

飞机复杂运动机构故障诊断方法体系结构研究

何东钰¹, 印寅¹, 梁涛涛², 董奥杰¹, 张鹏¹, 魏小辉¹, 聂宏¹

(1. 南京航空航天大学航空学院, 江苏南京 210016; 2. 南京航空航天大学通用航空与飞行学院, 江苏溧阳 213300)

摘要: 针对当前飞机复杂运动机构的故障诊断研究多侧重于系统功能失效分析, 对机构运动特征与实际故障之间关联机制解析不足的问题, 开展了复杂运动机构故障诊断方法研究。提出一种数据生成、特征处理以及数据分析三层展开的故障诊断分析体系。从复杂运动机构的运动规律和性能出发, 确定典型故障工况的参数映射关系, 基于动力学模型引入故障参数体系实现典型故障工况时序信号样本集的生成; 使用二维图像转换方法对一维时序信号进行映射, 建立特征级融合的多维张量; 依托深度学习算法实现复杂运动机构的故障精准诊断。以建立的方法体系为基础设计基于格拉姆角场和马尔可夫变迁场方法的协同特征转换, 以及引入通道、空间注意力机制的残差网络故障诊断模型。以起落架下位撑杆锁机构为例完成试验验证, 仿真试验结果表明, 所提出的方法在 95% 置信度下的准确率不低于 0.9566, 验证了方法在飞机复杂运动机构故障诊断应用方面的可行性; 消融试验结果表明, 所提方法表现最优, 验证了方法设计的有效性。

关键词: 故障诊断; 体系结构; 特征融合; 残差网络; 注意力机制; 下位撑杆锁

中图分类号: V226 文献标志码: A 文章编号: 1004-4523(2025)06-1167-16

DOI: 10.16385/j.cnki.issn.1004-4523.2025.06.005

Architectural design of fault diagnosis methods for aircraft complex motion mechanisms

HE Dongyu¹, YIN Yin¹, LIANG Taotao², DONG Aojie¹, ZHANG Peng¹, WEI Xiaohui¹, NIE Hong¹

(1. College of Aerospace Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. College of General Aviation and Flight, Nanjing University of Aeronautics and Astronautics, Liyang 213300, China)

Abstract: Current research on fault diagnosis for aircraft complex motion mechanisms primarily focuses on system functional failure analysis, neglecting a comprehensive understanding of the correlation between motion characteristics and actual faults. This study investigates fault diagnosis methods for complex motion mechanisms and proposes a three-tiered framework encompassing data generation, feature processing and data analysis to address this limitation. The framework utilizes dynamic modeling and a fault parameter system to generate a dataset of time-series signals representing typical fault conditions. One-dimensional time-series data are mapped using two-dimensional image conversion methods, constructing multidimensional tensors through feature-level fusion based on sensor types and feature extraction methods of the complex motion mechanisms. A deep learning-based fault diagnosis model is employed for precise fault identification of complex motion mechanisms. This framework further incorporates collaborative feature transformations using Gramian angular fields and Markov transition fields, as well as residual network models with channel and spatial attention mechanisms. Experimental validation using a landing gear lower strut lock mechanism demonstrates high accuracy, exceeding 0.9566 at a 95% confidence level, thus validating the feasibility of this approach for fault diagnosis in aircraft complex motion mechanisms. Ablation experiments confirm the effectiveness of each component, highlighting the overall superiority of the proposed framework.

Keywords: fault diagnosis; architecture; feature fusion; residual network; attention mechanism; lower lever lock

飞机上的舱门、起落架等复杂运动机构是确保飞机安全性、功能完整性以及正常运行的重要系统部件。它们不仅涉及飞机起降、乘客和货物的出

入, 还具有维持飞机气动外形以及在紧急情况下作为疏散通道的功能^[1]。根据美国国家运输安全委员会 (National Transportation Safety Board) 在 2022 年的

收稿日期: 2025-04-30; 修订日期: 2025-05-22

基金项目: 国家自然科学基金资助项目 (52172368, 52302453, 52275114); 江苏省自然科学基金资助项目 (BK20220135); 航空航天结构力学及控制全国重点实验室 (南京航空航天大学) 自主研究课题资助项目 (MCAS-I-0224G03); 南京航空航天大学前瞻布局科研专项资金资助项目 (1001-ILB23008)

一篇航空调查报告^[2]报道,一架波音 MD-82 飞机在着陆阶段,其左主起落架下位锁在起落架横滚过程中由于摆振阻尼失效导致结构失效,进而导致左主起落架倒塌,飞机在跑道上发生偏移并坠机起火,造成 4 名乘客受伤。事故调查结果表明,复杂运动机构一旦失效,将对飞机结构完整性和乘客安全造成重大风险。飞机复杂运动机构不仅存在许多非开放式的安装空间,而且是一个由若干关联的子系统组成的复杂系统,但传统的维修检查方式耗费大部分时间用于缺陷定位,通常需要一系列的拆卸组装过程^[3],这给飞机复杂运动机构设计、运维和防护等方面提出了新的挑战^[4]。因此,充分利用智能化技术对飞机复杂运动机构进行高效、准确且可靠的安全分析十分必要。

中国《“十四五”民用航空发展规划》^[5]明确指出,推动构建数字化、智能化的维护维修体系,使航空安全水平再上新台阶以突破安全飞行 1 亿小时大关。成功的异常事件管理依赖于及时发现异常、精准诊断故障以及预测过程演变^[6],故障诊断和预测作为飞机维修管理的重要组成部分,在提高飞机系统的安全性和可用性方面起着至关重要的作用^[7]。冯东洋^[8]基于 AMESim 搭建的飞机起落架液压系统模型构造故障数据集,并提出了一种基于双路特征融合卷积神经网络与粒子群优化支持向量机相结合的起落架液压系统故障诊断模型。杨超^[9]采用基于模型和故障响应动态观测器的方法对飞机起落架液压收放系统进行故障诊断,并在飞机起落架液压收放系统故障管理试验台上进行故障模拟。CHE 等^[10]结合长短时记忆神经网络 (LSTM) 和深度置信网络 (DBN) 深度学习算法提出了一种预测与健康管理体系 (PHM) 模型,基于 LSTM 对多个传感器的多元时间序列进行预测,并结合 DBN 算法评估系统的健康状况和实现飞机系统的故障分类。王强等^[11]针对民航舱门收放系统故障模拟代价大、故障数据少、故障诊断精度低的问题,提出基于组合粒子群优化与反向传播 (CPSO-BP) 神经网络的飞机舱门收放系统故障诊断方法,故障诊断正确率达到 93%。然而,目前针对飞机复杂机构的故障诊断研究主要集中于从液压系统角度进行分析,对于运动机构本身的动态特性、动力学行为的分析不足,这种研究偏向限制了对复杂机构整体故障机理的深入理解。

近年来,在运动机构的机械特性监测层面,国内外学者对旋转机械和电气操纵机构开展了多方面的研究。刘强等^[12]通过动态数据建模和多模态建模,利用动态时间规整等技术,实现了高速列车轴承的多模态运行监控与故障诊断,为构建覆盖典型故障模式的高保真数据集提供了参考。LEI 等^[13]从装在

行星齿轮箱不同位置的多个传感器信号中提炼特征,并利用适应神经模糊推理系统融合这些特征,对行星齿轮箱的故障模式和故障程度进行诊断。UNAL 等^[14]利用包络分析、希尔伯特变换和快速傅里叶变换,从振动信号中提取特征作为人工神经网络的输入进行故障诊断,并利用遗传算法优化人工神经网络的结构。宫文峰等^[15]提出了一种改进卷积神经网络的方法用于滚动轴承故障的快速智能诊断,整个诊断过程无需任何手工特征提取,该“端到端”的算法结构具有较好的可操作性和通用性。张艳飞等^[16]探究了弹簧操动机构在合闸弹簧储能阶段、合闸操作阶段、分闸操作阶段中的动作机理,给出分合闸弹簧疲劳故障的模拟设置方法,为弹簧操动机构的故障设置提供了依据。姜海龙等^[17]以合闸线圈电流为研究对象,对基于电流法的高压断路器弹簧机构故障诊断进行了仔细分析,通过模拟断路器的常见故障,采用最小二乘支持向量机 (LSSVM) 方法进行断路器故障诊断,为时序信号下的故障诊断分析提供了一种思路。RUDSARI 等^[18]将电流信号与行程曲线信号相结合,通过将多源信号进行结合以追求更为准确的状态判别。上述研究成果为从机构运动特征角度深入探究飞机复杂运动机构的工作状态、性能评估和故障诊断提供了理论基础和技术支撑。

综上,现有针对运动机构的研究主要从故障模拟数据生成、多源信号特征融合以及诊断算法设计三个层面开展。现有飞机复杂运动机构的故障诊断研究多侧重于系统性能失效分析,对机构运动特征与实际故障之间的关联机制解析不足,本文以运动机构动力学仿真分析为基础,研究飞机复杂运动机构的故障诊断方法体系结构和实现技术,以层级化与模块化的方式建立一种故障诊断分析框架,分别设计了数据生成层、特征处理层和数据分析层,并以某型起落架下位撑杆锁机构为例验证该体系的可行性和有效性,旨在为飞机复杂运动机构的故障诊断提供一种具备通用性和扩展性的方法体系结构。

1 飞机复杂运动机构的故障诊断分析框架结构

在实际工程应用中,针对飞机复杂运动机构的故障诊断技术面临以下 3 个方面的挑战:

- (1) 如何系统性建立机构运动故障因素与动力学模型之间的关联,构建覆盖典型故障模式的高保真数据集;
- (2) 如何充分利用多源时序传感数据与模型信息,构建特征有效融合的诊断模型输入;

(3) 如何设计面向高维度信号输入的故障诊断方法, 构建具有功能扩展性的诊断模型。

本文提出的飞机复杂运动机构故障诊断方法体系结构从 3 个层级建立故障诊断分析方法体系:

(1) 提出的数据生成层以运动机构动力学仿真模型为基础, 通过故障因素分析确定故障发生的影响参数, 并对故障参数进行定量; 同时, 通过部件级试验对仿真模型进行验证; 随后通过正交试验模拟组件级仿真模型的多种故障工况, 生成样本库;

(2) 提出的特征处理层依据特征级融合的方法, 采用不同的一维时序信号转换方法对数据生成层的时序信号进行处理, 并根据传感器类型、转换方法

类型以及对应的二维图像特征, 将这些要素组合为多维张量;

(3) 提出的数据分析层采用可拼接不同模块的结构设计, 引入深度学习算法, 同时重新设计网络结构以适配特征处理层输出的多维张量, 并通过结果分析验证故障诊断方法在飞机复杂运动机构的诊断任务中的可行性与有效性。

基于以上 3 个层级, 本文设计的故障诊断方法包括基于格拉姆角场和马尔可夫变迁场方法的协同特征转换, 以及引入通道、空间注意力机制的残差网络故障诊断模型, 最终建立如图 1 所示的特征融合的注意力残差网络故障诊断分析框架。

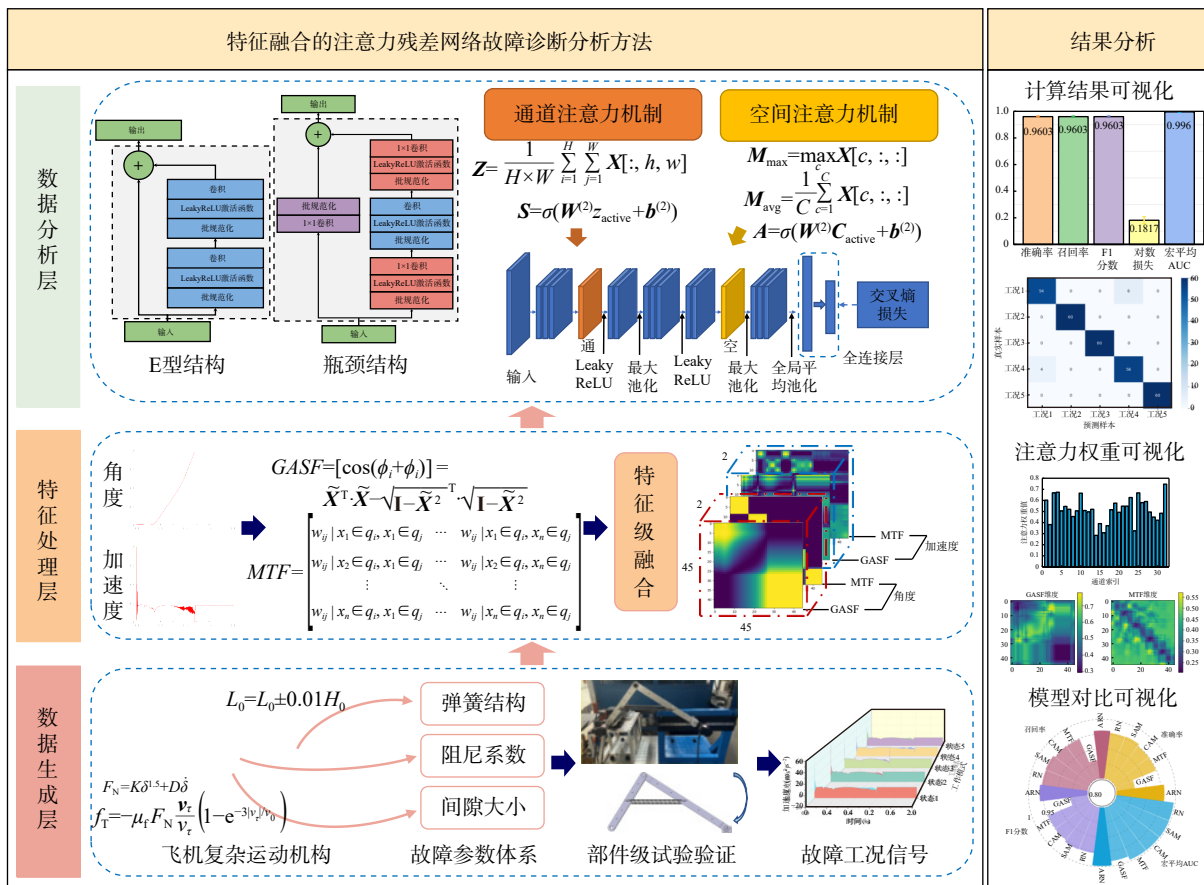


图 1 特征融合的注意力残差网络故障诊断分析框架

Fig. 1 Fault diagnosis analysis framework of attention residual network based on feature fusion

1.1 数据生成层

数据生成层既可作为复杂运动机构仿真模型的验证手段, 用以评估建模方法的有效性, 同时也为后续诊断模型提供所需的数据支撑。数据生成层的框架如图 2 所示, 包含了 4 个主要环节: 机构故障参数分析、部件级模型构建与试验验证、组件级运动-载荷关系建模以及批量仿真数据库构建。

对于故障参数分析, 利用故障树分析、故障模式与影响分析等可靠性分析方法获得影响机构正常运动的参数, 比如以杆件变形导致的舱门手柄机构运

动卡滞故障, 对应的是几何尺寸参数的改变; 弹簧疲劳导致的起落架下位锁机构无法正常上锁故障, 对应的是材料属性参数的改变。MUSTAFA 等^[19]提到在制造系统中, 可以通过利用虚拟制造工厂支持和加速设计与管理的决策过程, 但生成虚拟制造设施的主要障碍之一是创建模型所需的真实的数据。同样的, 在飞机复杂运动机构的仿真模型设计中, 可首先通过运动机构部件级试验获取真实数据, 该数据既用于构建运动机构的高精度仿真模型, 也为后续在无法开展整机实物试验的条件下, 于虚拟环境中

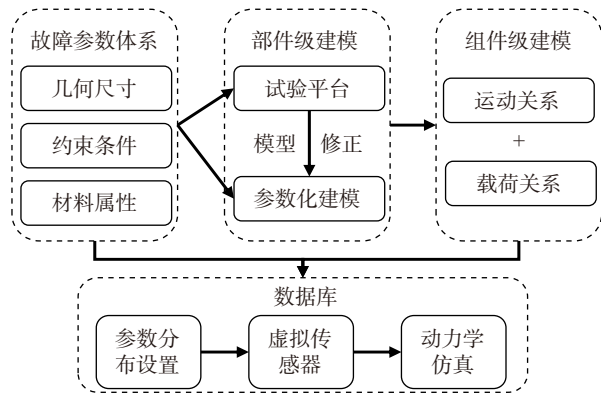


图2 数据生成层

Fig. 2 Data generation layer

对模型进行优化并生成多工况数据库提供支撑,从而显著降低试验成本。这4个环节以数据库构建为核心,以机构可靠性参数影响分析为输入,建立运动机构的关键故障参数指标体系,通过多体动力学软件建立部件的仿真模型并基于试验台确保仿真模型的有效性,根据经过验证的模型构建方法搭建组件级仿真模型,以数据分析软件设计正交试验得到仿真试验的数据库。

通过数据生成层,可以解决真实故障场景下难以通过实物试验反复获取故障信号的难题,并且通过多尺度的建模捕捉运动机构关键故障参数之间的作用,进一步拓展模型的覆盖工况,为故障诊断提供具有物理意义的训练数据。

1.2 特征处理层

数据生成层通过多尺度建模构建了运动机构的多种类型的运动信号和载荷信号等数据,但直接将一维时序信号输入故障诊断模型面临三方面的挑战:首先,多源传感器信号存在量纲差异,导致特征空间无法有效对齐;其次,信号直接堆叠会导致样本特征稀疏的问题;最后,关键故障模式可能被隐藏在时序信号的特定频段或相位关系中。因此针对原始运动信号,设计特征处理层,如图3所示。




图3 特征处理层

Fig. 3 Feature processing layer

特征处理层包含了两大主要步骤:一是采用一维信号特征转换方法,在标准化转换过程中消除量纲差异,并获得信号不同的特征信息;二是通过特征级融合,将故障模式的时间步长关系、幅值分布等表征信息整合到张量中,并依据传感器类型、转换

方法类型等要素构建多维张量,利用来自多个传感器的关联和互补的故障敏感信息,提高性能并更全面地了解机械状况^[20]。

通过特征处理层,可以解决多源时序信号共同输入时传感数据信息融合效率低的问题,利用先进的信号处理技术在增强数据集有效特征的同时,实现一定程度的数据压缩,降低故障诊断模型训练复杂度,为故障诊断提供具有高度整合的数据输入。

1.3 数据分析层

数据分析层接收来自特征处理层的数据输入,并且算法网络匹配高维张量结构。

数据分析层的核心是故障诊断模型的设计,其首先需要适配由特征处理层输入的张量维度;其次诊断模型需结合先进的机器学习或深度学习技术,具备高效识别和分类故障信号的能力,比如将故障诊断视作一种分类任务,则可选择残差网络作为诊断模型的主结构;其次,诊断模型还需要支持可扩展功能单元的设计,比如注意力模块以及优化器选择模块化接口等,允许对训练网络中单元模型进行替换或组合;最后,还要支持诊断模型的结果分析,通过统计指标量化评估模型性能、通过特征可视化与可解释性分析提升模型的解释能力、通过消融试验验证模块的有效性,量化不同模块对模型性能的影响,图4给出了数据分析层的框架结构。




图4 数据分析层

Fig. 4 Data analysis layer

通过数据分析层,能够实现飞机复杂运动机构的故障诊断任务,特别是从运动特性信号的角度进行深入分析,在此基础上,通过设计可扩展的模型模块,进一步提升诊断模型对不同运动机构的适应性,为故障诊断提供具有灵活适应的算法结构。

2 飞机复杂运动机构故障诊断技术

复杂运动机构的故障诊断分析涉及了机构动力学、机构运动学、信号处理方法和深度学习等学科领域,需要综合协同多个专业领域的分析工具。针对飞机复杂运动机构故障诊断分析框架中所论述的3个层级,给出实现每个层级所使用的主要技术方法,主要包括数据生成层中的动力学模型建立、多

源传感器数据特征转换与融合以及故障诊断模型搭建,从以上3个方面依次开展飞机复杂运动机构故障诊断技术应用研究。

2.1 可故障参数注入的动力学仿真模型

2.1.1 旋转副间隙模型

合理的孔轴间隙建模方法可以确保动力学分析的准确性^[21]。通常,带有间隙的运动副模型包括旋转副、圆柱副和球形关节的几何运动模型。本文所讨论的下位撑杆锁的运动副是轴销与轴套的圆柱副形式,因此建模过程采用圆柱副的间隙配合模型,采用5个球面接触模拟孔轴间隙配合,如图5所示,上下两个面孔壁尺寸为 D ,多球轴结构尺寸为 d ,间隙 $\Delta = D - d$ 。





图5 5个球面接触的孔轴间隙模型

Fig. 5 Hole-shaft clearance model of five spherical contact

由于孔轴的轴向由螺母进行约束,所以为了放开径向自由度限制轴向自由度,需要在孔轴圆柱副中额外设置点面约束,模拟孔轴间隙配合的两点接触模式和线接触模式,如图6所示。



(a) 两点接触模式 (a) Two-point contact mode
(b) 线接触模式 (b) Line contact mode

图6 孔轴间隙模型接触模式

Fig. 6 Contact mode of hole-shaft clearance model

2.1.2 接触力模型

接触碰撞力模型的准确性及有效性对于计算带结构间隙的孔轴配合动力学仿真极为重要,采用的碰撞接触力模型为Hertzian模型^[22],该模型将接触碰撞简化为一个弹簧阻尼系统,其基本形式如下:

$$F_N = K\delta^{1.5} + D\dot{\delta} \quad (1)$$

式中, D 表示阻尼系数; K 表示碰撞体的接触刚度系数; δ 表示穿透深度; $\dot{\delta}$ 表示穿透速度。

此外,动态系统必然存在摩擦力,本文具有间隙的圆柱副摩擦力模型采用修正的Coulbomb摩擦模型,即Threlfall模型,其表达形式如下:

$$f_T = -\mu_f F_N \frac{v_r}{v_0} \left(1 - e^{-3|v_r|/v_0}\right) \quad (2)$$

式中, μ_f 为动摩擦系数; v_r 为相对切向速度, v_r 为其矢量形式; v_0 为摩擦力与切向速度无关的临界速度。

运动机构由于其复杂的机械运动,随着工作时间的增加不可避免地会出现磨损、间隙等问题,因

此针对这两个方面进行详细建模是对动力学仿真模型进行故障参数注入的关键技术。同时,对于运动机构中可能出现的部件疲劳,则可通过动力学建模时修改其物理参数实现故障参数注入。

2.2 多源传感数据融合

2.2.1 格拉姆角场

格拉姆角场(Gramian angular field, GAF)是基于极坐标表示的一种理解时间序列的方法^[23],GAF的优点在于它提供了一种保持时间依赖性的方法,因为时间随着位置从左上角移动到右下角而增加。通过关于时间间隔 k 的方向的叠加来表示相对相关性。格拉姆角和场(Gramian angular summation field, GASF)的流程如图7所示,实现步骤如下:

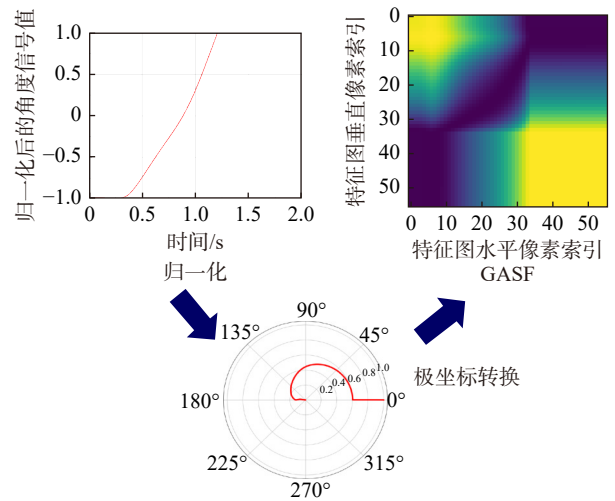


图7 格拉姆角和场示意图

Fig. 7 Schematic diagram of Gramian angular summation field

步骤1: 对于一个时间序列 $X = \{x_1, x_2, \dots, x_n\}$,将数据范围缩放到 $[-1, 1]$ 之间:

$$\tilde{x}_i = \frac{x_i - \max(X) + (x_i - \min(X))}{\max(X) - \min(X)} \quad (3)$$

步骤2: 将缩放后的序列数据转换到极坐标系,即将数值看作夹角余弦值,时间戳看作半径:

$$\begin{cases} \phi_i = \arccos \tilde{x}_i, -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r_i = \frac{t_i}{N_0}, t_i \in N_0 \end{cases} \quad (4)$$

式中, \tilde{X} 为归一化后的时间序列; t_i 为时间戳; N_0 为用于正则化极坐标系跨度的常数因子,转换后的角度范围为 $[0, \pi]$ 。

步骤3: 通过考虑每个点之间的三角和来识别不同时间间隔内的时间相关性,最终GASF的计算转化到直角坐标系下,变成了类似于内积的操作:

$$GASF = \cos(\phi_i + \phi_j) = \tilde{X}^T \cdot \tilde{X} - \sqrt{I - \tilde{X}^2} \cdot \sqrt{I - \tilde{X}^2} \quad (5)$$

式中, ϕ_i 和 ϕ_j 分别为时间序列中第 i 个和第 j 个数据

点转换后的极角; \mathbf{I} 为单位行向量。

2.2.2 马尔可夫变迁场

马尔可夫变迁场(Markov transition field, MTF)基于状态转移概率生成二维图像,能够反映时间序列在不同状态间的统计依赖性,适用于分析非平稳性信号的瞬态特征。MTF的流程如图8所示,实现步骤如下:

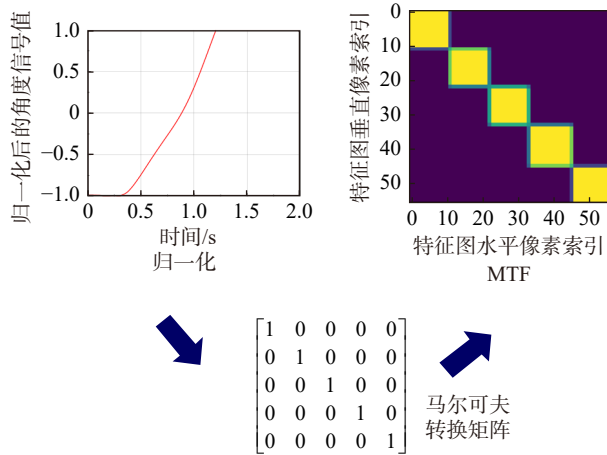


图 8 马尔可夫变迁场示意图

Fig. 8 Schematic diagram of Markov transition field

步骤 1: 首先将序列数据 $X = \{x_1, x_2, \dots, x_n\}$ 按照其取值范围划分为 Q 个分位箱,并将每个数据点分配给相应的箱 $q_j (j \in [1, Q])$ 。

步骤 2: 通过以一阶马尔可夫链沿着时间轴的方式计数分位数箱之间的转移来构造 $Q \times Q$ 加权邻接矩阵 W_q , $w_{i,j}$ 由分位数 q_j 中的点被分位数 q_i 的点跟随的频率给出:

$$W_q = \begin{bmatrix} w_{11} | P(x_t \in q_1 | x_{t-1} \in q_1) & \dots & w_{1Q} | P(x_t \in q_1 | x_{t-1} \in q_Q) \\ w_{21} | P(x_t \in q_2 | x_{t-1} \in q_1) & \dots & w_{2Q} | P(x_t \in q_2 | x_{t-1} \in q_Q) \\ \vdots & & \vdots \\ w_{Q1} | P(x_t \in q_Q | x_{t-1} \in q_1) & \dots & w_{QQ} | P(x_t \in q_Q | x_{t-1} \in q_Q) \end{bmatrix} \quad (6)$$

步骤 3: 构建马尔可夫变迁场, 矩阵尺寸为 $[n, n]$, $M_a[i, j]$ 的值为 $W_q[q_i, q_j]$:

$$M_a = \begin{bmatrix} M_{a11} & M_{a12} & \dots & M_{a1n} \\ M_{a21} & M_{a22} & \dots & M_{a2n} \\ \vdots & \vdots & & \vdots \\ M_{an1} & M_{an2} & \dots & M_{ann} \end{bmatrix} = \begin{bmatrix} w_{ij} | x_1 \in q_i, x_1 \in q_j & \dots & w_{ij} | x_1 \in q_i, x_n \in q_j \\ w_{ij} | x_2 \in q_i, x_1 \in q_j & \dots & w_{ij} | x_2 \in q_i, x_n \in q_j \\ \vdots & & \vdots \\ w_{ij} | x_n \in q_i, x_1 \in q_j & \dots & w_{ij} | x_n \in q_i, x_n \in q_j \end{bmatrix} \quad (7)$$

通过 GASF 和 MTF 对运动机构的仿真数据进行信号处理, 将一维时序信号分析转换为图像分析问题, 通过联合使用这两种信号转换方法, 一方面提取

运动时序信号的稳态特征以反映机构运行的基本表现, 另一方面提取动态突变特征以增强异常检测能力。

2.3 基于残差网络的故障诊断模型

残差网络由 HE 等^[24]提出, 通过引入残差连接(residual connection)解决了深层网络的梯度消失和网络退化问题。其核心思想是: 让网络学习残差, 即输入与输出之间的差异, 而不是直接学习输出, 通过跳跃连接将输入直接传递到输出, 使得网络更容易优化。

2.3.1 “E 型”残差块

“E 型”残差块(residual block)构建了一条长路径和一条短路径, 短路径执行尽可能少的操作以使学习深度架构变得更容易, 更少的操作意味着在梯度中出现噪声的机会更少, 这使得将有用的梯度反向传播比其他情况更容易; 长路径执行实际操作, 学习通过跳跃连接重新添加的复杂度单元。“E 型”残差块要求模块的输入和输出需要具有完全相同的形状, 其结构如图9所示。

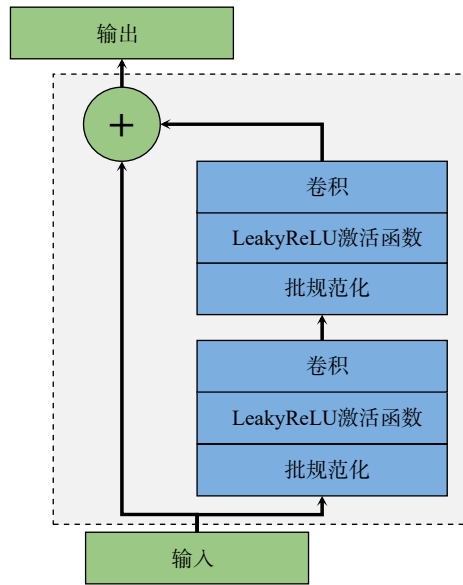


图 9 “E 型”残差块结构

Fig. 9 Type E residual block structure

2.3.2 残差瓶颈

瓶颈结构(bottleneck block)通过引入 1×1 卷积来减少特征图的通道数, 从而降低计算复杂度。短路径只是执行 1×1 卷积后执行批规范化, 改变张量的通道数据量; 长路径有 3 个隐藏层, 第 1 个隐藏层使用 1 个 1×1 卷积来缩小通道的数量进行降维, 在中间执行普通隐藏层, 然后再使用 1×1 卷积将通道数量恢复进行升维, 其结构如图10所示。

联合使用“E 型”残差块和瓶颈结构作为故障诊断模型的主架构, 可以构建具备稳定训练特性与优异学习能力的深层网络。其中, 瓶颈结构通过通道维度的压缩与扩张能更高效地学习数据中的复杂模

式,提升网络对故障特征的表达能力;同时“E型”残差块通过直连通道实现层间信息的跨层传递,增强了深层网络的可训练性。

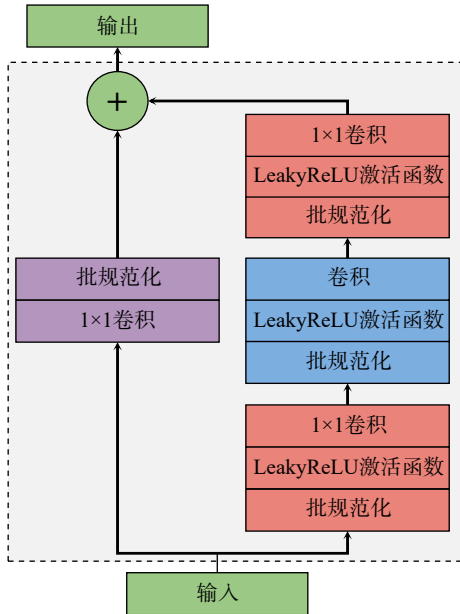


图 10 残差瓶颈结构

Fig. 10 Bottleneck block structure

2.3.3 注意力机制

注意力机制的核心框架最早由 BAHDANAU 等^[25]提出,旨在通过动态权重分配机制解决传统网络对输入特征全局均等处理导致的关键信息淹没问题。该机制的核心思想在于:模型不再只依赖最后一个隐藏状态进行决策,而是动态地“关注”输入样本的不同区域,并为这些区域分配差异化的权重系数。

(1) 通道注意力机制

传统网络通常假设所有输入或中间层通道具有同等重要性,而通道注意力通过计算通道间的全局统计相关性,为不同通道分配不同的权重,抑制冗余的均匀区域特征。通道注意力结构如图 11 所示,实现步骤如下:

步骤 1: 首先对特征图每个通道的空间维度进行压缩,使用全局平均池化将空间维度的信息压缩到一个标量,并构建通道级全局特征:

$$\mathbf{Z} = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W \mathbf{X}[:, i, j] \quad (8)$$

式中, H 和 W 分别为输入特征图垂直方向和水平方向的尺寸; h 和 w 分别为垂直方向和水平方向的空间索引。

步骤 2: 通过全连接网络构建多层感知机并学习通道间关系,生成权重向量,其中第一层用于降维并使用 ReLU 激活函数,第二层用于升维并使用 Sigmoid 激活函数:

$$z_{\text{low}} = \mathbf{W}^{(1)} \mathbf{Z} + \mathbf{b}^{(1)} \quad (9)$$




图 11 通道注意力结构

Fig. 11 Channel attention structure

$$z_{\text{active}} = \text{ReLU}(z_{\text{low}}) \quad (10)$$

$$\mathbf{S} = \sigma(\mathbf{W}^{(2)} z_{\text{active}} + \mathbf{b}^{(2)}) \quad (11)$$

式中, $\mathbf{W}^{(1)}$ 和 $\mathbf{W}^{(2)}$ 分别为第一层和第二层全连接层的权重矩阵; $\mathbf{b}^{(1)}$ 和 $\mathbf{b}^{(2)}$ 分别为第一层和第二层全连接层的偏置向量。

步骤 3: 将计算得到的通道权重与原始特征图逐通道相乘,得到输出特征图:

$$\mathbf{Y} = \mathbf{X} \otimes \mathbf{S}^T \quad (12)$$

(2) 空间注意力机制

空间注意力关注特征图中哪些局部区域更重要,通过计算空间位置的权重,突出关键区域。空间注意力结构如图 12 所示,实现步骤如下:

步骤 1: 首先进行多模式池化的信息提取,通过两种通道方向的池化操作获取空间特征,最大值池化保留每个位置的最大激活,平均值池化统计每个位置的平均激活:

$$\mathbf{M}_{\text{max}} = \max_c \mathbf{X}[c, :, :] \quad (13)$$

$$\mathbf{M}_{\text{avg}} = \frac{1}{C} \sum_{c=1}^C \mathbf{X}[c, :, :] \quad (14)$$

式中, C 为通道数; c 为通道索引。

步骤 2: 将两个池化结果合并成双通道张量 $\mathbf{M} = [\mathbf{M}_{\text{max}}, \mathbf{M}_{\text{avg}}]$,再通过卷积网络学习空间权重矩阵,其中第一层卷积使用 ReLU 激活函数,第二层卷积使用 Sigmoid 激活函数且输出通道数为 1:

$$\mathbf{C}_1 = \text{Conv}(\mathbf{W}^{(1)} \mathbf{M} + \mathbf{b}^{(1)}) \quad (15)$$

$$\mathbf{C}_{\text{active}} = \text{ReLU}(\mathbf{C}_1) \quad (16)$$

$$\mathbf{A} = \sigma(\mathbf{W}^{(2)} \mathbf{C}_{\text{active}} + \mathbf{b}^{(2)}) \quad (17)$$

式中, $\mathbf{W}^{(1)}$ 和 $\mathbf{W}^{(2)}$ 分别为第一层和第二层卷积的权重矩阵; $\mathbf{b}^{(1)}$ 和 $\mathbf{b}^{(2)}$ 分别为第一层和第二层卷积的偏置向量。

步骤 3: 将计算得到的权重矩阵与原始特征图逐元素相乘,得到输出特征图:

$$\mathbf{Y} = \mathbf{X} \otimes \mathbf{A}^T \quad (18)$$

针对飞机复杂运动机构故障所呈现的多种特征变化,联合使用通道和空间注意力机制可以使故障诊断模型更精准地区分正常状态与故障状态,同时通道和空间注意力结构可灵活地嵌入现有网络中,无需对现有网络层级间的接口进行大幅调整,也不会显著增加计算成本,从而提供了很强的扩展性。




图 12 空间注意力结构

Fig. 12 Spatial attention structure

3 试验验证与结果分析

以某型飞机起落架下位撑杆锁机构为例, 对本文设计的飞机复杂运动机构的故障诊断分析方法体系开展验证, 证明本文所述方法结构在具体应用时的可行性以及准确性。该起落架下位撑杆锁机构如图 13 所示。




图 13 起落架下位撑杆锁机构模型

Fig. 13 Landing gear lower pole locking mechanism model

下位撑杆锁机构由两套互相关联的过中心连杆系统组成: 上、下锁杆组成的一级过中心系统和过中心锁摇臂与过中心锁杆组成的二级过中心系统, 其中, 两套过中心机构不仅通过铰接相连, 其过中心锁摇臂与下锁杆之间还通过锁紧弹簧和解锁作动筒连接。该下位撑杆锁机构的具体结构参数如表 1 所示。

3.1 锁机构模型数据生成

为将体系框架中的数据生成层应用于下位撑杆锁机构, 相继开展故障模式分析、部件级试验验证、

组件级模型建模以及故障数据生成, 通过软件间的接口定义实现模型与数据库之间的连接, 数据生成层的处理流程如图 14 所示。

表 1 下位撑杆锁机构结构参数

Tab. 1 Structural parameters of lower pole locking mechanism

参数名称	单位	数值
OA铰接点距离	mm	373
AB铰接点距离	mm	55
上锁杆质量	kg	6.17
BC铰接点距离	mm	37.5
过中心锁杆质量	kg	0.63
CD铰接点距离	mm	65
过中心锁摇臂质量	kg	2.14
AE铰接点距离	mm	514.5
AD铰接点距离	mm	127
下锁杆质量	kg	15.82

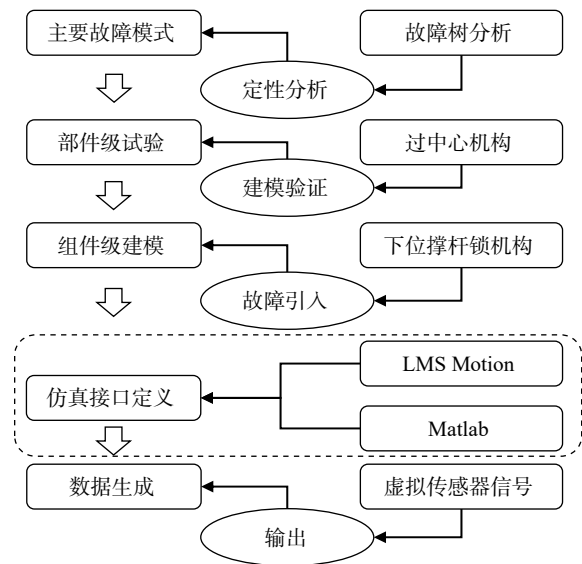


图 14 数据生成层处理流程

Fig. 14 Data generation layer processing flow

3.1.1 主要故障模式分析

对下位撑杆锁机构上锁失效故障进行故障分析, 以揭示影响锁机构上锁的故障因素, 并为后续故障诊断环节的关键故障模式分析提供支撑。本文采用故障树方法分析主要故障工况, 对下位撑杆锁机构上锁失效的影响因素进行了定性分析, 通过构建故障树模型, 系统梳理了各类故障原因及相互关系, 如图 15 所示, 故障树具体事件描述如表 2 所示。

本文研究对象为锁机构, 不考虑收放作动筒影响, 假定收放作动筒可以正常提供起落架收放驱动力。依据分析结果, 影响机构上锁的主要原因包括: 锁紧弹簧疲劳导致上锁力不足, 改变机构分叉点的数量, 影响机构的可靠性; 关节磨损松动导致间隙偏差使得轴与孔的配合可能出现设计范围之外的间隙, 使得锁机构无法顺利上锁; 关节润滑不足导致机

构的旋转阻尼增大, 使起落架的收放时间滞后; 锁杆变形导致机构运动轨迹偏移造成起落架运动卡滞。

由于机构的锁紧弹簧疲劳、关节间隙变大以及关节润滑不足三种故障模式在不进行机构拆除的条件下的检测难度高, 且其发生概率也较高, 因此对这三种故障因素进行着重分析。

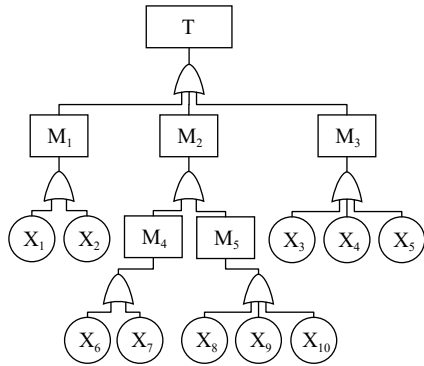


图 15 下位撑杆锁机构上锁失效故障树

Fig. 15 Lock failure fault tree of lower pole locking mechanism

表 2 故障树事件描述

Tab. 2 Fault tree event description

事件编号	事件描述	事件编号	事件描述
T	下位撑杆锁无法可靠上锁	X3	关节磨损松动
M1	收放作动筒失效	X4	关节润滑不足
M2	过中心锁机构失效	X5	锁杆变形
M3	锁杆机构卡滞	X6	弹簧疲劳
M4	上锁弹簧失效	X7	弹簧断裂
M5	二级锁杆卡滞	X8	关节磨损松动
X1	驱动力无法提供	X9	关节润滑不足
X2	驱动力不足	X10	锁杆变形

3.1.2 故障参数建模验证

弹簧在长期使用中的疲劳表现为最大承载能力下降, 由锁紧弹簧的结构可知, 相同刚度下压缩弹簧的原长与弹簧力成正比, 原长缩短相当于弹簧力变弱, 即疲劳程度加大, 通过调节原长的方式易于量化弹簧的故障程度, 因此, 本文通过改变锁紧弹簧的原长来模拟弹簧的疲劳故障程度; 旋转间隙可以体现孔与轴的配合, 减小旋转副连接销的外径则孔轴间隙变大, 对应于构建的孔轴间隙模型, 通过改变球的直径进而改变孔轴间隙的大小, 因此, 本文通过改变孔轴间隙模型中球的直径来模拟加工精度不足故障; 润滑状态会影响部件间的摩擦力, 而摩擦力可以等效为阻尼力, 通过选择摩擦系数较高的材料作为连接销的材料, 以模拟润滑不良, 对应于旋转副模型, 当润滑不良时, 摩擦力较大, 对应的阻尼系数也较大, 因此, 本文通过改变上锁杆与下锁杆旋转副的转动角阻尼系数来模拟润滑不良故障。

撑杆锁机构可以视作过中心机构^[26], 通过简单过中心机构的试验验证故障参数建模的有效性。该

简单过中心机构的运动形式又可视作曲柄滑块机构, 不同的是在曲柄和连杆之间设置有两根拉簧, 仿真建模验证试验如图 16 所示, 试验平台中, 曲柄通过根部的电机进行驱动, 与连杆相连的滑块被限制在一根滑轨上, 可以沿滑轨自由滑行。




图 16 仿真建模验证试验

Fig. 16 Simulation modeling verification test

以撑杆锁机构中的锁紧弹簧建模验证为例, 基于 LMS Virtula.Lab Motion 12 软件建立过中心机构仿真模型, 并设置弹簧原长、弹簧刚度以及弹簧的阻尼系数参数以匹配试验模型结果。在试验平台采集滑块的位移曲线并与仿真模型滑块位移输出结果对比, 如图 17 所示。




图 17 锁紧弹簧仿真建模验证

Fig. 17 Locking spring simulation modeling verification

上图中曲线为试验采集信号, 点划线为仿真信号, 基于均方根误差 (RMSE) 与交叉相关系数 (CCC) 衡量仿真信号与试验信号的差异:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} = 3.3732 \quad (19)$$

$$CCC = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}} = 0.9995 \quad (20)$$

式中, n 为样本数据点个数; y_i 和 \hat{y}_i 分别为第 i 个样本数据点的试验信号值和仿真信号值; \bar{y} 和 $\bar{\hat{y}}$ 分别为试验信号和仿真信号的均值。

由计算结果可知, 基于 LMS Motion 的建模方法与实物试验在弹簧参数影响下的信号输出基本一致, 故可基于该部件级建模方法扩展到整个锁机构

的组件级建模。其余故障因素遵循相同的试验验证流程:对于旋转间隙则改变曲轴与连杆之间连接销的尺寸,对于旋转阻尼则改变连接销的材料。

3.1.3 撑杆锁机构模型建立

经过部件级建模验证后,同样基于 LMS Motion 软件建立下位撑杆锁机构的仿真模型,下位撑杆锁机构各部件间具体的运动关系如图 18 所示。

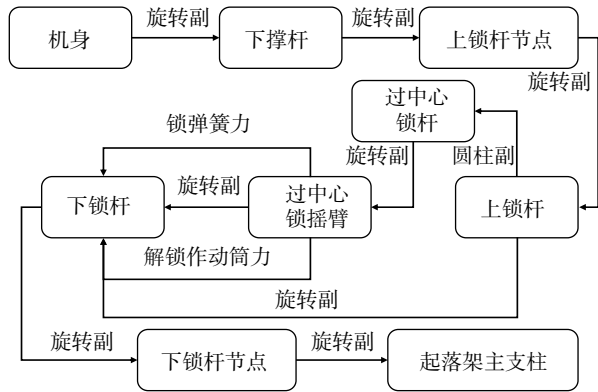


图 18 下位撑杆锁机构运动关系

Fig. 18 Motion relationship of lower pole locking mechanism

下位撑杆锁在起落架收放阶段的运动过程如下:当起落架收起时,在解锁作动筒的作用下,过中心锁摇臂受到的解锁力矩大于锁紧弹簧施加在其上的力矩,二级过中心锁机构解锁,同时收放作动筒作用于上锁杆,带动下锁杆绕上锁杆节点 Z 轴逆时针转动,一级过中心锁机构解锁,然后下锁杆节点沿着 X 轴方向往上锁杆节点靠近,直到起落架收上完毕;当起落架放下时,重力协助收放作动筒驱动起落架运动,此时下锁杆节点沿着 X 轴方向远离上锁杆节点,当下锁杆接近锁定位置时,过中心锁摇臂在锁紧弹簧的作用下迅速从上偏心状态跃迁到下偏心状态,然后带动一级过中心锁机构同时迅速跃迁,然后稳定在下锁杆下方的限位块的位置,从而完成起落架的下位锁定。建模时将解锁作动筒和锁紧弹簧简化为两点力,分别表示为 F_J 和 F_T ,下位撑杆锁机构上锁状态与收起状态的运动示意如图 19 所示。




图 19 下位撑杆锁机构运动状态

Fig. 19 Motion state of lower pole locking mechanism

3.1.4 仿真接口设置

(1) 虚拟传感器定义

在 LMS Motion 软件中分别定义虚拟加速度和角度传感器,如图 20 所示。考虑机构运动空间的影

响,加速度传感器设置在上锁杆侧端面 O_{ac} 节点位置,采集 Y_{ac} 轴方向的加速度信号;角度传感器设置在上锁杆与下锁杆之间的旋转副 O_{ang} 节点位置,采集 Z_{ang} 轴方向的角度信号。




图 20 虚拟传感器设置示意图

Fig. 20 Virtual sensor setup diagram

(2) 软件接口定义

为实现故障工况的自动批量仿真,本文使用 MATLAB 软件编写仿真脚本,实现从 Excel 表格中读取不同工况下的参数组合,然后再导入到 LMS Motion 的参数化模型中进行批量化仿真,再将仿真结果的虚拟传感器信号依次输出到结果 Excel 表格中,软件接口设置的流程如图 21 所示。




图 21 软件接口设置流程图

Fig. 21 Software interface setting flow chart

3.1.5 仿真参数设置

飞机起落架在执行飞行任务时,需完成从滑跑起飞的“收上解锁”到接地着陆“放下锁定”的状态转换。由于起落架下位撑杆锁机构具有动作上的互逆性,其解锁与锁定过程在执行结构和运动逻辑上高度相似,那么如果在起落架收上阶段未能及时发现潜在的锁机构异常,这些故障隐患可能在起落架放下落地时导致锁定失败,进而引发严重的安全风险。因此,在起落架收上阶段进行故障诊断具有预防性,有利于在飞行中及时识别问题并采取措施。

本文对该下位撑杆锁机构的收上解锁阶段进行仿真设置。建模时将起落架收放作动筒的作用简化为作用于上锁杆节点的力矩 $M = 55 \text{ N} \cdot \text{m}$,并且该解锁力矩从随时间依线性减少到 $10 \text{ N} \cdot \text{m}$,力矩驱动上锁杆绕 OZ 轴方向逆时针旋转。本文按照以上叙述的故障形式,一共设置 5 个工作状态,分别为正常、锁紧弹簧疲劳、锁紧弹簧失效、欠润滑和加工精度不足,各状态的故障模型参数设置如表 3 所示。


表 3 中弹簧原长与间隙大小的单位为 mm,角阻

尼系数的单位为 $\text{kg}\cdot\text{m}^2/\text{s}\cdot\text{rad}$ 。各类参数在其分布区间内满足高斯分布, 其中弹簧原长的变化范围参考生产误差 $L_0 = L_0 \pm 0.01H_0$, H_0 为期望长度。仿真时信号采集频率为 1000 Hz, 采集 2 s 仿真时间内下位撑杆锁机构运动过程的加速度和角度信号, 撑杆锁机构每个工作状态采集了 400 组弹簧原长、角阻尼系数和间隙大小的组合, 总共 2000 组参数设置。5 个工作状态下的典型仿真信号如图 22 所示。


表 3 故障模型参数设置

Tab. 3 Fault model parameter setting

状态编号	状态类别	弹簧原长	角阻尼系数	间隙大小
1	正常	297~303	0.3~0.5	0.05~0.08
2	锁紧弹簧一级疲劳	288~297	0.3~0.5	0.05~0.08
3	锁紧弹簧二级疲劳	270~288	0.3~0.5	0.05~0.08
4	欠润滑	297~303	0.5~1	0.05~0.08
5	加工精度不足	297~303	0.3~0.5	0.08~0.12



(a) 不同工况的振动数据
(a) Vibration data of different working conditions



(b) 不同工况的角度数据
(b) Angle data of different working conditions

图 22 锁机构仿真数据

Fig. 22 Lock mechanism simulation data

下位撑杆锁机构仿真初始载荷设置为收放力矩还未施加, 同时解锁作动筒的力还不足以解锁, 使得下位撑杆锁机构处于完全上锁状态, 但锁机构仿真初始位置为上锁杆与下锁杆的轴线重合, 所以锁机构会存在跃迁, 由振动数据结果可以看到锁机构在初始时刻存在明显的冲击; 从 0.3 s 后, 解锁力和收放力矩同时作用于撑杆锁机构, 由于撑杆锁机构解锁的过中心跳跃, 所以出现第一次不稳定小幅度振动;

在撑杆锁机构收上阶段的末尾, 出现第二次不稳定振动, 这是由于二级过中心锁机构从一级过中心机构 XZ 平面的 Y 向区域运动到了负 Y 向区域, 并再次形成类似于过中心的空间状态, 直到锁机构收起完毕引起小的冲击。因此, 将 Y_{ac} 轴方向的加速度时序信号作为特征数据之一。此外, Z_{ang} 轴角度相对变化值可以反映下位撑杆锁机构的收起状态, 因此将该信号作为另一个特征数据。

3.2 多源数据特征分析

为应用体系框架中的特征处理层, 相继开展传感信号特征转换、特征级融合以及模型张量构建, 设计针对数据生成层输入的张量集, 特征处理层的处理流程如图 23 所示。

机械机构的故障诊断需要综合多个传感器的信息, 振动信号反映了下位撑杆锁机构的动态特性, 比如旋转副间隙引发的冲击响应或过中心锁机构解锁瞬间的瞬态振动; 角度信号反映了下位撑杆锁机构的位置变化特征, 比如弹簧疲劳导致的解锁跳跃偏差或欠润滑引起的角度波动。而单一类型的信号往往只能表征机构某一侧面的状态, 因此需要对下位撑杆锁机构的多源数据进行融合。

本文采用双通道的特征级融合方法, 设计传感器类型层: 将振动和角度传感器信号作为两个独立的通道, 保留两个原始信号的物理意义差异, 使得后续设计的故障诊断模型可先针对每个信号类型独立学习其转换后的特征, 再融合不同传感器的信息, 避免将所有特征拼接为单一通道可能带来的信息混淆; 同时, 设计特征转化方法层: 将同一传感器时序信号通过 GASF 和 MTF 方法转化为两个二维特征图, 两种方法作为张量的深度, 使得模型能够同时学习输入的联合特征, 从而提高故障诊断的鲁棒性和准确性。通过特征级融合构建的张量结构见图 24。

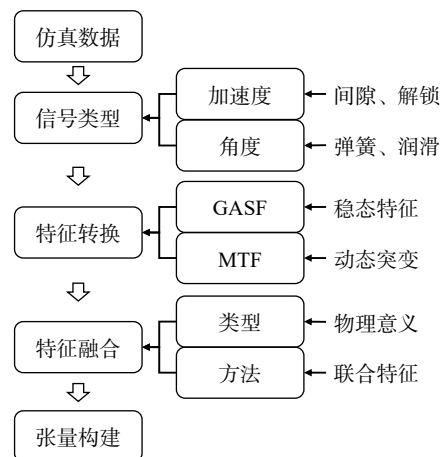


图 23 特征处理层处理流程

Fig. 23 Feature processing layer processing flow

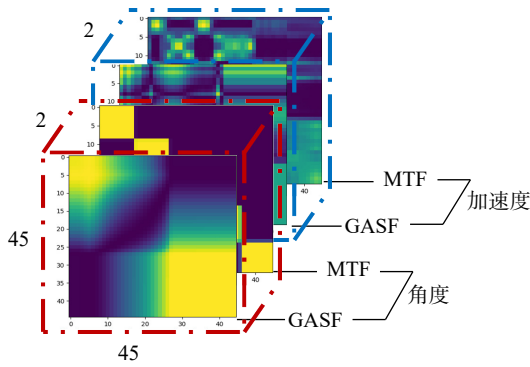


图 24 张量结构设计

Fig. 24 Tensor structure design

3.3 结合注意力机制的残差网络

为应用体系框架中的数据分析层,基于残差网络以及通道和空间注意力机制,设计了针对特征处理层输入的深度学习网络,数据分析层的处理流程如图 25 所示。

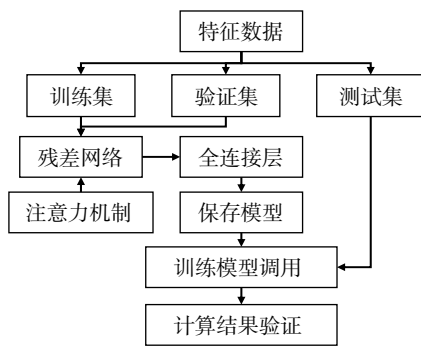


图 25 数据分析层处理流程

Fig. 25 Data analysis layer processing flow

3.3.1 计算环境

本文的神经网络基于 Python 3.12.7 和 PyTorch2.5.1 框架构建,训练过程在一台配备 NVIDIA RTX4080 SUPER(16 GB 显存)、AMD Ryzen 9 7900X CPU 和 32 GB 系统内存的电脑上完成,软件环境基于 CUDA 12.6,配合 NVIDIA 驱动程序 560.94,支持 GPU 计算加速。

数据分析层中的故障诊断模型各训练组件的设置:学习率调度器采用 Pytorch 中的 ReduceLRonPlateau 策略实现当验证集损失在若干个训练周期内无改进时自动衰减学习率,优化器使用保持权重衰减和自适应学习率相分离的 AdamW 算法,该算法参数设置为学习率 $\eta = 0.001$,一阶矩衰减率 $\beta_1 = 0.9$,二阶矩衰减率 $\beta_2 = 0.999$ 和数值稳定性参数 $\epsilon = 10^{-8}$,残差网络与诊断模型主结构中使用 LeakyReLU 激活函数,“leaking”因子设置为 $\alpha = 0.1$,分类损失函数采用交叉熵损失,全局随机数种子设置为 42。

将全部样本按照 0.70 : 0.15 : 0.15 的比例进行分层抽样,划分为训练集、验证集和测试集,以保持各

子集中的类别分布与总体一致,并设置批次大小为 64,那么训练集、验证集和测试集的批次数分别为 22、5 和 5,然后输入到故障诊断模型中进行训练和结果分析。本文设计的故障诊断模型主要分为 4 个阶段,分别采用两个最大池化和一个全局平均池化进行划分,其中在模型第一个瓶颈层后插入通道注意力模块,在第二个“E 型”层后插入空间注意力模块,故障诊断网络的结构如图 26 所示,网络结构参数设置如表 4 所示。




图 26 残差网络设计

Fig. 26 Residual network design

表 4 残差网络结构参数

Tab. 4 Residual network structure parameters

网络层	结构参数	网络层	结构参数
输入层	[Batch,2,2,56,56]	激活层2	LeakyReLU
瓶颈层1	[2,32,(1,3,3)]	E型层2	[64]
通道注意力层	[32]	空间注意力层	[64]
激活层1	LeakyReLU	池化层2	[1,2,2]
E型层1	[32]	瓶颈层3	[64,128,(1,3,3)]
池化层1	[1,2,2]	全局平均池化层	[1,7,7]
瓶颈层2	[32,64,(1,3,3)]	全连接层	128×7×7→5

3.3.2 性能指标

在模型评估过程中,对于样本集计算结果,若一个样本属于正类,并且被预测为正类,那么该结果标记为真正类 TP(true positive),这表明模型能够准确识别目标;若一个样本是正类,但被预测为负类,则该结果标记为假负类 FN(false negative),表明模型出现漏检;若一个样本是负类,但被预测为正类,则该结果标记为假正类 FP(false positive),反映了模型存在误报;若一个样本是负类,并且被预测为负类,那么该结果标记为真负类 TN(true negative)。

采用准确率、召回率、F1 分数、对数损失和宏平均 AUC(area under the curve)值作为故障诊断模型性能验证指标。宏平均 AUC 值是分别计算各类接收者操作特征(receiver operating characteristic)曲线下的面积后所取的平均值,其余指标相应的计算公式如下:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (21)$$

$$Recall = \frac{TP}{TP+FN} \quad (22)$$

$$Precision = \frac{TP}{TP + FP} \quad (23)$$

$$F1_Score = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (24)$$

$$Log_Loss = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^E y_{ij} \ln(p_{ij}) \quad (25)$$

式中, N 为样本数量; E 为类别数量; y_{ij} 为样本 i 对应于类别 j 的标签值; p_{ij} 为模型预测样本 i 属于类别 j 的概率。

3.4 结果分析

3.4.1 试验验证

由于卷积网络自身存在随机性, 为了更可靠地评估故障诊断网络的真实性能, 对设计的模型连续运行 10 次, 记录每次运行结果, 如图 27(a) 所示, 再对 10 次运行结果取平均值后, 计算每个指标在 95% 置信度区间下的数值结果, 如图 27(b) 所示, 其中 95% 置信区间的计算公式如下:

$$95\%CI = \bar{X} \pm 1.96 \cdot S_{\bar{X}} \quad (26)$$


式中, \bar{X} 为样本平均值; $S_{\bar{X}}$ 为样本标准差。

由以上试验结果得出, 基于本文设计框架所提出的故障诊断模型在 95% 置信度下的准确率、召回率、F1 分数和宏平均 AUC 值分别不低于 0.9566、0.9566、0.9566 和 0.9954, 对数损失值不高于 0.2088, 验证了本文设计的飞机复杂运动机构故障诊断方法体系的可行性。

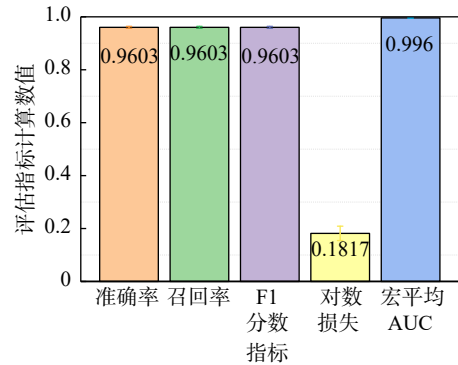
为了全面评估本文设计方法在飞机复杂运动机构故障诊断中的分类性能, 绘制某一次故障诊断模型运行结果的混淆矩阵和 ROC 曲线图, 分别如图 28 和 29 所示。混淆矩阵表示模型对不同故障类别的预测结果与实际标签之间的匹配情况, 曲线下面积 (AUC) 是评估模型整体性能的重要指标, AUC 越接近 1 表示模型的分类能力越强。

由故障分类结果得出, 故障诊断模型很难区分正常和欠润滑工况。分析其原因为两种信号在正交试验设计时的角阻尼系数波动范围不同, 当角阻尼系数在小范围内波动时, 其对下位撑杆锁机构的运动信号影响不明显; 当角阻尼系数在 $0.5 \text{ kg} \cdot \text{m}^2/\text{s}/\text{rad}$ 附近时, 由于正常工况和欠润滑工况的输出信号较为相似, 使得故障诊断模型难以作出区分。

接下来对故障诊断模型注意力模块的作用进行分析, 绘制第一批样本集输入下故障诊断模型的通道注意力权重和空间注意力表现, 如图 30 所示。由注意力模块可视化结果可以看出, 通道注意力更关注前面的通道和较为靠后的通道, 后续对故障诊断模型改进时可以进一步干预注意力通道, 取消激活权重低的通道, 提高模型的处理效率; 对于空间注



(a) 故障诊断模型连续 10 次运行结果
(a) The fault diagnosis model runs for 10 consecutive times



(b) 故障诊断模型性能指标
(b) Performance indexes of fault diagnosis models

图 27 故障诊断模型试验结果

Fig. 27 Experimental results of fault diagnosis models




图 28 故障诊断模型混淆矩阵

Fig. 28 Confusion matrix of fault diagnosis models




图 29 故障诊断模型 ROC 曲线

Fig. 29 ROC curve of fault diagnosis models

注意力来说, 空间注意力热图与特征转换层的图像基

本互补,尤其在图像尖锐处注意力权重的值较高,说明其更加关注图像边界的变化,后续可进一步结合插值运算将二维图像逆变换为一维时序信号,更加直观地展现空间注意力对原始时序信号的作用。

3.4.2 消融试验验证

设计消融试验,以验证基于该方法体系所构建诊断模型的性能,首先考虑特征融合的作用和注意力机制的作用,即 GASF 或 MTF 特征转换方法单独使用,以及调整通道注意力模块使其布置于网络深层(瓶颈层 2 后面添加)、取消通道注意力模块的作用和取消所有注意力模块的作用;其次考虑模型训练组件的作用和诊断模型采用 CNN 网络的影响,即更改学习率调度器为指数衰减、将诊断模型主结构

的 LeakyReLU 激活函数调整为 Sigmoid 激活函数、取消 LeakyReLU 激活函数的作用、取消“E 型”残差块在模型中的作用以及采用常规 CNN 网络(CNN 网络的层数与本文诊断模型的层数保持一致)的结果。为便于清晰地表述以上设置的消融试验模型,本文使用指定的英文符号指代各模型,每个模型运行 10 次,在 95% 置信度下的计算结果汇总见表 5。除对数损失值之外,将消融试验的其他计算结果进行可视化处理,并忽略各计算值的置信区间以更直观地对比不同模型配置的性能,如图 31 所示。

由消融试验结果得到,基于本文设计方法体系所提出的故障诊断模型的综合性能最优:对图 31(a)的试验结果进行分析,在特征处理方面,采用特征级融合模型的结果比单独采用 GASF 和 MTF 的特征转换方法的准确率分别提升了 9.76% 和 1.2%,说明特征级融合方法有效结合了 GASF 和 MTF 两种转换方法在稳态特征和动态突变信号识别的优势;在注意力机制方面,结合通道和空间注意力机制模型的结果比更改通道注意力模块、只保留空间注意力模块和取消注意力模块模型的结果准确率分别提升了 1.1%、0.29% 和 0.5%,说明注意力机制在该任务条件下对模型性能的提升不明显,但由对比结果可以看出通道注意力模块的位置对模型的影响较为显著,调整到深层位置后甚至比取消注意力模块的模型性能表现还要差;对图 31(b)的试验结果进行分析,首先能明显看出 SIG 模型的结果反而向图中圆心收缩,是因为在该模型指标下没有达到作图设置的最低阈值,表明该模型的性能欠佳;在训练组件方面,采用本文训练组件设置的模型结果比学习率调度器调整、激活函数调整和取消主结构的激活函数的模型结果准确率分别提升了 1.06%、16.66% 和 1.26%,说明依据本文设置的训练组件是有效的,尤其是在激活函数设置的表现上,调整为 Sigmoid 激活函数性能差的原因可能是激活函数饱和导致梯度

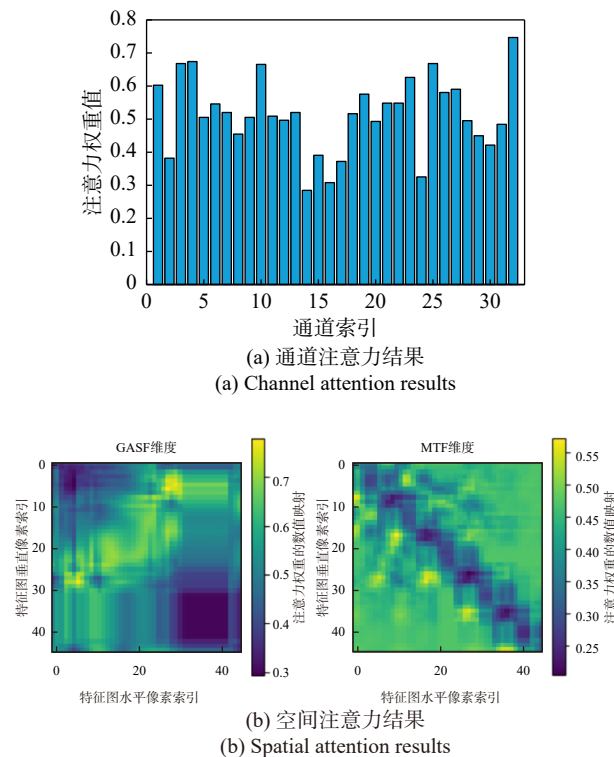


图 30 注意力模块结果可视化

Fig. 30 Visualization of attention module results

表 5 消融试验结果汇总

Tab. 5 Summary of ablation experimental results

模型	准确率	召回率	F1分数	对数损失	宏平均AUC
本文设计方法(ARN)	0.9603±0.0037	0.9603±0.0037	0.9603±0.0037	0.1817±0.0272	0.9960±0.0006
GASF转换单独作用(GASF)	0.8627±0.0296	0.8627±0.0296	0.8588±0.0340	0.4403±0.2045	0.9824±0.0035
MTF转换单独作用(MTF)	0.9483±0.0053	0.9483±0.0053	0.9483±0.0053	0.2416±0.0380	0.9948±0.0009
更改通道注意力模块(CAM)	0.9493±0.0049	0.9493±0.0049	0.9493±0.0049	0.2190±0.0264	0.9950±0.0007
只有空间注意力模块(SAM)	0.9574±0.0047	0.9574±0.0047	0.9573±0.0047	0.1698±0.0189	0.9960±0.0006
没有注意力模块(RN)	0.9553±0.0037	0.9553±0.0037	0.9553±0.0037	0.2039±0.0229	0.9951±0.0008
指数衰减(EDR)	0.9497±0.0057	0.9497±0.0057	0.9496±0.0057	0.2056±0.0315	0.9953±0.0007
Sigmoid激活函数(SIG)	0.7937±0.0793	0.7937±0.0793	0.7757±0.0906	0.8200±0.4112	0.9806±0.0067
取消激活函数(NAF)	0.9477±0.0062	0.9477±0.0062	0.9477±0.0062	0.2265±0.0212	0.9946±0.0004
取消E型残差块(NER)	0.9487±0.0031	0.9487±0.0031	0.9486±0.0031	0.1644±0.0116	0.9960±0.0006
常规CNN网络(CNN)	0.9337±0.0076	0.9337±0.0076	0.9333±0.0081	0.1743±0.0174	0.9933±0.0004




图31 消融试验结果

Fig. 31 Ablation experimental results

消失,使得模型性能明显下降;在模型结构方面,采用“E型”残差块和残差瓶颈组合的残差网络比仅采用残差瓶颈和CNN网络模型的准确率分别提升了1.16%和2.66%,说明采用残差网络结构形式的诊断模型在复杂运动机构的故障诊断任务中具有优势。以上结果验证了本文设计的飞机复杂运动机构故障诊断方法体系的有效性。

4 结论

本文提出了一种飞机复杂运动机构故障诊断方法体系,研究结论如下:

(1)提出了一种面向飞机复杂运动机构的故障诊断方法体系,设计了数据生成层、特征处理层和数据分析层分别解决传统复杂运动机构在典型故障模式下数据难获取、多源信号特征难融合以及故障工况难诊断的3个问题。

(2)应用本文设计的故障诊断分析框架,建立了飞机复杂运动机构的故障诊断分析流程,首先通过可靠性分析确定主要故障影响参数,然后结合实物试验验证仿真建模的有效性,再通过正交试验获得故障仿真样本库,并依据格拉姆角场和马尔可夫变迁场方法构建特征级融合的张量集,最后以结合注意力机制的残差网络实现故障诊断任务。

(3)以起落架下位撑杆锁机构为例,试验验证了本文设计的故障诊断方法体系具有可行性和有效性,本文方法为飞机复杂运动机构的故障诊断提供一种解决思路。

值得注意的是,现有的研究具有一定局限性,因为它考虑的是基于部件级试验验证的静态仿真模

型,并且没有考虑异构传感数据的输入影响。未来,将进一步在数据生成层运用数字孪生技术提升模型的自适应性,在特征处理层融入多源异构数据信号分析方法,以及在数据分析层继续融合其他深度学习方法和技巧以增强该方法体系的扩展性和通用性。

参考文献:

- [1] 甘亚东,姚雄华,刘万春.民用飞机舱门试验研究综述[J].航空工程进展,2022,13(5):28-35.
GAN Yadong, YAO Xionghua, LIU Wanchun. Research overview for door tests of civil airplane[J]. Advances in Aeronautical Science and Engineering, 2022, 13(5): 28-35.
- [2] NTSB. Aviation investigation final report[R]. Florida: National Transportation Safety Board, 2022.
- [3] 郭丞皓,于劲松,宋悦,等.基于数字孪生的飞机起落架健康管理技术[J].航空学报,2023,44(11):227629.
GUO Chenghao, YU Jinsong, SONG Yue, et al. Application of digital twin-based aircraft landing gear health management technology[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(11): 227629.
- [4] PHILLIPS P, DISTON D, STARR A. Perspectives on the commercial development of landing gear health monitoring systems[J]. Transportation Research Part C: Emerging Technologies, 2011, 19(6): 1339-1352.
- [5] 中国民用航空局,国家发展和改革委员会,交通运输部.“十四五”民用航空发展规划[R].北京:中国民用航空局,2021.
- [6] ZIO E. Prognostics and Health Management of Industrial Equipment[M]/Kadry S. Diagnostics and Prognostics of Engineering Systems: Methods and Techniques. Hershey, PA,

- USA: IGI Global, 2013: 333-356.
- [7] LYU S C, SUN W Z, WANG H. Aircraft fault diagnosis and prediction algorithm based on deep learning and Markov model[C]//Proceedings of 3rd International Conference on Artificial Intelligence and Autonomous Robot Systems (AIARS). IEEE, 2024: 427-432.
- [8] 冯东洋. 基于 AMESim 的飞机起落架液压系统故障诊断方法研究 [D]. 沈阳: 沈阳航空航天大学, 2022.
FENG Dongyang. Research on the fault diagnosis method of aircraft landing gear hydraulic system based on AMESim[D]. Shenyang: Shenyang Aerospace University, 2022.
- [9] 杨超. 飞机起落架液压收放系统故障诊断方法研究 [J]. *液压气动与密封*, 2021, 41(7): 50-52.
YANG Chao. Research on fault diagnosis method of aircraft landing gear hydraulic retraction and release system[J]. *Hydraulics Pneumatics & Seals*, 2021, 41(7): 50-52.
- [10] CHE C C, WANG H W, FU Q, et al. Combining multiple deep learning algorithms for prognostic and health management of aircraft[J]. *Aerospace Science and Technology*, 2019, 94: 105423.
- [11] 王强, 吴伟, 刘东, 等. 飞机舱门收放系统 CPSO-BP 神经网络故障仿真与诊断 [J]. *重庆理工大学学报(自然科学)*, 2023, 37(11): 293-299.
WANG Qiang, WU Wei, LIU Dong, et al. CPSO-BP neural network fault simulation and diagnosis of aircraft door retracting system[J]. *Journal of Chongqing University of Technology(Natural Science)*, 2023, 37(11): 293-299.
- [12] 刘强, 詹志强, 王硕, 等. 数据驱动的高速列车轴承多模态运行监控与故障诊断 [J]. *中国科学: 信息科学*, 2020, 50(4): 527-539.
LIU Qiang, ZHAN Zhiqiang, WANG Shuo, et al. Data-driven multimodal operation monitoring and fault diagnosis of high-speed train bearings[J]. *Scientia Sinica(Informationis)*, 2020, 50(4): 527-539.
- [13] LEI Y G, LIN J, HE Z J, et al. A method based on multi-sensor data fusion for fault detection of planetary gearboxes[J]. *Sensors*, 2012, 12(2): 2005-2017.
- [14] UNAL M, ONAT M, DEMETGUL M, et al. Fault diagnosis of rolling bearings using a genetic algorithm optimized neural network[J]. *Measurement*, 2014, 58: 187-196.
- [15] 宫文峰, 陈辉, 张泽辉, 等. 基于改进卷积神经网络的滚动轴承智能故障诊断研究 [J]. *振动工程学报*, 2020, 33(2): 400-413.
GONG Wenfeng, CHEN Hui, ZHANG Zehui, et al. Intelligent fault diagnosis for rolling bearing based on improved convolutional neural network[J]. *Journal of Vibration Engineering*, 2020, 33(2): 400-413.
- [16] 张艳飞, 邵阳, 公维炜, 等. 考虑小波包-灰度共生矩阵的高压断路器弹簧疲劳故障程度诊断研究 [J]. *机械科学与技术*, 2024, 43(2): 274-281.
ZHANG Yanfei, SHAO Yang, GONG Weiwei, et al. Depth diagnosis of spring mechanical faults of high voltage circuit breakers considering wavelet packet-gray level co-occurrence matrix method[J]. *Mechanical Science and Technology for Aerospace Engineering*, 2024, 43(2): 274-281.
- [17] 姜海龙, 李潼清, 程浩, 等. 基于 PSO-LSSVM 的高压真空断路器弹簧机构机械故障诊断 [J]. *高压电器*, 2019, 55(12): 248-255.
JIANG Hailong, LI Tongqing, CHENG Hao, et al. Mechanical fault diagnosis for spring mechanism of high-voltage vacuum circuit breaker based on PSO-LSSVM[J]. *High Voltage Apparatus*, 2019, 55(12): 248-255.
- [18] RUDSARI F N, RAZI-KAZEMI A A, SHOOREHDELI M A. Fault analysis of high-voltage circuit breakers based on coil current and contact travel waveforms through modified SVM classifier[J]. *IEEE Transactions on Power Delivery*, 2019, 34(4): 1608-1618.
- [19] MUSTAFA K, CHENG K. Improving production changeovers and the optimization: a simulation based virtual process approach and its application perspectives[J]. *Procedia Manufacturing*, 2017, 11: 2042-2050.
- [20] KIBRETE F, ENGIDA WOLDEMICHAEL D, SHIMELS GEBREMEDHEN H. Multi-sensor data fusion in intelligent fault diagnosis of rotating machines: a comprehensive review[J]. *Measurement*, 2024, 232: 114658.
- [21] 印寅. 起落架收放动力学及可靠性研究 [D]. 南京: 南京航空航天大学, 2017.
YIN Yin. Dynamics and reliability analysis of retraction of landing gear[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2017.
- [22] ZHANG Z P, WU S X, ZHU H, et al. Analysis of the synchronized locking dynamic characteristics of a dual-sidestay main landing gear retraction mechanism[J]. *Aerospace*, 2024, 11(5): 356.
- [23] WANG Z G, OATES T. Imaging time-series to improve classification and imputation[C]//24th International Joint Conference on Artificial Intelligence (IJCAI). Buenos Aires, Argentina, 2015: 3939-3945.
- [24] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016: 770-778.
- [25] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[EB/OL]. (2014-09-01)[2025-04-30]. <https://arXiv.org/abs/1409.0473v6>.
- [26] 南京航空航天大学. 基于控制延拓的起落架过中心机构分岔试验装置及方法: 202311340070.7[P]. 2024-01-12.

第一作者:何东钰(1998—),男,博士研究生。

E-mail: bx2401370@nuaa.edu.cn

通信作者:印寅(1986—),男,博士,教授。

E-mail: yinyin@nuaa.edu.cn