

【航空管理与安全】

基于 BO-LSTM 的飞机机电系统可靠性预测与预警

侣庆民, 李俊艳

(郑州航空工业管理学院 民航学院, 河南 郑州 450046)

摘要:为进一步提升飞机运行安全管理水平、满足持续适航要求,研究构建了基于贝叶斯优化的长短期记忆神经网络(BO-LSTM)的飞机机电系统可靠性预测与预警模型。运用故障模式及影响分析(FMEA)方法,明确了飞机机电系统典型故障模式、成因及影响,依据故障后果严重程度判定了严酷度,并从中筛选严酷度为 II 及以上的液压泵等关键部件作为可靠性预测指标。在此基础上,以严酷度为 II 的电机作为重点研究对象,运用某航空公司提供的数据验证了模型有效性。实验结果显示,BO-LSTM 模型在均方根误差(RMSE)和平均绝对误差(MAE)指标上优势明显,与 BP 神经网络和未优化的长短期记忆神经网络(LSTM)相比,在训练集和测试集中,该模型的 RMSE 和 MAE 降低 12%~26.8%。表明该模型预测准确率更高,能对潜在故障趋势预测预警,有力保障持续适航阶段的飞行安全。

关键词:航空安全;长短期记忆神经网络;贝叶斯优化;预警模型;时间序列分析;可靠性

中图分类号: V 267 **文献标识码:** A **DOI:**10.13486/j.issn.2097-4973.2025.02.001

航空安全是民用航空领域核心关注点和持续发展基石。据国际航空运输协会(IATA)统计,2018—2022 年全球航空运输定期航班发生 36 起致命事故致 1 213 人死亡;2023 年一架涡轮螺旋桨飞机在起飞不久后坠毁,致 72 人遇难^[1]。飞机机电系统为飞机上执行飞行保障功能的所有飞机系统的统称,在国外通常被称作公共设备系统,它是飞机正常、安全运行的基础,也是飞机各项功能得以充分发挥的必备条件^[2]。随着航空技术的不断发展,飞机机电系统正逐步向一体化和数字化方向演进,其技术水平已成为决定飞机整体性能的关键因素,并对飞机的可靠性、安全性和经济性产生深远影响。然而,飞机机电系统因其结构复杂性和高负荷运行特性,在长期使用过程中易受部件老化、环境变化及操作不当等因素影响,从而引发故障,对飞行安全构成潜在威胁。近年来,民用航空领域频发的事故进一步凸显了提升机电系统可靠性、安全性和经济性的迫切性与重要性。因此,对飞机机电系统设备的可靠性展开研究,进行可靠性预测与预警以提升飞机运行的安全性极具必要性。

在飞机可靠性预测与预警方面,众多学者进行了广泛而深入的研究,研究方法呈现多样化态势。从模型构建的方法来看,许多研究通过建立数学或物理预测模型,并结合历史信息来实现系统故障的预测、预警及诊断。例如,宗圣凯^[3]采用基于余弦相似度的改进证据理论融合算法,对飞机机电系统展开故障诊断研究。龚秋婷等^[4]提出一种基于快速存取记录器数据的燃油计量参数估计模型建模方法,用于诊断主燃油计量装置可能出现的故障。Jiang 等^[5]依据飞行数据,借助数据挖掘和模糊逻辑建模技术,间接判断运

收稿日期: 2024-12-24

基金项目: 郑州航空工业管理学院研究生教育创新计划基金项目(2024CX103)

第一作者简介: 侣庆民(1983—),男,山东菏泽人,副教授,博士,主要从事系统安全与风险评价、公共安全与应急管理研究。E-mail: siqingmin@zua.edu.cn

飞机的结构健康状态。Küçüker 等^[6]基于贝叶斯网络模型,结合收集的飞机运行数据进行飞机分系统的可靠性预测。然而,飞机运行数据具有高复杂性和非线性特点,传统模型构建方法在处理这些数据时存在局限性,难以准确反映系统的实际运行状态。机器学习方法具有较强的数据驱动能力、自动特征学习机制以及对复杂非线性关系的有效捕捉能力,能够实现更精准建模与预测,逐渐成为可靠性预测与预警的主流方法。例如,胡毅等^[7]基于试飞数据,提出利用经验模态分解和最小二乘支持向量机(SVM)进行故障率预测。马红亮等^[8]将随机森林算法与分层抽样法结合对快速存取记录器数据进行分析,以评估航空发动机运行可靠性。这些方法弥补了传统模型构建方法非线性拟合能力较差的问题,但是在处理时间序列数据时无法有效捕捉数据中的长期依赖关系。长短期记忆神经网络(LSTM)作为一种特殊的循环神经网络(RNN),具有记忆单元和门控机制,能够有效地处理时间序列数据中的长期依赖关系,已应用于航空安全领域故障预测、诊断及剩余寿命预测等方面。例如,何健等^[9]利用 QAR 数据和 LSTM 建立重着陆风险预测模型,实现了重着陆风险量化和重着陆风险预测;曾航等^[10]通过结合步进搜索和 Adam 算法优化 LSTM 模型超参数,提高了航空安全事件的预测率;朱新宇等^[11]引入融合麻雀算法的 LSTM 预测高原民航飞机空调系统故障,助力航空公司从事后维修向预防性维修转变。尽管 LSTM 在时间序列预测中表现出色,但其超参数优化问题仍然是一个挑战,传统的网格搜索和随机搜索方法效率低下,难以在复杂的高维空间中找到最优解。贝叶斯优化(BO)作为一种高效的全局优化算法,能够通过构建目标函数的概率模型,在较少的样本点下找到最优超参数组合,与 LSTM 相结合,能够进一步提升 LSTM 预测的性能。例如,张其霄等^[12]基于 BO-LSTM 对航空发动机的传感器数据进行时间序列预测,通过贝叶斯优化解决参数优化效率低、预测准确率差等问题。该模型在航空发动机故障预测方面有所应用,而在飞机机电系统可靠性预测与预警方面应用较少。

本文提出一种基于贝叶斯优化的 LSTM(BO-LSTM)的飞机机电系统可靠性预测与预警模型,与现有研究相比,BO-LSTM 模型在处理复杂非线性关系、时间序列数据的长期依赖关系以及参数优化效率方面具有显著优势。通过贝叶斯优化,LSTM 的超参数得到了有效调优,显著提升了模型的预测精度和泛化能力,可适应飞机机电系统复杂的工作环境与多样化的故障模式,为飞机持续适航阶段的飞行安全提供坚实的保障。

1 理论基础

1.1 长短期记忆神经网络

LSTM 是对传统 RNN 中循环单元进行创新设计的变体,其核心在于引入了三种门控机制:输入门、输出门和遗忘门。这些机制共同作用于 LSTM 的记忆单元,有效避免了传统 RNN 中常见的梯度消失或梯度爆炸问题,能够更好地处理序列数据^[13]。

遗忘门的核心功能在于决策上一时刻单元状态向当前时刻的传递程度,即决定细胞状态中信息的保留与丢弃。该门接收 h_{t-1} 与 x_t 的输入,经由 σ 层处理后,输出介于 $0 \sim 1$ 的数值 f_t ,该数值与细胞状态 C_{t-1} 中的每个元素逐点相乘。 t 时刻时遗忘门的激活值 $f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + b_f)$,式中: σ 是激活函数, \mathbf{W}_f 是遗忘门的权重矩阵, $[h_{t-1}, x_t]$ 是把两个向量连接成更长的向量, b_f 是遗忘门的偏置项。

输入门决定当前时刻的输入有多少能够保留到单元状态,含两个关键部分:第一部分为 σ 层,决定要更新什么值;第二部分为 \tanh 层,负责将新信息融入细胞状态。 \tanh 层生成新的细胞状态值向量 \tilde{C}_t , \tilde{C}_t 会被整合至状态中。 t 时刻时输入门的激活值 $i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + b_i)$, $\tilde{C}_t = \tanh(\mathbf{W}_C \cdot [h_{t-1}, x_t] + b_C)$,式中: \mathbf{W}_i 是输入门的权重矩阵, b_i 是输入门的偏置项, \tilde{C}_t 表示在时刻 t 的候选细胞状态, \tanh 是双曲正切激活函数, \mathbf{W}_C 是候选细胞状态的权重矩阵, b_C 是候选细胞状态的偏置项。

随后,进入旧细胞状态的更新阶段,即 C_{t-1} 向 C_t 的转换。此过程中,旧状态与 f_t 相乘,丢弃确定需要

丢弃的信息,同时叠加 $i_t * C_t$,从而完成细胞状态的更新。 t 时刻时的细胞状态 $C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$ 。

最后,输出门负责决策当前时刻单元状态的输出程度。通过 σ 层来甄选细胞状态中待输出的部分,细胞状态经 \tanh 层处理后,得到一个 $-1 \sim 1$ 的值,并与 σ 门的输出相乘,最终仅输出确定输出的部分。 t 时刻时输出门的激活值 $o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + b_o)$, $\mathbf{h}_t = o_t * \tanh(C_t)$, 式中: \mathbf{W}_o 是输出门的权重矩阵, b_o 是输出门的偏置项, \mathbf{h}_t 表示在时刻 t 的隐藏状态向量。

这些门控机制有效地管理和调整细胞状态的流动,使得 LSTM 能够处理和记忆长序列信息。

1.2 贝叶斯优化

贝叶斯优化是一种能够有效探索空间并寻找全局最优解的方法,其核心思想是通过构建目标函数的概率模型,利用先验知识并随着采样不断更新后验分布,以此在较少的样本点下就能对目标函数有较好的估计^[14]。LSTM 超参数空间很大,贝叶斯优化不需要像网格搜索那样在整个超参数空间进行大量的均匀采样,它可以根据已有的少量评估结果,有针对性地选择下一个最有潜力的超参数组合进行评估。本文采用高斯过程作为概率模型,概率提升函数 PI 表达式为

$$PI(x) = \Phi\left(\frac{y_{\min} - \mu_n(x)}{\sqrt{k_n(x, x)}}\right)$$

式中: y_{\min} 是最优观测值, $\mu_n(x)$ 是目标函数 $f(x)$ 的后验分布的均值函数, $k_n(x, x)$ 是目标函数 $f(x)$ 的后验分布的协方差函数在点 x 处的值。贝叶斯优化流程如图 1 所示。




图 1 贝叶斯优化流程

2 BO-LSTM 可靠性预测与预警模型概述

2.1 基于 BO-LSTM 可靠性预测与预警具体实施流程

在进行飞机可靠性预测与预警分析时,首先要对所研究的系统开展故障模式及影响分析(FMEA),旨在识别潜在故障模式并评估其对系统性能的影响。选取对系统影响显著的部件作为关键部件,并将这些关键部件确定为可靠性预测指标,采集该指标的数据,并进行数据归一化等处理。利用 BO-LSTM 算法构建飞机可靠性预测与预警模型,经过一系列的模型训练与验证后,获取预测与预警结果。通过上述流程,可以实现对飞机运行状况的监测,及时发现并识别潜在风险因素,进而迅速采取针对性的干预措施,以保障飞机的持续适航性。具体流程如图 2 所示。




图 2 BO-LSTM 可靠性预测与预警流程

2.2 评价指标

在深度学习中,合理选择评价指标对于准确评估模型的性能至关重要。本文选用均方根误差(RMSE)和平均绝对值误差(MAE)作为主要的评价指标。RMSE 和 MAE 的值越小说明模型的预测性能越好。

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|,$$

式中： n 为样本数量， y_i 为第 i 个样本的实际值， \hat{y}_i 为第 i 个样本的预测值。

3 案例分析

3.1 故障模式及影响分析

可靠性预测指标的选取是飞机运行中识别和预警潜在风险的核心环节,是对潜在危险因素进行有效预警的基础,选取 FMEA 方法用于识别产品设计或过程中可能发生的潜在故障模式,以及这些故障模式对系统功能的影响程度^[15]。CCAR-23-R4《正常类飞机适航规定》和 CCAR-25-R4《运输类飞机适航标准》从确保飞机运行安全和有效使用的角度出发,对飞机机电系统如燃油系统、起落架系统等进行了详细的规定和约束,因此本文以上述规章为理论基石,同时紧密结合实际维修工作经验以及丰富的文献资料,运用 FMEA 方法对飞机机电系统部分部件进行分析,这些部件的故障或性能退化将会引发连锁反应,直接关系到飞机的整体安全性和可靠性^[16]。通过故障模式及影响分析,确定机电系统典型的故障模式、故障原因以及故障影响,并根据各典型故障模式所致后果的严重程度确定其严酷度^[17]。严酷度类别有以下 4 种:Ⅰ类(灾难的),危及人员或飞机安全(如一等、二等飞行事故)及重大环境损害;Ⅱ类(严重的),人员伤亡或飞机部分损坏(如三等飞行事故)及严重环境损害;Ⅲ类(中等的),人员中等程度伤害或影响飞行任务完成(如误飞、中断或取消飞行,降低飞行品质,增加着陆困难等)及中等程度环境损害;Ⅳ类(可忽略的),无影响或影响很小,增加非计划维护或维修^[18]。飞机机电系统 FMEA 表单见表 1。

表 1 飞机机电系统 FMEA 表单

功能	故障模式	故障原因	故障影响			严酷度
			自身影响	约定层次影响	最终影响	
液压泵	流量输出不足	管路堵塞或有异物	功能下降	功能下降	影响整机安全	Ⅱ
液压作动器	响应缓慢	液压油压力不足或润滑不良	功能下降	功能下降	影响整机安全	Ⅱ
燃油泵	无流量输出	电机故障	功能丧失	功能丧失	损伤飞机	Ⅰ
电机	线圈短路	线路外皮老化或磨损	功能丧失	功能丧失	影响整机安全	Ⅱ
	轴承磨损	润滑不足或过载	功能丧失	功能丧失	影响整机安全	Ⅱ
	转子断条	疲劳断裂	功能下降	功能下降	影响任务完成	Ⅲ
蓄电池	容量不足	极板老化或硫化、电解液泄漏	功能下降	功能下降	影响任务完成	Ⅲ
火灾探测器	漏报警	传感器故障	功能丧失	功能丧失	影响整机安全	Ⅱ
空调组件	空气流量不足	风机电机故障或风道堵塞	功能下降	功能下降	影响任务完成	Ⅲ

3.2 数据来源

由表 1 飞机机电系统 FMEA 表单可以清楚知道主要部件的严酷度大小。当严酷度为Ⅰ时,其事故发生所造成的后果最为严重,因此严酷度为Ⅰ的部件都为关键部件;在严酷度为Ⅱ的部件当中,其事故发生所造成的后果较为严重,所以本文将所有严酷度为Ⅱ的也全部选取为关键部件。在机电系统中,电机广泛应用于各个子系统,如飞行控制系统、环境控制系统、液压系统等,其运行状态直接影响着整个系统的性能和可靠性,因此本文选择严酷度为Ⅱ的电机作为可靠性预测与预警的研究对象。

本文采用的数据来源于某航空公司提供的一架飞机机电系统监测数据,该数据集涵盖了电机轴承在长期使用过程中的各项运行指标、故障发生情况及相关维修信息。由于轴承振动数据是表征其运行状态的关键参数,故选取轴承振动轴向数据作为模型的输入数据。数据采集周期为 2 周,每日采集时长为 1 h,并采用加速度传感器对电机轴承的振动情况进行实时监测。数据集中包含了多组轴承振动轴向数据,每组数据由 2 500 个样本点构成,并且以 Excel 表格的格式进行储存,便于后续分析与处理。鉴于原始数据

量较为庞大,为了合理控制后续分析及模型计算的计算量,本文采用随机抽样的方法,从数据集中选取了 200 组轴承振动轴向数据。在此基础上,从所选取的这 200 组数据中,每组再按照等间隔的方式选取 500 个数据,从而构成一个新的数据组,将这 500 个数据作为模型的输入数据。为确保样本量的合理性和模型的泛化能力,本文通过交叉验证方法对模型进行了评估。结果表明,样本量在保证计算效率的同时,能够有效支持模型的训练和验证。为了更有效地利用篇幅,将数据转化为图片格式进行呈现,图 3 为其中一组轴承振动轴向数据的原始数据图,在该图中,横轴表示样本点数,纵轴表示振动加速度。由于篇幅所限,本文仅针对该组数据展开深入分析。表 2 是该组数据等间隔选取后的轴承振动轴向数据,共计 500 个数据,每列 100 个。




图 3 原始数据

表 2 选取后的轴承振动轴向数据

序号	数据列 1	数据列 2	数据列 3	数据列 4	数据列 5
1	-0.173	0.165	-0.230	0.472	0.338
2	-0.182	0.092	-0.161	0.441	0.356
3	-0.379	-0.202	0.016	0.248	0.283
.....
98	-0.206	-0.102	-0.323	-0.036	0.102
99	-0.196	-0.140	-0.124	0.236	0.306
100	-0.023	-0.263	0.284	0.406	0.323

为了避免不同尺度的特征对模型训练造成偏差,本文采用 Min-Max 归一化进行数据预处理,公式如下:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \cdot (b - a) + a。$$

式中: x 是原始数据; x_{\min} 和 x_{\max} 分别是数据集中的最小值和最大值; a 和 b 是目标区间的下限和上限,本文取 $[-1, 1]$; x' 是归一化后的数据。

3.3 预测结果分析

将所采集的数据予以预处理操作之后,将其作为 BO-LSTM 预测模型的输入数据,设置超参数的取值范围如下:隐含层神经元个数取值于 $[50, 300]$,初始学习率取值为 $[10^{-3}, 10^{-1}]$,L2 正则化取值为 $[10^{-10}, 10^{-3}]$,小批量大小取值为 $[16, 128]$,贝叶斯优化最大迭代次数设定为 30^[19]。当达到最大迭代次数后得到最佳可行点和目标函数值,如表 3 所示。

表 3 贝叶斯优化结果

	神经元个数	初始学习率	L2 正则化	小批量大小	目标函数值
观察到的最佳可行点	292	0.013 64	0.000 828 51	118	0.176 54
估计的最佳可行点	292	0.013 64	0.000 828 51	118	0.179 64

从表 3 可以看出,通过贝叶斯优化方法,目标函数值较小(0.176 54)说明预测误差已经得到了有效减少,模型的预测精度较高,且比估计值(0.179 64)略低,表明贝叶斯优化成功找到了一个非常接近最优的超参数组合,LSTM 的超参数已经得到了有效调优。

为验证 BO-LSTM 预测模型的有效性,本文选取需要手动调整参数的 LSTM 以及经典的 BP 神经网络时间序列预测模型作为对比模型。图 4 是贝叶斯优化后的 LSTM 预测集预测结果,图 5 是未优化的 LSTM 预测集预测结果。在未优化的 LSTM 预测结果图中,预测值和真实值的变化趋势有一定的相似性,但是二者的波动情况存在明显差异,整体预测效果有待提高,贝叶斯优化后的模型预测精度较高。




图 4 贝叶斯优化的 LSTM 预测集预测结果




图 5 LSTM 预测集预测结果

表 4 是 3 种预测模型的评价指标统计结果。从表中可以看出,BO-LSTM 模型在 RMSE 和 MAE 两项指标上均展现出显著优势。训练集上,其 RMSE 值为 0.119 5,较 BP 神经网络(0.155 8)降低 23.3%,较未优化的 LSTM(0.139 4)降低 14.3%;MAE 值为 0.093 6,对比 BP 神经网络(0.121 2)减少 22.8%,较 LSTM(0.109 7)降低 14.7%。测试集上, RMSE 值为 0.141 5,较 BP 神经网络(0.193 3)降低 26.8%,较 LSTM(0.160 7)降低 12%;MAE 值为 0.115 4,相比 BP 神经网络(0.149 7)减少 22.9%,较 LSTM(0.131 2)降低 12.1%。BP 神经网络在训练集和测试集中 RMSE 和 MAE 均达到最大值,其预测性能最差,LSTM 的预测性能优于 BP 神经网络;而 BO-LSTM 相较于前两种模型具有最佳的预测性能,由此表明贝叶斯优化后的 LSTM 模型在轴承可靠性预测中表现良好。

表 4 3 种预测模型的评价指标统计结果

预测模型	E_{RMSE}		E_{MAE}	
	训练集	测试集	训练集	测试集
BP	0.155 8	0.193 3	0.121 2	0.149 7
LSTM	0.139 4	0.160 7	0.109 7	0.131 2
BO-LSTM	0.119 5	0.141 5	0.093 6	0.115 4

在飞机可靠性的范畴内, RMSE 与系统的安全性和可靠性有着紧密的联系,因此本文选择将 RMSE 作为预警指标。通过进行多组数据预测以及参考飞机电机轴承的工程手册、维护经验和以往的故障案例将 $E_{RMSE}=0.2$ 设置为预警阈值。当新的预测结果对应的 RMSE 超过 0.2 时,即发出警报和提示。运行管理人员和飞行员根据系统提供的信息,采取必要的措施和调整,以确保飞行安全和效率。

4 结语

本文以 CCAR-23-R4《正常类飞机适航规定》、CCAR-25-R4《运输类飞机适航标准》等相关规章为理论基石,紧密结合实际维修工作经验以及丰富的文献资料,运用 FMEA 方法,针对飞机机电系统的部分部件展开了分析,明确了各部件可能出现的故障模式、成因以及影响。基于故障模式所导致后果的严重程度,对其严酷度进行了判定。在此基础上,经过筛选,选取了严酷度为 II 及以上的液压泵、液压作动器、燃油泵、电机和火灾探测器作为飞机机电系统的关键部件,并将这些关键部件确立为可靠性预测的指标。进一

步地以严酷度为 II 的电机作为研究对象,将贝叶斯优化算法与 LSTM 有机结合,成功构建了 BO-LSTM 可靠性预测与预警模型。为充分验证该模型的有效性,采用了某航空公司提供的数据进行实证检验。BO-LSTM 模型在 RMSE 和 MAE 指标上优势明显,与传统的 BP 神经网络以及未经优化的 LSTM 相比,在训练集和测试集中, RMSE 和 MAE 降低了 12%~26.8%。研究结果表明,借助贝叶斯优化算法对 LSTM 的超参数进行优化调整,能够显著提升 LSTM 的预测性能,并且相较于传统的 BP 神经网络序列预测模型,BO-LSTM 模型具有更高的预测精度和更优的拟合效果。通过该模型能够有效监测飞机运行状态,及时识别潜在风险并发出预警,从而确保飞机持续适航,保障航空运行安全。

本文构建的模型在复杂运行环境下的泛化能力仍有待进一步提升,尤其是在飞机不同运行阶段中,系统特性与可靠性要求存在显著差异,预警阈值需进行动态调整。此外,采集数据的质量与完整性对模型性能的影响仍需深入分析与研究,以确保数据输入的可靠性。基于上述问题,本文后续研究方向将聚焦以下三个方面:首先,引入迁移学习方法,通过跨领域数据的迁移学习提升模型在不同运行环境下的泛化能力;其次,探索动态阈值调整方法,根据飞机运行阶段的特点动态优化预警阈值,以提高模型的适应性与准确性;最后,进一步扩充数据集,增加样本量及数据多样性,以增强模型的鲁棒性与预测性能。

参考文献:

- [1] 中国民用航空网. 国际航协发布 2022 年全球航空运输安全报告[EB/OL]. (2023-03-09)[2024-12-13]. <https://www.ccaonline.cn/yunshu/yshot/835956.html>.
- [2] 张玉杰,彭宇,刘大同. 飞机机电系统部件数据驱动健康状态在线估计方法综述[J]. 仪器仪表学报, 2022,43(6):118-130.
- [3] 宗圣凯. 基于多分类器融合的飞机机电系统故障诊断研究[D]. 成都:电子科技大学,2021.
- [4] 龚秋婷,陈毅,刘渊,等. 基于数据驱动的主燃油计量装置故障诊断[J]. 推进技术,2024,45(5):231-240.
- [5] JIANG W, CHANG R C, ZHANG S Q, et al. Structural health monitoring and flight safety warning for aging transport aircraft [J]. Journal of aerospace engineering, 2023,36(5):04023059.
- [6] KÜÇÜKER F U, YET B. Reliability prediction for aircraft fleet operators: a Bayesian network model that combines supplier estimates, maintenance data and expert judgement [J]. Journal of the operational research society, 2023,74(10):2187-2198.
- [7] 胡毅,李飞敏,杨胜学. 基于试飞数据的故障率预测及预警监控[J]. 兵器装备工程学报, 2020,41(7):224-227.
- [8] 马红亮,冯蕴雯,刘骞,等. 一种航空发动机运行可靠性评估方法[J]. 航空工程进展, 2021,12(5):42-49.
- [9] 何健,钱宇,唐盛香. 基于 LSTM 的民用飞机重着陆风险预测评估研究 [J/OL]. 航空工程进展, (2024-06-11)[2024-12-13]. <http://kns.cnki.net/kcms/detail/61.1479.V.20240607.1120.002.html>.
- [10] 曾航,张红梅,任博,等. 基于改进 LSTM 模型的航空安全预测方法研究[J]. 系统工程与电子技术, 2022,44(2):569-576.
- [11] 朱新宇,吴佩汶. 基于 SSA-LSTM 的高高原民航飞机空调系统故障预测[J]. 郑州航空工业管理学院学报, 2024,42(5):36-41.
- [12] 张其霄,董鹏,王科文,等. 基于贝叶斯优化 LSTM 的发动机剩余寿命预测[J]. 火力与指挥控制, 2022,47(4):85-89.
- [13] 张琬琪,程月华,余自权,等. 基于 LSTM 的飞行器纵向可用过载预测方法研究[J]. 飞行力学, 2023,41(5):23-29.
- [14] 徐冬梅,王逸阳,王文川. 基于贝叶斯优化算法的长短期记忆神经网络模型年径流预测[J]. 水电能源科学, 2022,40(12):42-46.

- [15] SI Q M, LI J Y, ZHAO Y H, et al. Reliability analysis method of electric light aircraft based on failure mode effects and criticality analysis[J]. DYN-ingenieriae industria, 2024, 99(4): 433-440.
- [16] 中华人民共和国交通运输部. 运输类飞机适航标准(中华人民共和国交通运输部令 2016 年第 19 号)[EB/OL]. (2016-03-17) [2024-12-16]. https://xxgk.mot.gov.cn/2020/jigou/fgs/202006/t20200623_3307793.html.
- [17] 房冠成, 王海峰, 官霆, 等. 面向军用飞机任务能力的健康评估方法[J]. 航空工程进展, 2020, 11(1): 37-45.
- [18] 肖楚琬, 韩维, 王希彬, 等. 军用飞机 EWIS 适航性改进体系设计[J]. 火力与指挥控制, 2019(8): 1-6.
- [19] 雷萌, 吕游, 魏玮, 等. 基于 LSTM 神经网络与贝叶斯优化的电站风机故障预警[J]. 热能动力工程, 2022, 37(8): 213-220.

Reliability prediction and early warning of aircraft electromechanical systems based on BO-LSTM

SI Qingmin, LI Junyan

(School of Civil Aviation, Zhengzhou University of Aeronautics, Zhengzhou 450046, China)

Abstract: In order to further improve the safety management level of aircraft operation and meet the requirements of continuous airworthiness, the study constructed an electromechanical system reliability prediction and warning model based on Bayesian optimization long and short term memory neural network (BO-LSTM). Using the FMEA (Failure Mode and Effects Analysis) method, the typical failure modes, causes and effects of the electromechanical system were clarified, and the severity of the failure consequences was determined, from which the key components such as hydraulic pumps with a severity of II and above were selected as the reliability prediction indexes, and based on which the motor with a severity of II was taken as a key object of the study. The data provided by an airline company is used to verify the reliability of the model. The experimental results show that the BO-LSTM model has obvious advantages in root mean square error (RMSE) and mean absolute error (MAE) indicators, and compared with BP neural network and unoptimized LSTM network, the RMSE and MAE values of the model are reduced by 12%~26.8% in the training set and test set. This indicates that the model has higher prediction accuracy and is able to predict and warn potential failure trends, which is a strong guarantee of flight safety during the continuous airworthiness phase.

Keywords: aviation safety; long and short term memory neural networks; Bayesian optimization; early warning models; time series analysis; reliability

(责任编辑:唐立平)

引用格式 侣庆民, 李俊艳. 基于 BO-LSTM 的飞机机电系统可靠性预测与预警[J]. 山东航空学院学报, 2025, 42(2): 1-8.
SI Q M, LI J Y. Reliability prediction and early warning of aircraft electromechanical systems based on BO-LSTM [J]. Journal of Shandong University of Aeronautics, 2025, 42(2): 1-8.