

引用格式:郭煜,戴军,张均东,等.基于部分域适应的船用发动机故障诊断研究[J].大连海事大学学报,2026,52(1):52-64.

## 基于部分域适应的船用发动机故障诊断研究

郭煜<sup>1</sup>,戴军<sup>\*1</sup>,张均东<sup>2</sup>,孙斌<sup>2</sup>

(1.上海第二工业大学 智能制造与控制工程学院,上海 201209;2.大连海事大学 轮机工程学院,辽宁 大连 116026)

**摘要:**针对船用发动机变工况下故障数据匮乏及部分集迁移诊断(目标工况故障类别少于源工况)中无关故障类别引发负迁移、导致现有深度学习性能下降的问题,本文提出多尺度多视角域对抗网络(MMDAN)。该网络通过多尺度特征提取器捕获鲁棒故障特征,借助多视角分类器提升决策可靠性,并利用辅助域鉴别器量化筛选可迁移源域样本以抑制负迁移。实验表明,该方法在某型船用发动机故障数据集的多个变工况部分集任务中平均诊断准确率达96.58%,显著优于主流迁移学习模型,验证了其在复杂工况下的有效性与优越性。

**关键词:**船用发动机;故障诊断;迁移学习;部分域适应;对抗训练

中图分类号:U664.1;U672 文献标志码:A

文章编号:1006-7736(2026)01-0052-13

doi:10.16411/j.cnki.issn1006-7736.2026.01.006

### Research on fault diagnosis of marine engines based on partial domain adaptation

GUO Yu<sup>1</sup>, DAI Jun<sup>\*1</sup>, ZHANG Jundong<sup>2</sup>, SUN Bin<sup>2</sup>

(1. School of Intelligent Manufacturing and Control Engineering, Shanghai Polytechnic University, Shanghai 201209, China;

2. Marine Engineering College,

Dalian Maritime University, Dalian 116026, China)

**Abstract:** To address the problems of insufficient fault data of marine engines under variable operating conditions, and the negative transfer caused by irrelevant fault categories in partial-set transfer diagnosis (where the number of fault categories

in the target operating condition is less than that in the source operating condition), which leads to the performance degradation of existing deep learning methods, this paper proposed a multi-scale multi-view domain adversarial network (MMDAN). The network captured robust fault features through a multi-scale feature extractor, improved the reliability of decision-making with the help of a multi-view classifier, and used an auxiliary domain discriminator to quantify and screen transferable source domain samples to suppress negative transfer. Experiments show that the proposed method achieves an average diagnostic accuracy of 96.58% in multiple variable operating condition partial-set tasks on the fault dataset of a certain type of marine engine, which is significantly superior to mainstream transfer learning models, verifying its effectiveness and superiority under complex operating conditions.

**Key words:** marine engine; fault diagnosis; transfer learning; partial domain adaptation; adversarial training

## 0 引言

船用发动机是一个复杂的能量转换装置,各大系统与零部件的运行状况相互影响。其中,冷却不良、润滑异常、零件异常磨损等问题容易影响发动机的可用性和可靠性,甚至引发重大故障,严重威胁船舶航行安全,因此,船用发动机已成为状态监测与故障诊断技术的重要应用对象。传统的发动机故障诊断方法多依赖专家经验,需要维护

收稿日期:2025-09-05;修回日期:2025-10-03

基金项目:国家自然科学基金国家重大科研仪器项目(62127806);国家自然科学基金联合基金重点资助项目(U1905212);工信部高技术船舶科研项目(CBG3N21-3-3)

作者简介:郭煜(1995—),男,博士,讲师,E-mail:gy79210@foxmail.com;戴军\*(1983—),男,博士,教授,E-mail:daijun@sspu.edu.cn

人员依照维修经验或已有故障参数记录被动发现故障。然而,在无人机舱及智能化的航运背景下,这类方法在及时性与准确性方面存在明显不足。随着大数据与智能算法的发展,数据驱动的状态监测与故障诊断方法逐渐应用于船用发动机领域。在机械设备自动化诊断与状态监测中,机器学习等智能技术已取得显著成果,为船用发动机的智能监测与诊断奠定了技术基础<sup>[1-2]</sup>。

相比传统监测报警与人工巡检等方法,数据驱动的智能诊断方法在海事领域展现出广阔的应用前景。Han 等<sup>[3]</sup>利用长短期记忆网络(LSTM)构建了数据驱动的状态监测与故障诊断模型,并将其成功应用于船用发动机,取得了较好的预测效果。Zhou 等<sup>[4]</sup>提出一种基于 LSTM 的模型,用于发动机热负荷预测与故障诊断。Wang 等<sup>[5]</sup>构建了一种融合流形学习与隔离森林的混合状态监测与故障诊断方案。Li 等<sup>[6]</sup>提出本征多尺度色散熵框架,用于识别大型多缸船用发动机的工作状态。Fu 等<sup>[7]</sup>结合主成分分析、稀疏自动编码器与物理模型进行状态监测与故障诊断。Cai 等<sup>[8]</sup>开发了基于数据挖掘的状态监测与故障检测仿真系统,利用关联规则挖掘算法实现高效特征分析。Kowalski 等<sup>[9]</sup>引入一套全自动系统,用于识别发动机废气成分中的诊断信号,所提出的分解集成学习方法具有高精度与低分类耗时的优势。Xu 等<sup>[10]</sup>综合双层次信念规则、人工神经网络与证据推理,构建了可靠的磨损状态监测与故障诊断模型。Coraddu 等<sup>[11]</sup>提出一种弱监督的数据驱动监测方法,在误差控制与保证诊断精度方面表现优异。Kim 等<sup>[12]</sup>将可解释人工智能与异常检测算法结合,构建了发动机状态监测与故障诊断框架。Tan 等<sup>[13]</sup>提出基于单类支持向量机的状态监测与故障诊断方法,利用少量标记样本实现衰退预测。Gao 等<sup>[14]</sup>利用改进的白鲸优化算法优化 LSTM,有效解决了活塞环故障诊断中的特征提取问题。尽管上述数据驱动方法取得了一定成效,但其仍高度依赖高质量相关数据的支持,在数据稀缺或存在噪声的情况下,这类方法性能往往受限<sup>[15]</sup>。此外,船用发动机运行工况复杂,在变载荷等非平稳运行条件下,域分布不一致问题在实际诊断任务中普遍存在,严重影响了传统数据驱动方法的诊断性能<sup>[16]</sup>。

针对域分布不一致问题,域适应技术被广泛用于实现域间知识迁移,从而有效提升目标域诊断性能。早期域适应方法通常寻求线性变换,将源域与目标域数据映射至域不变特征空间,以对齐特征分布。近年来,得益于深度神经网络在非线形特征学习方面的优势,基于深度结构的域适应方法不断涌现。然而,现有方法大多假设源域与目标域故障类别空间一致,仅适用于闭集诊断场景。在实际应用中,源域样本标签易于通过实验模拟获取,而目标域任务往往难以保持与源域完全相同的标签空间。当目标域标签空间仅为源域的子集时,便构成部分集诊断问题,其核心挑战在于如何将源域中共享类别的诊断知识有效迁移至目标域。现有域适应诊断方法通常通过分布匹配策略(如概率分布对齐或对抗训练)缩小域间差异。但由于源域中存在目标域未包含的无关类别,这类方法在特征适配过程中易受无关类别样本干扰,进而产生特征误匹配与负迁移现象。

基于以上分析,本文研究在变工况条件下,目标域类别数量少于源域的部分集诊断问题,重点解决因源域无关类别干扰引起的负迁移现象,以提升域适应诊断的准确性与鲁棒性。

## 1 故障诊断模型

本文主要研究故障诊断中变工况部分集域适应问题。设  $D_s = \{(x_i^s, y_i^s)\}_{i=1}^{n_s}$ 、 $D_t = \{(x_i^t)\}_{i=1}^{n_t}$  分别为具有  $n_s$  个有标签的源域样本和  $n_t$  个无标签的目标域样本。假设源标签空间包含目标标签空间,即  $C_t \subseteq C_s$ ,由于操作条件的变化,源数据与目标数据采集的概率分布不同,即  $P(X^s) \neq P(X^t)$ 。如图 1 所示。

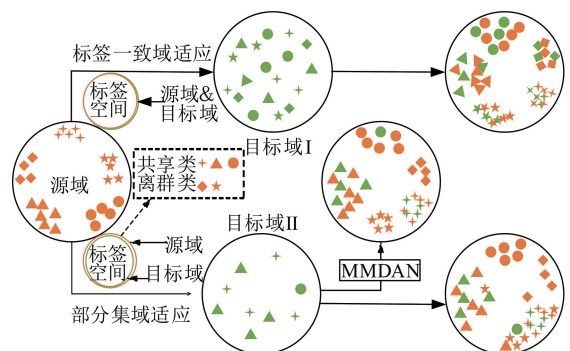


图 1 域适应中不同故障诊断场景示意  
Fig.1 Different fault diagnosis scenarios  
in domain adaptation

1.1 特征提取器

特征提取器 G 采用两个具有不同权重的深度可分离卷积(DSC)<sup>[17]</sup>层提取多视图特征,构成多尺度特征提取模块。采用参数量更少的 DSC 替代普通卷积进行特征提取,可有效降低模型复杂度、缩短训练时间。多尺度特征提取策略通过融合不同参数的 DSC 模块输出,能够提取到更丰富、互补的多尺度故障特征,从而包含更全面的诊断信息。

如图 2 所示。假设输入数据具有  $K$  个通道,卷积核的宽度和高度分别为  $D_m$  和  $D_n$ ,该部分的参数为  $D_m \times D_n \times K$ 。经过逐点卷积后,卷积核的大小为  $1 \times 1 \times K$ 。若输出为  $N$  个特征图,则逐点卷积的参数为  $K \times 1 \times 1 \times N$ 。DSC 的参数  $P_{DSC}$  为  $D_m \times D_n \times K + K \times 1 \times 1 \times N$ 。普通卷积的参数为  $D_m \times D_n \times K \times N$ 。两者的优化方程为(由于乘法计算量远大于加法,故加法计算量可忽略不计):

$$\frac{P_{DSC}}{P_{CNN}} = \frac{D_m \times D_n \times K + K \times 1 \times 1 \times N}{D_m \times D_n \times K \times N} = \frac{1}{K} + \frac{1}{D_m \times D_n} \quad (1)$$

式(1)中, DSC 的计算效率优于普通卷积神经网络(CNN)。DSC 在保证预测精度的前提下,大幅降低了参数量与计算量。因此,作为普通 CNN 的改进变体,DSC 的核心优势在于更高的计算效率与更少的网络参数。

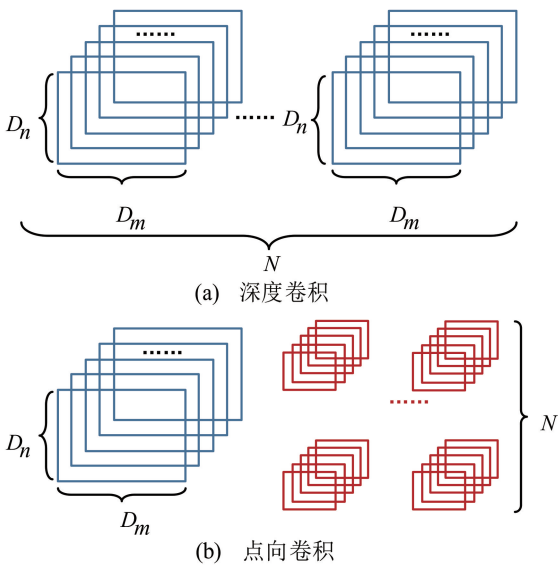


图 2 DSC 的结构图

Fig.2 The structure diagram of DSC

为有效抑制过拟合现象,采用最大池化层和平均池化层来降低特征维度,注意力层有助于消除冗余信息,而残差连接的设计则是为了避免训练过程中的梯度退化和信息丢失,方便不同层次的特征提取。特征提取过程可表示为:

$$f = \sigma \left[ \left( w_f \right)^T x + b_f \right] \quad (2)$$

式中:  $w_f$  为权重矩阵;  $b_f$  为偏置向量;  $x$  为最后一个池化层的输入向量。

在变工况部分集问题中,源类别与目标类别是不对称的。因此,源标签空间可以自然地划分为共享空间(与目标标签空间相同)与离群空间(与目标标签空间不同)。本文提出一种多尺度多视角对抗网络(MMDAN)的变工况部分集故障诊断算法,其网络结构如图 3 所示。具体来说, MMDAN 由多尺度特征提取器 G、多视图分类器 C、辅助域鉴别器  $D_1$  和域鉴别器  $D_2$  组成,各模块参数如图 4 所示。

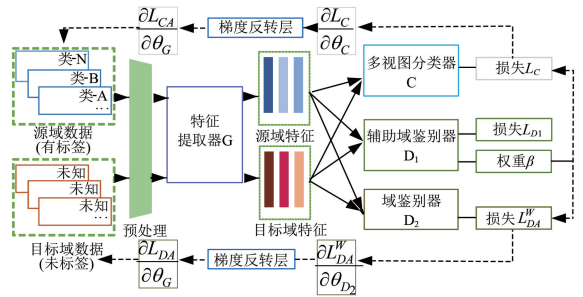


图 3 MMDAN 结构图

Fig.3 MMDAN structure diagram

1.2 辅助域鉴别器

在变工况部分集场景中,源域与目标域的标签空间存在不一致,即  $C_s \subseteq C_t$ ,导致直接施加对抗性训练时,源域中的离群类因在目标域中无对应类别而引入负迁移,进而降低模型测试性能。因此,在域适应中应忽略目标域中的离群类。然而,由于目标域数据无监督,其潜在故障类型未知,这给离群类的识别带来了挑战。一种合理的解决方案是在两个域之间对齐已知类别的样本,同时,在域适应过程中忽略目标域的离群值。

为此,本文提出一种相似性学习策略,用于衡量各源类对目标样本的贡献度,并通过域鉴别器  $D_1$  估计目标样本与源样本之间的相似性,进而为每个目标样本分配相似性权重。域鉴别器  $D_2$  与

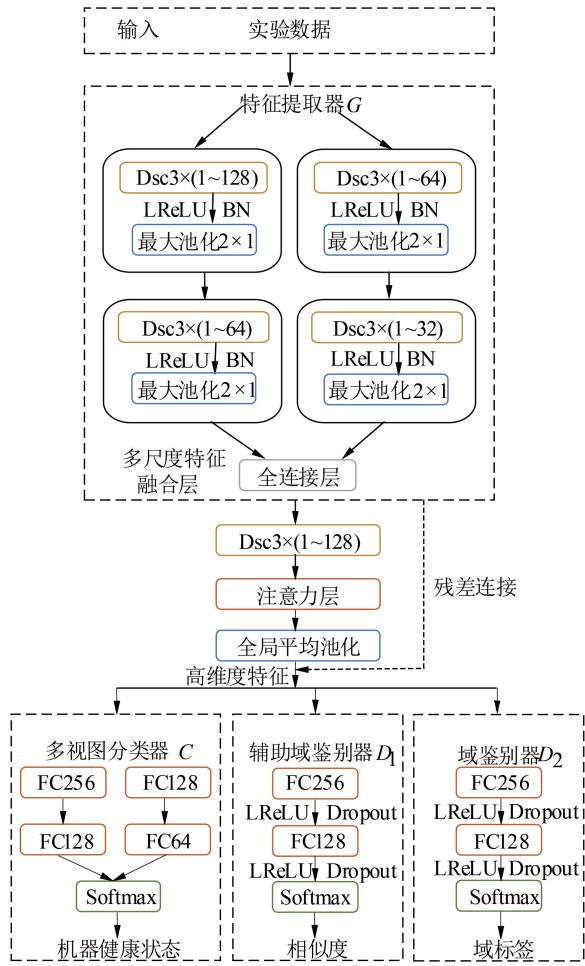


图 4 MMDAN 方法参数设置

Fig.4 MMDAN method parameter setting

特征生成器  $G$  进行最大最小博弈,探索可迁移的特征。由于源离群标签空间与目标离群标签空间互不相交,目标数据在分布上应显著区别于离群类样本。因此,目标样本被误分类为离群类的概率极低,而域标签分类误差可作为衡量该差异的量化指标。据此,本文将目标样本与源域的相似性定义为:

$$w = L_{CE}(D_1(G(x^t)), d^t) \quad (3)$$

式中:  $d^t$  为目标域的真实标签。此外,使用最小-最大归一化方法来表示不同目标样本的相对相似性,其数学表达式为:

$$w_j = \frac{w_j - \max(w)}{\max(w) - \min(w) + \varepsilon} \quad (4)$$

式中:  $w_j$  为第  $j$  个目标样本的相似度权重;  $\varepsilon$  为一个小的正值。这样一来,分配给共享类的相似度权重将大于离群类。由于离群类样本对模型的贡

献较小,域适应过程可选择性地在跨域的共享类之间进行,从而避免负迁移,促进正迁移。需要注意的是,辅助域鉴别器  $D_1$  不参与特征提取器的对抗性训练,因此,其损失函数  $L_{D_1}$  仅用于更新自身参数  $\theta_{D_1}$ 。

$$L_{D_1}(\theta_G, \theta_{D_1}) = \frac{1}{n_s} \sum_{i=1}^{n_s} L_{CE}(D_1(G(x_i^s), d_i^s)) + \frac{1}{n_t} \sum_{j=1}^{n_t} L_{CE}(D_1(G(x_j^t), d_j^t)) \quad (5)$$

式中:  $d_i^s, d_j^t$  分别为第  $i$  个源样本和第  $j$  个目标样本的域标签。在对抗性学习中,目标样本经最小-最大归一化后,其相似性权重被附加到目标样本上,以使域分布差异最小。因此,加权对抗学习的目标被定义为:

$$L_{D_{adv}}^W(\theta_G, \theta_{D_1}, \theta_{D_2}) = \frac{1}{n_s} \sum_{i=1}^{n_s} L_{CE}(D_2(G(x_i^s), d_i^s)) + \frac{1}{n_t} \sum_{j=1}^{n_t} w_j L_{CE}(D_2(G(x_j^t), d_j^t)) \quad (6)$$

域鉴别器  $D_1$  用于识别不同故障类别的重要性,并在共享特征空间中提取对质量域变化不敏感的不变表示。这意味着,对于来自异常源类的样本,可通过在对应损失函数中分配较小的权重,降低其对模型训练的干扰;而对于来自跨域共享类的样本,则应在目标域损失中赋予较高权重,以减小域间偏差,进而更好地匹配共享标记样本的源域和目标域。

### 1.3 多视图分类器

本文提出一种新的多视图预测对抗网络。该网络的分类器由两个具有不同视图的模块构成,其中,源域样本具有完整标注,而目标域样本未被标记。由于缺乏目标域的标签信息,因此,无法通过梯度下降来提高未标记样本的准确性。

为提高目标域的准确性,针对一个样本设计了两个具有不同视角的分类器。这两个分类器的权重受到约束,以确保其具有不同的视角。其中,  $y^1$  和  $y^2$  分别表示两个分类器预测概率最大的类别。若两个不同的分类器均满足  $y^1 = y^2$  的预测,则没有标签的样本就可以被准确预测。

源域中的样本含有大量标签,因此,网络可采用传统的监督学习方式进行训练。交叉熵损失通常被用作监督训练的指标,其表达式为:

$$L_Y = \frac{1}{n_s} \sum_{i=1}^{n_s} \left[ L_{CE}(G_y^1(G_f(x_i; \theta_f); \theta_{y1}), y_i) + L_{CE}(G_y^2(G_f(x_i; \theta_f); \theta_{y2}), y_i) \right] \quad (7)$$

式中:  $L_Y$  为交叉熵损失;  $n_s$  为源域数据量;  $G_y^1$  和  $G_y^2$  表示两个不同的分类器。在源域监督信号、多视图预测一致性及辅助域对抗性训练的共同引导下, 共享特征提取器和两个异构分类器将协同更新, 直至模型在目标任务上实现正确分类。为提升共享特征提取器与两个异构分类器在目标域的泛化能力, 通常采用均方误差损失作为衡量预测一致性的指标。其表达式为:

$$L_{con} = \frac{1}{n_s + n_t} \sum_{i=1}^{n_s+n_t} \left\| G_y^1(G_f(x_i; \theta_f); \theta_{y1}) - G_y^2(G_f(x_i; \theta_f); \theta_{y2}) \right\|_2^2 \quad (8)$$

式中:  $n$  为源域数据量;  $G_y^1(G_f(x_f; \theta_f); \theta_y)$  和  $G_y^2(G_f(x_f; \theta_f); \theta_y)$  为两个异构分类器的预测结果。

为确保对目标样本的准确分类, 设计分类器  $C_1$  和  $C_2$  从不同视角对共享特征空间中的样本进行判别。为此, 在模型优化过程中, 对  $C_1$  和  $C_2$  的权重施加不同的约束, 允许两个分类器从不同角度预测共享特征空间中的同一样本。在代价函数中, 包含了  $|\mathbf{W}_1^T \mathbf{W}_2|$ , 其中,  $\mathbf{W}_1$  和  $\mathbf{W}_2$  分别表示  $C_1$  和  $C_2$  中全连通层的权值。在数学上, 这种多视图约束的损失可以表示如下:

$$L_W = |\mathbf{W}_1^T \mathbf{W}_2| \quad (9)$$

#### 1.4 整体优化目标

综上所述, 拟议方法的总体目标如下:

$$E(\theta_f, \theta_D, \theta_y) = \alpha L_{D_{adv}}^W + \beta L_Y + \gamma L_{con} + \delta L_W \quad (10)$$

训练网络参数, 以实现:

$$\left( \hat{\theta}_f, \hat{\theta}_{y1}, \hat{\theta}_{y2} \right) = \arg \min_{\theta_f, \theta_{y1}, \theta_{y2}} E(\theta_f, \theta_{y1}, \theta_{y2}, \hat{\theta}_{d2}) \quad (11)$$

$$\hat{\theta}_{d2} = \arg \max_{\theta_{d2}} E(\hat{\theta}_f, \hat{\theta}_{y1}, \hat{\theta}_{y2}, \theta_{d2}) \quad (12)$$

$$\hat{\theta}_{d1} = \arg \max_{\theta_{d1}} E_{d1} \quad (13)$$

式中:  $\alpha$ 、 $\beta$ 、 $\gamma$  和  $\delta$  分别为  $L_{D_{adv}}^W$ 、 $L_Y$ 、 $L_{con}$  和  $L_W$  损失的惩罚系数。优化过程采用梯度下降法, 并在反向传播过程中加入梯度反转层。

拟议的 MMDAN 完整诊断程序可总结为以下几点。

第一步, 在使用源域和目标域的样本作为网络输入之前, 需先对数据进行归一化预处理, 以确保其数值保持在合理范围内; 同时, 将源域和目标域的样本分别划分为训练集和测试集。

第二步: 通过式 (2) 提取特征, 构建  $G_f$ 、 $G_d$  和  $G_y$ 。特别地, 将辅助鉴别器  $D_1$  嵌入域适应网络中, 以获得源域样本的权重函数, 突出不同样本的重要性。 $D_1$  的损失由式 (5) 计算,  $D_2$  的损失由式 (6) 计算。所有类别的共享特征提取器输出被发送到两个具有不同判别视角的分类器, 用于类别预测。

第三步: 结合式 (6)~式 (9), 构建统一的优化目标函数, 如式 (10) 所示, 并通过引入式 (9), 实现两个分类器多视角信息的协同优化。

第四步: 模型训练完成后, 将目标域测试集的样本输入共享特征提取器, 取两个分类器输出的平均值作为最终预测结果。

## 2 实验设计与结果分析

### 2.1 实施细节和比较方法

在变工况部分集场景下, 本文采用多种基准方法进行性能对比。所有方法的参数均依据相关文献及实验设定确定, 以确保良好的性能表现。为保证比较的公平性, 本文提出的 MMDAN 方法与对比方法在学习率、训练批次大小和迭代次数等关键训练配置上保持一致。模型训练基于 PyTorch 框架实现, 计算过程由 NVIDIA-2080 Ti GPU 加速。最终诊断结果基于 10 次独立实验的平均值计算, 以降低随机性影响。

本文的比较方法如下。

(1) 基线法。基线法是最基本的网络, 由一个共享特征提取器和一个分类器组成。采用基线法训练网络时, 只使用源域样本, 训练好的模型直接在目标域进行测试, 不需要迁移。

(2) CIDA<sup>[18]</sup>。CIDA 为一种部分集域适应方法, 基于两个分类器的输出计算类级权重。CIDA 将学到的权重应用于两个分类器, 以避免负迁移, 并利用分类器的不一致性来减少域分布差异。

(3) IWAN<sup>[19]</sup>。IWAN 为一种应用于计算机视觉的部分集域适应学习方法, 通过引入一个辅助的域鉴别器来衡量源样本的重要性。

(4) WATN<sup>[20]</sup>。WANT 为一种用于部分集域

适应故障诊断的加权对抗迁移网络,通过引入对抗性训练来学习类别特征与域不变特征,并采用加权学习策略衡量其对源分类器和域鉴别器的贡献。

(5) MWDAN<sup>[21]</sup>。MWDAN 为一种结合自适应加权机制与域对抗网络的模型,通过协同设计类级和实例级的加权机制来区分标签空间,并量化数据样本的可迁移性。

## 2.2 数据集描述

船用发动机故障诊断依赖于其在不同故障状态下的运行数据,开展数据分析与故障识别。故障数据来源主要包括实船发动机运行数据、发动机台架故障实验数据和发动机故障仿真数据。然而,实船运行中积累的故障数据往往不够全面,且通常在故障现象已较为明显时才被察觉。早期故障样本的识别多基于主观经验判断,缺乏客观量化依据。在实船上进行故障模拟以获取样本,不仅可能造成重大经济损失,还可能危及航行安全。尽管实验室台架试验所获得的数据更贴近实船数据,但多数发动机故障状态难以在实验中复现,部分关键参数也无法通过传感器直接监测,且试验成本高昂。

随着计算机技术和发动机工作过程模拟计算方法的进步,通过调整数学模型参数来模拟故障已成为构建故障数据库的重要手段。本实验室自主研发的轮机模拟器借鉴了挪威 Kongsberg Maritime 公司轮机模拟器的故障模拟功能,基于数学模型实现故障仿真。实验表明,该模型准确且稳定,可为故障诊断提供可靠的参数支持<sup>[22]</sup>。模拟器的模拟对象为主机机型 6S50MC,配备 TCA66 型涡轮增压器,其发动机与涡轮增压器的具体参数分别见表 1 和表 2。

测试数据集包括主机系统的正常数据、六类性能故障数据(涡轮增压器滤网脏污堵塞、进气口脏污堵塞、排气口脏污堵塞、空气冷却器脏污、涡轮增压器喷嘴结炭和缸套冷却水腔气堵)及四类异常边界条件数据(缸套冷却不充分、活塞冷却不充分、空气冷却器冷却水入口温度过高和空气冷却器冷却水入口温度过低),数据集类型及其标签信息详见表 3。

针对表 3 中所列的 10 种故障,分别从故障原因、作用机制、表现现象和可能后果四个维度进行

表 1 6S50MC 发动机的具体参数

参数	数值
缸数	6
冲程数	2
额定转速/(r·min <sup>-1</sup> )	127
持续功率/kW	9480
平均有效压力/MPa	1.9
缸径/mm	500
冲程/mm	2000
冲程/缸径	4
燃油消耗率/[g/(kW·h)]	178.35

表 2 TCA66 涡轮增压器的具体参数

参数	类型/值
排气涡轮机类型	轴流
压缩机类型	离心式
压缩机压缩比	3.75
压缩机流量/(kg·s <sup>-1</sup> )	24
额定转速/(r·min <sup>-1</sup> )	14 250
最高允许温度/°C	500
最大允许转速/(r·min <sup>-1</sup> )	16 000
涡轮机膨胀比	3.24
质量/kg	5500

表 3 实验数据集类型及其标签信息

Tab.3 Experimental dataset type and its label information

数据类型	发动机状况	标签
健康状况	没有任何故障	0
性能故障	涡轮增压器滤网脏污堵塞	1
	进气口脏污堵塞	2
	排气口脏污堵塞	3
	空气冷却器脏污	4
	涡轮增压器喷嘴结炭	5
	缸套冷却水腔气堵	6
异常边界条件	缸套冷却不充分	7
	活塞冷却不充分	8
	空气冷却器冷却水入口温度过高	9
	空气冷却器冷却水入口温度过低	10

系统性分析。

故障 1(滤网堵塞)与故障 2(进气口堵塞)均源于流道阻塞(滤网脏污/扫气口积碳),导致进气流量降低(约 15%)与流阻增大,表现为排烟温度升高、增压器性能衰减及扫气压力异常。故障 3(排气口堵塞)因排气道附着燃烧产物而导致流

通面积缩减(约 10%),引发排烟温度异常与燃烧室背压升高。故障 4(空冷器脏污)因结垢或积碳致使换热效率下降(约 20%)与压差增大,导致进排气温度同步上升。故障 5(喷嘴结炭)因燃油沉积导致涡轮通流面积减少(约 8%),引起排烟背压、温度及增压器转速同步异常升高。故障 6(缸套水腔气堵)与故障 7(缸套冷却不充分)均涉及缸套换热恶化(前者因气体聚集,后者因冷却水压/温异常),核心表象为缸套水系统参数(压力、出口温度)波动并伴随排温上升。故障 8(活塞冷却不充分)因滑油系统异常(流量减少约 15%)导致活塞散热不足,表现为滑油参数异常与相关温度轻微上升。故障 9/故障 10(空冷器水温异常)则分别因低温水系统效能不足/温控阀失

效,导致扫气温度过高(排温持续上升)/过低(排温异常降低,存在腐蚀风险)。

结合文献[11]的分析,明确界定了在上述故障诊断框架中涉及的 13 项关键性能参数。尽管有效燃油消耗率、单缸循环供油量和压气机流量也能反映上述故障的特征,但由于实船数据采集难度较大,最终未予采用。因此,与故障诊断相关的故障征兆参数共有 10 种,分别为缸内最大燃烧压力  $p_{zmax}$ 、扫气压力  $p_s$ 、扫气温度  $t_s$ 、增压器转速  $N_{tc}$ 、排烟总管温度  $t_{br}$ 、排烟总管压力  $p_{br}$ 、空冷器气侧进口温度/压气机出口温度  $t_k$ 、压气机出口压力  $p_k$ 、空冷器气侧进出口温差  $\Delta t_k$  及空冷器气侧进出口压差  $\Delta p_k$ 。以各类故障下各性能参数的平均值作为该故障的典型参数值,具体数值见表 4。

表 4 各故障模式对应的典型参数

Tab.4 Typical parameters of different fault patterns

参数	故障 1	故障 2	故障 3	故障 4	故障 5	故障 6	故障 7	故障 8	故障 9	故障 10
$p_{zmax}$ /MPa	12.97	12.54	15.36	14.40	15.78	14.24	15.46	14.58	14.19	13.85
$p_s$ /kPa	197.7	239.5	251.5	227.1	263.9	231.6	245.3	229.1	223.5	198.7
$t_s$ /°C	34.81	37.16	38.68	65.82	41.82	37.62	40.33	38.64	65.4	11.52
$N_{tc}$ /(r·min <sup>-1</sup> )	12 419	12 503	12 856	12 697	14 016	12 849	13 866	12 782	12 880	12 195
$t_{br}$ /°C	398.46	460.64	457.64	397.75	410.34	416.78	400.34	382.58	400.09	336.18
$p_{br}$ /kPa	187.39	198.51	213.56	203.57	235.27	205.02	229.41	205.96	215.04	176.91
$t_k$ /°C	175.27	186.93	188.29	180.97	205.34	183.93	202.17	185.10	179.18	174.95
$p_k$ /kPa	199.3	240.5	252.6	228.0	265.7	233.6	257.2	230.9	225.1	200.8
$\Delta t_k$ /°C	140.46	149.77	149.61	120.35	163.52	146.31	161.84	146.46	113.78	163.43
$\Delta p_k$ /kPa	21.07	13.73	14.82	16.86	24.34	26.92	25.97	24.47	21.89	27.60

通过各参数在不同故障下的响应变化,量化各故障对系统参数的影响程度。设故障参数值为  $p_F$ , 正常参数值为  $p_N$ , 则该参数的变化率为:

$$p' = \frac{p_F - p_N}{p_N} \quad (14)$$

图 5 为 10 种故障下各参数的变化率。由图 5 可知,10 种故障或与进排气系统有关,或与冷却系统有关,扫气温度对所有 10 种故障的敏感性均最为显著。图 5 的结果体现了不同类型故障的特征差异,表明表 4 中的典型参数值能够有效表征各类故障。在此基础上,聚类分析中定义的相似度量标准可将不同故障下的样本有效区分,适用于故障诊断中对待识别样本进行模式判断。

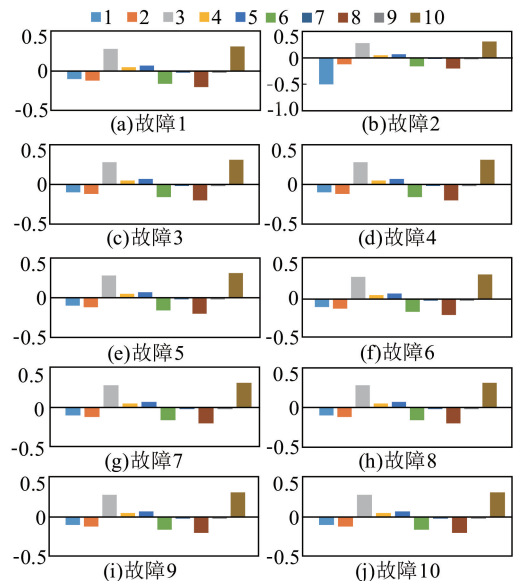


图 5 10 种故障模式下各参数变化率

Fig.5 Change rates of various parameters under 10 types of faults patterns

图 6 为三种状态的时域波形图。由图 6 可知,与正常状态相比,涡轮增压器滤网脏污堵塞会引发低频调制现象,其信号包络呈现周期性变化;而缸套冷却不充分则导致信号出现明显基线漂移,均值随时间增加而持续上升。两类故障特征

差异显著,为后续深度模型识别不同故障模式提供了可靠的判别依据。




图 6 三种状态时域波形图

Fig.6 Time-domain waveform diagrams of three states

### 3 实验结果分析

本文设计 10 个(M1~M10)变工况部分集学习任务,用于验证所提出方法的有效性。为模拟真实的船用发动机场景,源域由主机系统在 90% 负载工况下采集的全部健康状况数据构成,目标域则由 75% 和 50% 负载工况下采集的部分健康状况数据构成,其中,目标域的健康状况类别为随机选取,相关实验任务见表 5。在训练过程中,使用源域中所有健康状况的标记样本和目标域中部分健康状况的未标记样本。其中,80% 的样本用于训练,20% 用于测试。不同方法的分类精度及故障诊断实验结果分别如表 6 和图 7 所示。

表 5 实验任务

Tab.5 Experimental tasks

迁移任务编号	源域	目标域
M1	90%:All	75%:1 3 4 5 6 7 8 9 11
M2	90%:All	75%:1 2 5 6 7 8 10
M3	90%:All	75%:1 5 7 9
M4	90%:All	75%:1 3 6
M5	90%:All	75%:1
M6	90%:All	50%:1 2 3 5 6 7 9 10 11
M7	90%:All	50%:1 4 5 6 7 8 9
M8	90%:All	50%:1 2 6 8
M9	90%:All	50%:1 2 5
M10	90%:All	50%:1

表 6 不同故障诊断方法的分类精度

Tab.6 Classification accuracy of different fault diagnosis methods

任务	基线法	CIDA	IWAN	WATN	MWDAN	MMDAN
M1	47.39±0.02	61.51±1.22	73.59±1.02	86.14±4.14	88.04±3.02	96.47±1.25
M2	56.86±0.05	66.27±1.04	66.49±0.35	80.37±4.37	86.19±2.19	95.51±1.04
M3	41.53±0.03	72.04±1.35	75.06±5.13	78.35±4.56	84.47±3.16	96.64±1.28
M4	58.91±0.04	75.63±1.16	85.94±9.73	72.98±6.10	83.93±3.73	95.32±1.47
M5	54.57±0.06	84.14±1.53	91.46±19.41	81.04±6.46	88.59±1.96	99.68±0.24
M6	48.42±0.06	60.33±1.06	92.29±0.46	83.37±5.67	85.73±3.79	96.47±1.29
M7	55.15±0.05	64.54±1.26	75.70±1.53	80.98±5.25	79.86±3.64	95.63±1.19
M8	40.34±0.04	70.37±1.04	85.39±0.59	79.62±5.49	80.14±3.41	95.41±1.20
M9	55.98±0.03	72.85±0.24	92.70±8.49	78.18±13.47	77.49±3.27	95.57±1.10
M10	55.43±0.06	82.49±3.76	72.31±25.96	84.23±4.53	83.52±2.47	99.09±0.21
平均值	51.46	71.02	81.09	80.53	83.80	96.58
时间/s	832.7	1490.6	1876.5	1562.3	1286.4	1325.7




图 7 数据集的实验结果

Fig.7 Experimental results of the datasets


由表 6 和图 7 可得出以下结论。

(1) 在各项迁移任务中,本文提出的 MMDAN 方法诊断性能更优,平均准确率达 96.58%。此外,在不同工况下,本文方法的标准差通常较小,反映出 MMDAN 具有较高的稳定性。特别是对于具有挑战性的 M4 和 M9 迁移任务,MMDAN 的准确性仍高达 95%。


(2) 尽管 CIDA、IWAN、WATN 和 MWDAN 凭借其多分类器、辅助域鉴别、加权对抗迁移及类级与实例级权重等机制,在多数迁移任务中表现优于传统基线方法,但其平均准确率仍分别较 MMDAN 低 45.12%、25.56%、15.49% 和 12.78%,表明 MMDAN 在整体性能上具有更强的竞争力。

(3) 由表 6 可知,本文提出的 MMDAN 方法在多数情况下可在 10 min 内完成计算,具备较高的运行效率。尽管其计算时间略长于其他对比方法,但差异较小。考虑到故障诊断算法通常为离线运行,该计算负担在可接受范围内。综上,实验结果验证了 MMDAN 方法在准确性和计算效率方面均表现出良好的综合性能。

计算混淆矩阵旨在更全面地评估该方法的准确性。图 8 为 MWDAN 与本文 MMDAN 方法在任务 M6 上的诊断结果对比。由图 8 可知,MMDAN 在所有故障类型中的识别准确率均优于 MWDAN,尤其在故障类型 5 和 6 上,性能提升幅度分别达到 22% 和 20%。



(a) MWDAN



(b) MMDAN

图 8 MWDAN 与 MMDAN 在任务 M6 上测试精度的混淆矩阵

Fig.8 Confusion matrices of test accuracy for MWDAN and MMDAN on task M6

为验证 MMDAN 方法的性能优势,选取 M3、M4 和 M7 进行 F-score 与 AUC 指标计算,结果见表 7。由表 7 可知,本文提出的 MMDAN 方法在 F-score 和 AUC 两项指标上均表现最优。

表 7 M3、M4 和 M7 任务数据集的统计结果


Tab.7 Statistical results of M3, M4, and M7

方法	task datasets					
	M3		M4		M7	
	F-score	AUC	F-score	AUC	F-score	AUC
基线法	0.82	0.96	0.75	0.95	0.73	0.92
CIDA	0.63	0.90	0.50	0.87	0.91	0.90
IWAN	0.69	0.92	0.86	0.92	0.67	0.92
WATN	0.82	0.95	0.80	0.93	0.85	0.93
MWDAN	0.85	0.96	0.83	0.96	0.82	0.95
MMDAN	0.96	0.99	0.95	0.98	0.96	0.99


船舶机电数据诊断结果易受机器振动、仪表设备老化和传感器故障等因素干扰,进而影响模型的鲁棒性。为此,本文在 M6 实验数据中引入噪声,并结合船用发动机工作环境特点,分两组开展实验。

第一组实验引入脉冲噪声以验证仿真仪器数据的稳定性。在该过程中,选取全部数据,按其自身百分比随机添加不规则脉冲信号,模拟仪器数据振荡。根据专家经验,实际船舶航行过程中指针摆动幅度约为 20%,如图 9(a)所示。本文将脉冲强度提升至 50%,以更充分地测试模型的抗干扰能力。

第二组实验模拟发动机控制室控制台显示的数据特征,引入量化噪声。该过程通过将连续信号四舍五入至最接近的离散值,模拟信号从连续到离散的转换过程。鉴于该类数据通常伴随较小误差,噪声强度设定为 1%~5%,结果如图 9(b)所示。



(a)



(b)

图 9 MMDAN 模型在噪声下的性能表现

Fig.9 Performance of MMDAN model under noise conditions

实验结果表明,在脉冲噪声和量化噪声干扰下,MMDAN 模型诊断准确率均保持在 80%以上,具备较高的诊断精度和良好的鲁棒性。

为进一步检验 MMDAN 方法的有效性,本文设计了消融实验,系统研究噪声数据对分类性能的影响,并探讨多尺度特征提取结构和多视图分类器对检测精度和速度的影响。基于 MMDAN 方法设计的两种消融研究方案(NoDSC 与 NoMC)在结构上对原始网络进行了模块替换,以评估各组件对域自适应故障诊断性能的贡献。具体修改如下:在 NoDSC 中,原 MMDAN 中的 DSC 结构替换为 CNN 结构,而在 NoMC 中,将原 MMDAN 中多视图分类器替换为单视图分类器。所有模型均在原始数据上进行训练,并在含 10% 脉冲噪声的测试集上进行评估,结果见表 8。


由表 8 可知,所有方法的诊断精度均有所下降,这是由于含脉冲噪声的测试数据进一步掩盖了有用信息,导致各域数据分布差异增大。与 MMDAN 相比,NoDSC 的准确率虽无明显变化,但平均诊断时间显著增加 57.7%,表明 DSC 结构可有效减少模型参数量,降低运行成本。与 MMDAN 相比,NoMC 结构的平均诊断时间略有减少,但诊断精度却显著下降 20.86%,表明两个不同视图的分类器对变工况部分集学习具有促进作用。为直观展示 MMDAN 方法的有效性,采用 t 分布随机邻域嵌入(t-SNE)技术对不同方法的特征分布进行可视化对比。在该过程中,复杂性被设定为恒定值 100。图 10 和图 11 通过二维特征分布可视化高维特征空间。图中,圆圈表示源域中的类,三角形表示目标域中的类,相同形状的不

表 8 不同方法在噪声数据上的分类精度


Tab.8 Classification accuracy of different methods on noise data

任务	基线法	CIDA	IWAN	WATN	MWDAN	NoDSC	NoMC	MMDAN
M6	65.35	73.55	69.14	72.50	76.24	89.61	72.62	92.58
M7	60.24	67.28	58.65	68.13	75.12	88.29	70.87	90.47
M9	51.27	61.49	50.34	61.49	65.36	86.80	65.40	88.43
平均值	58.95	67.44	59.37	67.37	72.24	88.23	69.63	90.49
时间/s	858.4	1452.1	1905.7	1512.4	1239.3	2034.6	1314.9	1289.8

同颜色表示不同的运行状态。



(a) 原始数据

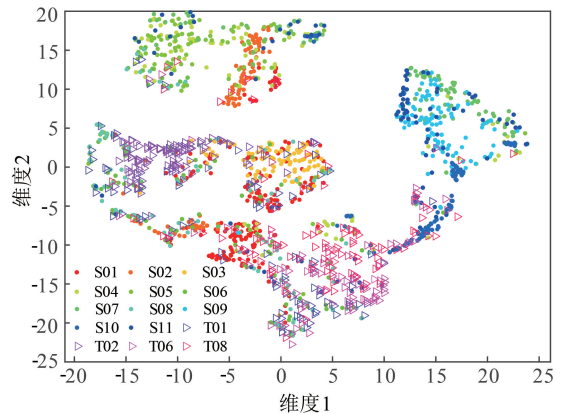


(b) MMDAN数据

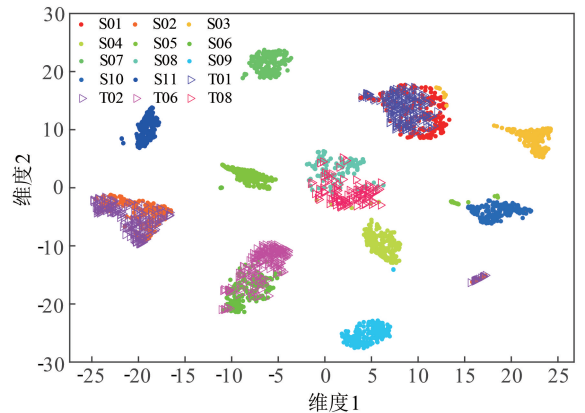
图 10 任务 M4 中的数据分布图

Fig.10 The distribution graph of the data in task M4

如图 10(a) 和图 11(a) 所示,在原始样本中,不同健康状态的特征分布存在严重重叠,导致源域与目标域的分类结果均不准确。图 10(b) 和图 11(b) 为 M4 和 M8 任务下, MMDAN 的可视化特征分布。可以看出, MMDAN 方法减少了不同类别之间的重叠,同时显著缩小了源域与目标域的



(a) 原始数据



(b) MMDAN数据

图 11 任务 M8 中的数据分布图

Fig.11 The distribution graph of the data in task M8

特征分布差异。例如,编号 S1 的源域显示了定义良好的分类边界,便于分类器进行准确的分类预测。此外,源域 S1 与目标域 T1 之间呈现一定程度的聚类现象,有助于缩小两个域之间的分布差异,表明 MMDAN 能够学习更多的类别不同但域不变的特征。可视化结果表明, MMDAN 具有较强的变工况部分集故障诊断能力。

为验证本文模型的有效性,将其与基线法、CIDA、IWAN、WANT 和 MWDAN 方法进行对比。结果表明,不同方法在故障诊断所需时间上差异

较小,但 MMDAN 的平均准确率为 96.58%,分别较上述方法提高 45.12%、25.56%、15.49% 和 12.78%。实验结果表明,MMDAN 在变工况部分集背景下可有效减小域间分布差异,并且优于现有其他方法。

MMDAN 的优异性能可归因于以下机制:首先,DSC 层可以有效降低模型的输入维数。通过处理不同尺度的特征,DSC 层可以捕获本地和全局级别的信息,从而可以更全面地理解输入数据。维数的减少有助于避免维数的堆叠,提高模型的效率。其次,通过将构建多视图分类器的方法与辅助域对抗训练相结合,可以获得许多优势。该策略能够对无关源样本进行自适应识别和过滤,这意味着只利用最相关和信息最丰富的源样本,即可提高知识转移过程的质量和效率。多视图分类器的构建与辅助域对抗训练的结合有助于最小化共享标签空间中域之间的分布差异,这对于有效的知识转移至关重要,因为减少域差异可以提升知识从多标记源域向未标记目标域的可转移性。

## 4 结 论

针对船用发动机在变工况条件下部分集跨域故障诊断的挑战,本文提出一种多尺度与多视角域对抗网络,旨在解决源域与目标域标签空间异构导致的负迁移问题。该方法通过深度可分离卷积层重构特征提取模块,在保证特征表征精度的同时显著降低模型复杂度。设计多视角分类器策略,利用异构分类器权重约束增强共享类知识的迁移鲁棒性。进一步引入辅助可迁移性鉴别器,动态量化源域样本的迁移价值并过滤离群样本干扰,从而在共享标签空间内实现跨域分布差异的渐进式对齐。在变工况部分集船用发动机数据集上的实验表明,MMDAN 在船用发动机和轴承跨域任务中平均故障诊断准确率分别达 96.58% 和 96.23%,显著优于基线法、CIDA、IWAN、WATN 和 MWDAN 等对比方法。本文为变工况条件下部分集跨域故障诊断提供了新范式,其框架可扩展至其他存在域偏移与部分集的智能装备健康管理系统。

## 参考文献(References):

[1]董建伟,曾鸿,刘鑫龙,等.基于 DBN-SVR 的船舶主

机排烟温度基线模型[J].大连海事大学学报,2022,48(2):101-109.

DONG J W, ZENG H, LIU X L, et al. Exhaust gas temperature baseline model of main engine based on DBN-SVR [J]. Journal of Dalian Maritime University, 2022, 48(2): 101-109. (in Chinese)

[2]姜兴家,刘云志,代英伟,等.基于机器视觉的船舶管路滴漏监测[J].大连海事大学学报,2024,50(1):125-133.

JIANG X J, LIU Y Z, DAI Y W, et al. Ship pipeline drip monitoring based on machine vision [J]. Journal of Dalian Maritime University, 2024, 50(1): 125-133. (in Chinese)

[3]HAN P H, ELLEFSEN A L, LI G Y, et al. Fault prognostics using LSTM networks: application to marine diesel engine [J]. IEEE Sensors Journal, 2021, 21(22): 25986-25994.

[4]ZHOU R, CAO J Y, ZHANG G, et al. Heat load forecasting of marine diesel engine based on Long Short-Term Memory Network [J]. Applied Sciences, 2023, 13(2): 1099.

[5]WANG R H, CHEN H, GUAN C, et al. Research on the fault monitoring method of marine diesel engines based on the manifold learning and isolation forest [J]. Applied Ocean Research, 2021, 112: 102681.

[6]LI Y B, GUO Z W, LI Z X, et al. Instantaneous angular speed-based fault diagnosis of multicylinder marine diesel engine using intrinsic multiscale dispersion entropy [J]. IEEE Sensors Journal, 2023, 23(9): 9523-9535.

[7]FU C, LIANG X X, LI Q, et al. Comparative study on health monitoring of a marine engine using multivariate physics-based models and unsupervised data-driven models [J]. Machines, 2023, 11(5): 557.

[8]CAI C T, WENG X Y, ZHANG C B. A novel approach for marine diesel engine fault diagnosis [J]. Cluster Computing, 2017, 20(2): 1691-1702.

[9]KOWALSKI J, KRAWCZYK B, WOZNIAK M. Fault diagnosis of marine 4-stroke diesel engines using a one-vs-one extreme learning ensemble [J]. Engineering Applications of Artificial Intelligence, 2017, 57: 134-141.

[10]XU X J, ZHAO Z Z, XU X B, et al. Machine learning-based wear fault diagnosis for marine diesel engine by fusing multiple data-driven models [J]. Knowledge-Based Systems, 2020, 190: 105324.

[11]CORADDU A, ONETO L, ILARDI D, et al. Marine dual fuel engines monitoring in the wild through weakly

- supervised data analytics[J]. *Engineering Applications of Artificial Intelligence*, 2021, 100:104179.
- [12] KIM D H, ANTARIKSA G, HANDAYANI M P, et al. Explainable anomaly detection framework for maritime main engine sensor data[J]. *Sensors*, 2021, 21(15): 5200.
- [13] TAN Y H, NIU C Y, TIAN H, et al. A one-class SVM based approach for condition-based maintenance of a naval propulsion plant with limited labeled data[J]. *Ocean Engineering*, 2019, 193: 106592.
- [14] GAO B W, XU J, ZHANG Z R, et al. Marine diesel engine piston ring fault diagnosis based on LSTM and improved beluga whale optimization[J]. *Alexandria Engineering Journal*, 2024, 109: 213-228.
- [15] 姜兴家, 刘云志, 宋志敏, 等. 基于迁移学习的船舶机舱火灾图像检测方法[J]. *大连海事大学学报*, 2023, 49(1): 103-109.  
JIANG X J, LIU Y Z, SONG Z M, et al. Image detection method for ship engine room fire based on transfer learning [J]. *Journal of Dalian Maritime University*, 2023, 49(1): 103-109. (in Chinese)
- [16] 王承远, 徐久军, 严志军. 基于多属性群决策的柴油机故障证据融合方法[J]. *大连海事大学学报*, 2018, 44(3): 71-78.  
WANG C Y, XU J J, YAN Z J. Evidence fusion method for diesel engine fault based on multi-attribute group decision making[J]. *Journal of Dalian Maritime University*, 2018, 44(3): 71-78. (in Chinese)
- [17] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [S.l.]:IEEE, 2017: 1800-1807.
- [18] SAITO K, WATANABE K, USHIKU Y, et al. Maximum classifier discrepancy for unsupervised domain adaptation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 3723-3732.
- [19] FU B, CAO Z J, LONG M S, et al. Learning to detect open classes for universal domain adaptation[C]//Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 567-583.
- [20] TUCHLER M, SINGER A C, KOETTER R. Minimum mean squared error equalization using a priori information [J]. *IEEE Transactions on Signal Processing*, 2002, 50(3): 673-683.
- [21] ZHANG W, LI X, MA H, et al. Open-set domain adaptation in machinery fault diagnostics using instance-level weighted adversarial learning[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(11): 7445-7455.
- [22] 张爱萍. 复杂网络社团探测方法及在轮机故障诊断中应用的研究[D]. 大连:大连海事大学, 2015.  
ZHANG A P. Research on community detection method in complex networks and its application to fault diagnosis in marine engineering[D]. Dalian: Dalian Maritime University, 2015. (in Chinese)