文章编号:1674-8190(XXXX)XX-001-11

基于STL和BI-MLLSTM的航向误差故障事件预测研究

郭建升[1,2],任博[1],曾航[1],贾向阳[2],牛玲[2]
(1.空军工程大学 装备管理与无人机工程学院,西安 710052)
(2.中国人民解放军93920部队,汉中 723000)

摘 要: 航班密集化及航线复杂化对飞机航向精度提出了更高要求,因此准确预测航向误差故障事件(HEFE)对飞机飞行安全及优化维修策略具有重要意义,然而HEFE机理复杂,呈现季节性、非线性及不规则波动性等特点。鉴于此,提出一种局部加权回归季节趋势分解(STL)与双向堆叠式长短期神经网络(BI-MLLSTM)相结合的方法对HEFE进行预测。首先,采用STL方法将HEFE数据分解为解释性较强的周期项、趋势项及剩余项;然后,结合BI-MLLSTM的双向学习及时序处理优势搭建预测模型;最后,将本文模型与其他预测模型进行对比。结果表明:本文模型的MAE和RMSE最低,分别为0.3111、0.3588,能够有效实现HEFE预测。

关键词: 航向误差;故障预测;时间序列;STL分解;BI-MLLSTM神经网络
中图分类号: V328 **文献标识码:** A
DOI: 10.16615/j.cnki.1674-8190.XXXX.XX.01

Research on heading error fault prediction based on STL and BI-MLLSTM

GUO Jiansheng[1,2], REN Bo[1], ZENG Hang[1], JIA Xiangyang[2], NIU Ling[2]
(1. College of Equipment Management and UAV Engineering, Air Force Engineering University, Xi'an 710052, China)
(2. Unit 93920 of the PLA, Hanzhong 723000, China)

Abstract: The increasing density of flight schedules and the complexity of flight routes have raised higher demands for the accuracy of aircraft heading precision. Therefore, accurately predicting Heading Error Fault Events (HEFE) is of significant importance for flight safety and the optimization of maintenance strategies. However, the mechanism of HEFE is complex, showing seasonal, nonlinear and irregular fluctuations. In light of this, this paper proposes a method that combines Seasonal and Trend Decomposition using Loess (STL) with a Bi-directional Multi-layer Long Short-Term Memory Network (BI-MLLSTM) for predicting HEFE. Firstly, the STL method is employed to decompose the HEFE data into highly interpretable seasonal components, trend components, and residuals. Secondly, a predictive model is constructed by leveraging the bidirectional learning and temporal processing advantages of BI-MLLSTM. Finally, compared with other prediction models, the model in this paper has the lowest MAE and RMSE, which are 0.3111 and 0.3588 respectively, which can effectively realize HEFE prediction.

Key words: heading error; fault prediction; time series; STL decomposition; BI-MLLSTM neural

收稿日期: 2025-03-21; **修回日期:** 2025-06-17

通信作者: 郭建升(1987—),男,硕士,工程师。E-mail: 278795895@qq.com

引用格式: 郭建升,任博,曾航,等. 基于STL和BI-MLLSTM的航向误差故障事件预测研究[J]. 航空工程进展,XXXX,XX(XX):1-11.
GUO Jiansheng, REN Bo, ZENG Hang, et al. Research on heading error fault prediction based on STL and BI-MLLSTM[J]. Advances in Aeronautical Science and Engineering, XXXX, XX(XX): 1-11. (in Chinese)

0 引 言

航向误差[1]故障是指飞行器在使用中导航系统出现偏差,与实际航向不符的情况,相应手册规定偏差值超过±2°,即为航向误差故障。近年来,航空产业飞速发展,航班数量迅猛增长,区域航线日趋饱和,空中交通安全压力倍增,对飞机导航设备的可靠性提出更高要求[2]。据调查,飞机空中迷航时有发生,历史上也曾发生多起由于飞机迷航而导致空域冲突、空中相撞、飞机撞山等严重事故,因此确保飞机航向精确无误差,对飞行安全尤为重要。然而航向误差故障却时有发生,据统计,某航空公司近五年年平均航向误差故障50余起,严重影响飞行安全及运行效益。因此利用历史航向误差故障事件(Heading error fault event,HEFE)数据构建航向误差故障事件预测模型,实现故障事件定量预测,提前给出预警信息,是前移故障关口减少空中运行故障的主要手段。也是优化维修策略,减少维修停机时间的重要依据。

故障预测方法分为基于机理模型和基于数据驱动两类[3],对于复杂的飞机导航系统,建立机理模型难度大、精度低且迁移能力有限。基于数据驱动方法随着机器学习、深度学习等算法的发展成为故障预测方法的主流。数据驱动方法以系统历史运维数据为基础,利用数据分析方法提取隐藏信息,从而实现对未来时刻的预测。系统运维数据通常呈现出时间序列特征和非线性关系,因此常用时间序列预测方法进行预测,典型预测方法有自回归(Autoregressive,AR)[4]、滑动平均(Moving Average,MA)[5]、自回归滑动平均模型(Autoregressive Integrated Moving Average,ARIMA)[6],循环神经网络(Recurrent Neural Network,RNN)[7],长短期神经网络(Long Short-Term Memory,LSTM)[8]等。但时间序列大多具有趋势性、季节性及不规则波动性等特点,单一时间序列预测方法难以实现精准预测,因此国内外学者多采用分解方法,将时间序列分解为趋势项、周期项及残差项后再进行组合预测。局部加权回归季节趋势分解(Seasonal and trend decomposition using Loess,STL)方法操作简单、参数少、分量可解释性强,适用于任何类型时间序列分解,成为当前分解算法的主流。

作为飞机重要系统之一,研究人员对飞机导航系统误差进行了研究。周紫君等[10]、韩宾等[11]利用协方差矩阵模型、CNN-BiLSTM回归模型对导航误差进行修正,在一定程度上提高了导航精度;薛永生等[12]利用故障树对航向误差大故障进行分析,精确定位故障原因;成果达等[13]、袁丁等[14]采用长短期记忆网络对导航误差进行补偿,可减小复杂环境下导航误差;严恭敏等[15]将Kalman滤波与误差协方差分析相结合,对导航误差进行分析,为导航误差研究提供了理论依据。

当前,飞机导航系统误差故障预测方面研究文献较少,但在故障诊断领域对其研究较为深入。孙诗源[16]、赵靖等[17]、邓世界[18]利用解析模型与估计迭代等方法实现了无人机导航系统故障智能诊断与完好性监测,为无人机导航系统故障研究工作提供了参考;张晨远等[19]利用迭代双模卡尔曼滤波方法,在飞行仿真数据集上对导航系统传感器开展故障诊断,实现传感器突变及渐变故障诊断;赵善飞等[20]提出改进深度信念网络的组合导航系统故障诊断方法,并在仿真数据集上进行验证,故障识别准确率达到98%;谷一宽[21]采用卷积神经网络对MEMS陀螺仪进行特征提取,并开展故障诊断,平均准确率达到99.16%;陈瑞等[22]基于MHSS-PCA对多源融合导航系统开展故障检测,突变故障检出时间在1 s左右,缓增故障检出时间提前6.5 s左右,为故障预测提供了一定思路。此外,相似系统也在一定程度上开展了故障预测研究,张强等[23]基于GRU模型对仪表着陆系统航向信标故障进行预测,预测精度达到95%以上;李玥[24]利用灰色相关向量机(AGO-RVM)对船用惯导漂移误差开展预测,提高了随机漂移的预测精度;孙昊[25]基于数据驱动方法对导航卫星故障进行预测,为导航卫星健康评估提供有效支撑。上述研究对航向误差故障预测有一定借鉴意义,但仍存在局限性。具体而言,实验数据多为理想实验环境下获得,与设备实际复杂工况环境下的数据有所差异;所用模型多围绕传感器、陀螺仪等单点故障展开,对机队层面故障数量关注较少;上述方法虽然可一定程度提高故障检出率,提高系统可靠性,但对优化维修策略帮助略显不足。

鉴于此,本文梳理某航司机队HEFE数据,将其处理为单变量时间序列,利用时间序列模型开展故障预测。考虑HEFE数据季节性、非线性及不规则波动特点,使用STL算法将HEFE数据分

解为便于解释与预测的季节项(seasonal)、趋势项(trend)与剩余项(resid),并借助BI-MLLSTM算法的双向学习及时序处理优势构建STL-BI-MLLSTM预测模型,以期为航向误差故障事件预测及优化维修策略提供理论依据。

1　模型建立

1.1　基础理论

1.1.1　STL分解

时间序列是指变量依据时间先后顺序呈现出一定的规律性,通常用来描述变量在一定范围内的变化趋势,具有季节性、趋势性、随机性等特点。航向系统误差故障数据属于单变量时间序列,若直接应用此类数据构建预测模型,则无法充分利用数据内在的信息,影响模型的精确度。为提高模型的准确性,需采用时间序列分解方法对数据进行预处理。

STL分解是一种基于局部加权回归(Locally Weighted Scatterplot Smoothing,Loess)进行数据分解的方法,通常应用于水利、煤矿、光伏、新能源等领域。STL通常包括加法模型与乘法模型两种,如公式(1)~公式(2)所示。

$$Y_t = T_t + S_t + R_t, t \in (0, n] \tag{1}$$

$$Y_t = T_t \times S_t \times R_t, t \in (0, n] \tag{2}$$

式中:Y_t为原始数据;T_t为分解出的趋势项;S_t为分解出的季节项;R_t为去除趋势项及季节项后的不规则剩余项。

本文根据实验结果采用加法模型,具体分解过程如下:

步骤①:趋势项估计。使用Losses进行趋势估计,加权函数通常使用核函数进行,如公式(3)所示。

$$T_t = \sum_{i=1}^{n} \omega_i(t) Y_i \tag{3}$$

式中:T_t为趋势估计值;ω_i为权重;Y_i为时间序列原始值。

步骤②:季节项估计。原始序列去除趋势项后,再次利用Losses进行季节估计,此步骤需考虑周期性,即在每个周期内独立完成Losses加权回归,如公式(4)所示。

$$S_t = \sum_{i=1}^{n} \omega_i(t, s)(Y_i - T_i) \tag{4}$$

式中:S_t为趋势估计值;$\omega_i(t, s)$为t时刻计算季节s权重;$Y_i - T_i$为去趋势值。

步骤③:剩余项计算。原始数据去除趋势项及季节项后,即可得到剩余项,剩余项表示时间序列中无法被趋势性和季节性所解释的部分,如公式(5)所示。

$$R_t = Y_t - T_t - S_t \tag{5}$$

步骤④:迭代过程。STL分解是一个不断迭代的过程,即不断重复上述步骤,直至趋势项、季节项及剩余项都逐步收敛,即完成分解。

STL分解包含周期(period)、季节平滑(seasonal)、趋势平滑(trend)、趋势步长(trend_jump)、季节步长(seasonal_jump)、低通滤波步长(low_pass_jump)等关键参数。本文依次遍历各类参数组合,选取趋势项趋势明显、季节项周期稳定、剩余项数值最小的参数组合作为最终实验参数,如表1所示。

表1　STL参数

Table 1　STL parameters

关键参数	周期	季节平滑	趋势平滑
参数值	2	9	13
关键参数	趋势步长	季节步长	低通滤波步长
参数值	2	2	2

1.1.2　LSTM结构

LSTM是一种改进后的RNN网络,主要解决RNN网络训练时所产生的梯度消失或梯度爆炸问题。LSTM引入了三个关键“门”结构,分别为遗忘门(forget gate)、输入门(input gate)和输出门(output gate),用来控制时序信息流动,从而具备长期记忆能力,其网络结构如图1所示。

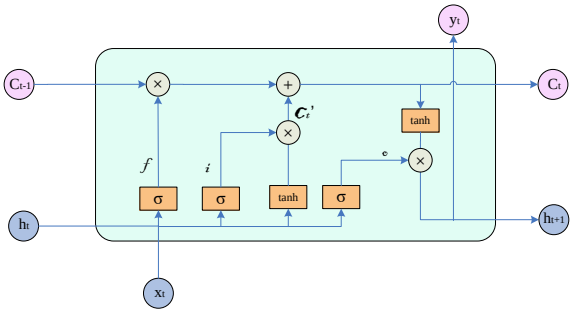

图1　LSTM网络结构

Fig. 1　LSTM network structure

从图 1 可以看出：前一时间步的隐状态 h_t 与当前时间步的输入向量 x_t 合并为综合输入信号，这一信号随后被送入三个关键的门控机制：遗忘门 f、输入门 i 及输出门 o，遗忘门负责调节记忆单元 C_{t-1} 中遗忘信息的程度，输入们则决定将多少新信息注入到当前的记忆单元 C_t 中，输出门则负责调控从当前记忆单元 C_t 中输出信息到隐状态 h_t 与预测输出 y_t 的比例。各单元更新公式如下：

$$f_t=\sigma(W_f x_t+U_f C_{t-1}+b_f) \tag{6}$$

$$i_t=\sigma(W_i x_t+U_i C_{t-1}+b_i) \tag{7}$$

$$o_t=\sigma(W_o x_t+U_o C_{t-1}+b_o) \tag{8}$$

$$c_t=f_t\cdot c_{t-1}+i_t\cdot\sigma(W_c x_t+b_c) \tag{9}$$

$$h_t=o_t\cdot tanh(c_t) \tag{10}$$

式中：W、U 为向量 y_{t-1}、C_{t-1} 的权重；b 为权重。

sigmoid 函数如下：

$$\sigma(x)=\frac{1}{1+e^{-x}} \tag{11}$$

tanh 函数如下：

$$tanh(x)=\frac{e^{x}-e^{-x}}{e^{x}+e^{-x}} \tag{12}$$

1.1.3 BI-MLLSTM 结构

传统的单层 LSTM 网络对数据深层次信息挖掘能力不足，且处理数据时只考虑前向信息，未考虑后向依赖。基于航向误差数据的复杂性与不确定性，本文将单层 LSTM 进行双向堆叠，构成 BI-MLLSTM 网络，以提高预测效果。其结构如图 2 所示。图 2 中输入为 $X_t=\{x_i, i=1,2,3,\cdots,n\}$，输出为 $H_t=\{h_i, i=1,2,3,\cdots,n\}$。

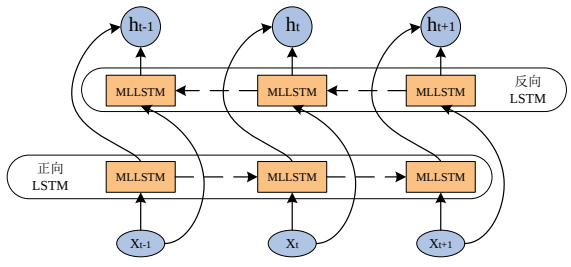

图 2 BI-MLLSTM 网络结构

Fig. 2 BI-MLLSTM network structure

MLLSTM 表示多层 LSTM 网络进行堆叠，便于挖掘数据深层信息；正向 LSTM 与反向 LSTM 构成双向网络，便于挖掘时间序列的正向与反向依赖关系。改进后的模型不仅可以提升模型的训练深度，还可以将正反两方向的信息进行合并，从而提高模型的稳定性与泛化能力。

1.1.4 模型评价指标

为验证模型的有效性，本文采用绝对误差（absolute error，AE）、平均绝对误差（mean absolute error，MAE）、均方根误差（root mean square root，RMSE）作为模型的评价指标，各评价指标公式如下：

$$AE=|(\hat{y}_i-y_i)| \tag{13}$$

$$MAE=\frac{1}{n}\sum_{i=1}^{n}|(\hat{y}_i-y_i)| \tag{14}$$

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

式中：$\hat{y}_i$ 为预测值；y_i 为真实值。

1.2 预测模型构建流程

航向误差故障预测模型流程如图 3 所示，具体步骤如下。

步骤①：数据收集及处理。完成航向误差故障数据收集，并进行 0 值与异常值处理。

步骤②：数据集分解。将数据划分为训练集与测试集，采用 STL 时序分解算法，对训练集进行分解得到趋势项、季节项与剩余项。

步骤③：数据集归一与重构。将分解后各分项数据进行 min-max 归一化，并根据 BI-MLLSTM 模型数据输入要求进行数据重构。

步骤④：开展预测。将重构后各项数据输入模型进行训练，并利用训练好的模型进行滚动预测，得出各分项预测结果。

步骤⑤：分项结果叠加。将各分项预测结果进行叠加，得出航向误差故障最终预测结果。

步骤⑥：模型评价。采用 AE、MAE、RMSE 对模型最终预测效果进行评价。

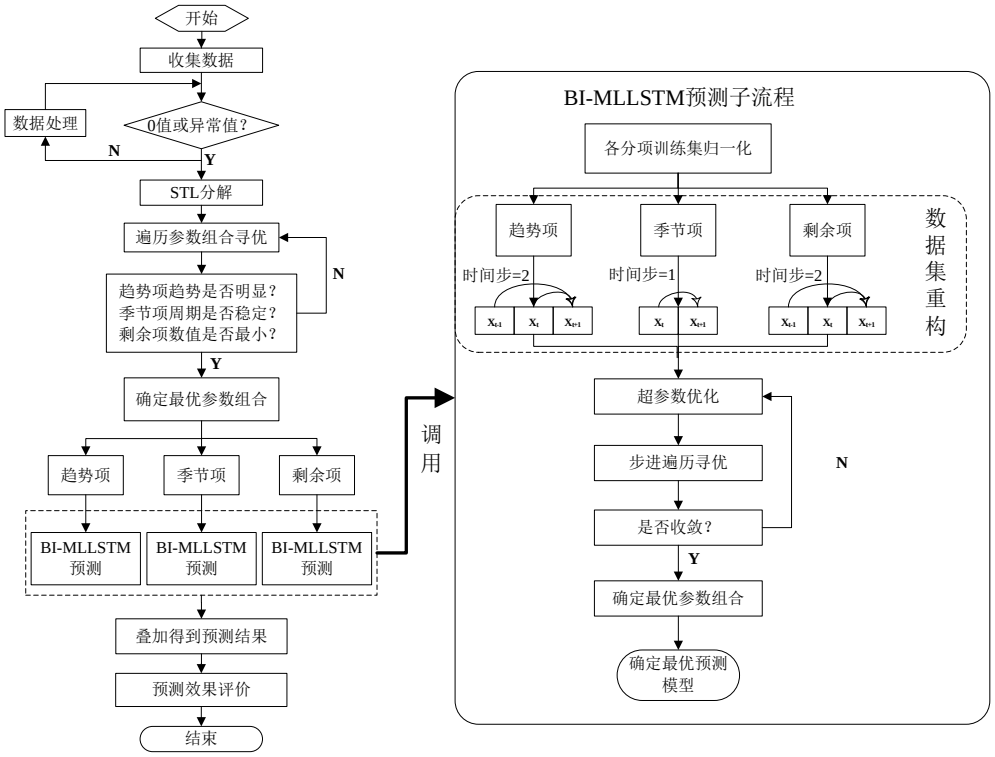

图3　基于STL与BI-MLLSTM航向误差故障预测流程

Fig. 3　Process of the heading error fault prediction based on STL and BI-MLLSTM

2　算例验证

2.1　数据准备

2.1.1　数据收集

本文以某航空公司航向误差故障为研究对象,收集该公司历史航向误差故障数据,并逐月进行统计,共收集故障样本88条,如表2所示。如图4绿色折线所示,横坐标表示月份,纵坐标表示故障发生次数。将数据集进行划分,前80个数据作为训练集,用于模型训练,后8个数据作为测试集,用于检验模型精度。

表2　航向误差故障样本

Table 2　Heading error fault sample

序号	故障事件数	序号	故障事件数
1	2	8	6
2	3	…	…
3	1	84	3
4	1	85	2
5	2	86	0
6	4	87	6
7	0	88	3

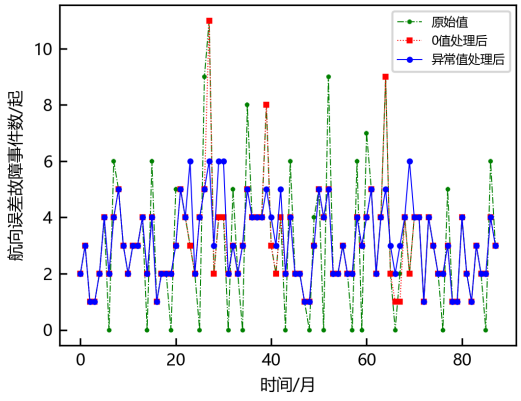

图4　航向误差故障样本折线图

Fig. 4　Heading error fault sample line chart

2.1.2　0值与异常值处理

时序模型预测时应该保证时间序列数据的完整性,数据缺失或异常,则可能会对预测精度产生很大影响。分析故障样本数据发现,故障样本中存在一定量0值以及异常值,如果采用直接删除的方法,则会导致数据不连续,同时也会减少样本数量,对预测精度不利,因此需采用合理的方式处理0值与异常值。

1)0值处理

从表2可以看出:每个0值之后一般伴有突变

值，进一步查阅维修记录，发现突变值的故障数据多数集中当月的前几日，经分析可能的原因为：故障发生后，由于飞行延误、故障验证等原因导致故障录入不及时，将前一月故障记录入至下一月，则会出现前一月为0值，下一月为突变值的情况。根据维修记录，将突变值当月故障数据按2:3比例分配至“0值”月与“突变值月”，按此方法处理后的故障数据如图4红色折线所示，可以看出0值已被处理。

2）异常值处理

将0值处理后的数据进行异常值检测，如图5(a)所示，通常将超出±1.5IQR(IQR为四分位距)的数据定义为异常值。从图5(a)可以看出：故障样本中共3个异常值，分别为样本30、42、67，分析具体原因为航空公司对飞机航向设备进行全面检查，提前更换部分性能参数超差的机件，在数据上则会出现异常值情况。根据故障件工作时间，将样本30的11个数据取出5个，以1:2:2分至后3个样本；将样本42的8个数据取出3个，以1:1:1分至后3个样本；将样本67的9个数据取出4个，以1:1:2分至后3个样本。处理后数据如图5(b)所示，可以看出：数据中已无异常值。经0值与异常值处理后的数据如图4蓝色折线所示，每年9～10月份故障次数相对较多，1～2月份相对较少，故障数据存在一定的季节性规律。

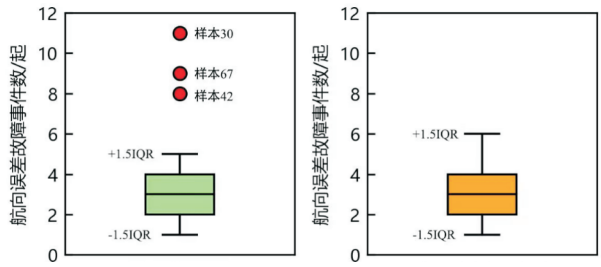

(a) 0值处理后 (b) 异常值处理后

图5 航向误差故障样本箱线图

Fig. 5 Boxplot of heading error fault samples

2.2 数据预处理

2.2.1 故障数据STL分解

STL是基于局部多项式回归拟合方法进行分解，为避免训练集数据包含测试集信息，而使预测模型失去预测意义，因此只将训练集进行分解，分解后可得到趋势项、季节项和剩余项，如图6所示，可以看出：趋势项及季节项可基本反应原始数据的大部分信息，从趋势项可知每月故障数在2～5起范围内波动，且在一段时间内呈现出一定的线性特性，符合时间序列样本特征。季节项反应了故障数据的周期特性，规律性较强，便于进行预测。剩余项则与趋势项、季节项有很大差异，散点图波动较大，规律性较差。

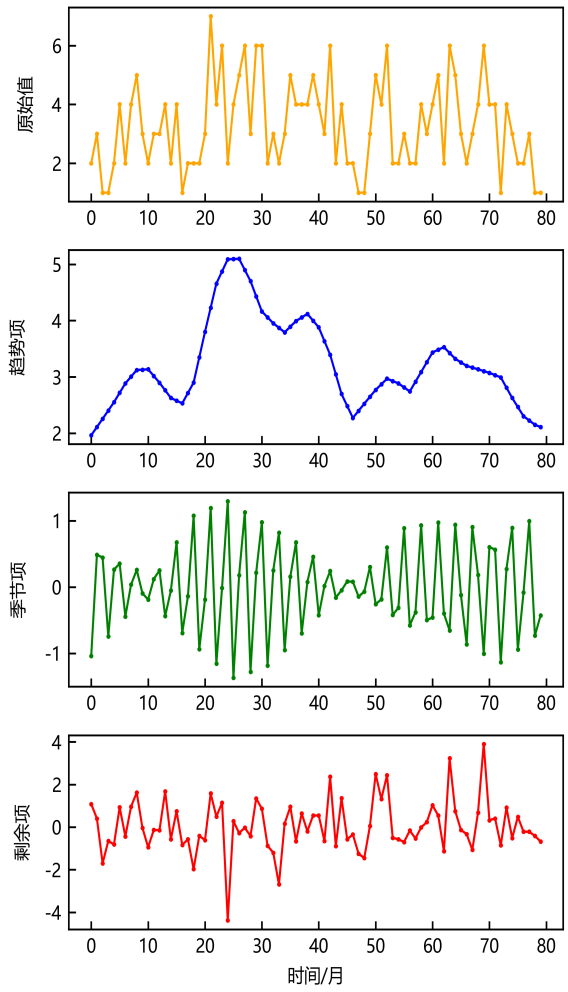

图6 STL分解后的故障数据

Fig. 6 Fault data after STL decomposition

2.2.2 数据集归一与重构

LSTM是一种采用梯度下降方法求解的有监督学习神经网络，不同量纲的数据会对网络模型收敛速度及稳定性产生很大影响，因此在模型训练之前需对数据进行预处理，其中数据归一化可统一数据尺度，提高模型收敛速度以及稳定性；此外，还需对数据集进行重构，以便满足LSTM网络的数据形式。

1) 数据归一化

常见的数据归一化方法包括最小-最大归一化(min-max scaling)、Z得分归一化(Z-score normalization)、小数定标归一化(decimal scaling)等,不同的方法应用于不同的数据类型。经STL分解后的数据无明显异常值且分布相对较为均匀,适用于最小-最大化归一方法,因此本文采取该方法进行数据处理。其公式为:

$$X_{norm}=\frac{X-X_{min}}{X_{max}-X_{min}} \tag{16}$$

式中:X为原始数据样本;X_{norm}为归一化数据样本;X_{max}为样本中的最大值;X_{min}为样本中最小值。

经归一化处理后,趋势项、季节项及剩余项都被缩放至[0,1]区间,便于后续模型训练。

2) 数据集重构

LSTM神经网络结构特点要求对数据集进行重构,即重构为特征集$\{X_n, n=1,2,3,\cdots,n\}$与输出集$\{Y_n, n=1,2,3,\cdots,n\}$的形式,以满足其输入要求。

将本实验数据训练集$X=\{x_1,x_2,x_3,\cdots,x_n\}$($n=80$)进行重构,重构后训练集为:

$$X'=\{x_{t-q},x_{t-q+1},\cdots x_{t-1}\} \tag{17}$$

$$Y=\{y_t\},y_t=x_t \tag{18}$$

X'为输入集,Y为输出集,t为时间序列序号,q为时间步(timestep),且$t=1,2,3,\cdots,80$,$q=1,2,3,\cdots,79$,$q<t$。

即:使用t时刻之前q个时刻的数据对t时刻数据进行预测。本实验中季节项规律性强,便于预测,故将q值设为1。趋势项及剩余项规律性较弱,为了提高模型预测精度,选其时间步$q=2$。重构后的季节项、趋势项和剩余项数据集如下所示。

季节项,$q=1$:

$$\{x_{t-1},y_t\},y_t=x_t \tag{19}$$

其中$t=1,2,3,\cdots,80$。

趋势项和剩余项,$q=2$:

$$\{x_{t-2},x_{t-1},y_t\},y_t=x_t \tag{20}$$

其中$t=1,2,3,\cdots,80$。将重构后的数据集输送至模型进行训练。

2.3　模型训练

本节首先根据STL分解后各分项数据特点选择相应的预测模型,其次针对训练结果调整优化模型超参数,再次将各分项结果相加得到HEFE预测结果并进行预测效果评价,同时将本文提出的方法与其他方法进行对比,得出实验结论。

2.3.1　预测模型选择

合适的预测模型对模型预测精度,泛化能力以及整体性能有着至关重要的影响,因此必须根据数据特点、问题类型等因素对模型进行选择。本研究根据航向误差故障事件的周期及趋势特点,选用BI-MLLSTM网络对分解后的数据分量进行预测。

2.3.2　模型超参数选择

合适的模型参数可提高模型泛化能力,防止模型过拟合或欠拟合,同时能优化模型整体性能。BI-MLLSTM模型需确定的模型超参数有训练次数(epoch)、批大小(batch_size)、隐层数量(layer_size)及隐层节点数(hidden nodes)。本节以季节项为例,分析其预测模型的训练过程,选出最优的模型参数。

1) 训练次数epoch选择

模型训练损失曲线如图7所示,初始训练次数设置为180,可以看出:模型在初始15次训练中,训练损失值由0.32迅速衰减值0.07,15次后训练损失值下降逐渐缓慢,当训练次数epoch=150损失值逐渐趋于收敛,因此选择epoch=150比较合理,既可以满足模型精度,又能提升训练效率。

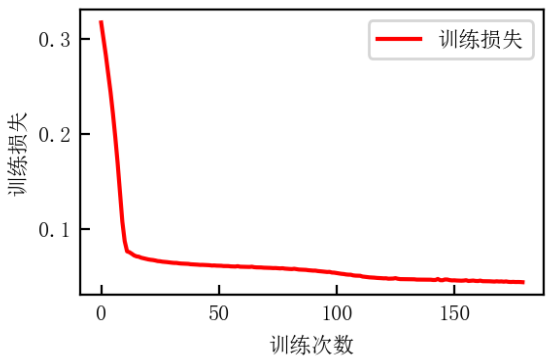

图7　训练损失曲线

Fig. 7　Training loss curve

2) 隐层节点数及隐层数量选择

模型超参数的选择通常有网络搜索、随机搜

索、遗传算法以及重复实验等方法，本文采用重复实验方法，即依次遍历超参数组合，最终确立最优的模型参数组合。以季节项隐层节点数选择为例，固定训练次数 epoch=150，时间步 time_step=1，依据经验依次改变批量大小以及隐层节点数，并以训练均方根误差 RMSE 为评价指标，最终选出最优组合。考虑到训练时梯度下降的随机性，每一种组合进行 10 次实验，求出平均 RSME 作为该组合的评价指标，如表 3 所示。

表 3 不同隐含层节点数与批大小组合 RMSE

Table 3 RMSE of different hidden nodes and batch size combination

隐含层节点数	批大小								
	3	4	…	9	10	11	…	14	15
8	0.227	0.199	…	0.207	0.197	0.203	…	0.206	0.209
9	0.200	0.208	…	0.201	0.189	0.197	…	0.199	0.203
10	0.198	0.202	…	0.193	0.174*	0.178	…	0.188	0.191
11	0.203	0.205	…	0.205	0.193	0.199	…	0.202	0.209
12	0.208	0.207	…	0.207	0.195	0.204	…	0.208	0.209

从表 3 可以看出：模型超参数组合在 hidden_nodes=10，batch_size=10 时 RSME 最小，其值为 0.174，如“*”标记所示，模型效果最优，因此可确定季节项第一层参数为：epoch=150，hidden nodes=10，batch_size=10，time_step=1。同理可确定季节项隐层数量，以及趋势项和剩余项模型的超参数，如表 4 所示。其中，hidden_nodes 中分别代表每一层的隐藏节点数，比如趋势项，从第 1 层至第 4 层依次为 20，25，15，5。

表 4 不同数据分量超参数组合

Table 4 Hyperparameter combinations of different data portions

数据分量	超参数				
	隐层数量	隐层节点数	训练次数	批大小	时间步
季节项	4	10，15，15，5	30	10	1
趋势项	4	20，25，15，5	150	2	2
剩余项	4	10，25，15，5	100	30	2

2.4 结果分析与对比

设置好各模型参数，将训练集输入模型进行训练，并利用训练好的模型预测航向误差故障事件，预测结果如图 8 所示，分别为季节项、趋势项、剩余项以及叠加重构后的最终预测值。其中蓝色折线表示训练集，红色折线表示测试集，绿色折线表示预测值。趋势项预测值对真实值的拟合程度较高，预测值在 2～3 之间呈缓慢增长趋势，说明本文提出的 BI-MLLSTM 模型在趋势项预测中具有较强的可行性；季节项预测值能够较好的还原数据的季节规律，8 个预测值已经呈现出与历史数据相似的波形，说明本模型在季节项预测中取得良好效果；剩余项预测值在 ±0.1 范围内波动，对预测整体效果影响较小；将各分量预测值进行叠加，可得到最终预测结果。从图中可以看出，预测值在 2～3 之间波动，与测试数据接近，且与测试集趋势一致。

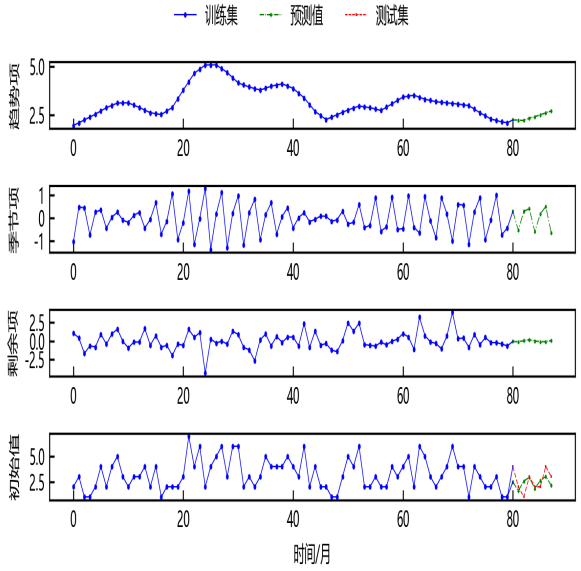

图 8 航向误差预测结果

Fig. 8 Heading error prediction result

为进一步验证模型的有效性，将本文模型与 BIMLLSTM、STL_BILSTM、STL_MLLSTM、

PHOPRET、时间卷积网络(Temporal Convolutional Network, TCN)模型对比,对比模型超参数与本文所提模型一致,结果如图9所示。分析发现本文模型性能优于单独BIMLLSTM模型,说明STL分解所构建的模型对测试集的拟合度优于其他模型。此外,通过与STL_BILSTM、STL_MLLSTM模型对比,说明双向堆叠模型可一定程度提高模型精度。同时与业界经典模型PHOPRET及前言时序模型TCN进行对比,本文模型准确度优于对比模型,进一步说明了本文模型的有效性。

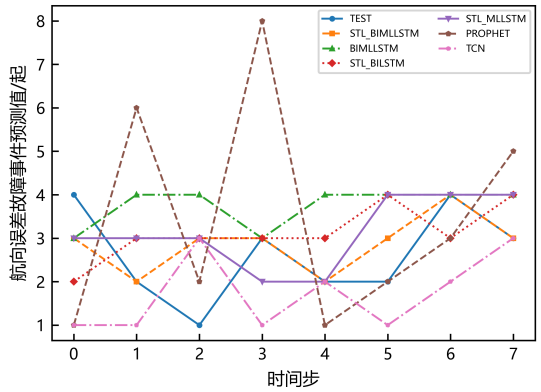

图9　模型结果对比图

Fig. 9　Model result comparison chart

为了更直观的验证模型性能,采用AE、MAE、RMSE对模型进行定量评价。如图10和表5所示。本文所提模型在8个时间步上AE值整体较小,优于其他模型。所提模型的MAE和RMSE在测试集上误差最小,其中MAE为0.31,RMSE为0.36,这说明STL方法可充分挖掘数据背后隐含信息,并进行整理归类,再利用BIMLLSTM的强时间序列处理能力,对数据进行充分学习,所构建出的模型具有更好的稳健性及预测精度。

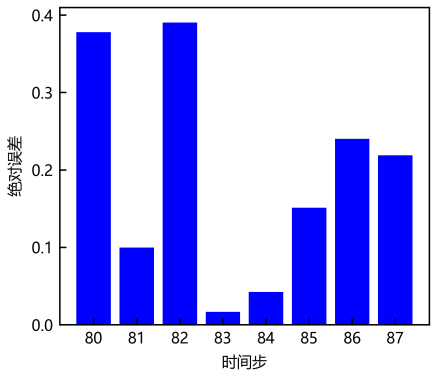

(a) STL－BIMLLSTM绝对误差

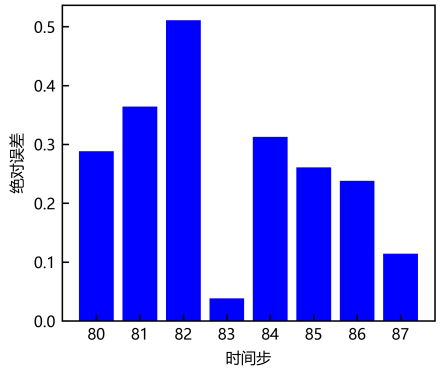

(b) BIMLLSTM绝对误差

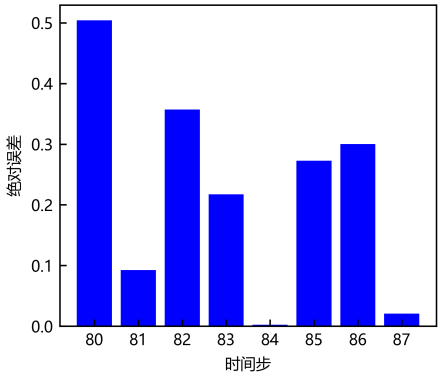

(c) STL－BILSTM绝对误差

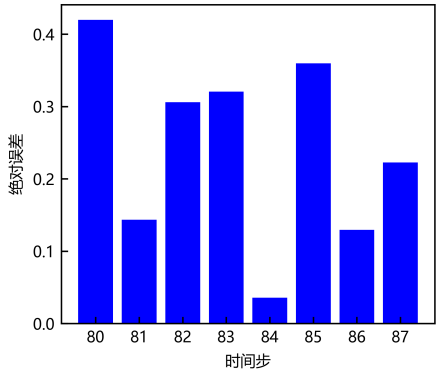

(d) STL－MLLSTM绝对误差

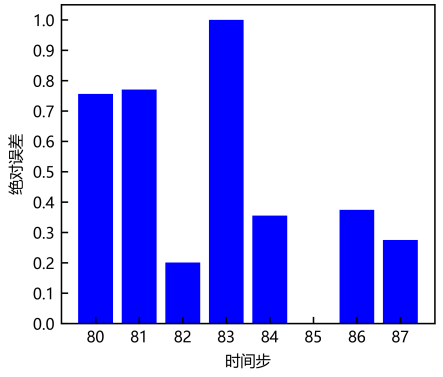

(e) PROPHET绝对误差

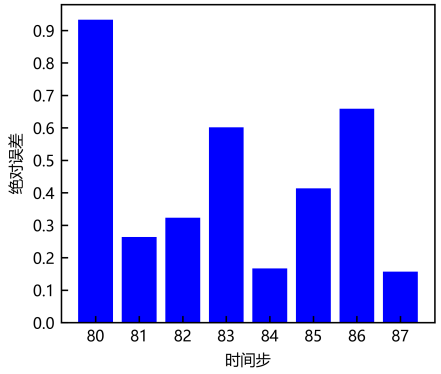

(f) TCN绝对误差

图10 绝对误差对比图

Fig. 10 Absolute error comparison chart

表5 各模型MAE与RMSE

Table 5 MAE and RMSE of various models

方法	MAE	RMSE
STL-BIMLLSTM	0.311 1	0.358 8
BIMLLSTM	0.500 4	0.577 6
STL_BILSTM	0.884 9	1.098 8
STL_MLLSTM	0.970 2	1.088 0
PROPHET	1.867 8	2.258 9
TCN	2.312 3	2.513 6

3 结 论

1) 本文提出的基于SLT和BI-MLLSTM的预测方法在航向误差故障预测中表现出色,AE、MAE及RMSE指标均优于其他对比模型,验证了该方法的有效性。

2) 预测模型可有效预估下月航向误差故障发生数量,维护人员可以合理安排维修活动,提前进行航材调配、人员安排、排故场所申请等工作,从而减少非计划停机时间,优化资源分配,提高运行效率。

3) 该方法不仅适用于航向误差故障预测,未来还可通过梳理分析其他故障模式,验证其在不同故障预测中的适用性。

4) 本文方法的局限性在于数据样本有限,且未考虑飞行时间、飞行架次、系统工作时间等因素的影响,未来研究可进一步扩展数据样本并纳入更多相关因素,以提高模型的泛化能力。

参 考 文 献

[1] 戴洪德, 马宇峰, 戴邵武, 等. 航向误差非线性预测的惯性行人导航零速修正算法[J]. 系统工程与电子技术, 2023, 45(8): 2555-2561.
DAI Hongde, MA Yufeng, DAI Shaowu, et al. Zero velocity update algorithm for inertial pedestrian navigation based on nonlinear prediction of heading error[J]. Systems Engineering and Electronics, 2023, 45(8): 2555-2561. (in Chinese)

[2] MOHTASHAM M M, SARADAR A, RAHMATI K, et al. Predictive models for concrete properties using machine learning and deep learning approaches: a review[J]. Journal of Building Engineering, 2023, 63: 105444.

[3] 周靖南, 唐宏宾, 任广安, 等. 机理模型与数据驱动融合的液压泵变载荷工况故障诊断方法[J]. 电子测量与仪器学报, 2025, 39(4): 247-257.
ZHOU Jingnan, TANG Hongbin, REN Guang'an, et al. Fault diagnosis method for hydraulic pumps under variable load conditions based on the fusion of mechanistic models and data-driven approaches[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(4): 247-257. (in Chinese)

[4] BEHROOZ H, ILBEIGI M. A deep learning autoregressive forecasting model for probabilistic water pipe break prediction[J]. Journal of Computing in Civil Engineering, 2025, 39(4): 04025044.

[5] JACK M W, BANDI M M. Extreme value statistics of peak residential electricity demand: Effect of aggregation and moving-average smoothing[J]. Sustainable Energy, Grids and Networks, 2025, 42: 101674.

[6] 黄世泽, 张肇鑫, 张帆, 等. 基于自回归滑动平均模型的道岔动作电流故障曲线预测方法[J]. 城市轨道交通研究, 2022, 25(12): 52-55.
HUANG Shize, ZHANG Zhaoxin, ZHANG Fan, et al. Prediction method of ARMA-based turnout operation current fault curve[J]. Urban Mass Transit, 2022, 25(12): 52-55. (in Chinese)

[7] 张学友, 石永建, 李冀, 等. 应用LSTM-RNN的特高压直流输电系统继电保护故障检测方法[J]. 中国测试, 2025, 51(3): 177-184.
ZHANG Xueyou, SHI Yongjian, LI Ji, et al. Research on fault detection method of UHV DC transmission system relay protection based on LSTM-RNN[J]. China Measurement & Test, 2025, 51(3): 177-184. (in Chinese)

[8] ZENG H, GUO J S, ZHANG H M, et al. Research on aviation safety prediction based on variable selection and LSTM[J]. Sensors, 2023, 23(1): 41.

[9] ZENG H, ZHANG H M, GUO J S, et al. A novel hybrid STL-transformer-ARIMA architecture for aviation failure events prediction[J]. Reliability Engineering & System Safety, 2024, 246: 110089.

[10] 周紫君, 郁丰, 吴方, 等. 一种机载惯性/光电组合导航误差修正方法[J]. 中国惯性技术学报, 2024, 32(8): 779-786, 794.
ZHOU Zijun, YU Feng, WU Fang, et al. Error correction method for airborne SINS/EODS integrated navigation[J]. Journal of Chinese Inertial Technology, 2024, 32(8): 779-

786, 794. (in Chinese)

[11] 韩宾, 邵一涵, 罗颖, 等. GNSS拒止时基于并行CNN-BiLSTM回归和残差补偿的UAV导航误差校正方法[J]. 湖南大学学报(自然科学版), 2024, 51(8): 57-69.
HAN Bin, SHAO Yihan, LUO Ying, et al. Method based on parallel CNN-BiLSTM regression and residual compensation for correcting UAV navigation error in GNSS denied environment[J]. Journal of Hunan University (Natural Sciences), 2024, 51(8): 57-69. (in Chinese)

[12] 薛永生, 宋立廷. 航向姿态参考系统磁航向误差偏大故障分析[J]. 航空工程进展, 2021, 12(6): 142-146.
XUE Yongsheng, SONG Liting. Failure analysis on magnetic heading error of AHRS[J]. Advances in Aeronautical Science and Engineering, 2021, 12(6): 142-146. (in Chinese)

[13] 成果达, 岳亚洲, 韦彦一, 等. 复杂环境下基于自监督LSTM网络的导航误差建模补偿[J]. 中国惯性技术学报, 2024, 32(2): 115-124.
CHENG Guoda, YUE Yazhou, WEI Yanyi, et al. Navigation error modeling and compensation via self-supervised LSTM network in complex environments[J]. Journal of Chinese Inertial Technology, 2024, 32(2): 115-124. (in Chinese)

[14] 袁丁, 王艳红, 雒旭峰. 基于自适应滤波的无人机视觉导航误差补偿方法研究[J]. 中国安全生产科学技术, 2023, 19(6): 193-198.
YUAN Ding, WANG Yanhong, LUO Xufeng. Study on error compensation method of UAV visual navigation based on adaptive filtering[J]. Journal of Safety Science and Technology, 2023, 19(6): 193-198. (in Chinese)

[15] 严恭敏, 陈浩然, 李静, 等. 一种基于实测飞行轨迹的惯导误差分析方法研究[J]. 导航定位与授时, 2024, 11(3): 58-65.
YAN Gongmin, CHEN Haoran, LI Jing, et al. Covariance analysis for INS errors based on in-field measured flight trajectory[J]. Navigation Positioning and Timing, 2024, 11(3): 58-65. (in Chinese)

[16] 孙诗媛. 无人机导航系统智能故障诊断方法的研究[D]. 成都: 电子科技大学, 2024.
SUN Shiyuan. Research on intelligent fault diagnosis method for UAV navigation system[D]. Chengdu: University of Electronic Science and Technology of China, 2024. (in Chinese)

[17] 赵靖, 宋丹. 无人机GNSS/IMU组合导航系统完好性监测方法[J]. 航空学报, 2024, 45(7): 328943.
ZHAO Jing, SONG Dan. Integrity monitoring method for GNSS/IMU integrated navigation system of UAV[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(7): 328943. (in Chinese)

[18] 邓世界. 无人机IMU阵列融合与多源导航系统故障诊断技术研究[D]. 成都: 西南交通大学, 2023.
DENG Shijie. Research on UAV IMU array fusion and multi-source navigation system fault diagnosis technology [D]. Chengdu: Southwest Jiaotong University, 2023. (in Chinese)

[19] 张晨远, 刘海颖. 基于迭代双模型卡尔曼滤波的惯性传感器故障诊断方法[J/OL]. 系统工程与电子技术, 2025: 1-10. (2025-01-03). https://kns.cnki.net/kcms/detail/11.2422.TN.20250102.1453.031.html. ZHANG Chenyuan, LIU Haiying. Fault diagnosis method of inertial sensor based on iterative double-model extended Kalman filter[J/OL]. Systems Engineering and Electronics, 2025: 1-10. (2025-01-03). https://kns.cnki.net/kcms/detail/11.2422.TN.20250102.1453.031.html. (in Chinese)

[20] 赵善飞, 张华强, 贾明玉, 等. 改进深度信念网络的组合导航系统故障诊断方法[J]. 探测与控制学报, 2024, 46(6): 65-71.
ZHAO Shanfei, ZHANG Huaqiang, JIA Mingyu, et al. Improved deep belief network of fault diagnosis integrated navigation systems[J]. Journal of Detection & Control, 2024, 46(6): 65-71. (in Chinese)

[21] 谷一宽. 基于卷积神经网络的MEMS陀螺仪特征提取与故障诊断研究[D]. 太原: 中北大学, 2024.
GU Yikuan. Research on feature extraction and fault diagnosis of MEMS gyroscope based on convolutional neural network[D]. Taiyuan: North University of China, 2024. (in Chinese)

[22] 陈瑞, 赵龙. 基于MHSS-PCA的多源融合导航自主完好性监测方法[J]. 导航与控制, 2024, 23(增刊1): 57-68.
CHEN Rui, ZHAO Long. Autonomous integrity monitoring method for multi-source fusion navigation based on MHSS-PCA[J]. Navigation and Control, 2024, 23(s1): 57-68. (in Chinese)

[23] 张强, 祁江涛, 焦浩博, 等. 基于GRU的仪表着陆系统故障预测方法研究[J]. 航空工程进展, 2024, 15(3): 62-70.
ZHANG Qiang, QI Jiangtao, JIAO Haobo, et al. Research on fault prediction method of instrument landing system based on gate recurrent unit[J]. Advances in Aeronautical Science and Engineering, 2024, 15(3): 62-70. (in Chinese)

[24] 李玥. 船用某型电源及惯导部件故障预测系统研制[D]. 哈尔滨: 哈尔滨工业大学, 2018.
LI Yue. Development of fault prediction system for specific marine power supply and inertial navigation components [D]. Harbin: Harbin Institute of Technology, 2018. (in Chinese)

[25] 孙昊. 数据驱动的导航卫星故障检测与预测方法研究与系统实现[D]. 北京: 中国电子科技集团公司电子科学研究院, 2023.
SUN Hao. Research on data-driven fault detection and prediction methods for navigation satellites with system implementation[D]. Beijing: China Academy of Electronics and Information Technology, 2023. (in Chinese)

(编辑:马文静)