

doi: 10.7690/bgzd.2025.07.012

## 基于增强元学习与注意力机制的民机故障诊断

李易健<sup>1</sup>, 刘冰<sup>1,2</sup>, 方元<sup>2</sup>, 罗灵鲲<sup>1</sup>, 胡士强<sup>1</sup>

(1. 上海交通大学航空航天学院, 上海 200240; 2. 中国航空工业集团中国航空无线电电子研究所, 上海 200241)

**摘要:** 针对民机机械部件故障样本缺乏且类不平衡以及故障信号复杂多样导致的故障诊断精度低, 识别不稳定的问题, 提出基于增强元学习与通道注意力机制(learn to reweight with SE-1DLeNet, LRS)的故障诊断方法。利用小样本平衡验证集指导了不平衡训练集的损失权重更新以改善原始不均衡样本分布, 提出元梯度增强的梯度裁剪策略; 在 1D-LeNet 的基础上引入 SE 注意力机制对多维度故障特征通道自适应加权。结果表明: 以民机大梁和机械轴承故障作为仿真试验数据集, 与当前主流的故障诊断算法 ProtoNet、DNCNN、GAN-CNN 等相比, 该方法诊断效果最优, 在样本极端不平衡时准确率达 95% 以上, 能够进行准确故障诊断。

**关键词:** 民机故障诊断; 类不平衡问题; 深度学习; 元学习; 注意力机制

**中图分类号:** V263.6 **文献标志码:** A

## Civil Aircraft Fault Diagnosis Based on Reinforcement Meta-learning and Attention Mechanism

Li Yijian<sup>1</sup>, Liu Bing<sup>1,2</sup>, Fang Yuan<sup>2</sup>, Luo Lingkun<sup>1</sup>, Hu Shiqiang<sup>1</sup>

(1. School of Aeronautics and Astronautics, Shanghai Jiao Tong University, Shanghai 200240, China;

2. China Radio Research Institute of AVIC, Aviation Industry Corporation of China, Shanghai 200241, China)

**Abstract:** In order to solve the problem of low accuracy and unstable recognition of fault diagnosis caused by the lack of fault samples of civil aircraft mechanical components and their imbalanced classes, as well as the complexity and diversity of fault signals, a fault diagnosis method based on enhanced meta-learning and channel attention mechanism is proposed. The balanced validation set of small samples is used to guide the updating of the loss weight of the imbalanced training set to improve the distribution of the original imbalanced samples, and the gradient pruning strategy of meta-gradient enhancement is proposed. On the basis of 1D-LeNet, the SE attention mechanism is introduced to adaptively weight the multi-dimensional fault feature channels. The results show that compared with the current mainstream fault diagnosis algorithms such as ProtoNet, DNCNN and GAN-CNN, the proposed method has the best diagnosis effect, and the accuracy is more than 95% when the samples are extremely unbalanced, capable of accurate fault diagnosis.

**Keywords:** civil aircraft fault diagnosis; class imbalance problem; deep learning; meta-learning; attention mechanism

### 0 引言

民机在线故障诊断技术通过在机载设备上布置各类传感器实时监控和分析设备运行的机理信号, 从而在故障发生时能及时、准确地定位和识别故障。其生成的故障预警信息可以为飞行员实施故障隔离以及备份方案的启动等补救操作提供充足的响应时间, 这对保证民用航空器的运行安全具有重要意义<sup>[1]</sup>。然而由于民机通常工作在正常状态下, 可获得的历史运行数据中真实故障样本缺乏, 但健康状态样本充沛, 这使得民机机械部件的故障数据呈现小样本且类不平衡的特性, 基于数据驱动的故障诊断模型由于缺乏足够的故障信息容易发生过拟合的问题<sup>[2]</sup>, 并导致识别结果倾向于健康状态而忽略潜在的故障隐患, 从而无法为飞行员提供准确的故障预警信息,

对民机以及机载人员的安全造成威胁。针对上述问题, 笔者提出设计一种能利用现有小且不平衡故障样本的民机故障诊断方法, 实现对民机设备故障的精准、敏捷地识别和诊断。

相较于传统的基于模型的故障诊断方法而言, 基于数据驱动的故障诊断不依赖于精确的解析模型<sup>[3]</sup>, 可在缺乏经验知识的前提下, 借助机器学习等智能算法实现故障的定位、识别与隔离。一些基于数据的机器学习算法如支持向量机(support vector machine, SVM)<sup>[4-5]</sup>、 $k$  近邻( $k$ -nearest neighbors, KNN)等也被应用于故障诊断任务中, 但却无法解决故障数据分布不均衡以及数据缺乏引起诊断精度低的问题。为解决上述问题, Zhang 等<sup>[6]</sup>通过数据增强的方法使用深度梯度惩罚 GAN 来生成轴承的振动数据, 有效地扩展了训练故障数

收稿日期: 2024-09-10; 修回日期: 2024-10-20

基金项目: 国家自然科学基金(61773262, 62006152); 航空科学基金(20142057006)

第一作者: 李易健(1997—), 男, 辽宁人, 硕士。

据集,提升了诊断模型的泛化能力。Cabrera 等<sup>[7]</sup>提出了一种基于小波变换与 GAN<sup>[8]</sup>结合的不平衡故障诊断方案,使用小波包变换提取 2 维时频特征,并通过 GAN 进行数据特征增强。但当只有少数样本可用于训练时,GAN 生成的故障样本分布高度相似于原始故障样本,样本的分布容易边缘化,难以代替真实故障样本<sup>[9]</sup>。模型参数稀疏化与正则化也可以在一定程度上缓解数据缺乏的影响<sup>[10]</sup>。Saufi 等<sup>[11]</sup>提出一种基于堆叠稀疏自动编码器(stacked sparse automatic encoder, SSAE)的齿轮箱故障诊断方法,以 Kullback-Leibler 散度为稀疏惩罚项,减少了 SSAE 中要训练的参数,稀疏化的自编码器在一定程度上降低了过拟合的风险<sup>[12]</sup>。Jia 等<sup>[13]</sup>使用归一化卷积神经网络(denoising convolutional neural network, DNCNN)进行不平衡轴承故障识别,通过构建归一化卷积全连接层降低了不平衡样本对故障分类的负面影响。正则化类方法虽然能够提高模型泛化能力,但当训练样本缺乏且不平衡时对诊断精度的提升有限,而且由于引入了稀疏惩罚项导致模型更加复杂且难以训练。

虽然上述研究针对故障样本小且不平衡的问题提出了一些有效方案,但仍存在故障数据不真实、模型难以训练、稳定差等问题。同时,民机机械部件的种类繁多,部件运行环境如压力、温度、载荷等工况复杂。多样化的故障数据分布为故障的精准识别带来了极大挑战,仍需要在处理样本问题的基础上提升模型对故障特征的提取能力;因此,笔者针对上述问题提出一种基于增强元学习与注意力机制(LRS)的故障诊断方法,不依赖于数据生成便可以实现精准的在线故障识别,其重要贡献如下:

1) 针对民机故障样本小且不平衡的问题,提出了基于增强学习重权重(learn to reweight, LTR)的元学习在线故障诊断算法,利用小且平衡的验证集指导不平衡训练集样本的损失权重更新,从而纠正了不平衡样本训练的参数更新方向,改善了原始不均衡的样本分布,有效避免了模型过拟合问题。针对原始权重学习方法的元梯度消失导致的权重更新乏力的问题,提出了一种元梯度增强的权重裁剪策略。该策略提升了故障样本的利用率,丰富了可利用的故障信息,有效提升了故障诊断的稳定性。

2) 针对故障类型以及运行工况的多样化导致的故障特征复杂难以提取的问题,在卷积神经网络的基础上引入了通道注意力机制,对位置、压载、损伤大小以及其他隐性故障特征按照其重要性自适

应加权。有效提升了模型的特征提取能力并提升了故障诊断的准确率。

## 1 增强元学习与注意力机制的故障诊断

图 1 为 LRS 故障诊断算法的模型,通过 SE-1DLeNet 网络提取故障特征信息,实现了不同类型高维故障特征的加权重组,最大限度提升关键特征的影响占比。LRS 利用基于学习重权重<sup>[14]</sup>的策略优化了网络的参数更新方式。同时,利用元梯度增强的方式提升了原始样本的利用率,有效提升了故障诊断模型的识别稳定性和准确率。




图 1 LRS 模型

### 1.1 基于学习损失权重的元学习算法

当原始故障样本中故障样本体积小且类不平衡时,模型训练的过程中大量健康样本信息会吞没少量故障样本信息从而使诊断结果倾向于健康状态,导致模型过拟合从而降低诊断精度。在误差反向传播过程中,样本损失权重决定了不同样本对于模型参数更新的影响大小;因此,为大类样本提供更小的权重,而为小类样本提供更大的权重以改善原始不平衡故障集的分布特性。学习重权重算法通过计算小样本平衡验证集的损失来更新不平衡训练集样本权重的方式解决上述样本不平衡问题,假设有不平衡的训练集样  $\{(x_i, y_i), 1 \leq i \leq N\}$ , 以及小的平衡验证集样本对  $\{(x_j, y_j), 1 \leq j \leq M\}$ ,  $M \ll N$ 。验证集样本来源于训练集。 $\phi(x, \theta)$  为神经网络模型,  $\theta$  为模型参数。最终目的是最小化训练集的损失函数  $\frac{1}{N} \sum_{i=1}^N L(\hat{y}_i, y_i) = \frac{1}{N} \sum_{i=1}^N f_i(\theta)$ , 式中每个输入样本的权重都相等,采样训练集  $(x_i, y_i)$ ,  $1 \leq i \leq n$ ,  $n$  为 mini-batch 的批量大小,使用 SGD 优化器做一步虚拟更新,公式如下:

$$f_{i,\epsilon}(\theta) = \epsilon_i f_i(\theta); \quad \theta_{t+1} = \theta_t - \alpha \nabla \left( \frac{1}{N} \sum_{i=1}^N w_{i,t} f_i(\theta_t) \right). \quad (1)$$

式中： $\alpha$  为学习率； $\epsilon_i$  为训练集样本权重。将验证集输入给虚拟更新后的模型  $\hat{\theta}_{t+1}(\epsilon)$  并计算小且平衡验证集的损失，通过误差反向传播以及梯度下降的方式更新原始损失权重，为降低计算成本，利用一步梯度下降来估计权重最优值，由于负样本权重会造成损失在零附近剧烈摆动以及梯度爆炸的问题，影响训练稳定性，所以有必要进行梯度裁剪以保留正值权重。权重更新公式如下：

$$\left. \begin{aligned} u_{i,t} &= -\eta \frac{\partial}{\partial \epsilon_{i,t}} \frac{1}{m} \sum_{j=1}^m f_{ji}^v(\theta_{t+1}(\epsilon)) \Big|_{\epsilon_{i,t}=0} \\ w_{i,t} &= \max(u_{i,t}, 0) \end{aligned} \right\} \quad (2)$$

式中  $w_{i,t}$  为更新后的权重，包含验证集的平衡特征，对不平衡训练集损失加权后改善其不平衡的分布特性，从而提升模型分类平衡数据集的性能。利用新的权重对训练集样本做实际更新：

$$\theta_{t+1} = \theta_t - \alpha \nabla \left( \frac{1}{N} \sum_{i=1}^N w_{i,t} f_i(\theta_t) \right) \quad (3)$$

以上为一个 mini-batch 的模型参数更新过程。图 2 展示了具体的参数更新步骤，更新过程主要分为虚拟更新、元更新以及实际更新。并通过测试机验证最终模型的诊断效果，训练集损失下降意味着模型具备分类不平衡数据集的能力，同时验证集损失下降意味着模型具备分类平衡数据集的能力。学习权重算法将小且不平衡的验证集数据分布特性作为一种元知识，从而指导了不平衡训练集的参数更新方向。使其在故障数据不平衡的条件下仍能在平衡的测试集中取得较好的诊断精度。

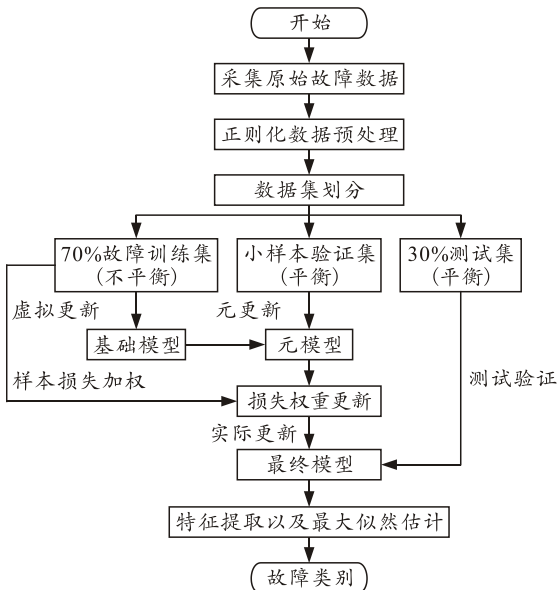


图 2 基于学习权重重的故障诊断训练流程

## 1.2 元梯度增强的裁剪策略

学习权重重算法改善了不平衡训练集的样本分布特性，从而提升了故障诊断模型在小且不平衡数据集上的诊断精度。但由于原始梯度裁剪舍弃负权重，保留正权重的方式如式(3)所示，虽然避免了加权损失的震荡以及梯度爆炸的问题，但却丢弃了大量珍贵的故障样本特征信息。在故障样本有限时，该梯度裁剪方式会降低实际参与参数更新的样本数量，从而影响模型更新的稳定性，增加过拟合的风险。针对上述问题，通过线性映射的方式将原始元梯度映射到  $[0, 1]$  区间。改进的梯度裁剪公式如下：

$$\hat{u}_{i,t} = u_{i,t} - c * \min(u_{i,t}) \quad (4)$$

$$w_{i,t} = \max(\hat{u}_{i,t}, 0) \quad (5)$$

式中： $c$  为增强系数； $\hat{u}_{i,t}$  为增强的梯度； $w_{i,t}$  为改进后的样本损失权重，通过对梯度增加一个正向偏置，使得权重更新后的正值权重比例得以提升，既维持了不同样本相对权重分布，又保留了珍贵的故障样本特征信息。梯度裁剪改进前后的权重分布如图 3 所示。




图 3 改进梯度裁剪策略原理对比

图 3 中，“•”代表小类样本损失，“△”代表大类样本损失，虚线表示分类边界。“•”，“△”面积大小表示该样本损失权重大小，数量表示样本实际参与模型更新的数量。图 3(b) 中原始的梯度裁剪策略虽然合理分配损失权重，却舍弃了大部分原始大类样本。由于其原始样本利用率较低，导致可利用训练样本量降低，使得模型容易出现过拟合的问题。如图 3(c) 所示，改进后的梯度裁剪策略充分利用了原始故障样本，并未出现样本丢弃的现象。并且样本损失仍然获得合理的权重分配。经试验验证，该策略不仅保证了原始故障样本信息的有效利用率，而且保障了故障信息真实性和完备性，从而提升了故障诊断算法的准确率和稳定性。

## 1.3 基于特征通道增强的 SE-1DLeNet 模型

增强元学习算法有效解决了不平衡故障样本导

致的识别精度低的问题,提升了故障诊断的稳定性。但故障诊断的性能还取决于模型网络的结构以及其特征提取能力。在实际民机设备运行过程中不同的工况环境,如温度、压载、位置、以及损伤大小等,使得故障数据特征分布复杂多样,难以识别。这也导致不同维度特征对诊断识别的重要性存在差异,例如螺栓松动故障中螺栓的位置信息更加关键,而压载的影响较低。在机械轴承故障识别任务中,轴承的损伤大小以及损伤位置更加关键,而环境温度的重要性较弱。提出基于通道注意力的 1 维卷积神经网络结构 SE-1DLeNet,通过对卷积神经网络提取的特征层中不同的特征通道自适应加权来提升重要特征的影响,并弱化次要特征的影响。压缩与激励(squeeze and excitation, SE)通道注意力机制是 Hu 等<sup>[15]</sup>提出的增强图像特征提取能力的神经网络模块。笔者将其与 1D-CNN 结合并应用在时序故障特征提取过程中。通过提升整个特征层次结构中空间编码的质量来增强 CNN 的表征能力,其模型结构如图 4 所示。




图 4 SE 通道注意力

图 4 中,首先对于任何给定的变换  $F_{tr}$ , 将输入  $x$  映射为特征空间。以卷积操作为例,输入  $x$  通过 1 维卷积映射为  $H \times W \times C$  的特征空间  $u$ 。随后通过挤压操作  $F_{sq}(u_c)$  对特征矩阵进行全局池化,从而在全局感受野的维度上获得一个特征空间  $u$  的低维嵌入,其计算公式如下:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (6)$$

该低维嵌入  $z_c$  包含不同特征通道的全局信息。激励操作  $F_{ex}(z, W)$  需要连接 2 层全连接层,通过权重  $W$  生成自适应的通道权重。计算公式如下:

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)) \quad (7)$$

式中  $W_1, W_2$  为 2 层全连接层的权重参数,其中存在一个挤压超参数  $R$ ,其大小表示通道权重的挤压程度。经过上述操作构建了自适应通道权重的生成模型,最终通过通道加权获得 SE 通道注意力模块的特征输出:

$$x_c = F_{scale}(u_c, s_c) = s_c u_c \quad (8)$$

如图 5 所示,SE-1DLeNet 主要由 3 层 1 维卷

积层、2 层全连接层以及 Softmax 层构成。1 维卷积由于其对时序相关性敏感的特点更加适用于笔者的时序故障特征提取<sup>[16-17]</sup>。为提升模型的稀疏性以降低过拟合风险,每层卷积操作后都进行批量正则化以及 dropout 和最大池化操作。由于最后一层卷积层提取的特征通道维数最多,对故障特征的解耦程度也最大。所以选择将通道注意力机制嵌入到最后一层卷积层与全连接层之间能最大限度加强特征表达性。使得 SE-1DLeNet 对特征通道的自适应加权有效提升了复杂故障信息的表征能力,并提升模型识别准确率。

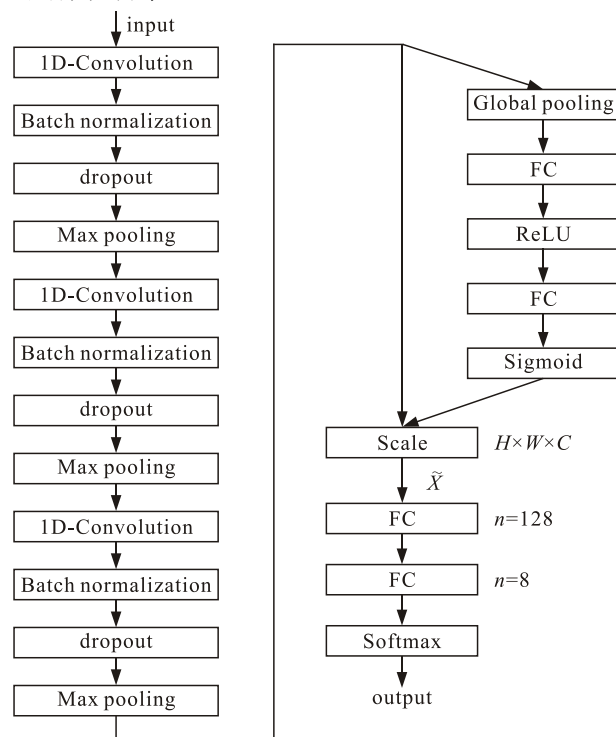


图 5 通道增强 SE-1DLeNet 结构

## 2 仿真试验与结果分析

试验运行环境为 VScode, 计算硬件平台为 inter core i7-10875 CPU 和 NVIDIA GEFORCE GTX2060 GPU。并通过 Pytorch 搭建深度学习框架测试平台, Python 版本为 3.8.1。

### 2.1 数据集与试验设定

由于真实的民机故障数据难以获取,机械轴承与螺栓作为民机中的常见机械部件,对民机故障而言是具有代表性的;因此,选用公开的机翼大梁螺栓故障数据集以及 CWRU 机械轴承故障数据集测试验证故障诊断算法的性能。机翼大梁通过松动对应位置螺栓模拟螺栓故障,并对机翼大梁发射 Lamb 电波,激励信号频率为 200 kHz。同时在螺栓



端(LS)利用压电传感器采样响应信号,采样频率为 10 MHz。机翼大梁螺栓数据集中总共 4 种故障模式即正常(N)、螺栓 1 松动(L1)、螺栓 2 松动(L2)、螺栓 3 松动(L3)。机械轴承故障数据集采集实验中通过对轴承不同位置进行电火花打点损伤来模拟轴承故障,损伤程度按照电火花打点大小来判定。分别为 0.07 英寸、0.14 英寸、0.21 英寸等。通过风扇端(FE)和驱动端(DE)加速度传感器采集振动信号。故障数据集参数分布如表 1 所示,采样频率为 12 kHz 与 48 kHz,故障模式共 3 种,分别为正常(N)、滚轴故障(B)、内圈故障(IR)、外圈故障(OR)。

表 1 故障数据集分布

数据来源	数据集	类别	标签	端口	频率/Hz
机械轴承	DE-1	N/B/IR/OR	1/2/3/4	DE	$12\times10^3$
	DE-2	N/B/IR/OR	1/2/3/4	DE	$48\times10^3$
	FE	N/B/IR/OR	1/2/3/4	FE	$12\times10^3$
机翼螺栓	LS	N/L1/L2/L3	1/2/3/4	LS	$10\times10^6$

为了降低随机噪声对故障数据的影响,采用正则化的方法对原始故障样本进行预处理,并通过滑动窗口的模式在故障信号中无重叠滑动采样长度为 200 的故障样本。最终得到 CWRU 数据集中 4 种故障模式(N, B, IR, OR)对应的样本量为(300, 300, 300, 300)。民机机翼大梁螺栓的 4 种故障模式(N, L1, L2, L3)对应的样本量为(400, 400, 400, 400)。为了验证 LRS 在不平衡小样本下的故障诊断性能,将样本构造不平衡训练数据集,不平衡度  $P$  表示健康样本占总样本的百分比。同时构造平衡小样本验证集,包含 8 个样本,2 个为一种故障模式。平衡的测试集用来验证故障真诊断的准确率,内部各类样本分布平衡,其样本量为总样本的 30%。

2.2 试验结果与分析

为验证元梯度增强的学习重权重算法在小且不平衡样本被故障诊断中的性能优势,设定对照试验 1。如图 6 所示,分别使用 CNN 与 LRS 在 DE1 机械轴承故障数据集上进行故障识别测试来验证 LRS。故障模式为(N, B, IR, OR)。设定  $P=[0.5, 0.7, 0.8, 0.9]$  4 种工况下不同平衡度对诊断准确率的影响,来对比自适应更新权重方法与传统 CNN 方法的性能差异。例如,  $P=0.9$  表示健康样本占总样本量的 90%, 剩余 3 类故障样本占总样本量的 10%。除 LRS 所需的小样本平衡验证集(样本总量为 8, 且类平衡)外,其他训练集与测试集 2 种方法的配置均相同。

通过图 6 可知:LRS 方法在不同不平衡度下的

平均准确率为 97.03%, 而传统的 CNN 神经网络的平均准确率为 81.52%。在样本较为均衡的情况 ( $P=0.5$ )时, 2 种方法的准确率差异并不大且都能达到 98%以上, 但随着不平衡的增加, 故障样本在总样本量的比例越来越少, 可利用的故障信息更加有限。传统的 CNN 方法在  $P=0.9$  时出现了明显的过拟合现象。模型倾向将样本分类为大类的健康样本。导致识别的准确率在 51.60%。由于增强元学习的学习重权重方法通过自适应更新权重的方式改善了不平衡训练集的样本损失分布。在  $P=0.9$  情况下, 其准确率依然可以稳定在 95%以上。相比于传统的 CNN 方法准确率提升了 44.51%。


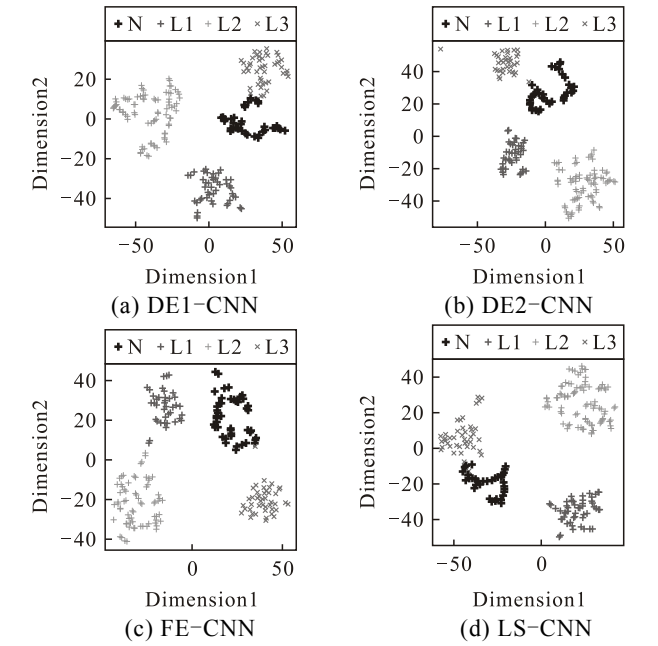


图 6 准确率对比

由于试验 1 无法直观地体现基于通道增强的 SE-1DLeNet 特征提取模块是否对故障体征的提取以及故障识别的准确率造成实际影响, 设定对照试验 2。使用 t 分布随机邻接嵌入对网络末尾层特征非线性降维, 通过观测不同模式下样本特征的分布情况来探究本文中方法与传统 CNN 网络在特征提取方面的差异。试验 2 分别对机械轴承故障数据集 DE1、DE2、FE、LS 训练 5 000 个循环, 并绘制 T-SNE 特征分布如图 7 所示。



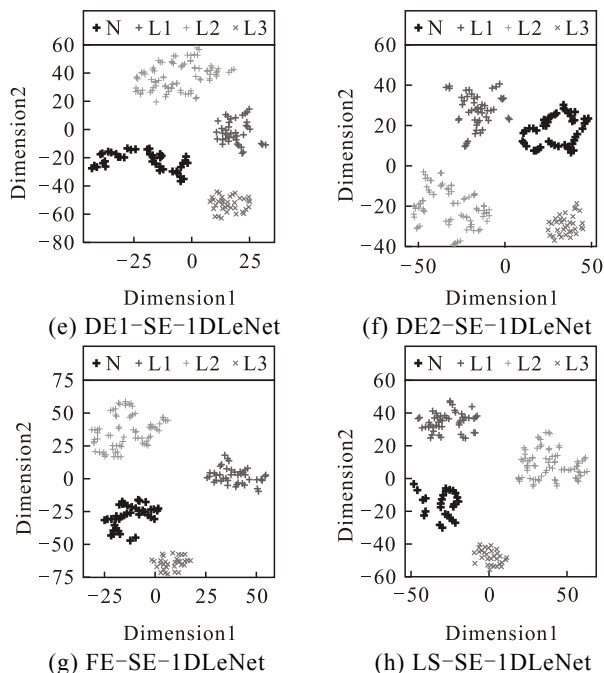


图 7 故障特征分布

图 7(a)CNN 方法的特征分布图中内圈故障 IR 与外圈故障特征分布出现重叠相互混淆, 而图 7(e)中 SE-1DLeNet 方法 IR 与 OR 特征分布相对独立, 同时健康状态与 3 类故障的分别边界清晰明显。图 7(b)与(f)对 DE2 数据集的对比测试中, 呈现相同规律。说明内外圈故障信号的相似度较高不易分离。图 7(c)中风扇端的特征分布呈现不同特性, 滚珠故障与内圈故障特征发生混淆, 且滚珠故障特征内部聚合度不高, 呈现出 2 个独立的特征簇。可能的原因是滚珠故障中不同程度的电火花损伤大小对信号影响较大。图 7(g)SE-1DLeNet 方法提取的特征分布同样出现滚珠故障内部分离的特点, 但相比于前者聚合度更高, 同时消除了滚珠与内圈故障特征混淆的问题。针对民机机翼大梁螺栓故障的数据特征分布对比情况来看。图 7(d)中螺栓 2 部分与螺栓 1 故障混淆, 在图 7(h)中得到解决。整体上看由于通道注意力机制对不同的特征进行自适应加权, 强化了关键特征的影响, 弱化了不关键特征的影响; 因此, SE-1DLeNet 对各类故障数据的特征提取内部聚合度更高, 同时不同类别之间分离性更强。试验 2 直观地展现了 SE-1DLeNet 在故障特征提取方面的优势为验证元梯度增强对学习重权重算法的稳定性性能提升, 设置对照试验 3, 在  $P=0.9$  不平衡数据分布条件下, 如图 8 所示, 对 LS 螺栓数据集测试故障诊断分类精度, 同时绘制样本损失曲线观察改进前后损失变化。

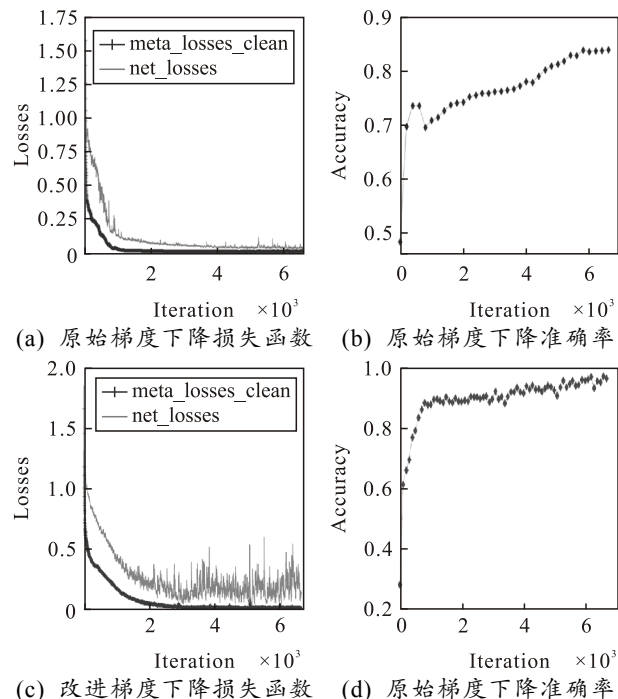


图 8 元梯度增强对比实验

图 8(a)中, 网络损失与元损失随着网络的更新幅值波动较大, 元损失即验证集损失快速收敛并无限接近 0, 意味着训练后期对训练集损失权重的更新乏力, 无法在类不平衡的数据集自适应学习权重了。这也体现在模型准确率的变化中, 准确率 89% 左右停滞。

图 8(b)展示了元梯度增强策略带来的改善。损失的波动减小了, 并且在 2 500 个循环附近时, 验证集损失会随着训练集损失的突变快速响应, 意味着权重更新动力十分充足, 同时网络损失波动较大, 意味着权重更新响应迅速。不同的权重并不适用于不同批次样本, 但网络损失整体呈现下降趋势, 可以快速改善原始不平衡样本分布。同时, 模型识别的准确率也提升到 95% 以上。该试验验证了由于元梯度增强保留了更多珍贵的故障信息, 这对不平衡小样本故障识别任务来说十分重要。试验 3 也充分证明了元梯度增强策略相对于原始梯度裁剪策略在稳定性和准确率上的性能优势。

为验证本文中方法相对故障诊断方法的优越性, 试验 4 选取支持向量机 SVM、KNN、基于生成对抗网络的 GAN-CNN、堆叠自编码器 SSAE、归一化卷积神经网络 DNCNN、原型网络 ProtoNet 等不平衡小样本故障诊断领域流行的方法进行性能对比。在  $P=[0.5, 0.8, 0.95]$  时记录诊断准确率。

每组做 5 次试验并取平均值作为最终诊断精

度。试验结果如表 2 和 3 所示。在机翼大梁螺栓故障诊断中 SVM、KNN 等传统机器学习方法由于特征提取能力有限以及受不平衡样本集数据分布分离度低影响,诊断准确率相对最差。SSAE 与 DNCNN 原理相似,通过稀疏化的方式降低网络复杂度从而减少过拟合的风险,但面对不平衡数据集其改善效果有效。当  $P=0.95$  时,准确率维持在 70%以下。GAN-CNN 通过数据增强的方式生成小类故障样本,ProtoNet 通过计算样本特征分布中心即原型来判别故障,特别适用于处理不平衡小样本分类。在本试验中性能表现较好,机械轴承故障与机翼螺栓故障各类方法的性能表现相似,本文中的 LRS 方法在  $P=0.95$  时,在 2 个数据集上的诊断精度均超过 95%,同时在  $P=0.5$ 、0.8 时的诊断准确率也均优于其他方法。该结果表明:无论是平衡还是不平衡故障诊断,该方法的准确率都优于其他方法,充分验证了其针对不平衡样本故障诊断稳定性强、准确率高的性能优势。

表 2 准确率对比实验 (LS) %			
方法	准确率		
	$p=0.5$	$p=0.8$	$p=0.95$
SVM	93.24	76.35	57.93
KNN	92.74	74.72	53.47
SSAE <sup>[18]</sup>	95.32	73.84	65.34
DNCNN	96.34	83.13	67.48
GAN-CNN <sup>[19]</sup>	96.78	90.26	87.35
ProtoNet <sup>[20]</sup>	95.26	89.57	83.27
LRS	98.08	96.25	95.02

表 3 准确率对比实验 (DE1, DE2, FE) %			
方法	准确率		
	$p=0.5$	$p=0.8$	$p=0.95$
SVM	92.24	70.35	53.93
KNN	91.84	73.48	56.34
SSAE	94.93	75.67	65.50
DNCNN	96.87	78.98	69.85
GAN-CNN	97.25	91.80	89.34
ProtoNet	96.26	93.37	91.29
LRS	99.65	97.31	95.52

从更多维度评价诊断性能,分别对 4 个数据集在  $P=0.95$  条件下的分类结果计算 F1-score, F1-score 是分类问题常用的评测指标,兼顾了分类模型的准确率和召回率评价因素。其分值越高,模型的分类性能越好。重复 5 次试验并取均值得到 F1-score 值对照结果如图 9 所示。其中 LRS 方法的 F1-score 均值在 4 个数据集上取得最高值,平均 F1-score 分数为 0.983 7。验证了本文中方法的多分类性能在准确率和召回率上都达到最优,证明了本文中提出的 LRS 针对小且不平衡样本复杂故障诊断任务中的有效性。




图 9 算法性能对比 (F1-score)

3 结论

针对民机故障诊断领域中的故障样本小且不平衡的问题,提出了一种基于增强元学习与注意力机制的故障诊断算法 LRS。通过学习重权重策略对样本损失权重自适应更新,并改进梯度裁剪策略,提升了样本利用率。引入 SE 通道注意力机制增强了卷积神经网络对复杂工况故障的特征提取能力。经试验验证, LRS 方法可在样本小且不平衡前提下体现优异的诊断性能,并优于其他主流诊断方法。

本文中的方法仍有一定的局限性,该方法目前仅适用于部件级别的故障诊断,对于民机复杂系统级别故障的识别和诊断任务,仍需进一步研究。

参考文献:

[1] 曾声奎, MICHAEL G P, 吴际. 故障预测与健康管理 (PHM) 技术的现状与发展[J]. 航空学报, 2005(5): 626-632.

[2] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-9, 16.

[3] 吴明强, 史慧, 朱晓华, 等. 故障诊断专家系统研究的现状与展望[J]. 计算机测量与控制, 2005(12): 1301-1304.

[4] XI P P, ZHAO Y P, WANG P X, et al. QLeast squares support vector machine for class imbalance learning and their applications to fault detection of aircraft engine[J]. Aerosp Sci Technol, 2019, 84: 56-74.

[5] 徐启华, 师军. 基于支持向量机的航空发动机故障诊断[J]. 航空动力学报, 2005(2): 298-302.

[6] ZHANG T C, CHEN J L, LI F D, et al. Intelligent fault diagnosis of imbalanced data: A state-of-the-art review and possible extensions[J]. ISA Transactions, 2022, 119: 19-578.

[7] CABRERA D, SANCHO F, LONG J, et al. Generative adversarial networks selection approach for extremely imbalanced fault diagnosis of reciprocating machinery[J]. IEEE 2019, 7: 70643-70653.