

基于 MEF-MSCNN-LSTM 模型的飞机电控舵面故障检测研究

耿子庆, 姜硕, 蔺吉媛, 王储, 张巍严

(吉林通用航空职业技术学院, 吉林 吉林 132013)

摘要: 随着航空系统智能化水平的提升, 飞行器对飞控系统的实时响应与自主诊断能力提出更高要求; 电控舵面作为关键执行部件, 其故障将直接影响飞行稳定与安全; 为提升识别精度与响应效率, 研究构建融合多尺度卷积与长短期记忆网络的故障检测模型, 并引入多阶段信号降噪机制以优化特征提取; 模型基于多源飞行数据训练, 精准捕捉电压、电流与偏转角等关键序列特征的演化模式; 实验表明, 模型在完全训练后准确率达 98.7%, 可在异常发生前 2.2 s 实现高置信度预警, 具备出色的时效性与稳定性; 同时在典型巡航工况下识别出微弱间歇性迟滞故障, 分类置信度为 0.974, 体现了良好的早期检测能力; 研究验证了该模型在复杂非线性场景中的鲁棒性与实用性, 为飞控系统故障诊断由被动响应向智能预测转变提供了技术支撑。

关键词: 电控舵面; 多尺度卷积神经网络; 长短期记忆网络; 多阶段信号降噪; 故障检测

Electric Control Fault Detection of Aircraft Rudder Surface Based on MEF-MSCNN-LSTM Model

GENG Ziqing, JIANG Shuo, LIN Jiyuan, WANG Chu, ZHANG Weiyan

(Jilin General Aviation Vocational and Technical College, Jilin 132013, China)

Abstract: With the improvement of intelligent aviation systems, it needs higher requirements for aircraft to meet real-time responsiveness and autonomous diagnosis of flight control systems. As a critical actuator component, its failures can directly affect flight stability and safety. To enhance detection accuracy and response efficiency, this paper proposes a fault detection model combining multi-scale convolutional neural networks (MSCNN) and long short-term memory (LSTM) networks. A multi-stage signal denoising mechanism is integrated to optimize feature extraction. The model is trained on multi-source flight data to accurately capture the temporal evolution patterns of key parameters such as voltage, current, and deflection angle. Experimental results show that the model achieves an accuracy of 96.7% and a miss rate of below 1.08% after full training. It can generate a high-confidence early warning of 2.2 s before the occurrence of abnormal events, demonstrating excellent timeliness and stability. Additionally, the model successfully identifies weak intermittent lag faults during typical cruise conditions with a classification confidence of 0.974, indicating a strong early detection capability. The robustness and practical applicability of the model are verified under complex nonlinear scenarios, which provides technical support for shifting fault diagnosis in flight control systems from passive response to intelligent prediction.

Keywords: electric control rudder surface; MSCNN; LSTM; multi-stage signal denoising; fault detection

0 引言

随着航空技术的持续发展, 现代飞行器对飞行控制系统的可靠性与智能化水平提出了更高要求^[1]。作为飞控系统中承载姿态调节与飞行稳定控制关键任务的核心部件, 电控舵面系统的运行状态直接影响到飞行器的飞

行安全与控制精度^[2]。近年来, 电传操纵技术、集成化执行单元与分布式控制结构不断发展, 使得舵面系统呈现出高集成、高非线性、多变量耦合等特点, 在提升控制性能的同时也加剧了故障隐蔽性与检测复杂性^[3]。一旦舵面发生故障, 轻则引起机动性能下降, 重则可致失控事故。因此, 构建一种具备高鲁棒性、强泛化能力与

收稿日期:2025-06-16; 修回日期:2025-07-23。

基金项目:吉林省 2024 年度职业教育与成人教育教学改革研究项目(2024ZCY166)。

作者简介:耿子庆(1981-),男,副教授。

引用格式:耿子庆,姜硕,蔺吉媛,等.基于 MEF-MSCNN-LSTM 模型的飞机电控舵面故障检测研究[J].计算机测量与控制,2025,33(11):23-31.

实时响应性能的故障检测方法，对保障飞行安全、延长系统寿命具有重要现实意义。

当前，智能故障检测技术日益成为研究热点，其中以卷积神经网络 (CNN, convolutional neural networks) 为代表的深度学习方法在故障识别领域中取得了显著进展。国内外学者均对其展开了研究，例如，文献 [4] 针对传统多元统计方法在多模态过程故障检测中存在的阈值设定困难、误报与漏报率高等问题，提出一种基于平铺 CNN 的故障检测方法。该方法将多传感器数据编码为二维图像，借助深度学习实现模式识别。通过 Adam 算法优化模型权重，并引入灰狼优化算法进行超参数调优^[4]。文献 [5] 针对传统转子故障诊断精度低、适应性差的问题，提出一种基于 CNN 的故障识别方法。通过试验平台采集不平衡、碰摩等故障工况下的时域振动信号，构建 CNN 模型。实验结果表明，该方法准确率达 99.16%，展现出良好的应用前景与工程适应性^[5]。文献 [6] 针对滚动轴承早期故障时间点难以检测的问题，提出一种融合卷积深度置信网络与多核极限学习机自编码器的无监督健康指标构建方法。该方法先由卷积深度置信网络提取频谱信号的高维特征，再通过粒子群优化的多核极限学习机自编码器进行特征重构，计算重构误差以构建健康指标^[6]。文献 [7] 为解决组合导航系统中子滤波器故障依赖经验参数、对软故障不敏感的问题，提出了一种基于残差频域信息的卷积故障检测网络。该方法通过小波变换预处理残差信号，并利用短时傅里叶变换提取频域特征，输入 CNN 进行训练^[7]。文献 [8] 针对旋转机械在复杂工况下单一信号难以全面表征故障特征的问题，提出一种融合注意力机制的 CNN 故障检测模型。该模型引入自注意力模块，并结合多信号源特征互补与傅里叶变换优化技术，实现了高效的特征提取与融合。实验结果表明，所构建模型的故障检测精度为 99.64%^[8]。

尽管已有方法在工业设备和航空系统部件中取得一定成果，但在电控舵面系统中仍存在显著局限。电控舵面信号的高度非线性和非平稳特征，使传统模型在提取动态演化规律时易出现特征退化与过拟合，难以准确刻画潜在故障信息。同时，飞行环境中复杂的振动、气动和电磁干扰对特征提取的抗噪性与模型稳定性提出更高要求，而现有方法在鲁棒性方面表现不足。此外，电控舵面故障检测对实时性具有极高要求，然而多数深度学习模型存在推理延迟大、对硬件依赖性强等问题，难以满足飞行控制系统对快速响应与高可靠性的需求。这些不足限制了主流方法在电控舵面系统中的直接应用与推广，亟需提出更具针对性的检测策略。

针对上述问题，国内外学者已在其他航空关键部件的故障检测领域开展了深入探索，并取得丰富成果。例

如，文献 [9] 为提升飞机绕线式同步起动/发电机系统的可靠性，提出一种基于主励磁机定子励磁电流幅值分析的旋转整流器故障诊断方法。通过计算定子电流平方和并定位其最大值，再构建故障检测比率，实现对开路与短路故障的有效识别。该方法为首个可覆盖系统静止、起动与发电全过程的旋转整流器二极管故障诊断技术^[9]。文献 [10] 针对飞行数据驱动的航空系统故障诊断领域，提出了一种融合真实飞行数据与模拟数据的多阶段诊断框架。该框架结合无监督的层次聚类算法与有监督的组合分类器，并覆盖初始、训练、运行与改进四个阶段，实现对飞机系统全生命周期的故障识别与学习优化^[10]。文献 [11] 为解决电动飞机电机滚动轴承在强噪声干扰下故障特征难以提取的问题，提出了一种融合减法优化器与柯西策略的北方鹰隼算法，用于优化改进型全集合经验模态分解中的噪声参数。再结合多尺度卷积神经网络 (MSCNN, multi-scale convolutional neural networks) 进行去噪信号的时频特征提取与信息融合，并通过长短期记忆网络 (LSTM, long short-term memory) 实现多速工况下的故障识别。实验结果显示，该模型在各工况下平均识别准确率达 98.67%^[11]。在众多飞行系统部件中，电控舵面作为飞行控制系统的执行关键环节，其运行状态直接关系到飞行器姿态调节与操控稳定性的保障，其相关理论与工程应用已趋于成熟。例如，文献 [12] 针对翼身融合飞机舵面多功能与作动系统类型复杂所导致的架构设计困难问题，研究基于约束满足问题算法对飞控作动系统架构进行建模与筛选，构建变量、值域与约束集，并引入回溯算法快速生成满足安全性与技术约束的架构方案^[12]。文献 [13] 为系统梳理民用飞机飞行控制系统故障分析研究进展，研究基于快速存取记录器数据，提出包括故障监测、识别、诊断与预测的四阶段分析框架，归纳了以舵面位置、飞行姿态等为核心的数据建模方法，涵盖物理建模、多变量统计、逻辑推理与机器学习等技术^[13]。

综上所述，虽然现有技术在发电系统、转动部件及部分飞行系统中实现了高性能故障检测，但针对电控舵面系统，特别是在应对复杂非线性特征、强噪声干扰及高实时性要求等方面，尚缺乏高效可靠的检测方案。因此，针对舵面信号非平稳性强、故障特征弱及噪声干扰重叠等问题，研究提出一种融合多阶段降噪与改进深度卷积时序建模的飞机电控舵面故障检测方法。该方法通过最大相关峰度解卷积 (MCKD, maximum correlation kurtosis deconvolution)、经验模态分解—快速独立成分分析 (EMD-FastICA, empirical mode decomposition-fast independent component analysis)，结合 MSCNN 提取空间特征，并引入 LSTM 建模故障演化依赖关系，最终实现分类判别。该模型旨在提升电控舵面系统的故

障识别精度、抗干扰能力与实时响应水平, 为飞行控制系统的智能监测与预警提供理论支持与工程实现路径。

1 舵面故障特征与数据获取

电控舵面作为飞行器姿态控制系统中的核心执行部件, 其运行状态直接关系到飞行稳定性与飞控闭环精度。受控对象的复杂耦合结构使得舵面系统在长期运行中易受到扰动激励、负载波动及信号漂移等多种因素干扰, 从而导致响应延迟、角度偏移、电流冲击或传感异常等典型故障行为。此类故障往往呈现出多源异构、特征弱化以及非线性演化等特性, 对故障识别的精度与时效性提出更高要求。

为获取具有代表性的故障演化信息, 研究基于民航客机机载快速存取记录器 (QAR, quick access recorder) 构建诊断数据体系。QAR 数据以高频率记录飞行全程多类参数, 覆盖环境状态 (如高度、温度)、飞行性能 (如速度、俯仰速率) 及关键执行器响应 (如电流、电压、偏转角反馈等), 为故障建模与智能识别提供了真实可信的时序基础。系统采样频率设定为 1 kHz, 能够捕获舵面在高动态调控过程中的细微变化。在数据预处理阶段, 通过滑动窗口重采样及归一化等多重策略, 有效抑制原始信号中的高频干扰与尺度不一致问题, 构建出多通道二维时序特征输入。该结构不仅保留了时域关键变化趋势, 同时增强了模型对多类故障形态的区分能力。

2 故障诊断流程

在明确了电控舵面故障的表现形式与数据来源后, 构建系统化的故障检测流程成为确保模型可靠运行的关键环节, 诊断流程具体如图 1 所示。

如图 1 所示, 电控舵面故障诊断模型包括数据准备、模型训练与推理诊断三个阶段。在数据准备阶段, 系统采集飞行器历史 QAR 数据, 包括正常飞行数据和已知故障数据, 提取与舵面状态密切相关的特征参数 (如指令角、电流、电压、反馈角等), 并归一化处理以增强训练稳定性。在此基础上构建训练与测试集, 并采用多尺度卷积融合模型建模舵面响应的时序演化特征。

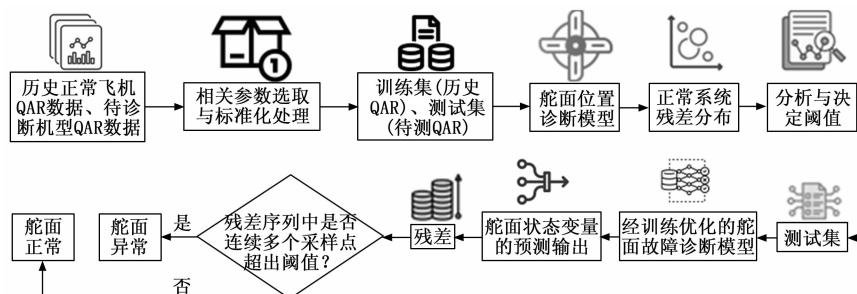


图 1 故障诊断流程图

训练阶段中, 模型学习正常状态下的响应模式, 输出预测序列并与实际值计算残差, 进而构建残差分布基准。推理阶段中, 模型预测新样本舵面响应并生成残差序列, 当连续时刻残差超出容差阈值时, 即判定舵面系统发生异常, 实现智能诊断与预警。

基于上述分析, 本研究提出一种融合多阶段降噪与改进深度卷积时序建模 (MEF-MSCNN-LSTM) 的飞机电控舵面故障检测方法, 以进一步提升模型对复杂非线性特征的表征能力。

3 MEF-MSCNN-LSTM 模型设计

3.1 MSCNN-LSTM 模型设计

针对舵面系统信号特征呈现出的高维度、非线性及多时序耦合等特点, 仅依靠单一建模策略难以全面刻画其动态演化规律。在多源故障特征提取与时间序列建模的双重需求驱动下, 构建具备时空联合感知能力的混合神经网络模型成为关键^[16-17]。因此, 研究基于融合 MSCNN 与 LSTM 构建出一种飞机电控舵面故障检测模型 (MSCNN-LSTM)。模型前端由三组并联的卷积模块构成, 分别采用 1×1 、 1×3 、 1×5 大小的卷积核, 兼顾不同感受野下的局部故障特征提取。每组卷积层均配套 ReLU 激活函数, 以加快收敛速度并提升鲁棒性。接着通过最大池化操作减少维度, 增强特征紧凑性。中间结构为 LSTM 模块, 捕捉信号序列中的长期依赖信息。LSTM 输出接全连接层与 Dropout 层, 防止过拟合, 并通过 Softmax 实现故障类型的多分类输出。输入端将多通道舵面响应信号序列以矩阵形式送入多尺度卷积模块, 借助不同感受野的并行卷积核提取信号中的突变、缓变与非线性扰动特征。融合后的多尺度特征输入 LSTM 模块, 进一步捕捉序列中的动态演化规律与长短期依赖关系, 实现故障信息的深度感知与时序表达。LSTM 单元结构中引入遗忘门、输入门与输出门机制, 动态调控信息流的保留与更新过程, 从而增强模型对时序动态变化的辨识能力^[18-19]。经过时序建模的深层特征通过全连接网络进一步映射至高维特征空间, 并由 Softmax 分类器输出故障类型的概率分布。其中, 卷积

运算数学表达式如式 (1) 所示^[20]:

$$y_i = \text{ReLU}(\sum_{j=1}^k x_{i+j-1} \cdot w_j + b) \quad (1)$$

式中, y_i 为第 i 个特征在卷积层输出, x_i 为输入数据, w_j 为卷积核, $j = 1, 2, \dots, k$, b 为偏置, k 为卷积核大小, ReLU 为激活函数。然后利用 LSTM 对飞机电控舵面故障中长期时序依赖关系进行表达, 每个门具体的表达如式 (2) 所示:

$$\begin{cases} f_t = \sigma(W_f h_{t-1} + U_f x_t + b_f) \\ i_t = \sigma(W_i h_{t-1} + U_i x_t + b_i) \\ y_t = \sigma(W_y h_{t-1} + U_y x_t + b_y) \cdot \tanh C_t \end{cases} \quad (2)$$

式中, f_t 为遗忘门, i_t 为输入门, y_t 为输出门, σ 为 sigmoid 激活函数, h_{t-1} 为前一时刻的隐藏状态, W 、 U 分别为门的循环和输入权重, b 为偏置项, \tanh 为双曲正切激活函数。记忆细胞的状态更新由遗忘门和输入门共同控制, 具体的状态更新如公式 (3) 所示:

$$C_t = f_t * C_{t-1} + i_t * \tanh(W_y h_{t-1} + U_y x_t + b_y) \quad (3)$$

式中, C_t 为 t 时刻记忆细胞状态值, C_{t-1} 为上一时刻记忆细胞状态值。通过全连接层, 将 LSTM 的输出映射到分类器, 最终输出具体表达如公式 (4) 所示:

$$y_t = W_y \cdot h_t + b_y \quad (4)$$

式中, y_t 为时段 t 的预测值, W_y 、 b_y 分别为全连接层的权重和偏置。模型各部分协同作用, 期望其在面对多类舵面异常状态时依然保持鲁棒、稳定的检测性能。

3.2 MEF-MSCNN-LSTM 模型设计

然而, 面向复杂飞行工况和高维多通道信号环境, 原始数据中普遍存在显著的背景噪声、设备干扰及非稳态扰动, 这些因素将直接影响模型的判别边界与特征敏感性, 进而限制故障识别的准确性与泛化能力^[21-23]。因此, 为进一步提升模型对微弱故障特征的感知能力并增强信号语义表达, 研究引入 MCKD 和 EMD-FastICA 对舵面故障的振动信号进行处理。其中, MCKD 通过构建以相关峭度为目标的优化函数, 迭代设计最优卷积滤波器, 用以强化故障信号中周期性冲击成分的统计可识别性^[24-25]。滤波器的设计参数如滤波器长度 L 和信号周期 t 是通过优化算法来迭代确定的, 以确保能够最大化信号中的周期性冲击特征。滤波器的迭代次数由目标函数的收敛情况来决定, 通常设定为 100 次迭代, 直到误差收敛至设定阈值以下。该策略通过提升输出信号的峭度指标, 有效增强了关键脉冲特征的响应强度, 使得目标故障模式在高阶统计域内表现出更强的分离度, 其数学表达式如公式 (5) 所示:

$$\vec{y} = \vec{f} * \vec{x} \approx \vec{d} \quad (5)$$

式中, \vec{y} 为输出信号, \vec{x} 为原始信号, \vec{d} 故障信号, \vec{f} 为最

优滤波器。并且 MCKD 算法通过不断迭代来匹配最佳滤波器 \vec{f} , 来达到从被测信号中提取出故障信号的目的, MCKD 目标函数表达式如公式 (6) 所示:

$$\max_{\vec{f}} CK_M(t) = \max_{\vec{f}} \frac{\sum_{n=1}^N (\prod_{m=0}^M y_{n-mt})^2}{(\sum_{n=1}^N y_n^2)^{M+1}} \quad (6)$$

式中, L 为滤波器长度, M 为位移数, n 为输入信号样本数, t 为故障信号周期。通过该算法, 可以计算出解卷积信号 \vec{y} , 初步达到对信号的降噪处理。在此基础上, 构造目标向量并引入迭代优化机制, 对滤波器权重进行动态修正, 直至 $\Delta CK_M(t)$ 满足误差收敛条件。此外, 为方便进行迭代, 将公式 (6) 转化为等价的矩阵形式, 其具体展开如公式 (7) 所示:

$$\vec{f} = \frac{\|\vec{y}\|}{2\|\vec{\beta}\|^2} (X_0 X_0^\top)^{-1} \sum_{m=1}^M X_m \vec{\alpha}_m \quad (7)$$

式中, $\vec{\beta}$ 为约束条件相关的参数向量, $\vec{\alpha}_m$ 为峭度梯度相关的权重向量, X_r 为输入信号的时延矩阵。鉴于舵面故障信号中多源混叠与高频干扰并存的复杂特性, 研究利用 EMD-FastICA 自适应降噪策略, 通过分解信号的本征模态函数 (IMF, intrinsic mode function) 以捕捉不同时间尺度的演化特征, 进而利用 FastICA 实现对独立源信号的快速提取与干扰剔除, 从而提升特征提取的判别精度。EMD-FastICA 的处理机制与信号分离流程如图 2 所示。

如图 2 所示, 该方法利用 EMD 对轴承故障的振动信号进行初步分离, 获取到不同的 IMF 分量, 并与初始信号进行组合。在此基础上, 采用 FastICA 算法进一步对混合信号进行高效独立解构, 通过最大化非高斯性准则实现特征源信号的解混与重构。EMD 的分解层数由信号的频率特征和时域变化决定, 研究选择分解为 5 层 IMF, 以确保能够捕捉到故障信号的关键特征。分解过程中, IMF 的选择标准基于各分量的峭度和与故障信号的相关性, 筛选出对故障模式具有高度相关性的 IMF 进行后续处理。在 FastICA 中, 采用非对称性增强的非线性函数加速其迭代过程, 迭代次数通常设定为

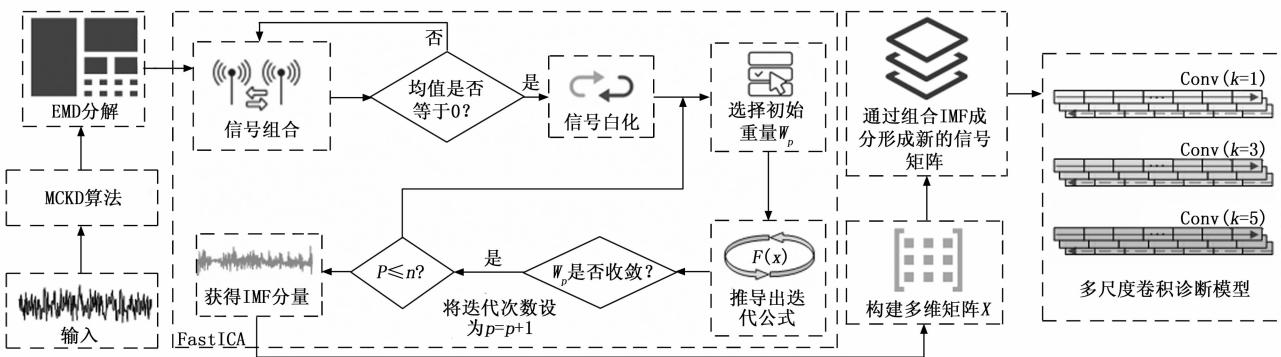


图 2 EMD-FastICA 信号分离方法

500 次, 直到收敛为止, 以提高算法的稳定性和收敛效率。而具体 EMD-FastICA 方法先基于独立成分分析 (ICA, independent component analysis) 模型, 结合向量一矩阵算法, 并通过置换矩阵 P 以及其逆来表达 ICA 模型, ICA 模型数学表达如公式 (8) 所示^[26-27]:

$$u = AP^{-1}Ps \quad (8)$$

式中, A 为混合矩阵, s 为随机向量, u 为多个混合信号。为优化 FastICA 的收敛效率与稳定性, 研究对其分布函数及逆矩阵迭代策略进行了结构性调整, 采用非对称性增强的非线性函数加速迭代过程, 并引入正交约束矩阵保证结果的全局最优性。改进后的累计分布函数 $g(s)$ 的表达式如式 (9) 所示:

$$g(s) = \frac{1}{a_1} \log(\cosh a_1 s) \quad (9)$$

式中, a_1 是常量, 通常取 $a_1 = 1$ 。混合矩阵 A 的逆矩阵 W 的改进迭代计算如公式 (10) 所示:

$$W_i = E\{2g(W_i^T z)\} - E\{g(W_i^T z)\} \cdot W \quad (10)$$

式中, z 为一个在约束 $z^T z = 1$ 条件下, 使得 $g(W_i^T x)$ 最大的向量, E 为单位矩阵。通过改进直到 W 收敛, 使得 $W = (W \cdot W^T)^{-1/2} \cdot W$ 。EMD 作为一种自适应分解方法, 能够按照高频、中频和低频的顺序对信号进行分解, 从而精准处理非平稳信号^[28-29]。EMD 技术基本计算方法的公式, 如式 (11) 所示^[30]:

$$x(t) = \sum_{i=1}^n C_i(t) + r_n(t) \quad (11)$$

式中, $x(t)$ 为信号, $C_i(t)$ 为多个本征模态分量 IMF, $r_i(t)$ 为序列。因此, 研究将 EMD 与 FastICA 技术结合, 通过 EMD 技术把非平稳信号分解得到多个 IMF 分量, 再通过 FastICA 对分解结果进行独立性增强处理, 实现信号源的结构性重组。最终, 从重构信号中筛选出与故障响应高度相关的特征分量, 作为后续建模与识别的优化观测输入, 从而有效抑制冗余干扰并强化特征辨识能力。综上, 研究结合 MCKD-EMD-FastICA 方法对

信号进行多层次降噪处理, 并融合 MSCNN-LSTM 构建出一种优化飞机电控舵面故障检测模型 (MEF-MSCNN-LSTM)。MEF-MSCNN-LSTM 模型结构如图 3 所示。

如图 3 所示, 研究提出的 MEF-MSCNN-LSTM 模型通过 4 个关键模块实现了舵面故障的高效检测与准确识别。多阶段降噪模块结合了 MCKD 和 EMD-FastICA 方法, 针对舵面信号中的噪声和背景干扰, 通过最大化峭度值和信号分解提取独立成分, 显著提升了微弱故障信号的可识别性, 为后续的特征提取和时序建模提供了纯净的信号输入。而 MSCNN 通过多个不同尺度的卷积核对多通道信号进行特征提取, 分别捕捉信号中的局部突变、缓变和非线性扰动特征。该模块的多尺度特征提取能力使得模型能够有效处理舵面故障的不同变化模式, 提高了对复杂故障模式的感知与辨识能力。LSTM 模块则将 MSCNN 提取的时空特征传递并进行时序建模, 捕捉信号中的长短期依赖关系, 从而有效模拟舵面故障的演化过程, 提升了对动态时序特征的建模能力。故障分类识别模块通过 Softmax 分类器对 LSTM 输出的特征进行故障类型的分类判别, 确保高准确率地识别舵面系统中的异常状态。整体模型通过多层次降噪、时空特征提取与时序建模的深度融合, 来提高故障检测的智能化水平和实时性, 以满足电控舵面系统对高精度、鲁棒性和实时响应的要求。

4 实验

4.1 MEF-MSCNN-LSTM 模型性能分析

为评估所提出的 MEF-MSCNN-LSTM 融合诊断模型在实际飞行环境下的识别能力, 研究将其与 CNN-LSTM、卷积神经网络—全连接网络 (CNN-FCN, CNN-Fully connected network)、结合 MCKD-EMD-FastICA 方法的支持向量机 (MEF-SVM, MCKD-EMD-FastICA and support vector machine) 3 种模型进行对比分析。选取 QAR 记录的 1 000 组飞行数据进行

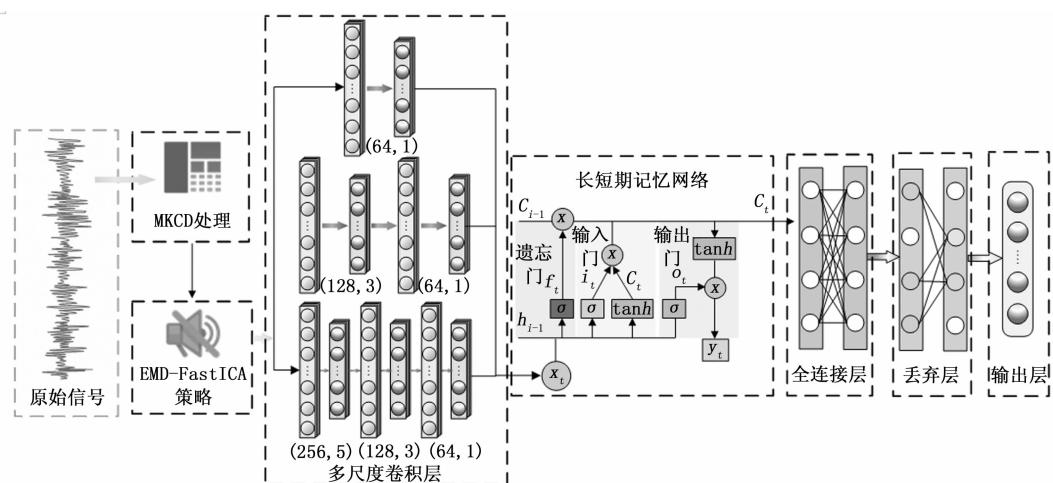


图 3 MEF-MSCNN-LSTM 模型结构图

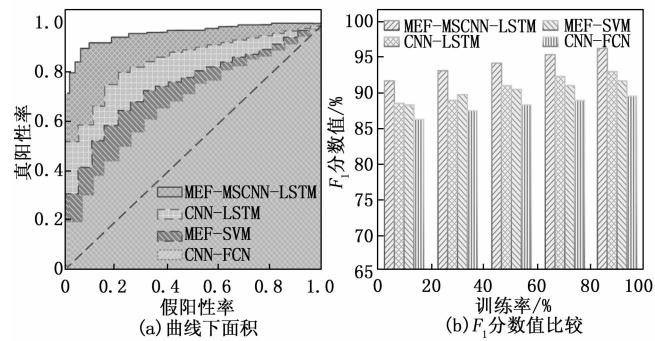
建模分析, 这些数据涵盖多个典型飞行阶段, 包括起飞、爬升、巡航、下降和着陆等, 确保了样本的多样性和代表性。在数据集中, 故障数据主要来源于已知的舵面故障模式, 包括舵面卡滞、摩擦故障和响应延迟等, 故障信号占数据集的约 20%, 其余为正常操作数据。样本数据覆盖多个典型飞行阶段, 并包含高度、气压、飞行速度、俯仰速率、舵面偏转角、电流电压等关键参数。这些数据能够全面反映舵面系统在不同工况下的响应特性, 为故障检测提供丰富的信号来源。在数据预处理阶段, 所有特征采用标准差标准化法, 该方法能够增强模型对不同量纲数据的统一处理能力, 从而提高模型的泛化能力。在训练配置方面, MSCNN 模块中的多尺度卷积核数量设置为 32 组, 卷积步长为 1, 池化窗口设为 2, LSTM 模块的时间步长为 50。采用 Adam 优化器, 初始学习率设为 0.001, 衰减因子为 0.96, 每 5 轮衰减一次。训练轮数为 100, 批次大小设为 128, 并引入早停机制控制过拟合。在样本构建过程中, 引入合成少数类过采样技术算法扩展故障类别样本, 解决样本分布不均的难题, 并采用高斯噪声扰动与时间窗平移进行数据增强, 提升模型鲁棒性。实验环境具体配置参数和使用设备型号详见表 1。

表 1 实验环境配置

名称	描述
数据集	QAR 记录
训练集: 测试集	4:1
数据集数量(组)	1 000
操作系统	Windows 10 64-bit
系统配置	Intel Core i7-7500UCPU @ 16G, NVIDIA GeForce RTX 3060
仿真工具	MATLAB R2019b

在上述参数的基础上, 研究从多维角度出发, 分析模型在舵面故障检测性能方面的具体表现, 具体评估指标包括曲线下的面积 (AUC, area under curve) 值、 F_1 分数、准确率以及算法收敛曲线。选用这些评价指标是因为 AUC 能综合评估模型在各决策阈值下的分类能力, 反映正负样本的区分效果。而 F_1 分数作为准确率和召回率的调和平均值, 能够有效平衡这两者的权重, 尤其在不平衡数据集 (如舵面故障数据) 中, 避免模型偏向多数类, 提升对少数类故障信号的识别能力。准确率衡量模型整体分类能力, 表示正确预测样本的比例。而收敛曲线分析训练过程中的稳定性与优化效率, 快速收敛和低损失值表明模型能够有效捕捉数据规律, 避免过拟合或欠拟合, 展示良好的泛化能力和训练效率。首先对所提模型的 AUC 值和 F_1 分数进行分析, 实验结果如图 4 所示。

如图 4 (b) 所示, 基于 QAR 飞行数据构建的

图 4 MEF-MSCNN-LSTM 模型的 AUC 值与 F_1 分数图

MEF-MSCNN-LSTM 模型在故障样本的分类判断中展现出显著判别能力, 其曲线整体走势贴近左上角, AUC 值达到 0.977, 显著优于对比模型的 0.852、0.793 和 0.728, 表明该模型在舵面故障检测中具备高度的正确识别能力。结合图 4 (b) 的结果分析, F_1 分数在训练阶段保持稳定波动, 普遍维持在 92.1% 以上, 最终达到 98.8%, 显著领先于其他模型, 说明该模型在保证故障识别准确率的同时, 具备较强的漏报抑制能力与冗余信息自适应能力, 充分满足飞控系统对检测精度与响应完整性的双重要求。为更全面地评估所提模型的检测性能, 研究进一步通过舵面故障检测准确率和收敛曲线对模型进行衡量分析, 结果如图 5 所示。

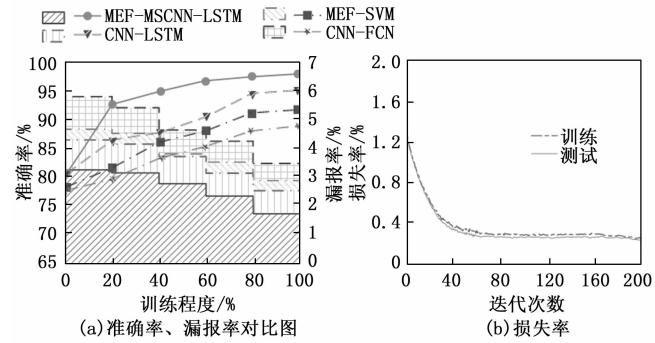


图 5 准确、漏报及损失率曲线图

如图 5 (a) 所示, 点线图为准确率, 线面图为漏报率。随着训练数据比例的增加, MEF-MSCNN-LSTM 模型的检测准确率始终保持较高水平, 在使用全部训练数据时达到 98.7%, 显著高于 CNN-LSTM 模型的 93.3%、MEF-SVM 模型的 89.9% 和 CNN-FCN 模型的 87.6%。而漏报率在完全训练时最低能达到 1.08%, 显著低于三种对比模型, 显示出其对舵面早期故障状态的敏感感知能力与高置信判别水平, 具备良好的实际诊断适应性。由图 5 (b) 可知, MEF-MSCNN-LSTM 模型在第 38 次开始, 训练损失明显收敛并趋于稳定, 验证集损失率维持在 0.29%, 体现了所提模型在舵面特征学习方面的高效性。最后, 为验证所提 MEF-MSCNN-LSTM 融合诊断模型中各核心模块对性能提升的具体贡献, 研究设计了消融实验, 分别移除

MSCNN、MEF 和 LSTM 模块, 统计对模型故障检测性能的影响, 以全面分析模块在舵面故障识别中的作用, 具体实验结果如表 2 所示。

表 2 不同模块组合下模型故障检测性能对比

方法	AUC 值/%	F_1 分数/%	准确率/%	漏报率/%
去除 LSTM 模块 (MEF-MSCNN)	91.8	94.6	94.2	3.1
去除 MEF 模块 (MSCNN-LSTM)	90.3	93.1	92.8	4.7
去除 MSCNN 模块 (MEF-LSTM)	88.5	91.4	90.9	6.3
MEF-MSCNN-LSTM	97.7	98.8	98.7	0.29

由表 2 可见, MEF、MSCNN 和 LSTM 三大模块对整体模型性能均具有显著促进作用。首先, 去除 LSTM 模块后 (MEF-MSCNN), 模型失去了对舵面故障演化过程的时序依赖建模能力, 虽仍保持一定空间识别效果, 但 AUC 值降至 91.8%, 准确率降为 94.2%, 漏报率升至 3.1%, 表明模型难以对动态异常实现提前感知, 表现出一定的滞后性。进一步移除 MEF 模块 (MSCNN-LSTM) 后, 模型缺乏有效的信号降噪与特征解耦机制, 使原始电控信号中的冗余与干扰未能充分处理, AUC 值下降至 90.3%, 漏报率上升至 4.7%, 说明模型对早期微弱异常响应能力显著削弱, 抗噪性不足。当完全移除 MSCNN 模块 (MEF-LSTM) 时, 模型空间特征提取能力显著退化, 仅凭传统卷积难以捕捉舵面响应中的多尺度局部变化, 导致 AUC 值进一步降至 88.5%, 准确率降低至 90.9%, 漏报率增至 6.3%, 显示其在复杂故障模式识别中的泛化能力明显不足。相对而言, 完整融合三模块的 MEF-MSCNN-LSTM 模型在各项指标上均表现最优, AUC 值达 97.7%, F_1 分数 98.8%, 准确率 98.7%, 漏报率仅 0.29%。这充分说明: MEF 模块在增强故障信号有效性方面至关重要, MSCNN 模块显著提升了空间特征分辨率, 而 LSTM 单元则精准建模了时序演化规律。三者协同可高效识别多源舵面异常信号, 提升早期预警能力和模型鲁棒性, 是实现复杂飞控场景智能诊断的核心支撑结构。

4.2 MEF-MSCNN-LSTM 模型应用效果实例分析

为进一步验证 MEF-MSCNN-LSTM 模型在不同飞行工况下的工程适应性, 研究基于典型飞行段 QAR 实录数据, 选取了两段舵面潜在异常事件进行应用分析, 以评估模型在实际状态演化过程中的感知能力与输出稳定性。其中, 俯仰姿态突变导致的电控舵面响应异常识别如图 6 所示。

如图 6 (a) 所示, 该飞行段发生于一架大型客机爬升至 7 200 m 过程中, 执行器舵偏反馈角持续在

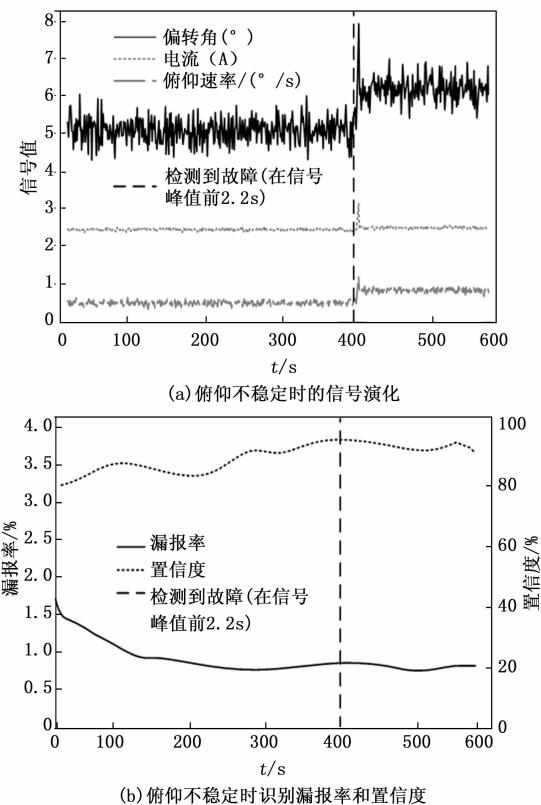


图 6 俯仰姿态突变导致的电控舵面响应异常识别

$[2.35^\circ \sim 2.55^\circ]$ 区间内平稳变化, 整体标准差仅为 0.07, 但在约第 412 s 处出现连续 4 s 的异常波动, 最大偏转角达 3.12° 。同时, 舵机电流也呈现出显著异常, 从 5.1 A 上升至 7.9 A, 期间俯仰速率由 $0.51^\circ/\text{s}$ 跃升至 $1.22^\circ/\text{s}$, 表现出明显的不协调趋势。如图 6 (b) 所示, 模型处理该段数据后, 卷积模块成功捕捉到电流、电压与舵面偏移之间的非线性局部跃迁, LSTM 单元进一步识别出故障演化的时间依赖性, 在电流峰值前 2.2 s 即完成高置信度异常判别。最终分类输出置信度为 0.985, 误报率低于 0.9%, 且在滑窗策略下判定结果连续稳定, 无检测间断, 验证了该模型在俯仰失稳诱发的舵面响应突变场景中的预警能力。研究进一步对模型在巡航阶段高频振动扰动下的早期微故障感知性能进行分析, 具体如图 7 所示。

如图 7 (a) 所示, 图中呈现出巡航阶段轻微异常演化趋势, 结合电流变化、俯仰速率平缓漂移与峭度递增。具体为某航段飞行器处于稳定巡航阶段 (高度约为 10 800 m, 持续时长超过 320 s), 在此期间整体偏转角分布范围为 $[2.43^\circ \sim 2.58^\circ]$, 执行器电压波动在 ± 0.8 V 范围内, 表现无显著异常。然而在飞行第 225 s 之间, QAR 记录到电流存在轻微异频漂移, 其峰度从标准值 3.1 升高至 3.93, 振动特征的峭度显著增强, 同时俯仰速率微幅升高 $0.12^\circ/\text{s}$ 。如图 7 (b) 所示, 在传统诊断规则无法判断的背景下, MEF-MSCNN-LSTM 模型通

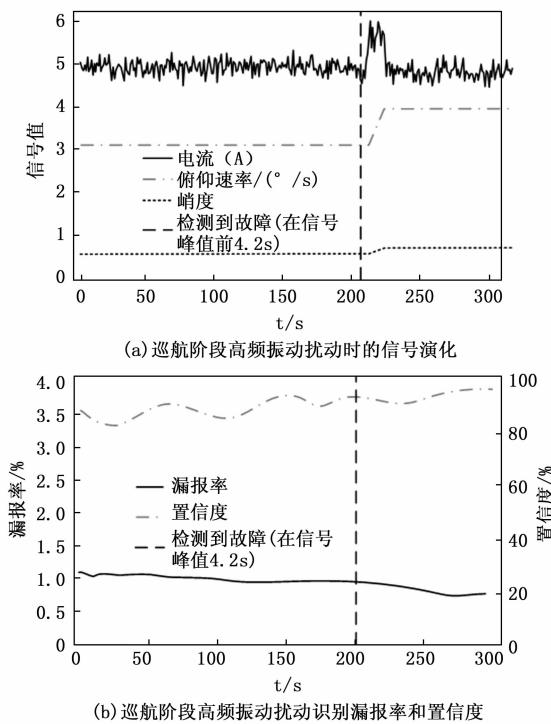


图 7 巡航阶段高频振动扰动下的早期微故障感知

过 MCKD 降噪与 EMD-FastICA 信号结构还原, 成功还原出电控信号中存在的周期微扰模式。经过卷积感知与序列建模后, 并在电流峰值前 4.2 s 即完成高置信度故障感知判别, 模型以 0.974 置信度输出预警标签, 标定该时段为舵面微退化早期征兆区域。后续飞行器地面检修验证中确认该执行器控制回路存在细微间歇性迟滞, 进一步证实了模型的有效性与高灵敏度。综上, 在实际识别过程中, 模型能稳定识别舵面偏转异常、电流响应漂移与俯仰速率扰动等异常模式, 表现出良好的时间序列建模能力和舵面故障检测性能。

4.3 模型性能差异讨论

结合典型飞行数据实例可见, MEF-MSCNN-LSTM 模型在不同飞行阶段及故障类型下展现出差异化性能表现。在动态爬升阶段, 如图 6 所示, 执行器舵偏角于 412 s 处从平稳区间 $[2.35^\circ \sim 2.55^\circ]$ 突变至 3.12° , 舵机电流由 5.1 A 升至 7.9 A, 俯仰速率从 $0.51^\circ/\text{s}$ 跃升至 $1.22^\circ/\text{s}$, 模型凭借多尺度卷积与 LSTM 序列建模能力, 在电流峰值前 2.2 s 即完成高置信度异常识别 (置信度 0.985), 有效捕捉快速跃迁型故障的非线性动态特征。相较之下, 在稳定巡航阶段的微退化故障检测中 (图 7), 舵面偏转角在 $[2.43^\circ \sim 2.58^\circ]$ 间变化、电压波动小于 $\pm 0.8 \text{ V}$ 、电流峰度从 3.1 升高至 3.93、俯仰速率轻微升高 $0.12^\circ/\text{s}$ 。模型仍可提前 4.2 s 完成预警 (置信度 0.974), 说明其对缓变微扰信号仍具备较强分辨力, 特别在 MCKD-EMD-FastICA 的联合降噪与特征解构支持下, 显著提升了对微弱周期扰动的

识别能力。

综合来看, 模型对突发类故障 (如舵偏突变、电流异常) 具备高灵敏度与时效性, 适用于高动态环境下的故障预警, 对微退化类故障虽也具备识别能力, 但识别置信度略低, 且对冗余干扰成分敏感, 反映出其在特征提取与故障模式耦合处理方面仍存在优化空间。此外, 从整体实验统计结果看, 模型在 1 000 组 QAR 数据中的平均误报率低于 1.3%, AUC 值达 0.989、 F_1 分数为 0.988, 表明其具有出色的判别能力与鲁棒性。然而, 对复合型、多源耦合故障尚未具备明确分类策略, 未来可考虑引入注意力机制与多模态融合策略提升其对复杂场景的适应性。

5 结束语

针对现代飞行器电控舵面系统故障检测中存在的非线性特征难提取、噪声干扰强及实时诊断精度不足等问题, 研究构建了一种融合多阶段降噪策略与深度学习结构的 MEF-MSCNN-LSTM 故障检测模型。该方法通过 MCKD、EMD 与 FastICA 联合实现信号分解与重构, 增强了故障特征提取的信噪比。再结合多尺度卷积与 LSTM 结构, 实现时序高维特征的有效感知与建模。实验结果表明, 所提模型在飞机电控舵面故障识别任务中表现出良好性能。该模型在 QAR 实飞数据样本中, 检测准确率达到 98.7%, AUC 值为 0.977, 平均 F_1 分数为 96.8%, 在典型俯仰失稳案例中实现 0.985 置信度的实时判别, 最大漏报率低于 1.08%。此外, 在巡航阶段微扰场景下, 模型通过多阶段降噪策略, 可提前捕捉微故障信号并输出 0.974 置信度预警, 表现出较强的灵敏度与鲁棒性。综上所述, MEF-MSCNN-LSTM 模型在高维复杂环境下具备良好的工程适应性与实时诊断能力, 能够有效提升电控舵面系统的健康管理水平。尽管研究模型已取得较高识别性能, 但其在多工况样本间的泛化能力与跨机型迁移能力尚待增强, 且对故障等级划分与定位识别的能力仍需拓展。同时, 模型训练过程中对高质量标签数据依赖度较高, 数据稀缺性将影响模型稳定性。未来工作可考虑引入迁移学习、对比学习与小样本学习机制, 以提升模型跨任务适应能力。

参考文献:

- [1] 杨卫平. 新一代飞行器导航制导与控制技术发展趋势 [J]. 航空学报, 2024, 45 (5): 146–170.
- [2] 何晶晶, 张家盛, 刘波. 飞机舵面作动系统动压反馈特性分析 [J]. 液压与气动, 2024, 48 (5): 151–157.
- [3] 王兴坚, 杨新宇, 王少萍. 大型民机操纵系统容错控制技术综述 [J]. 机械工程学报, 2024, 60 (4): 50–65.
- [4] 王琪善, 章国宝, 黄永明, 等. 基于卷积神经网络的多模态过程故障检测 [J]. 制造业自动化, 2023, 45 (1): 185–191.

- [5] 潘宏刚, 李员禄, 郭宝仁, 等. 基于卷积神经网络的转子系统故障诊断与研究 [J]. 汽轮机技术, 2024, 66 (2): 145–148.
- [6] 肖飞, 马萍, 张宏立, 等. 无监督健康指标在轴承早期故障检测中的应用 [J]. 组合机床与自动化加工技术, 2024 (6): 151–155.
- [7] 刘军坡, 吴兆麟, 曹玉墀, 等. 基于卷积神经网络的智能船舶组合导航系统故障检测算法 [J]. 舰船科学技术, 2023, 45 (2): 155–158.
- [8] 张玉华, 刚润振. 基于注意力机制的互特征融合旋转机械故障检测技术 [J]. 计算机测量与控制, 2024, 32 (11): 146–152.
- [9] LI X, LIU W, JIAO N, et al. Fault diagnosis of rotating rectifier in aircraft wound-rotor synchronous starter-Generator based on stator currents under all operational processes [J]. IEEE Transactions on Power Electronics, 2023, 38 (12): 16072–16084.
- [10] DAHLENI KRAEMER A, VILLANI E. Framework for offline data-driven aircraft fault diagnosis [J]. Journal of Aerospace Information Systems, 2024, 21 (4): 348–361.
- [11] YUAN D, LIU F, YIN Z, et al. A novel method based on the SCNGO-ICEEMDAN and MCNN-BiLSTM model for fault diagnosis of motor bearings for more electric aircraft [J]. IET Electric Power Applications, 2024, 18 (12): 1773–1785.
- [12] 杨建忠, 杨洪利, 孙晓哲. 基于 CSP 算法的 BWB 飞机飞控作动系统架构设计 [J]. 液压与气动, 2024, 48 (2): 165–173.
- [13] 王岩韬, 高艺, 时统宇. 基于 QAR 数据的飞行控制系统故障研究综述 [J]. 中国安全科学学报, 2024, 34 (4): 1–9.
- [14] LI Z, ZHANG Y, AI J, et al. A lightweight and explainable data-driven scheme for fault detection of aerospace sensors [J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59 (6): 8392–8410.
- [15] RAOUF I, KUMAR P, CHEON Y, et al. Advances in prognostics and health management for aircraft landing gear—progress, challenges, and future possibilities [J]. International Journal of Precision Engineering and Manufacturing-Green Technology, 2025, 12 (1): 301–320.
- [16] KOSOVA F, UNVER H O. A digital twin framework for aircraft hydraulic systems failure detection using machine learning techniques [J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2023, 237 (7): 1563–1580.
- [17] 樊智勇, 王振良, 刘哲旭. 基于 XGBoost 的民航飞机发动机性能参数预测模型 [J]. 计算机测量与控制, 2023, 31 (6): 46–52.
- [18] HELGO M. Deep learning and machine learning algorithms for enhanced aircraft maintenance and flight data analysis [J]. Journal of Robotics Spectrum, 2023, 1: 90–99.
- [19] MOOSAKUNJU S, MINI V P, USHAKUMARI S, et al. A hybrid fault detection and diagnosis algorithm for five-phase pmsm drive [J]. Arabian Journal for Science and Engineering, 2023, 48 (5): 6507–6519.
- [20] 谢星怡, 张正江, 闫正兵, 等. 基于信号特征提取和卷积神经网络的轴承故障诊断研究 [J]. 计算机测量与控制, 2023, 31 (10): 21–27.
- [21] DANGUT M D, JENNIONS I K, KING S, et al. A rare failure detection model for aircraft predictive maintenance using a deep hybrid learning approach [J]. Neural Computing and Applications, 2023, 35 (4): 2991–3009.
- [22] HUIYONG W, SHUCHUN J, ZHU J. Simulation model and fault analysis of air circulation system of the aircraft based on grasshopper optimization algorithm: support vector machine [J]. Soft Computing, 2023, 27 (18): 13269–13284.
- [23] 孙晔, 郭琳. 基于传感器技术和 I-LSTM 算法的风电机设备运行故障检测及诊断研究 [J]. 计算机测量与控制, 2024, 32 (9): 51–57.
- [24] WU Z, NIU W, ZHAO Y, et al. Application of extended isolation forest in avionics equipment fault diagnosis [C] //Fourth International Conference on Machine Learning and Computer Application (ICMLCA 2023). SPIE, 2024, 13176: 864–869.
- [25] DOMINGUEZ-MONFERRER C, RAMAJO-BALLESTER A, ARMINGOL J M, et al. Spot-checking machine learning algorithms for tool wear monitoring in automatic drilling operations in CFRP/Ti6Al4V/Al stacks in the aircraft industry [J]. Journal of Manufacturing Systems, 2024, 77: 96–111.
- [26] 任良, 甄龙信, 赵云, 等. 基于 SSA-VMD-MCKD 的强背景噪声环境下滚动轴承故障诊断 [J]. 振动与冲击, 2023, 42 (3): 217–226.
- [27] ZHANG D, JUNYU G, TENGHUAN D, et al. Aircraft sensor fault detection based on temporal two-dimensionalization [J]. Xibei Gongye Daxue Xuebao/Journal of Northwestern Polytechnical University, 2023, 41 (6): 1033–1043.
- [28] CUI B, GUO P, ZHANG W. Research on fault diagnosis of rolling bearing based on the MCKD-SSD-TEO with optimal parameters [J]. Journal of Mechanical Science and Technology, 2023, 37 (1): 31–42.
- [29] TANG T, ZHOU Y, ZENG X, et al. Fault location based on FastICA and fuzzy C-means clustering for single-phase-to-ground fault in the compensated distribution network [J]. Electrical Engineering, 2023, 105 (6): 4079–4093.
- [30] 李鹏飞, 闫佳, 左蓬, 等. 基于 EMD 和 Hilbert 谱的风电机组滚动轴承故障诊断方法研究 [J]. 微型电脑应用, 2024, 40 (1): 36–40.