

基于飞行数据的 MSCNN-LSTM 水平安定面系统状态监测方法

张鹏^a, 胡芳语^b, 段照斌^a, 刘静静^b

(中国民航大学 a.工程技术训练中心, b.电子信息与自动化学院, 天津 300300)

摘要: 针对真实飞行数据中故障样本匮乏、数据类间失衡且缺少标注问题, 本文提出了一种基于多尺度卷积神经网络(MSCNN, multi-scale convolutional neural network)与长短时记忆(LSTM, long short-term memory)网络的水平安定面系统状态监测方法。此方法不依赖于标注数据, 利用无监督学习的方式对水平安定面系统进行状态监测。首先, 利用 MSCNN-LSTM 对系统正常运行状态的快速存取记录器(QAR, quick access recorder)数据从空间和时间两个维度进行特征提取, 以实现舵面位置预测; 其次, 计算舵面位置预测值与舵面位置实际值的残差, 分析残差分布来确定系统健康状态的阈值; 最后, 利用某飞机的 QAR 数据进行验证。实验结果表明, 本文所提方法能准确实现水平安定面系统飞行级的异常状态识别, 并能在系统发生故障时, 提前 1 个飞行循环进行异常预警。

关键词: 飞行数据; MSCNN-LSTM; 水平安定面; 状态监测; 无监督学习

中图分类号: TP181 **文献标志码:** A **文章编号:** 1674-5590(2025)01-0060-07

MSCNN-LSTM method for monitoring the state of horizontal stabilizer system based on flight data

ZHANG Peng^a, HU Fangyu^b, DUAN Zhaobin^a, LIU Jingjing^b

(a. Engineering Techniques Training Center, b. College of Electronic Information Engineering, CAUC, Tianjin 300300, China)

Abstract: To address the problems of insufficient fault samples, imbalanced data classes and lack of labeling in real flight data, a state monitoring method for a horizontal stabilizer system based on multi-scale convolutional neural network (MSCNN) and long short-term memory (LSTM) network is proposed in this paper. This method does not rely on labeled data and uses unsupervised learning to monitor the state of the horizontal stabilizer system. Firstly, the quick access recorder (QAR) data of the system in normal operation are extracted in both spatial and temporal dimensions using MSCNN-LSTM to achieve rudder position prediction. Secondly, the residuals between the predicted and actual values of the rudder position are calculated and the distribution of the residuals is analyzed to determine the threshold for the health state of the system. Finally, the QAR data of an aircraft is used for verification, and the experimental results show that the proposed method in this paper can accurately achieve the abnormal state identification of the horizontal stabilizer system at the flight level and can provide an abnormal alarm one flight cycle in advance when system failure occurring.

Key words: flight data; MSCNN-LSTM; horizontal stabilizer; state monitoring; unsupervised learning

飞行数据几乎涵盖了飞机所有系统的传感器数据, 记载了飞机驾驶员的操纵、飞行参数及系统工作信息, 挖掘飞行数据中的内在规律和潜在信息, 对飞机状态监控、故障诊断等应用具有重要意义^[1-3]。

近年来, 随着大数据和深度学习技术的快速发展, 海内外学者开展了结合深度学习技术的飞行数据挖掘的相关研究^[4]: 文献[5]利用长短时记忆(LSTM, long short-term memory)网络捕获飞行数据中的时间依赖

性, 选取相关参数对飞机的着陆距离进行预测, 进而降低飞机长距离着陆溢出跑道的风险; 文献[6]利用 LSTM 对飞机发动机的剩余使用寿命进行预测, 并使用贝叶斯优化算法对 LSTM 的参数进行寻优, 使其预测效果更佳; 文献[7]在无人机真实的飞行数据中, 利用卷积神经网络(CNN, convolutional neural network)与 LSTM 相融合的方式建立执行器的故障诊断模型, 使其诊断准确率更高。

可见,基于深度学习技术的飞行数据挖掘可以取得良好效果。然而,与飞行控制系统的飞行数据有关的研究^[8-10],都是通过搭建相应的仿真平台获取丰富的数据量来开展相关工作,这是由于在实际飞机运行数据中,故障数据较为匮乏,故障样本存在数据量不充足、样本类间失衡且缺乏标注等问题,致使难以建立有效的深度学习算法模型。

为解决上述飞行控制系统的飞行数据挖掘工作中存在的问题,本文通过参考文献[11]中的研究方法,提出以快速存取记录器(QAR, quick access recorder)数据为实验研究基础,以水平安定面系统为研究对象,建立基于多尺度卷积神经网络与长短时记忆网络(MSCNN-LSTM, multi-scale CNN-LSTM)堆叠的状态监测模型。此方法旨在挖掘飞行数据中的隐含信息,无须依赖故障数据,仅通过飞机历史正常运行数据即可完成系统状态监测模型的建立,实现在无标注数据下水平安定面系统的状态监测。实验结果表明,本文所提方法可准确监测水平安定面系统飞行级的运行状态。

1 水平安定面系统分析及状态监测方法

1.1 系统分析

水平安定面系统是飞行控制系统的重要组成部分,其主要功能是实现飞机的俯仰配平^[12]。

B787 型飞机的水平安定面伺服机构主要由水平安定面作动器(HSTA, horizontal stabilizer trim actuator)、2 个电动马达控制单元(EMCU, electric motor control unit)、3 个安定面位置模块(stabilizer position module)、3 个水平安定面负载传感器(horizontal stabilizer load sensor)等构成。

HSTA 作为系统的关键部分,是机身与水平安定面的结构连接,如图 1 所示,HSTA 通过 2 个电动马达驱动水平安定面。

HSTA 中位置传感器共有 3 个,其主要功能是反馈舵面位置信息和监控故障。其中 2 个位置传感器分别向 2 个 EMCU 发送数据信息,另一个位置传感器直接向飞行控制电子设备(FCE, flight control electronics)发送数据信息。

HSTA 中负载传感器共有 3 个,其主要功能是检测主负载路径的磨损状态或结构故障,2 个位于 HSTA 下部,1 个位于 HSTA 上部。

EMCU 的主要功能为:接收 FCE 的指令并依据




图 1 水平安定面作动器

Fig.1 Horizontal stabilizer trim actuator

FCE 的指令信息控制电动马达移动安定面的速率,并且 EMCU 还收集 HSTA 中的舵面位置传感器数据和负载传感器数据并发送给 FCE。

1.2 状态监测方法

QAR 数据记录了飞机上千个不同的飞行参数,几乎涵盖了飞机所有系统的传感器数据^[13]。QAR 数据的特点为:①时间相关性;②空间相关性;③无标注。

本文基于 QAR 数据提出一种改进的 MSCNN-LSTM 水平安定面系统状态监测方法,具体监测流程如图 2 所示。

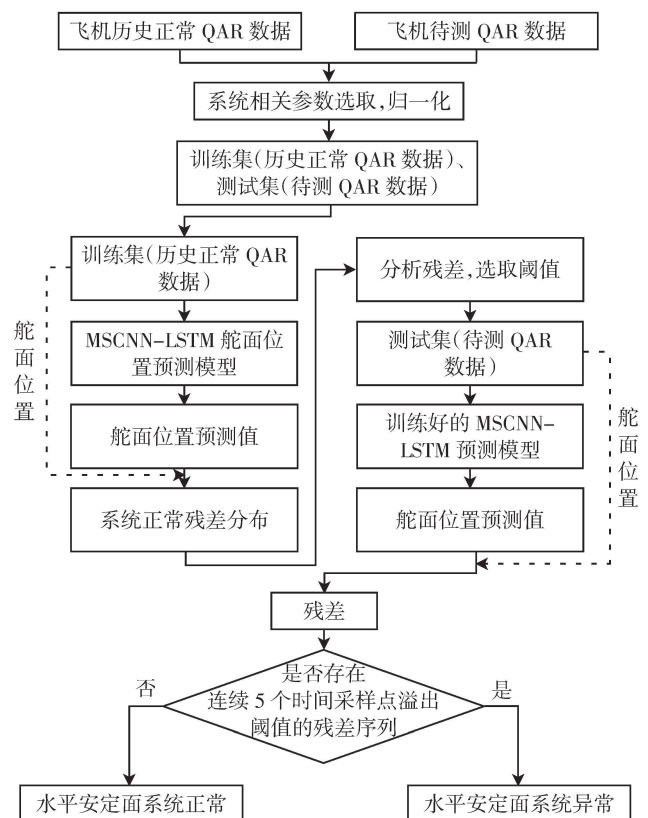


图 2 水平安定面系统状态监测流程图

Fig.2 Flow chart of horizontal stabilizer system state monitor

首先,获取飞机历史正常运行状态下的 QAR 数据以及飞机待测 QAR 数据中水平安定面系统特征参数数据,对其进行归一化处理并划分训练集和测试集;然后,利用训练集训练 MSCNN-LSTM 舵面位置预测模型,训练完成后,输出水平安定面系统舵面位置预测值,得到水平安定面系统健康状态下预测值与实际值的残差分布,并进行阈值的选取;最后,将飞机待测 QAR 数据输入训练好的预测模型,使预测模型输出其舵面预测值并计算与舵面位置实际值的残差,结合阈值判断水平安定面系统的运行状态。此外,考虑到 QAR 数据中瞬时异常点的存在,结合本文所用参数在 QAR 数据中的采样间隔为 1 s,将待测数据中,存在残差连续 5 次溢出阈值的飞行循环定义为水平安定面系统状态异常。

2 相关算法

2.1 卷积神经网络

CNN 作为一种前馈神经网络具有强大的特征提取能力^[14-15]。卷积层由多个卷积单元组成,通过感受野对输入进行一定规律的滑动,并在对应的区域内进行卷积运算,卷积运算的结果经过激活函数的作用得到当前卷积层提取的特征。其卷积运算公式为

$$f_i^{\text{out}} = a(\cdot) \sum (x_i^j * w_i^j + b_i^j) \quad (1)$$

式中: f_i^{out} 是第 i 层卷积后的特征输出; x_i^j 表示第 i 层第 j 个被卷积的区域;“*”表示卷积运算; w_i^j 表示第 i 层第 j 个权值参数; b_i^j 是第 i 层第 j 个卷积偏置项; $a(\cdot)$ 是激活函数。

池化层通常位于卷积层之后,主要作用是提取主要特征,降低数据维度,减少网络计算的运算量,防止过拟合。两者的交替连接,构成了 CNN 的核心模块。

2.2 长短时记忆网络

LSTM 作为循环神经网络(RNN, recurrent neural network)的变体,相较于传统的 RNN,记忆单元的引入使 LSTM 能够长时间有选择地保留在早期阶段检测到的输入重要特征,解决了传统 RNN 长期依赖的问题^[16]。LSTM 主要由 3 个门控单元构成,结构如图 3 所示。图 3 中: x_t 表示当前时刻的输入值; h_{t-1} 和 h_t 分别表示上一时刻和当前时刻的输出值; c_{t-1} 和 c_t 分别表示上一时刻和当前时刻细胞的信息状态;LSTM 有 3 个门限,分别为遗忘门 f_t 、输入门 i_t 、输出门 o_t 。




图 3 LSTM 结构图

Fig.3 Structure diagram of LSTM

经过遗忘门之后的输出为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

式中: W 、 b 分别表示相应的权重和偏置项; $\sigma(\cdot)$ 表示 Sigmoid 激活函数。 h_{t-1} 、 x_t 经过 Sigmoid 函数和 tanh 函数处理之后相乘,确定结果中写入当前细胞 c_t 的信息,公式如下

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

c_{t-1} 更新为 c_t , 此时的 c_t 中包含当前时刻输入的有用信息和此前输入中保留的有用信息,公式如下

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (5)$$

上一时刻的输出 h_{t-1} 与当前时刻的输入 x_t 经过激活函数 σ 输出得到 o_t , c_t 经过激活函数 tanh 与 o_t 进行乘积运算完成对 h_t 的更新,即

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t \times \tanh(c_t) \quad (7)$$

2.3 Squeeze-and-Excitation 网络

SENet(squeeze-and-excitation networks)的主要作用是在网络训练过程中,对输入的多个通道特征按照重要程度进行权值分配,强化重要程度较高的通道,削弱重要程度较低的通道^[17]。SENet 的关键操作为:挤压(squeeze)、激励(excitation)、缩放(scale)。具体步骤如图 4 所示。

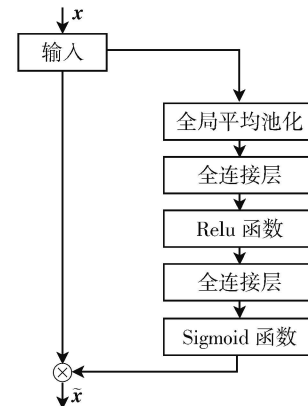


图 4 SENet 运算步骤流程图

Fig.4 Flow chart of SENet operation steps

图 4 中:输入经过全局平均池化实现 squeeze 操作,得到全局特征信息图;然后使用沙漏型结构的 2 层全连接层对特征信息进行降维、升维,并使用 Sigmoid 激活函数生成特征通道权值完成 excitation 操作;最后, scale 操作是将权值对原始输入 x 进行加权处理得到 \tilde{x} 。

3 水平安定面系统状态监测实验

3.1 数据准备

依据水平安定面系统分析,从 QAR 数据中抓取相应的安定面特征参数:安定面负载传感器参数(3 个)、安定面位置传感器参数(3 个)以及安定面位置指示器参数(1 个),共计 7 个特征参数如表 1 所示。

表 1 安定面特征参数表

Tab.1 Table of characteristic parameters of stabilizer

参数	参数名称	参数含义	单位
A	STABLDSNSRLWRL	安定面左下部负载传感器	Inches
B	STABLDSNSRLWRR	安定面右下部负载传感器	Inches
C	STABLDSNSRUPRL	安定面上部负载传感器	Inches
D	STABPOSN1	安定面位置传感器 1	Degree
E	STABPOSN2	安定面位置传感器 2	Degree
F	STABPOSN3	安定面位置传感器 3	Degree
G	STABPOSNVOT	安定面位置指示器	Units

表 1 中的参数 G 对应图 2 监测流程图中的舵面位置。根据 B787 的飞机维修手册(AMM, aircraft maintenance manual)可知:参数 $G = 4$ 时,水平安定面为中立状态;参数 $G < 4$ 时,水平安定面为“NOSE DOWN”向下修正状态;参数 $G > 4$ 时,水平安定面为“NOSE UP”向上修正状态。

3.2 状态监测模型

本文基于深度学习框架 TensorFlow 来搭建相关算法模型。水平安定面系统状态监测模型可大致分为 2 部分:舵面位置预测模型和阈值选取。

3.2.1 舵面位置预测模型

对于舵面位置预测模型,根据 QAR 数据的时间相关性、空间相关性等特点建立 MSCNN-LSTM 预测模型^[8],结构如图 5 所示。其中:输入为 QAR 数据中安定面的特征参数(表 1 中的参数 A~F);输出为模型输出的预测值(表 1 中的参数 G 舵面位置);“?”表示预测模型批训练数量,本文取值为 100,即对 100 个连续时间点的 QAR 数据进行批训练;Conv1D 表示一维卷积运算。使用多尺度卷积网络,在空间维度上对 QAR 数据进行特征提取,获得更丰富、宽泛的特征信息。然后,再利用 LSTM 进行时间维度上的特征提取^[9],使模型

具有空间和时间双重特征的表达能力。

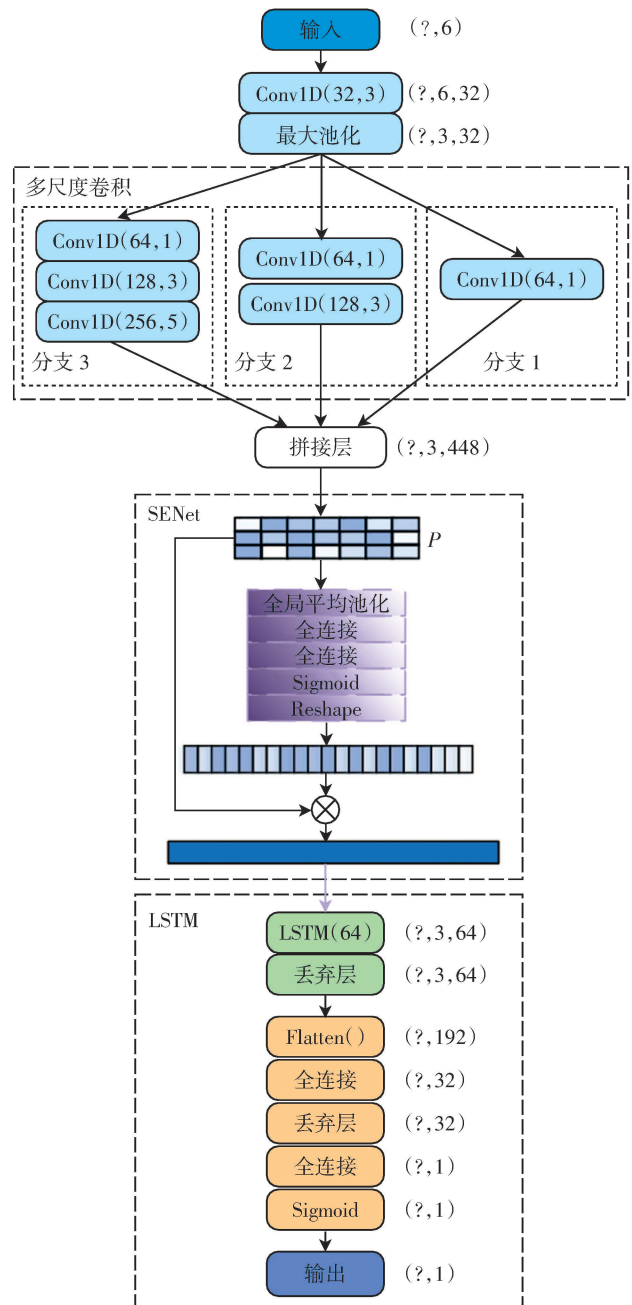


图 5 MSCNN-LSTM 预测模型结构图

Fig.5 Structure of MSCNN-LSTM prediction model

如图 5 所示,预测模型主要由 3 个模块拼接而成。多尺度卷积模块共有 3 个分支,每个分支中的卷积层数、卷积核步长递增,卷积核数量呈倍增形式。本文设置多样的卷积尺度来对 QAR 数据进行特征提取,并利用拼接层进行特征信息拼接,获得更宽泛的特征信息,实现对 QAR 数据空间维度上的特征提取。SENet 模块为通道注意力模块,其中 P 为多尺度卷积模块特征提取后所得的特征图,经过 SENet 模块运算后,实现对特征信息进行赋权运算。LSTM 模块对加权处理

后的特征进行时间维度上的特征提取,使用丢弃层防止模型在训练过程中出现过拟合,并利用全连接层与 Sigmoid 激活函数实现舵面位置的预测。

预测模型建立完成后,选取 B787 机队中正常运行状态下的 14 个飞行循环的 QAR 数据,每个循环的数据定义为一个样本,按照图 2 中的状态监测流程在每个样本中抓取表 1 中的特征参数并进行归一化,以此作为 MSCNN-LSTM 预测模型的训练集,共计 256 676 条数据。

在模型训练过程中,使用 Adam 学习器对网络参数进行优化学习,初始学习率取值为 0.001,迭代训练次数为 40 次。待训练完成后,利用模型在训练集上学习到的安定面位置传感器信息、安定面负载传感器信息与舵面位置的关系,使其输出舵面位置预测值,然后计算得到舵面位置预测值与实际值之间的残差如下

$$y_{error} = y_{pre} - y_{true} \tag{8}$$

式中: y_{pre} 为舵面位置预测值; y_{true} 为舵面位置实际值。

训练集舵面预测值与实际值残差分布如图 6 所示。




图 6 训练集舵面预测值与实际值残差分布


Fig.6 Residuals distribution of the predicted and actual values of the training set rudder

3.2.2 预测模型性能分析


为验证 MSCNN-LSTM 模型对 QAR 数据特征的提取能力,引入与 MSCNN-LSTM 模型训练参数相同的 CNN-LSTM、LSTM 2 种模型,对其在训练集上的预测效果进行对比分析。计算引入预测模型的舵面位置预测值与舵面位置实际值的残差,并将各预测模型的残差值进行分布可视化。为更直观地对比分析本文预测模型与其他模型之间的预测效果,将图 6 转化为残差分布直方图,如图 7(a)所示,图 7(b)、7(c)两图分别为 CNN-LSTM、LSTM 两种模型的残差分布直方图。

从图 7 中可以直观地看出:残差的分布都集中于横坐标为 0 点附近的区间;3 张图中幅值位于区间 $[-0.01, 0.01]$ 的残差数量占比分别为 89.5%、41.3%、38.0%。MSCNN-LSTM 模型在区间 $[-0.01, 0.01]$ 的残差


数量占比最高,说明了本文模型的有效性;LSTM 模型在区间 $[-0.01, 0.01]$ 的残差数量占比最低,说明在 QAR 数据上具有双重特征表达能力的 MSCNN-LSTM、CNN-LSTM 两种模型相较于单一特征表达能力的 LSTM 模型,特征提取能力更强。



(a)MSCNN-LSTM



(b)CNN-LSTM



(c)LSTM

图 7 不同预测模型的残差分布直方图

Fig.7 Histogram of residual distribution of different prediction model

此外,本文还采用平均绝对误差(MAE, mean abso-

lute error)、均方误差(MSE, mean square error)、均方根误差(RMSE, root mean square error)等评价指标对各模型的预测性能进行量化,以验证 MSCNN-LSTM 模型预测性能的优越性,计算公式为

$$e_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_{pre_i} - y_{true_i}| \quad (9)$$

$$e_{MSE} = \frac{1}{n} \sum_{i=1}^n (y_{pre_i} - y_{true_i})^2 \quad (10)$$

$$e_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{pre_i} - y_{true_i})^2} \quad (11)$$

式中, n 为舵面位置预测值的数量。

计算结果如表 2 所示,表 2 中各评价指标的数值越小,说明舵面位置的预测值与真实值越接近,模型的预测性能更优越。

表 2 各预测模型误差计算结果

Tab.2 Error calculation results of each prediction model

模型	$e_{MSE}/10^{-3}$	$e_{RMSE}/10^{-3}$	$e_{MAE}/10^{-3}$
MSCNN-LSTM	0.04	6.14	3.82
CNN-LSTM	0.10	10.00	7.91
LSTM	0.11	10.57	8.49

从表 2 中可以看出, MSCNN-LSTM 模型的各项评价指标误差值均为最小, LSTM 模型的误差计算数值均为最大,说明 MSCNN-LSTM 模型对 QAR 数据的双重特征提取能力更有效,预测性能更优。

综上,从残差分布和多种预测性能量化指标 2 个角度验证了 MSCNN-LSTM 模型的预测性能更优越。故将 MSCNN-LSTM 模型作为本文状态监测的预测模型。

3.2.3 阈值选取

预测模型建立后,需选取其监测模型的阈值,对 MSCNN-LSTM 预测模型在正常运行下的飞行数据(训练集)进行残差分析。阈值选取过程中,结合输出值的特点,阈值的上下界在数值上需保持相等。通过计算,阈值选取为 $[-0.044, 0.044]$,此阈值包含了 99.9%的残差数量,如图 8 所示。

3.3 监测模型验证

利用训练好的 MSCNN-LSTM 预测模型以及阈值 $[-0.044, 0.044]$ 对待测飞行数据进行监测。待测飞行数据选用的是某架 B787 飞机于 2018 年 11 月 21 日至 23 日的 QAR 数据,共计 5 个飞行循环(5 个样本),数据量为 115 822 条,将其作为监测模型测试集。

将测试集中的 5 个样本按照飞行任务的执行时间先后进行编号排序(1~5),预测模型输出测试集的舵面位置预测值与实际值的残差分布如图 9 所示。




图 8 状态监测模型的阈值

Fig.8 Thresholds of the state monitoring model




图 9 测试集舵面位置预测值与实际值残差

Fig.9 Residuals of the predicted and actual values of the test set rudder position

由图 9 可以看出,测试集的第 4 个样本中存在大量溢出阈值的残差,将第 4 个飞行循环(简称飞行循环 4)中的残差按照时间先后进行可视化如图 10 所示。




图 10 测试集飞行循环 4 的残差

Fig.10 Residuals of test set flight cycle 4

结合图 9 和图 10 可知,在飞机的进近降落阶段,存在多个时间点连续超出阈值的情况,故将本飞行循环的状态定义为异常状态。查阅此周期内该架飞机的航线维护记录(LMR, line maintenance record),记录中显示,飞机健康管理系统(AHM, aircraft health management)告警有 STAB CHANNEL 状态信息,关联相关维

护信息,航后机务人员根据 AMM 27-41-03 更换左 EMCU,检查安装好,测试通过。图 9 中,更换 EMCU 后的飞行循环(飞行循环 5)残差均位于阈值区间内,系统处于正常运行状态。

此外,图 9 飞行循环 3 中,较少部分残差溢出阈值区间且存在连续 12 个采样点溢出阈值的情况,已满足本文所设定连续 5 个采样点溢出阈值定义为异常状态的条件,故飞行循环 3 已出现异常。

为解释监测模型将飞行循环 4 定义为异常状态的原因,依据航后处理信息并查阅部件维护手册(CMM, component maintenance manual)可知,与左 EMCU 相关联的参数为表 1 中的 C 、 E 。

图 11 为水平安定面系统正常飞行循环与异常飞行循环 4 参数 C 、 E 的幅值变化图。




图 11 正常飞行循环与异常飞行循环 4 参数 C 、 E 变化
Fig.11 Parameters C and E change of normal flight cycle and abnormal flight cycle 4

从图 11 中可以看出:在飞机进近降落阶段中,正常飞行循环的参数 C 、 E 的幅值变化频繁,这是因为飞机进近降落阶段俯仰姿态不稳定,配平系统处于活跃状态;而异常飞行循环 4 的参数 C 、 E 的幅值处于稳定状态,与正常状态存在差异,符合图 10 中大量残差在此阶段中溢出阈值区间的监测结果。通过分析异常飞行循环与正常飞行循环参数 C 、 E 的差异可知,本文监测模型的监测结果具有一定的可靠性。

为解释监测模型在飞行循环 3 的异常状态,抓取溢出阈值残差点对应的 QAR 数据。此时,QAR 数据中舵面位置参数 $G = 8.5$;将正常飞行循环与测试集飞行

循环 3 中参数 $G = 8.5$ 时的水平安定面系统其他参数进行对比分析。因不同参数的量纲存在差异,为更直观地观察参数之间的差异,对归一化后的参数幅值进行可视化,如图 12 所示。




图 12 正常飞行循环与飞行循环 3 参数差异
Fig.12 Differences in parameters between normal flight cycle and flight cycle 3

从图 12 可知,飞行循环 3 与正常飞行循环参数 $A \sim F$ 中,参数 A 和参数 C 幅值差异较大。QAR 数据中,参数 $G = 8.5$ 时,飞行循环 3 的参数 A 、 C 的值分别为 0.11、0;正常飞行循环的参数 A 、 C 的值分别为 0.10、-0.02;监测模型在飞行循环 3 将此部分数据监测为异常,且参数 C 、 E 又与左 EMCU 相关联,结合航后处理信息,可知本文所建立的监测方法在本文所用的数据集上,能够在一定程度上给出预警。

4 结语

本文通过对 B787 水平安定面系统分析,抓取某航空公司 B787 机队正常运行状态下 QAR 中的多个相关特征参数数据作为监测模型的训练集,利用无监督学习的方式监测水平安定面系统的状态。首先,根据 QAR 数据的特点,建立了具有双重特征表达能力的 MSCNN-LSTM 预测模型,在训练集上输出其舵面位置预测值,获得训练集上舵面位置预测值和实际值的残差及其分布;其次,分析残差并确立阈值;最后,以某 B787 飞机的 QAR 数据作为测试集。测试结果表明,本文所提方法能准确识别水平安定面系统状态异常的飞行循环,且在一定程度上给出预警。故本研究可为飞行控制系统的 QAR 数据挖掘提供一种新的思路。此外,随着快速存取记录器(WQAR, wireless groundlink quick access recorder)技术的发展^[20],本文方法可为飞行控制系统运行状态的实时监测以及系统的预防性维修提供参考。

(下转第 82 页)