

DOI: 10.20189/j.cnki.CN/61-1527/E.202503009

多尺度通道注意力卷积神经网络的 机电作动器故障诊断

史新骏^{1,2}, 胡昌华², 何显松¹, 王兆强², 赵孝礼^{1,2*}

(1. 南京理工大学 机械工程学院, 江苏 南京 210094;

2. 火箭军工程大学, 陕西 西安 710025)

摘要: 针对复杂工况下机电作动器 (electro-mechanical actuator, EMA) 滚珠丝杠副故障难以被及时准确识别的问题, 提出一种基于多尺度通道注意力卷积神经网络 (multi-scale convolutional neural networks with squeeze-and-excitation network, MCNN-SE) 的 EMA 故障诊断方法。首先, 利用多尺度卷积结构自动提取多层次的特征信息, 增强模型对不同故障模式的适应性和特征区分能力, 同时通过 SE 模块对通道特征进行加权, 突出其关键特征, 抑制无关干扰; 然后, 将所提取的特征输入到 softmax 分类器进行智能诊断与分类, 以提升诊断的精度和鲁棒性; 最后, 将所提的 MCNN-SE 算法与 MobileNet、ResNet18、CNN、MCNN 4 种传统算法进行对比, 以验证所提方法的高效性。结果表明: 所提出的 MCNN-SE 算法在复杂工况下的平均诊断准确率能够达到 98.77%, 具有良好的诊断稳定性与较高的计算效率。

关键词: 机电作动器; 故障诊断; 深度学习; 注意力机制

中图分类号: V19

文献标志码: A

文章编号: 2097-2741(2025)03-090-09

Fault Diagnosis of Electro-Mechanical Actuators Based on Multi-Scale Convolutional Neural Network with Squeeze-and-Excitation Network

SHI Xinjun^{1,2}, HU Changhua², HE Xiansong¹,
WANG Zhaoqiang², ZHAO Xiaoli^{1,2*}

(1. School of Mechanical Engineering, Nanjing University of Science and Technology, Nanjing 210094, China;

2. Rocket Force University of Engineering, Xi'an 710025, China)

ABSTRACT: To overcome the challenges of timely and accurate fault identification in ball-screw

收稿日期: 2024-11-28

修回日期: 2025-01-15

录用日期: 2025-01-20

基金项目: 国家自然科学基金 (52205062, 62227814); 国家重点研发计划 (2024YFB4709600, 2024YFB3311204); 中央高校基本科研业务费专项资金 (30922010701); 江苏省自然科学基金 (BK20220950); 上海航天科技创新基金 (SAST2024-055); 陕西省自然科学基金基础研究计划 (2025JC-QYXQ-038); 军事科研重点实验室开放基金 (ICL-2023-0305)

第一作者: 史新骏 (2002—), 男, 硕士研究生, 主要从事故障诊断与寿命预测研究。E-mail: 15035643602@163.com

通信作者: 赵孝礼 (1991—), 男, 副研究员, 主要从事机电液装备智能运维与健康管理、武器装备智能化、人工智能与智能机器人、数字孪生等研究。E-mail: xlzhao@njust.edu.cn

引用格式: 史新骏, 胡昌华, 何显松, 等. 多尺度通道注意力卷积神经网络的机电作动器故障诊断[J]. 火箭军工程大学学报, 2025, 39 (3): 90-98. SHI Xinjun, HU Changhua, HE Xiansong, et al. Fault diagnosis of electro-mechanical actuators based on multi-scale convolutional neural network with squeeze-and-excitation network[J]. Journal of Rocket Force University of Engineering, 2025, 39 (3): 90-98.

pairs in electro-mechanical actuator (EMA) under complex working conditions, a fault diagnosis method based on multi-scale convolutional neural network with squeeze-and-excitation network (MCNN-SE) was proposed. First, the model's adaptability and feature discrimination ability for different fault modes were enhanced by utilizing a multi-scale convolution structure to automatically extract multi-level feature information. At the same time, the SE module was used to weight the channel features, highlight key features, and suppress irrelevant interferences. Subsequently, the extracted features were input into a softmax classifier for intelligent diagnosis and classification, to improve the accuracy and robustness of the diagnosis. Finally, the proposed MCNN-SE algorithm was compared with four traditional algorithms of MobileNet, ResNet18, CNN, and MCNN to verify its effectiveness. The results show that the average diagnostic accuracy of the proposed MCNN-SE algorithm under complex working conditions reaches 98.77%, with good diagnostic stability and high computational efficiency.

KEYWORDS: electro-mechanical actuator; fault diagnosis; deep learning; attention mechanism

机电作动器^[1] (electro-mechanical actuator, EMA) 作为电传飞控执行机构的重要组成部分, 凭借其结构简单、功重比高、维护便捷等优点在先进航天装备领域得到广泛应用和深入研究。但其复杂的运行环境、频繁的启停操作以及恶劣的温度和压力条件, 使其容易产生故障^[2]。尤其是 EMA 中作为传递力矩和位移关键部件的滚珠丝杠副^[3], 若长时间运行可能会出现磨损、剥落、卡滞等问题, 若这些故障未能被及时检测和处理, 将对系统安全构成潜在威胁, 甚至会造成系统失效等灾难性后果。因此, 开展 EMA 滚珠丝杠副的故障诊断研究, 可为航天器提供坚实的系统安全保障与可靠性参考, 具有一定的理论意义和应用价值^[4]。

当前基于模型驱动的故障诊断与基于数据驱动故障诊断^[5]是 2 种主要的诊断方式。在 EMA 故障诊断领域, 基于模型的故障诊断方法因其主要依靠高精度的数学模型^[6], 需要大量先验知识, 难以应对多故障和不确定性等工况。越来越多的研究开始转向数据驱动的方法, 或者探索基于模型和数据驱动的融合诊断方法。例如, 通过采集 EMA 的工作信号进行模态分解或傅里叶变换构建故障分类特征^[7-10], 同时利用主成分分析等算法对故障数据进行降维, 构建适用于随机森林、支持向量机等机器学习算法的故障特征集以实现准确的故障分类^[11-14]。此外, 王晓明等^[15]为克服传统集合经验模态分解算法在故障特征识别中的局限性, 以及学习矢量量化网络在训练效率和稳定性方面的不足, 将学习矢量量化网络和集合经验模态分解 2 种方法相结合, 设计了一种新型的故障诊

断方法, 实现了高效检测并区分机电作动器的典型故障类型及其耦合模式。左乾君等^[16]针对滚珠丝杠副故障信号提取困难的问题, 将麻雀搜索算法优化后的支持向量机和变分模态分解相结合, 相比于传统的经验模态分解和变分模态分解算法, 具有更高的故障识别精度, 成为一种更加有效的解决方案。王剑等^[17]针对 EMA 突发性故障这一挑战, 结合交互式多模型和无迹卡尔曼滤波, 提出一种新的故障诊断方法, 不仅有效解决了可测量参数有限导致的诊断难题, 还在故障类型与预设模型偏差较大时提升了诊断响应速度和准确性。虽然上述方法在 EMA 故障诊断领域成效良好, 然而大多采用传统机器学习方法, 仍需对输入数据进行繁杂的特征提取操作, 增加了诊断系统的复杂性, 在处理高维非线性数据时, 难以充分捕捉故障特征的深层信息。

为此, 学者们开始尝试通过深度学习开展 EMA 故障诊断研究^[18-24]。例如, 李世晓等^[25]采用一维卷积神经网络来提取特征并整合为端到端的过程, 实现了更高的可操作性。Yang 等^[26]采用半监督稀疏自编码器的故障诊断模型, 很好地解决了 EMA 数据中存在的冗余问题。Zhang 等^[27]针对 EMA 信号的非线性和时间序列特征, 提出了一种结合混合时空注意力机制与基于时间序列特征的故障诊断方法, 获取了更多的故障信息用于预测多重时间序列数据。Wang 等^[28]针对 EMA 故障诊断中的域差异问题, 提出了一种深度学习域适应方法, 将联合最大均值差异引入卷积神经网络, 有效消除了域差异。尽管上述研究在智能故障诊断方法上取得了一定的进展, 但却很少考虑复杂

工况中处于不同尺度故障特征的重要性,并且在方法的泛化能力、计算复杂性等方面仍存在诸多不足。

综上所述,EMA故障诊断的研究已取得初步进展,但是目前的研究仍存在一些不足。一是传统方法依靠人为的选择特征,增加了诊断的复杂性;二是传统方法往往无法准确适应数据分布的差异,导致诊断结果不稳定;三是一些智能算法很少重视不同特征的重要程度,并且引入了复杂的模型结构,导致其诊断速度慢、计算成本高。基于此,首先,针对机电作动器故障特征提取难的问题,提出基于多尺度卷积的特征提取方法,增强了故障信号适应性,提升了特征区分度;同时,引入挤压-激励(squeeze-and-excitation, SE)模块,对各通道特征进行加权,以突出关键故障特征,抑制无关特征,提出了多尺度通道注意力卷积神经网络模型(mutiscale convolutional neural network with squeeze-and-excitation network, MCNN-SE)算法;最后,基于MCNN-SE算法,提出了基于多尺度通道注意力卷积神经网络的机电作动器故障诊断方法。

1 基本原理

1.1 多尺度卷积神经网络

1.1.1 卷积神经网络介绍

卷积神经网络(convolutional neural network, CNN)是一种用作精炼复杂数据特征的网络模型,能够有效解决传统神经网络的过拟合问题。CNN由多个特征提取层组成,基本架构如图1所示。

1) 卷积层(convolutional layer)

卷积层本质是利用卷积核对原始数据实行卷积运算以构建特征提取的网络结构。不同的卷积

核可获取不同特征,因此卷积核的数量和尺度直接影响着卷积神经网络的性能效果。卷积层利用卷积核从第*i*层特征图的输出 X_j 中提取特征,卷积的具体操作可以表示为

$$X_j^k = f \left(\sum_{i \in Q_j} X_i^{k-1} \odot W_{ij}^k + b_i^k \right), j = 1, 2, \dots, Q \quad (1)$$

式中: $\odot$ 为卷积运算符号; X_i^k 为当前层*k*的第*i*个特征图; X_i^{k-1} 为上一层(*k*-1)的第*i*个特征图; W_{ij}^k 为卷积核; b_i^k 为偏置; j 为输入特征集。

同时,为提升神经网络对复杂关系的拟合能力,一般选择在网络中添加激活函数。其中ReLU激活函数既引入了非线性因素,又解决了梯度衰减的困扰,因此使用频率最高。

2) 池化层(pooling layer)

在网络模型训练复杂数据的过程中常常面临过拟合风险,而池化操作可以有效减少此种情况的出现。常用的池化方法有最大池化、平均池化、混合池化和随机池化等。

3) 全连接层(fully-connected layer)

全连接层用于对前面提取的特征信息进行分类。对于多个输出的分类,全连接层之后通常会加上softmax函数进行分类输出,将输入的特征进行全局归一化处理,最终得到0~1之间概率值的输出,实现对数据类别的划分。softmax函数的计算公式为

$$P_i = \frac{e^{\delta_i}}{\sum_{j=1}^N e^{\delta_j}} \quad (2)$$

式中: $i = 1, 2, \dots, N$, N 为故障类别的数量; δ_i 为第*i*个输出; P_i 为每个输出的概率值,所有概率之和为1。

1.1.2 多尺度卷积神经网络介绍

对于复杂多样的数据输入,传统的卷积神经网络难以提取到完整的数据特征,导致一些重要




图1 卷积神经网络基本结构

Fig. 1 Basic structure of the convolutional neural network

特征容易被忽略。为有效精炼原始数据中的重要特征, 可以选择构造多尺度卷积神经网络 (multi-scale convolutional neural network, MCNN) 模型来改善。其核心思想是选择多个不同尺度的卷积核同时处理输入数据, 可以极大地扩展网络的感受野, 从而获取更全面的特征信息并且不会改变计算难度。MCNN 模型架构如图 2 所示, 将输入的数据分成 n 个通道进行特征提取, 逐次增加通路 1 至通路 n 中的卷积核尺寸, 以提取不同层次的故障特征。

1.2 SE 模块

使用 SE 模块能够重新分配网络提取的特征权重, 这种机制可以根据全局数据来自主地强调重要特征并忽略干扰特征。SE 模块主要包括全局信息嵌入 (squeeze)、自适应重新校准 (excitation) 和重新加权 (scale) 3 个步骤, 以提高网络的表达能力。

1) 全局信息嵌入操作

对输入特征图 X , 形状为 $L \times M \times N$, L 为特征图高度, M 为特征图宽度, N 为通道数。使用全局平均池化将其压缩成一个特征向量 z , 形状为 $1 \times 1 \times N$, 使得生成的特征向量 z 能够包含全局特征, 其操作表达式为

$$z = F_{sq}(x) = \frac{1}{L \times M} \sum_{i=1}^L \sum_{j=1}^M x \quad (3)$$

式中: F_{sq} 代表 squeeze 操作; x 为输入特征图 X 。

2) 自适应重新校准操作

以压缩后的向量 z 作为输入, 并依次连接 2 个全连接层来减少计算量。第一个全连接层将 N 个通道缩减至 N/r 个通道 (r 为压缩比例), 第二个全

连接层再将通道数增至 N 个通道, 再接一个 Sigmoid 函数获得权重向量 s , 其表达式为

$$s = F_{ex}(z, W) = \sigma(W_2 \delta(W_1 z)) \quad (4)$$

式中: F_{ex} 代表 excitation 操作; $W_1 \in \mathbf{R}^{N/r \times N}$ 、 $W_2 \in \mathbf{R}^{N \times N/r}$ 代表全连接层的权重; δ 为 ReLU 激活函数; σ 为 Sigmoid 函数。

3) 重新加权操作

将得到的注意力权重 s 加权到每个通道的特征上, 即将通道注意力权重向量 s 与原始输入特征图 X 逐通道相乘, 增强重要通道, 同时削弱次要通道, 实现通道注意力机制。最终得到加入 SE 注意力机制的特征图 $\tilde{X}$, 形状同样为 $L \times M \times N$, 其表达式为

$$\tilde{X} = F_{sc}(x) = s \cdot X \quad (5)$$

式中: F_{sc} 代表 scale 操作。

2 MCNN-SE 算法模型

传统 CNN 在用于 EMA 的故障诊断时难以识别出完整的信号特征, 导致其泛化能力不足。因此, 提出 MCNN-SE 模型, 用于机电作动器系统故障诊断, 其网络基本结构如图 3 所示。图中的 $\{H_{[i,j]} | i = 0, 1, \dots, n, j = 1, 2, \dots, n\}$ 表示隐藏层中的计算值, $O_1, O_2, \dots, O_m$ 表示输出结果, $P_1, P_2, \dots, P_m$ 表示结果的概率值。

为保证复杂工况下的故障诊断准确率, 该算法首先使用多尺度卷积神经网络提取试验台的故障数据特征, 即利用不同尺度的卷积核进行故障特征提取。通过提取与融合多尺度特征, 能够




图 2 多尺度卷积神经网络基本结构

Fig. 2 Basic structure of the multi-scale convolutional neural network




图 3 结合通道注意力机制的多尺度卷积神经网络

Fig. 3 Multi-scale convolutional neural network with squeeze-and-excitation network

为复杂数据提供更全面的特征表示，对数据尺度变化的适应性更好，且综合多尺度信息使其对噪声和局部变化更具鲁棒性，能够有效减少错误诊断或分类。

模型同时集成了SE注意力机制模块，对不同通道的特征进行自适应重加权。对于不同的输入数据，其通道的重要性可能会发生变化，SE模块能够根据这些变化动态调整权重，增强重要通道的作用，帮助模型更好地关注输入数据中的关键信息以提升诊断的精度和稳定性。

MCNN-SE模型以卷积神经网络为主体，设计了多通道的特征提取层，并加入了注意力机制模块。其网络架构如下。

输入层：接收试验台的故障信号数据。

多尺度卷积层：这一部分分为2个通道，分别以尺寸为 3×3 与 5×5 的卷积核进行运算，其中 3×3 的卷积核侧重于更细致的特征，而 5×5 的卷积核主要专注于更宽泛的特征。每个卷积层后紧跟ReLU激活函数和最大池化层，用于提取不同层次的特征。

SE注意力模块：在融合多层次特征之后，插入SE注意力模块加权不同层次的特征，强调主要特征并忽略无关特征。

卷积层：在SE注意力机制之后设置1个卷积核尺寸为 3×3 卷积层，以实现更有针对性的特征提取。

全连接层：整合所提取的所有特征，并传递到全连接层通过学习得到的权重综合判断输入数据的所属类别，最终输出4个EMA故障类别的概率分布。

率分布。

本文网络模型训练批次大小设置为16，在训练数据集上迭代更新次数为50，学习率设为 1×10^{-3} ，优化器选择Adam，损失函数选择交叉熵损失，其整体结构参数信息如表1所示。模型的构建和训练等操作均基于Python语言环境完成。

表 1 MCNN-SE 架构参数

Table 1 Architecture parameters of MCNN-SE

层	超参数
卷积层 1	Filter=64, kernel size=(3,3), stride=1, padding=1, activation=ReLU
卷积层 2	Filter=64, kernel size=(5,5), stride=1, padding=1, activation=ReLU
SE 模块	Channel=128
卷积层 3	Filter=128, kernel size=(3,3), stride=1, padding=1, activation=ReLU
全连接层 1	256, activation=ReLU
全连接层 2	4, activation=Softmax

3 实验验证与分析

3.1 故障诊断实验数据

为测试本文所提的网络模型对EMA故障诊断的性能，使用NASA的机电作动器FLEA实验数据进行验证。FLEA实验台共设计3个不同的作动器，分别为故障注入作动器、正常作动器、动态负载作动器，其结构组成如图4所示。测试中将负载调整到故障作动器，可以实现对作动器的故障

注入, 并且不会改变其工作情况。




图 4 FLEA 实验台

Fig. 4 FLEA test bed

EMA 由动力系统、传动系统、传感监测系统和控制系统组成, 主要故障类型有传感器故障、机械故障、电气故障和控制系统故障。由于电气故障和控制系统故障在其余机械控制系统中已被广泛研究, 本实验选择传感器故障与机械故障作为 EMA 故障诊断中的重点研究对象。在机械结构中, 齿轮与轴承的故障诊断技术已相对成熟, 而且减速器等也可以通过优化结构来降低故障率, 但滚珠丝杠却难以通过结构设计达到进一步优化。因此, 本文主要针对 EMA 的位移传感器故障、滚珠丝杠剥落和滚珠丝杠卡滞 3 种故障类型进行故障诊断的网络模型设计。

将上述 3 种故障模式分别注入 FLEA 实验台, 同时进行一组正常工作模式的实验, 对实验数据进行记录, 共得到 4 组不同的实验数据。将得到的 4 组实验数据划分不同类别的标签, 其中正常工作、位移传感器故障、滚珠丝杠剥落、滚珠丝杠卡滞所对应的标签分别为 1、2、3、4。

实验数据包括 1 类正常数据与 3 类故障数据, 每类数据中包括作动器位移、电机 X 电流、电机 Y 电压、电机 X 温度、螺母 Z 温度 5 种信号, 采集的 EMA 样本原始时域信号如图 5 所示。本研究中, 位置传感器的故障直接反映在作动器位移信号上, 具体表现为返回值恒定为 100。同时, 位置传感器故障可能导致电机电流和电压信号出现异常反馈, 且长期异常运行可能引起温度信号的显著升高。因此, 这些信号可用于辅助分析传感器故障的传播路径和影响范围, 从而进一步验证诊断模型的有效性和鲁棒性。对于 4 个类别的数据, 通过随机方式进行划分, 选取 80% 的试验数据作

为训练集, 其余作为测试集。




图 5 EMA 样本原始时域信号

Fig. 5 Original time-domain signals of EMA samples

3.2 故障诊断验证分析

分别运用 MobileNet、ResNet18、CNN、MCNN 4 种模型对相同的实验数据进行分析, 并与本文模型的故障诊断结果进行比较。

其中, MobileNet 模型采用深度可分离卷积方法把卷积这个单一过程分为深度与逐点 2 个过程, 大幅减少了总计算量; ResNet18 模型是一种深度为 18 层的残差网络模型, 通过引入残差块很好地解决了提取特征时的梯度消失和梯度爆炸问题; CNN 模型即为传统神经网络; MCNN 模型是在 CNN 架构上新增不同尺度的卷积运算以提取更全面的特征。这 5 种模型使用完全一致的卷积网络结构和超参数, 用训练集样本对 5 种网络模型进行充分训练。训练充分后将测试数据输入模型进行性能验证, 5 种模型诊断结果的混淆矩阵如图 6 所示, 每种模型相应的平均准确率和方差如表 2 所示。可以看出, 5 种模型中, MCNN-SE 模型的平均准确率为 98.77%, 明显高于其他 4 种模型, 说明 MCNN-SE 模型的准确率更高; 方差为 0.43%, 远低于其他 4 种模型, 说明 MCNN-SE 模型的鲁棒性更强。




图 6 5种模型的混淆矩阵
Fig. 6 Confusion Matrices of five models

表 2 不同网络模型比较

网络模型	平均准确率/%	方差/%	参数量/ 10^6
MCNN-SE	98.77	0.43	2.18
MobileNet	94.53	4.90	3.20
ResNet18	96.49	3.11	11.2
CNN	91.70	2.69	0.26
MCNN	97.45	2.50	2.18

4 结论

为增强EMA滚珠丝杠副故障诊断准确率，提出了一种基于多尺度通道注意力卷积神经网络的EMA故障诊断方法，并基于可飞式机电作动器实验数据验证了本文模型具有更优的性能。主要结论如下。

1) 通过构建2个独立的CNN通道，并分别使用不同尺度的卷积核代替传统CNN单一卷积核进行特征提取，实现了从高维度更全面的特征提取，大幅提升了EMA故障特征的可信度。

2) 现有的多尺度卷积主要是将提取到的故障特征进行简单合并，未能充分考虑不同尺度特征

的重要性差异，导致特征利用效率不高。通过引入SE注意力机制有效增强了模型对故障特征的敏感性，提升了模型的鲁棒性。

3) 与传统的MobileNet、ResNet18、CNN及MCNN模型相比，所提模型的结构更为简洁，不仅显著降低了运算成本并加快了诊断速度，同时准确率更高。

本研究所提出的模型虽然在NASA公开数据集中得到了验证，但由于该数据集涵盖的故障数据类型有限，因此后续EMA故障诊断的研究还应结合速度传感器、电流传感器等部件的故障信号，以进一步提升模型的性能。

参考文献

[1] YIN Z Y, HU N Q, CHEN J G, et al. A review of fault diagnosis, prognosis and health management for aircraft electromechanical actuators[J]. IET Electric Power Applications, 2022, 16(11): 1249-1272.

[2] SONG Y T, DU J H, LI S Y, et al. Multi-scale feature fusion convolutional neural networks for fault diagnosis of electromechanical actuator[J]. Applied Sciences, 2023, 13(15): 8689.

- [3] YIN Z Y, YANG Y, SHEN G J, et al. Dynamic modeling, analysis, and experimental study of ball screw pairs with nut spalling faults in electro-mechanical actuators[J]. *Mechanical Systems and Signal Processing*, 2023, 184: 109751.
- [4] WANG J Y, ZHANG H, MIAO Q. Source free unsupervised domain adaptation for electro-mechanical actuator fault diagnosis[J]. *Chinese Journal of Aeronautics*, 2023, 36(4): 252-267.
- [5] ZHU Z Q, LEI Y B, QI G Z, et al. A review of the application of deep learning in intelligent fault diagnosis of rotating machinery[J]. *Measurement*, 2023, 206: 112346.
- [6] KAWATSU K, TSUTSUMI S, HIRABAYASHI M, et al. Model-based fault diagnostics in an electromechanical actuator of reusable liquid rocket engine[C/OL]//AIAA Scitech 2020 Forum. (2020-01-05) [2024-11-09]. <https://doi.org/10.2514/6.2020-1624>.
- [7] RUIZ-CARCEL C, STARR A. Development of a novel condition monitoring tool for linear actuators [C]//The Twelfth International Conference on Condition Monitoring and Machinery Failure Prevention Technologies, 2015: 1-12.
- [8] WATSON M J, SMITH M J, KLODA J, et al. Prognostics and health management of aircraft engine EMA systems[C]//ASME 2011 Turbo Expo: Turbine Technical Conference and Exposition. Vancouver, British Columbia, Canada: ASME, 2012: 427-435.
- [9] LIU H M, JING J, MA J. Fault diagnosis of electromechanical actuator based on VMD multi-fractal detrended fluctuation analysis and PNN[J]. *Complexity*, 2018, 2018: 9154682.
- [10] CHEN J, WANG L Y. Electromechanical actuator modeling and its application in fault diagnosis [J]. *DEStech Transactions on Engineering and Technology Research*, 2018: 65595213.
- [11] RIAZ N, ALI SHAH S I, REHMAN F, et al. An intelligent hybrid scheme for identification of faults in industrial ball screw linear motion systems [J]. *IEEE Access*, 2021, 9: 35136-35150.
- [12] CHIRICO A J III, KOLODZIEJ J R. A data-driven methodology for fault detection in electromechanical actuators[J]. *Journal of Dynamic Systems, Measurement and Control*, 2014, 136(4): 041025.
- [13] LOU S W, YANG C J, WU P, et al. Fault diagnosis of blast furnace iron-making process with a novel deep stationary kernel learning support vector machine approach[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 3521913.
- [14] SUN Y Y, ZHANG H Q, ZHAO T T, et al. A new convolutional neural network with random forest method for hydrogen sensor fault diagnosis [J]. *IEEE Access*, 2020, 8: 85421-85430.
- [15] 王小明, 付继伟, 韩松, 等. 基于EEMD-LVQ的机电作动器故障诊断方法[J]. *导弹与航天运载技术(中英文)*, 2023(5): 1-7.
- WANG X M, FU J W, HAN S, et al. Fault diagnosis based on EEMD-LVQ for electro-mechanical actuator[J]. *Missiles and Space Vehicles*, 2023(5): 1-7.
- [16] 左乾君, 陈国华, 毛杰, 等. 基于SSA-VMD和SVM的滚珠丝杠副故障诊断[J]. *机床与液压*, 2024, 52(12): 231-238.
- ZUO Q J, CHEN G H, MAO J, et al. Fault diagnosis of ball screw pair based on SSA-VMD and SVM[J]. *Machine Tool & Hydraulics*, 2024, 52(12): 231-238.
- [17] 王剑, 王新民, 谢蓉, 等. 基于IMM-UKF方法的机电作动器突发性故障诊断研究[J]. *北京理工大学学报*, 2019, 39(2): 198-202, 208.
- WANG J, WANG X M, XIE R, et al. Abrupt fault diagnosis for electro-mechanical actuator based on IMM-UKF[J]. *Transactions of Beijing Institute of Technology*, 2019, 39(2): 198-202, 208.
- [18] SONG Y T, DU J H, LI S X, et al. Multi-scale feature fusion convolutional neural networks for fault diagnosis of electromechanical actuator[J]. *Applied Sciences*, 2023, 13(15): 8689.
- [19] JIANG G Q, HE H B, YAN J, et al. Multi-scale convolutional neural networks for fault diagnosis of wind turbine gearbox[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(4): 3196-3207.
- [20] KUMAR P, HATI A S. Convolutional neural network with batch normalisation for fault detection in squirrel cage induction motor[J]. *IET Electric Power Applications*, 2021, 15(1): 39-50.
- [21] REN L, JIA Z D, WANG T, et al. LM-CNN: a cloud-edge collaborative method for adaptive fault diagnosis with label sampling space enlarging[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(12): 9057-9067.
- [22] GONG R H, TANG Z Q. Further investigation of convolutional neural networks applied in computational electromagnetism under physics-informed consideration[J]. *IET Electric Power Applications*, 2022, 16(6): 653-674.

- [23] ZHAO X L, ZHU X J, LIU J H, et al. Model-assisted multi-source fusion hypergraph convolutional neural networks for intelligent few-shot fault diagnosis to electro-hydrostatic actuator[J]. Information Fusion, 2024, 104: 102186.
- [24] ZHAO X L, JIA M P. A novel unsupervised deep learning network for intelligent fault diagnosis of rotating machinery[J]. Structural Health Monitoring, 2020, 19(6): 1745-1763.
- [25] 李世晓, 杜锦华, 龙云. 基于一维卷积神经网络的机电作动器故障诊断[J]. 电工技术学报, 2022, 37(S1): 62-73.
- LI S X, DU J H, LONG Y. Fault diagnosis of electromechanical actuators based on one-dimensional convolutional neural network[J]. Transactions of China Electrotechnical Society, 2022, 37(S1): 62-73.
- [26] YANG J, GUO Y Q, ZHAO W L. An intelligent fault diagnosis method for an electromechanical actuator based on sparse feature and long short-term network[J]. Measurement Science and Technology, 2021, 32(9): 095102.
- [27] ZHANG X Y, TANG L W, CHEN J S, et al. Fault diagnosis for electro-mechanical actuators based on STL-HSTA-GRU and SM[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 3527716.
- [28] WANG J Y, ZHANG Y J, LUO C, et al. Deep learning domain adaptation for electro-mechanical actuator fault diagnosis under variable driving waveforms[J]. IEEE Sensors Journal, 2022, 22(11): 10783-10793.
- (编辑: 于福兴)

“临近空间浮空器研发与应用”专题征稿

临近空间是航空航天领域的重要空间圈层, 具有极高的战略和科学价值。平流层飞艇作为临近空间浮空飞行器的重要代表, 可以实施对地观测、侦察监视、网络通信和信号中继等任务, 是重要的临近空间战略平台, 具有非凡的装备应用前景。近年来, 我国临近空间浮空器技术取得了突破性的进展, 正在从性能提升向装备应用发展。但是一些关键技术瓶颈仍不同程度制约浮空器向更高性能指标发展, 例如极端环境下超轻质高强韧结构技术、动力推进技术、高可靠性能源技术、智能飞行控制技术、隐身技术、大尺度载荷搭载应用技术等。

本专题重点关注临近空间平台轻量化结构技术、高效推进技术、高可靠能源技术、智能飞行控制技术、大尺度多功能载荷布局及应用技术等, 围绕临近空间浮空器总体技术、航空航天装备与热管理、临近空间浮空器控制与载荷、临近空间浮空器材料、临近空间浮空器控制与载荷等领域问题, 诚邀相关基础理论研究、实际工程应用和前沿科学问题探究等方面的国内专家、学者和科研人员积极投稿。

投稿方式

军网网址: <http://xb.epgc.mtn>

电子邮箱: depbxb@126.com

联系电话: 029-84744009; 029-84741602

通信地址: 陕西省西安市灞桥区同心路2号学报编辑部

邮政编码: 710025

网 址: <http://hju.cbpt.cnki.net/portal/>

《火箭军工程大学学报》编辑部