu, \delta^2)$ 。本文在无故障的验证集上进行预测,确定高斯分布参数 μ 和 δ 。在实际进行故障检测时,选取标准差倍数 N ,当预测误差满足 $e > \mu + N\sigma$ 时,则认为发生了故障;当预测误差满足 $e < \mu + N\sigma$ 时,则认为未发生故障。

4 多维时序遥测数据的故障判定

第3节介绍了如何将基于LSTM的预测模型用于单参数数据的故障检测。然而,对于通信卫星系统级的故障,本文需要挖掘出多维时序数据中的特征信息,判断与地影监测事件相关的24个参数整体是否为故障。

在前文的基础上,本文对24维遥测数据的每一维分别训练出对应的LSTM预测模型,每一个LSTM预测模型仅用于对相应参数的遥测数据进行预测。利用全部为正常样本的训练集 s_N 进行训练,得到相应的LSTM模型,并在全部为正常样本的验证集 v_{N1} 上进行预测,得到预测误差的高斯分布参数 μ 和 σ 。然后,本文提出了一种基于相关系数与F1分数的阈值化方法,用于实现对多维时间遥测数据故障的判定。

统计学中,在对故障值或离群点的判定方面,应用最广泛的方法为三倍标准差原则,该原则在统计推断尤其是产品的质量检测中有着重要的应用。但是在卫星多维遥测数据中,不同参数的数据特点不同,尤其是数据中的某些变化过大,容易被误判为故障。本文以标准差倍数 N 为调整参数,以最大化相关系数为原则,为每个遥测参数确定最佳故障判定阈值。取 y 为故障实际值, \hat{y} 为故障预测值,两者都为0-1变量,0表示未发生故障,1表示发生故障,计算过程的表达式为:

$$\hat{y}_i = \begin{cases} 0, & e_i \leq \mu + N\delta \\ 1, & e_i > \mu + N\delta \end{cases}, N \in \{0, 1, \dots, 50\} \quad (14)$$

$$r = -\frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} \quad (15)$$

式(14)中, e_i 表示该参数在 i 时刻的预测误差, μ 和 σ 表示该LSTM模型在验证集上的预测误差的均值和标准差。式(15)中, r 为故障实际值 y 与故障预测值 \hat{y} 的相关系数。在统计学领域中,相关系数被广泛应用于衡量两个变量的线性相关性,其值介于-1与1之间,当值为1时,表明两个变量的线性变化完全一致。本文通过最大化相关系数 r 的方式,为每个遥测参数选取一个最合适标准差倍数 N ,从而得出各参数的故障判定阈值。当预测误差 e_i 大于该阈值时,认为该时刻发生了故障。在正常数据上实现LSTM模型的训练,并在验证集上为每个参数确定合适的阈值后,输入多维时序遥测数据可以得到故障判定矩阵,如图4所示。

Parameter IN7 IN17 VN1 ... TN4 TN23

$$\text{time} \left\{ \begin{array}{c} \begin{bmatrix} 0 \\ 0 \\ 1 \\ \vdots \\ 0 \end{bmatrix} \begin{bmatrix} 0 \\ 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \\ 1 \\ \vdots \\ 0 \end{bmatrix} \dots \begin{bmatrix} 1 \\ 0 \\ 1 \\ \vdots \\ 0 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \end{array} \right\}$$

图4 故障判定矩阵

Fig. 4 Fault decision matrix

该矩阵的纵轴为时间轴,横轴为参数轴,每一列代表单个参数的时序数据,对应于通信卫星地影监测事件的24个参数,此矩阵共有24列。得到此故障判定矩阵后,对每行进行求和,得到每个时间发生的故障数。以最大化F1分数为目标,取 $num \in [1, 24]$ 。F分数是机器学习中用来衡量二分类

模型精确度的一个指标,也可以看作是模型查准率和查全率的一种加权平均,其计算表达式如下。

$$F_\beta = (1 + \beta^2) \cdot \frac{\text{precision} \times \text{recall}}{\beta^2 \cdot \text{precision} + \text{recall}} \quad (16)$$

其中, precision 表示查准率,指“正确检索到的结果”占“所有实际被检索到的结果”的比例; recall 表示查全率,指“所有被正确检索到的结果”占“所有应该被检索到的结果”的比例。

对图4中的故障判定矩阵的行求和,得到此多维遥测数据随时间变化的故障数序列 $P = \{P_1, P_2, \dots, P_t\}$,当 t 时刻的故障数 $P_t > num$ 时,则认为该时刻发生了故障。

5 实验结果

本节使用所提方法构建了一个基于LSTM的阈值化方法的通信卫星故障检测模型,并基于某航天机构提供的通信卫星地影监测事件数据测试了该模型。

5.1 实验流程

首先,从某航天机构数据库中获取原始卫星遥测数据,经过数据清洗、数据标准化等流程,将数据划分为训练集、验证集和测试集;然而,通过训练集训练LSTM预测模型,在验证集上进行预测计算,得到合适的阈值;最后,用测试集验证模型效果。

5.2 数据集

实验数据集为某航天机构提供的通信卫星与地影监测事件相关的24维遥测数据,其中包含了该通信卫星2017年至2018年两年时间中地影监测事件的所有记录,共有398346条,大多数为正常数据,故障数据只发生在小部分时间,共有7050条。

本文将数据分为训练集 s_N 、验证集 v_{N1} 和 v_{N2} 、测试集 t_N 。利用全部为正常数据的训练集 s_N 来训练LSTM预测模型,用全部为正常数据的验证集 v_{N1} 来计算预测误差的高斯分布参数,用带有故障数据的验证集 v_{N2} 来计算相应的阈值。最后,采用带有故障数据的测试集 t_N 来验证模型的准确性。

5.3 评价指标

本文引入机器学习领域常用的准确率(accuracy)、查准率(precision)、查全率(recall)作为评价指标。首先,引入以下4个参数。

- 1) TP : 将样本判定为故障样本且实际为故障样本的数量;
- 2) TN : 将样本判定为正常样本且实际为正常样本的数量;
- 3) FP : 将样本判定为故障样本且实际为正常样本的数量;
- 4) FN : 将样本判定为正常样本且实际为故障样本的数量。

对应的评价指标计算方式如下:

$$\text{accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (17)$$

$$\text{precision} = \frac{TP}{TP + FP} \quad (18)$$

$$\text{recall} = \frac{TP}{TP + FN} \quad (19)$$

5.4 实验步骤与结果

所有模型均在NVIDIA Corporation GP102[TITANXp]上训练,训练时长为77h。对全部为正常样本的训练集 s_N 建立LSTM预测模型,采用批量梯度下降法进行训练,通过经验与测试选定最佳模型参数。选定LSTM的输入时间窗口长度

$timestep=300$,输出时间窗口长度为1,设置学习率 $learning_rate=0.1$,批次大小 $batch_size=128$,迭代次数 $epoch=30$ 。模型采用3层LSTM网络结构,3个隐藏层神经元个数分别为64,256,100;为了防止过拟合,取 $dropout$ 为0.2。

在正常样本上训练得到各个遥测参数的LSTM预测模型后,在全部为正常样本的验证集 v_{N1} 上进行预测,得到预测误差的高斯分布参数;在带有故障样本的验证集 v_{N2} 上进行计算。不同于传统的采用三倍标准差原则,本文采用最大化相关系数的方式来计算出每个遥测参数的最佳标准差倍数,计算结果如表1所列。

表1 阈值计算结果
Table 1 Results of threshold

参数名	预测误差 均值(μ)	预测误差 标准差(σ)	标准差 倍数(N)
IN7	0.016	0.061	8
IN17	0.015	0.051	10
VN1	0.065	0.387	1
IN1	0.054	0.11	9
PN1	0.012	0.051	3
PN2	0.054	0.074	4
PN3	0.038	0.053	3
PN4	0.023	0.053	3
VN5	0.035	0.058	4
VN8	0.042	0.06	3
ZS77	0.028	0.057	3
ZS78	0.021	0.052	5
IN3	0.011	0.19	3
IN5	0.017	0.04	13
IN13	0.011	0.215	4
IN15	0.019	0.051	10
ZK17	0.019	0.058	16
ZK19	0.059	0.069	13
TK36	0.06	0.032	6
TK37	0.039	0.022	7
TN1	0.022	0.038	9
TN3	0.015	0.019	26
TN4	0.02	0.021	25
TN23	0.077	0.052	6

对于各个遥测参数,当其预测值 \hat{y} 与真实值 y 满足式(20)时,则认为该参数在该时间为故障点。最后在多维时序遥测数据上进行判定,在验证集 v_{N2} 上,以最大化F1分数为原则,求得综合判断的故障数阈值 num 为5。当某时刻发生故障的参数个数大于 num 时,认为其发生了故障。

$$|\hat{y}-y|>\mu+N\delta \quad (20)$$

将基于LSTM的阈值化方法(简称为LSTM-Threshold)与故障检测领域中的KNN,K-Means,GMM,SVM等传统机器学习算法进行对比,结果如表2所列。

表2 与传统机器学习模型比较

Table 2 Comparison with traditional machine learning models

(单位:%)			
模型	准确率	查准率	查全率
GMM	87.00	4.66	21.83
K-Means	54.91	2.33	41.66
KNN	97.50	0.00	0.00
SVM	97.50	0.00	0.00
BP	97.50	0.00	0.00
LSTM-Threshold	99.34	81.93	94.62

表2的结果表明,传统的机器学习算法中,GMM,K-Means等无监督学习算法倾向于将非故障点判定为故障点,KNN,SVM,BP神经网络等有监督学习算法倾向于将故障点判定为非故障点。这说明此通信卫星的故障数据与正常数据无法通过数据分布进行区分,而通过基于LSTM的方法可以有效地保留其趋势特征,通过变化趋势的异常来判定故障。

将LSTM-Threshold模型与非阈值化的LSTM故障检测模型进行比较,LSTM(3σ)表示对单参数采用三倍标准差原则判断故障,LSTM(one)表示单个参数发生故障即为系统故障,LSTM(3σ ,one)表示对单参数采用三倍标准差原则判断故障且单个参数发生故障即为系统故障。各类模型的检测结果如表3所列。

表3 与基于LSTM的 3σ 模型与one模型比较
Table 3 Comparison with LSTM-based 3σ model and single-dimensional model

(单位:%)			
模型	准确率	查准率	查全率
LSTM(3σ)	99.14	74.34	99.97
LSTM(one)	98.65	64.89	100.00
LSTM(3σ ,one)	92.42	24.77	100.00
LSTM-Threshold	99.34	81.93	94.62

表3的结果表明,LSTM-Threshold更能根据不同参数的特点计算出合适的阈值,也有效减少了因个别参数发生的非故障变化导致的误判,能够同时达到较高的查准率和查全率。所有模型均在相同的训练集、测试集上进行训练和测试,达到了良好的效果。

结束语 本文提出了一种基于LSTM的阈值化方法的通信卫星故障检测模型,用于对多维遥测数据进行研究。实验结果表明,该模型在查准率和查全率方面明显高于其他传统的故障检测模型,可以有效地检测出通信卫星系统级的故障。但该模型进行多维判断时没有考虑各个参数的故障程度,将其同等对待,而且隐含地假设了各维数据分布独立;同时,根据LSTM预测模型计算出时序的预测误差,此预测误差序列将不再具有趋势性和周期性,可以考虑利用传统的机器学习算法对预测误差序列进行故障检测。今后将尝试对这两方面进行改进。

参考文献

- [1] PENG X Y, PANG J Y, PENG Y, et al. Overview of anomaly detection of spacecraft telemetry data[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 1929-1945.
- [2] GAO Y, YANG T, XU M Q, et al. An unsupervised anomaly detection approach for spacecraft based on normal behavior clustering[C]// 2012 Fifth International Conference on Intelligent Computation Technology and Automation. IEEE, 2012: 478-481.
- [3] MUNIYANDI A P, RAJESWARI R, RAJARAM R. Network anomaly detection by cascading k-Means clustering and C4.5 decision tree algorithm[J]. Procedia Engineering, 2012, 30: 174-182.
- [4] MÜNZ G, LI S, CARLE G. Traffic anomaly detection using k-means clustering[C]// GI/ITG Workshop MMBnet. 2007: 13-14.

- [5] ERFANI S M, RAJASEGARAR S, KARUNASEKERA S, et al. High-dimensional and large-scale anomaly detection using a linear one-class SVM with deep learning[J]. *Pattern Recognition*, 2016, 58:121-134.
- [6] AMER M, GOLDSTEIN M, ABDENNADHER S. Enhancing one-class support vector machines for unsupervised anomaly detection[C]// *Proceedings of the ACM SIGKDD Workshop on Outlier Detection and Description*. ACM, 2013:8-15.
- [7] GEORGE A, VIDYAPEETHAM A V. Anomaly detection based on machine learning; dimensionality reduction using PCA and classification using SVM[J]. *International Journal of Computer Applications*, 2012, 47(21):5-8.
- [8] MALHOTRA P, VIG L, SHROFF G, et al. Long short term memory networks for anomaly detection in time series[C]// *23rd European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*. 2015:89.
- [9] NANDURI A, SHERRY L. Anomaly detection in aircraft data using Recurrent Neural Networks (RNN)[C]// *2016 Integrated Communications Navigation and Surveillance (ICNS)*. IEEE, 2016.
- [10] SHEIKHAN M, JADIDI Z, FARROKHI A. Intrusion detection using reduced-size RNN based on feature grouping[J]. *Neural Computing and Applications*, 2012, 21(6):1185-1190.
- [11] BONTEMPS L, MCDERMOTT J, LE-KHAC N A. Collective anomaly detection based on long short-term memory recurrent neural networks[C]// *International Conference on Future Data and Security Engineering*. Cham: Springer, 2016:141-152.
- [12] MALHOTRA P, RAMAKRISHNAN A, ANAND G, et al. LSTM-based encoder-decoder for multi-sensor anomaly detection[J]. *arXiv:1607.00148*, 2016.
- [13] CHENG M, XU Q, LV J, et al. MS-LSTM: A multi-scale LSTM model for BGP anomaly detection[C]// *2016 IEEE 24th International Conference on Network Protocols (ICNP)*. IEEE, 2016:1-6.
- [14] 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*. ACM, 2018:387-395.
- [15] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8):1735-1780.
- [16] CHANDOLA V, BANERJEE A, KUMAR V. Anomaly detection: A survey[J]. *ACM computing surveys (CSUR)*, 2009, 41(3):15.
- [17] GOLDSTEIN M, UCHIDA S. A comparative evaluation of unsupervised anomaly detection algorithms for multivariate data[J]. *PLoS One*, 2016, 11(4):e0152173.
- [18] LI Q, ZHOU X S, LIN P, et al. Anomaly detection and fault diagnosis technology of spacecraft based on telemetry-mining [C]// *2010 3rd International Symposium on Systems and Control in Aeronautics and Astronautics*. IEEE, 2010:233-236.
- [19] ESKIN E, ARNOLD A, PRERAU M, et al. A geometric framework for unsupervised anomaly detection[M]// *Applications of data mining in computer security*. Boston: Springer, MA, 2002:77-101.
- [20] LIU F T, TING K M, ZHOU Z H. Isolation-based anomaly detection[J]. *ACM Transactions on Knowledge Discovery from Data*, 2012, 6(1):1-39.
- [21] BAY S D, SCHWABACHER M. Mining distance-based outliers in near linear time with randomization and a simple pruning rule [C]// *Proceedings of the Ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. ACM, 2003:29-38.
- [22] IVERSON D. Data mining applications for space mission operations system health monitoring[C]// *SpaceOps 2008 Conference*. 2008:3212.
- [23] KRIEGEL H P, KRÖGER P, SCHUBERT E, et al. LoOP: local outlier probabilities[C]// *Proceedings of the 18th ACM Conference on Information and Knowledge Management*. ACM, 2009:1649-1652.
- [24] PAJOUH H H, JAVIDAN R, KHAYAMI R, et al. A two-layer dimension reduction and two-tier classification model for anomaly-based intrusion detection in IoT backbone networks[J]. *IEEE Transactions on Emerging Topics in Computing*, 2016, 7:314-323.
- [25] DE VRIES T, CHAWLA S, HOULE M E. Finding local anomalies in very high dimensional space[C]// *2010 IEEE International Conference on Data Mining*. IEEE, 2010:128-137.
- [26] CHO K, VAN MERRIËNBOER B, BAHDANAU D, et al. On the properties of neural machine translation: Encoder-decoder approaches[J]. *arXiv:1409.1259*, 2014.
- [27] DUAN Y, LV Y, WANG F Y. Travel time prediction with LSTM neural network[C]// *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*. IEEE, 2016:1053-1058.



LIU Yun, born in 1995, postgraduate. His main research interests include machine learning and anomaly detection.



YIN Chuan-huan, born in 1976, associate professor. His main research interests include SVM, machine learning and network security (intrusion detection).