

# 控制与决策

Control and Decision

## 基于多粒度对齐和证据推理的多源域自适应故障诊断方法

陈洋洋, 周谧, 张永斌

引用本文:

陈洋洋, 周谧, 张永斌. 基于多粒度对齐和证据推理的多源域自适应故障诊断方法[J]. *控制与决策*, 2025, 40(11): 3403-3414.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0221>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于地标特征和元学习方法推荐最适用优化算法

Recommending best suitable metaheuristic based on landmarking feature and meta-learning approach  
*控制与决策*. 2021, 36(5): 1223-1231 <https://doi.org/10.13195/j.kzyjc.2019.0993>

#### 基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM  
*控制与决策*. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

#### 基于双权重多邻域保持嵌入的间歇过程故障检测

Fault detection of batch process based on double weight and multiple neighborhoods preserving embedding  
*控制与决策*. 2021, 36(12): 3023-3030 <https://doi.org/10.13195/j.kzyjc.2020.0659>

#### $l_p$ -范数约束下MKL-OC-ELM的装备故障检测

MKL and OC-ELM fault detection based on  $l_p$ -norm constraint  
*控制与决策*. 2021, 36(10): 2379-2388 <https://doi.org/10.13195/j.kzyjc.2020.0443>

#### 改进集成深层自编码器在轴承故障诊断中的应用

Application of improved ensemble deep auto-encoder in bearing fault diagnosis  
*控制与决策*. 2021, 36(1): 135-142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

# 基于多粒度对齐和证据推理的多源域自适应故障诊断方法

陈洋洋<sup>1,2</sup>, 周 溢<sup>1,2†</sup>, 张永斌<sup>3</sup>

(1. 合肥工业大学 管理学院, 合肥 230009; 2. 过程优化与智能决策教育部重点实验室, 合肥 230009;  
3. 合肥工业大学 噪声振动工程研究所, 合肥 230009)

**摘要:** 针对多源域自适应故障诊断方法中多域对齐不足和多源信息协同不充分问题, 提出一种端到端的基于多粒度对齐和证据推理规则的多源无监督域自适应故障诊断方法 (MAERAN)。首先, 设计多粒度对齐模块实现由浅入深的多级分布对齐。具体地, 使用浅层域鉴别器对共享域浅层特征实施域对齐以降低浅层特征分布偏差; 构建多视图子网络提取每对源域和目标域的深层特征并实施域对抗策略以实现特征分布对齐; 通过两阶段域对齐挖掘域不变特征, 可有效减少跨域分布差异; 同时, 设置细粒度类对齐以增强类别区分性。然后, 提出基于证据推理规则的多源信息协同决策模块对多源诊断信息进行自适应加权融合, 以提升模型的泛化能力和诊断性能。最后, 通过在两个轴承数据集上的实验验证了 MAERAN 方法在多源迁移任务中的有效性和优越性。

**关键词:** 智能故障诊断; 迁移学习; 多源域; 领域自适应; 证据推理规则

中图分类号: TH165+.3; TP183 文献标志码: A

DOI: 10.13195/j.kzyjc.2025.0221

引用格式: 陈洋洋, 周溢, 张永斌. 基于多粒度对齐和证据推理的多源域自适应故障诊断方法 [J]. 控制与决策, 2025, 40(11): 3403-3414.

## Multi-source domain adaptation fault diagnosis method based on multi-granularity alignment and evidential reasoning

CHEN Yang-yang<sup>1,2</sup>, ZHOU Mi<sup>1,2†</sup>, ZHANG Yong-bin<sup>3</sup>

(1. School of Management, Hefei University of Technology, Hefei 230009, China; 2. Key Laboratory of Process Optimization and Intelligent Decision-Making of Ministry of Education, Hefei 230009, China; 3. Institute of Noise and Vibration Engineering, Hefei University of Technology, Hefei 230009, China)

**Abstract:** To address the issues of insufficient multi-domain alignment and inadequate multi-source information collaboration in multi-source domain adaptive fault diagnosis, an end-to-end multi-source unsupervised domain adaptation fault diagnosis method is proposed, named the adaptation network based on multi-granularity alignment and evidential reasoning rule (MAERAN). Firstly, a multi-granularity alignment module is designed to achieve progressive multi-level distributed alignment from shallow to deep. Specifically, the shallow domain discriminator is used to align the shallow features of the shared domain to reduce the distribution bias of shallow features. Next, a multi-view sub-network is constructed to extract the deep features from each pair of source and target domains, and the domain adversarial strategy is implemented to align the feature distribution. By mining domain invariant features through two-stage domain alignment, the difference of cross-domain distribution is effectively reduced. At the same time, fine-grained class alignment is performed to enhance category distinguishability. Then, a multi-source information collaboration decision-making module based on evidential reasoning rule is proposed, which adaptively weights and fuses multi-source diagnostic information to enhance the generalization ability and diagnostic performance of the model. Finally, experimental results on two bearing datasets validate the effectiveness and superiority of the proposed method in multi-source transfer tasks.

**Keywords:** intelligent fault diagnosis; transfer learning; multi-source domain; domain adaptation; evidential reasoning rule

## 0 引言

随着现代工业的快速发展, 对机械系统的安全

性和可靠性提出了越来越高的要求。滚动轴承作为旋转机械的重要组件, 其性能直接决定了设备的可

收稿日期: 2025-03-04; 录用日期: 2025-06-13.

基金项目: 国家自然科学基金项目 (72471069).

责任编委: 阳春华.

†通信作者. E-mail: zhoumi83@163.com.

靠性. 因此, 对旋转机械的智能故障诊断有利于进行可靠性维护, 降低维修成本. 深度学习方法因其诊断流程自动化、对专业知识依赖较低以及诊断准确率较高等优点, 被广泛应用于工业智能故障诊断问题.

然而, 一些深度学习方法<sup>[1-2]</sup>一方面高度依赖大量标注数据, 另一方面通常假设训练集与测试集为同一分布, 这限制了其在实际应用中的诊断性能. 而无监督领域自适应 (UDA) 作为迁移学习的重要分支, 为进行有效地故障诊断提供了关键思路. 目前, 主流的领域自适应框架有两种: 1) 基于度量准则<sup>[3-4]</sup>的领域自适应方法. 文献 [5] 利用代价敏感的重新加权和改进的最大均值差异 (MMD) 联合适应类别不平衡域; 文献 [6] 利用局部最大均值差异实现了同类别内子域分布匹配. 2) 基于对抗训练<sup>[7-9]</sup>的领域自适应方法. 文献 [10] 提出了一种基于域对抗图卷积网络, 通过对抗训练捕获域不变特征, 实现了跨域故障诊断; 文献 [11] 提出了一种基于 Transformer 和领域对抗神经网络 (DANN) 的域对抗网络, 在变负载任务中实现了良好的诊断性能. 上述领域自适应方法均集中于单源域, 由于单一源域的诊断知识有限难以覆盖目标域, 限制了模型的泛化能力. 若忽略域分布差异直接混合所有域, 则难以同时对齐所有域以获得一般诊断知识.

多源无监督域自适应 (MUDA)<sup>[12-13]</sup>通过对多源域数据进行有效融合以获取更全面的诊断知识, 解决了单一源知识的固有局限; 文献 [14] 通过 MK-MMD 损失和 L1 损失最小化实现了特定空间下的分布对齐和多分类器对齐, 但是, 该方法并未考虑不同源域与目标域任务的不同贡献, 在多源信息融合上存在一定的盲目性和不稳定性; 文献 [15] 对小样本扩充后使用局部最大均值差异最小化实现了特定源域与目标域的分布对齐, 并对各源域赋权实现了最终分类, 但是, 这种全局对齐方法仅调整特定空间下的特征, 会增加分布对齐难度导致多域对齐不足; 文献 [16] 构建了双对抗模块以提高域不变特征学习能力, 并通过置信度分数实现了多分类器融合决策, 但不变特征源自域级别和类级别, 上述方法仅关注域级不变特征, 导致特征可迁移性和诊断泛化有限. 因此, 上述 MUDA 故障诊断方法虽然取得了一定进展, 但是仍然存在一些不足: 1) 现有研究多通过调整特定空间下的特征减少全局域差异, 易导致多域对齐不充分, 且忽略了可区分性类特征, 会导致类别混淆从而影响分类准确性; 2) MUDA 方法多通过对齐多分类器并简单平均多源结果来实现分类, 并未充

分协同融合多源域特征, 限制了其在诊断任务中的鲁棒性.

针对上述问题, 本文提出一种基于多粒度对齐和证据推理规则的多源域自适应故障诊断方法 (MAERAN). 首先, 通过共享特征提取网络和多视图子网络充分提取丰富的特征表示; 然后, 采用两阶段域对抗训练的方式实现域级特征分布对齐, 以学习域不变特征并缩小每对源域与目标域间的分布差异; 同时, 引入 MMD 对类分布进行度量, 以增强类特征的可区分性; 接着, 提出基于证据推理规则的多源信息协同模块对多源诊断信息进行自适应加权融合, 以提升模型的泛化能力和诊断性能; 最后, 通过在两个轴承数据集的实验验证了所提出方法优越的领域自适应性和鲁棒性. 本文的主要内容总结如下.

1) 针对不同域间的分布差异, 设计多粒度对齐机制以实现浅层特征级、多视图子域级以及类级的多级分布对齐.

2) 针对多源诊断信息融合不充分问题, 提出基于证据推理规则的多源信息协同决策模块. 通过对多源诊断信息进行自适应加权融合实现协同决策, 提升模型的泛化能力和诊断精度.

3) 通过在 CWRU 和 PU 两个公开数据集上设置多源迁移任务, 验证所提出方法具有良好的领域自适应性.

## 1 理论背景

### 1.1 问题描述

在多源无监督域自适应故障诊断中, 源域数据是由  $N$  个不同运行状态下获取的含标签的集合, 表示为  $\mathcal{D}_s = \mathcal{D}_1, \mathcal{D}_2, \dots, \mathcal{D}_N$ . 其中: 第  $n$  个源域  $\mathcal{D}_n$  中包含  $n_s$  个样本  $x_i$  和对应标签  $y_i$  的源域数据集, 表示为  $\{(X_n, Y_n)\} = \{(x_i^n, y_i^n)\}_{i=1}^{n_s}$ , 标签类别  $y_i = \{0, 1, \dots, c\}$ ,  $c$  为故障类别数. 无标签的目标域表示为  $\mathcal{D}_T = \{x_j\}_{j=1}^{n_t}$ , 是包含有  $n_t$  个样本  $x_j$  但是无对应标签  $y_j$  的目标域数据集.

### 1.2 对抗域自适应

Ganin 等<sup>[17]</sup>集成了对抗学习和领域自适应技术提出了领域对抗神经网络 (DANN), 如图 1 所示. 该网络由特征提取器、分类器和域判别器组成, 其中域判别器通过梯度反转层与特征提取器连接, 用于区分所输入的特征是来自源域还是目标域. 通过对抗训练使得模型学习域不变特征以实现领域自适应. 域判别器损失定义为

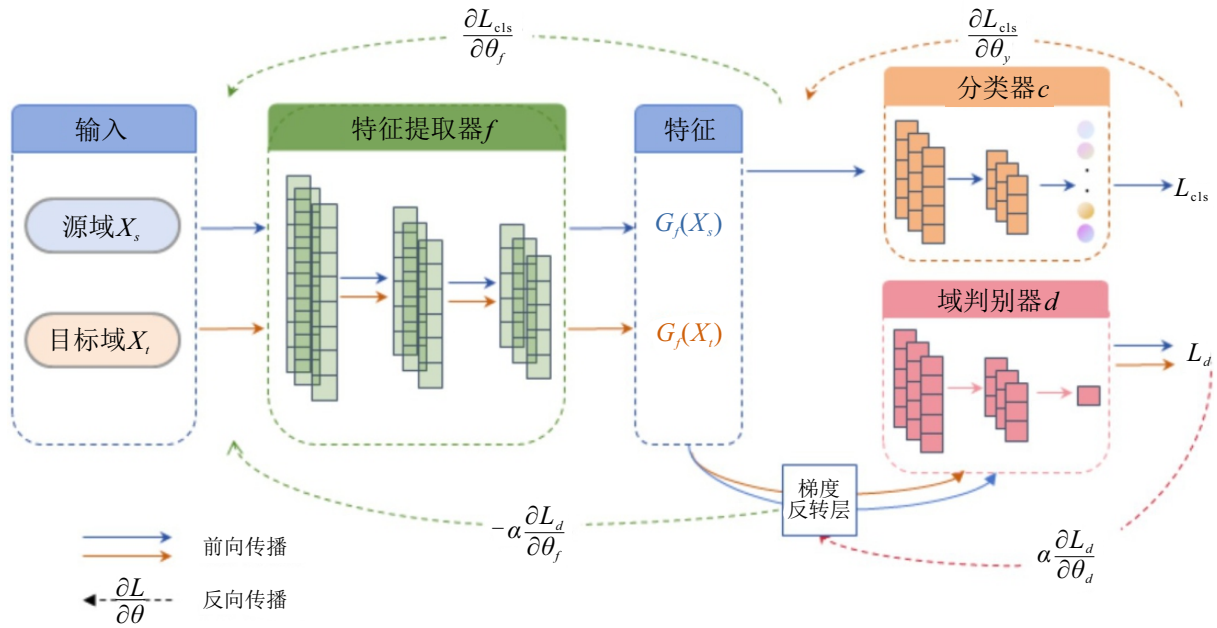


图1 领域对抗神经网络结构示意图

$$L_d = \frac{1}{n} \sum_{i=1}^n (d_i \log G_d(G_f(x_i)) + (1 - d_i) \log(1 - G_d(G_f(x_i)))) \quad (1)$$

其中:  $d_i$  为第  $i$  个样本的域标签,  $G_d(G_f(x_i))$  为域判别器对输入特征生成的预测域标签.

### 1.3 最大均值差异

最大均值差异 (MMD)<sup>[18]</sup> 是用于评估两个分布间距离的统计量, 其核心是将数据映射至再生核希尔伯特空间, 利用核方法度量两分布间的差异. 假设  $X$ 、 $Y$  是通过独立同分布采样从分布  $P$  和  $Q$  得到的两个样本集, 其样本量为  $n$  和  $m$ , 则对应的度量为

$$\text{MMD}^2(P, Q) = \left\| \frac{1}{n} \sum_{i=1}^n f(x_i) - \frac{1}{m} \sum_{j=1}^m f(y_j) \right\|_H^2 \quad (2)$$

其中:  $H$  为再生核希尔伯特空间,  $k(\cdot)$  为再生核希尔伯特空间 RKHS 中的核函数.

## 2 多源无监督域自适应方法

所提出 MAERAN 方法的整体框架如图 2 所示. 该网络由共享特征提取器、浅层域判别器、特定源特征提取器、特定源分类器、多粒度对齐模块以及基于证据推理规则的多源信息协同模块几个部分组成, 所提出模型的详细结构参数描述如表 1 所示.

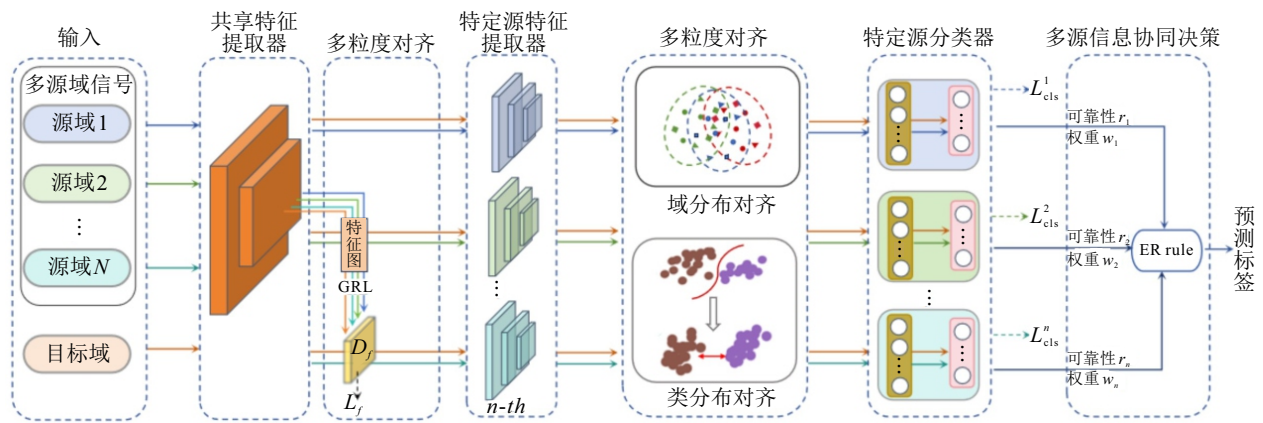


图2 本文 MAERAN 模型框架

### 2.1 特征提取模块

1) 共享特征提取网络. 通过共享特征提取器将不同域数据映射至同一特征空间, 以挖掘领域无关的特征表示.

2) 特定源特征提取网络. 由于分布差异不仅存

在于源域与目标域间, 各源域间也存在显著的域偏移, 为减少源域间的干扰, 并保留各源域独特的信息, 设计了多视图子网络, 对每个源域建立了特定源特征提取器  $G_j$ , 将源域和目标域成对映射至特定特征空间, 以独立并行的方式挖掘源域-目标域对的特定领域知识.

表1 本文 MAERAN 模型结构参数

网络组件	网络结构	激活函数	输出尺寸
输入	原始信号输入	—	1×2048
共享特征提取器	Conv(16@(1×32)) BN(16)	ReLU	32×251
	Conv(32@(1×3)) BN(32)	ReLU	
浅层域判别器	Conv(16@(1×1))	Leakey-ReLU	1×251
	Conv(1@(1×1))	Leakey-ReLU	
特定源特征提取器	FC		
	Conv(64@(1×3)) BN(64) MP(2×2)	ReLU	
	Conv(128@(1×3)) BN(128) MP(2×2)	ReLU	128×31
特定源分类器	Conv(128@(1×3)) BN(128) MP(2×2)	ReLU	
	FC(128) BN(128)	ReLU	$C$
特定源判别器	FC( $C$ )	Softmax	
	FC(128)	Leakey-ReLU	2
	FC	Softmax	

## 2.2 特定源分类器

将经过共享特征提取器  $F$  和特定源特征提取器  $G_j$  的不同源域特征  $G_j(F(x_i^{sj}))$  输入至特定源分类器  $C_j$ , 以实现针对不同源域样本的故障类别预测. 多源域分类损失定义为

$$L_{cls} = \sum_{j=1}^N L_{ce}(C_j(G_j(F(x_i^{sj}))), y^{sj}). \quad (3)$$

其中:  $L_{ce}$  为交叉熵损失函数,  $y^{sj}$  为在第  $j$  个源域上样本所对应的标签.

## 2.3 多粒度对齐模块

为减少多源域与目标域间的分布差异来增强域混淆, 本文提出了多粒度对齐策略, 实现了浅层特征级、多视图子域级以及类级 3 级分布对齐, 以学习可迁移判别特征消除负迁移, 提高模型泛化能力.

### 2.3.1 浅层特征分布对齐

与深度学习相比, 浅层神经网络通过较少层数可提取更接近输入的特征, 而这些特征通常包含更一般的信息, 具有较强的迁移性<sup>[19]</sup>, 因此, 通过对浅层特征对齐有助于降低直接对齐所有域的难度. 浅层特征对齐损失可表示为

$$L_f = \frac{1}{N_s \times L} \sum_{i=1}^{N_s} \sum_{l=1}^L (D(F(x_i^{sj}))_l)^2 + \frac{1}{N_t \times L} \sum_{i=1}^{N_t} \sum_{l=1}^L (1 - D(F(x_i^t))_l)^2. \quad (4)$$

其中:  $N_s$  和  $N_t$  分别为源域和目标域的样本量,  $D(F(x_i^{sj}))_l$  和  $D(F(x_i^t))_l$  为域判别器  $D$  对共享特征提取器  $F$  从源域和目标域提取到特征图对应位置的预测.

### 2.3.2 多视图子域对齐

对抗域分布对齐是通过领域对抗训练方式减少

源域与目标域的特征分布差异的, 使得模型学习域不变特征. 通过构建多视图子网络, 将每个源域与目标域逐对应映射至特定空间, 可充分挖掘每对源域和目标域的特定领域知识, 并实施域对抗对齐策略以有效减少源域与目标域间的分布差异. 多视图子域对齐的对抗损失可定义为

$$L_d = \left( \frac{1}{N_s} \sum_{i=1}^{N_s} d_i \log D_j(G_j(F(x_i^{sj}))) + \frac{1}{N_t} \sum_{i=1}^{N_t} (1 - d_i) \log D_j(G_j(F(x_i^t))) \right). \quad (5)$$

其中:  $d_i$  为第  $i$  个样本的真实域标签,  $D_j(G_j(F(x_i^{sj})))$  为第  $j$  个域判别器  $D_j$  对经过第  $j$  个特征源提取器后的第  $i$  个样本的预测域标签.

### 2.3.3 类分布对齐

上述两阶段分布对齐仅实现了多域特征混淆, 但是, 不同域下相同标签的样本仍然可能在特征空间中映射得很远, 可能会出现类错位问题特别是决策边界附近的样本易导致分类器误分. 本节在两阶段域分布对齐的基础上提出了类分布对齐, 包括类内分布对齐和类间分布对齐两部分, 以更好地学习域不变特征和判别特征, 为故障分类提供了清晰且稳健的决策边界. 类分布对齐的总损失可表示为

$$L_{class} = L_c^{intra} - L_c^{inter}. \quad (6)$$

其中:  $L_c^{intra}$  为类内分布对齐损失,  $L_c^{inter}$  为类间分布损失. 首先, 类内分布对齐通过缩小不同领域同类别样本间的距离来实现类对齐, 其损失函数可表示为

$$L_c^{intra} = \frac{1}{C} \sum_{c=1}^C \text{MMD}(X_c^{sj}, X_c^t) = \frac{1}{C} \sum_{c=1}^C \left\| \frac{1}{N_s} \sum_{i=1}^{N_s} p_{ic}^{sj} \times G_j(F(x_i^{sj})) - \frac{1}{N_t} \sum_{i=1}^{N_t} p_{ic}^t \times G_j(F(x_i^t)) \right\|_H^2. \quad (7)$$

这里:  $C$  为故障类别,  $p$  为样本  $x_i$  属于类别  $c$  的概率. 而类间分布对齐通过扩大各域中不同类别样本间的距离, 以避免不同类别的混淆, 其损失可表示为

$$L_c^{inter} = \frac{2}{C(C-1)} \sum_{c_1=1}^{C-1} \sum_{c_2=c_1+1}^C (\text{MMD}(X_{c_1}^{sj}, X_{c_2}^{sj}) + \text{MMD}(X_{c_1}^t, X_{c_2}^t)). \quad (8)$$

考虑到边界样本易在较大概率的类别间混淆, 为减少计算量, 类间分布损失可优化为计算最大概率类别与次大概率类别的距离, 从而有效减少边界样本的混淆. 可表示为

$$L_c^{\text{inter}} = \frac{1}{2} (\text{MMD}(X_{\max_1}^{s_j}, X_{\max_2}^{s_j}) + \text{MMD}(X_{\max_1}^t, X_{\max_2}^t)). \quad (9)$$

## 2.4 多源信息协同模块

针对现有方法在多源域诊断信息协同融合方面存在一定的盲目性和不稳定性, 提出了一种基于证据推理规则的多源信息协同模块, 无需依赖先验知识, 通过自适应加权融合来实现多源诊断信息的协同决策, 提高分类的准确性和鲁棒性。

证据理论是由 Dempster 在 1967 年提出的, 后经 Shafer 进一步发展起来的多源不确定信息融合方法, 其核心是 Dempster 证据融合规则, 以两个证据为例, 设识别框架  $\Theta = \{\theta_1, \theta_2, \dots, \theta_c\}$ ,  $m_1(\cdot)$  和  $m_2(\cdot)$  为  $\Theta$  上的两个基本概率分配, 则  $\forall A \subset \Theta, A \neq \varnothing$ , 可得到在焦元  $A$  上的基本概率分配为

$$m_{1,2}(A) = k \sum_{\substack{B \cap C = \theta \\ B, C \subset \Theta}} m_1(B) m_2(C),$$

其中  $k$  为冲突因子, 计算公式为

$$k = \frac{1}{1 - \sum_{\substack{B \cap C = \varnothing \\ B, C \subset \Theta}} m_1(B) m_2(C)}.$$

而证据推理 (ER) 规则<sup>[20]</sup>以 Dempster-Shafer (D-S) 证据理论为基础, 明确区分了证据的可靠性  $r_j$  和重要性权重  $w_j$ , 解决了传统 D-S 证据理论在高冲突证据融合中的局限性. 其中: 可靠性反映了证据的固有属性, 重要性用于反映该证据与其他证据相比的相对重要性。

在智能故障诊断中, 曲线下面积 (AUC) 被认为是很好解决代价敏感问题的评价指标, 因此, 将特定源分类器的 AUC 作为分类器可靠性指标, 表示为

$$r_j = \text{AUC}_j = \left( \frac{\sum_{\text{ins}_i \in \text{positiveclass}} \text{rank}_{\text{ins}_i} - \frac{M \times (M+1)}{2}}{M \times N} \right)_j. \quad (10)$$

其中:  $\text{rank}_{\text{ins}_i}$  为第  $i$  个样本概率的排序位置,  $M$  和  $N$  分别为正样本和负样本的数目. 而重要性权重通过特定源分类器对目标域预测的不确定性和各特定源分类器间的一致性两方面确定. 首先, 利用信息熵来度量特定源分类器对目标域预测的不确定性, 表示为

$$\text{ent}_j = \sum_{i=1}^{N_t} \left( - \sum_{c=1}^C p_{ij}^c \log(p_{ij}^c) \right), \quad (11)$$

$$w_j^{\text{ent}} = \frac{1/\text{ent}_j}{\sum_{j=1}^N (1/\text{ent}_j)}. \quad (12)$$

这里:  $p_{ij}^c$  为第  $j$  个特定源分类器对目标域上第  $i$  个样本属于  $c$  类别的预测概率;  $\text{ent}_j$  值越高, 分类器对样本预测的不确定性越大, 应赋予越低的权重. 其次, 多源分类器间的一致性使用余弦相似度来衡量, 可表示为

$$\text{sim}(C_j, C_{j'}) = \frac{\sum_{c=1}^C (p_j^c \cdot p_{j'}^c)}{\left\| \sum_{c=1}^C p_j^c \right\| \left\| \sum_{c=1}^C p_{j'}^c \right\|} = \frac{\sum_{i=1}^{N_t} \sum_{c=1}^C (p_{ij}^c \cdot p_{ij'}^c)}{\sqrt{\sum_{i=1}^{N_t} \sum_{c=1}^C (p_{ij}^c)^2} \cdot \sqrt{\sum_{i=1}^{N_t} \sum_{c=1}^C (p_{ij'}^c)^2}}, \quad (13)$$

$$w_j^{\text{sim}} = \frac{\frac{1}{N-1} \sum_{j \neq j'} \text{sim}(C_j, C_{j'})}{\sum_{j=1}^N \left( \frac{1}{N-1} \sum_{j \neq j'} \text{sim}(C_j, C_{j'}) \right)}, \quad (14)$$

其中  $\|p_i^c\|$  为向量的二范数. 综上, 重要性权重  $w_j$  可表示为

$$w_j = (w_j^{\text{ent}} + w_j^{\text{sim}})/2. \quad (15)$$

基于可靠性  $r_j$  和重要性  $w_j$  的证据推理规则<sup>[20]</sup>流程如下. 判别框架定义为  $\Theta = \{\text{正常}, \text{轻度球故障}, \dots, \text{重度内圈故障}\}$ , 证据即第  $j$  个特定源分类器诊断结果的概率分布, 可表示为

$$e_j = \left\{ (\theta, p_{\theta,j}), \forall \theta \subseteq \Theta, \sum_{\theta \in \Theta} p_{\theta,j} = 1 \right\}, \quad (16)$$

其中  $p_{\theta,j}$  为证据  $e_j$  对  $\theta$  的支持程度. 同时, 考虑证据的权重和可靠性的质量函数  $\tilde{m}_{\theta,j}$  为

$$\tilde{m}_{\theta,j} = \begin{cases} 0, & \theta = \varnothing; \\ \tilde{w}_j p_{\theta,j}, & \theta \subseteq \Theta, \theta \neq \varnothing; \\ 1 - \tilde{w}_j, & \theta = P(\Theta). \end{cases} \quad (17)$$

这里  $\tilde{w}_j = w_j/(1 + w_j - r_j)$  为将证据的权重  $w_j$  和可靠性  $r_j$  进行融合后的混合权重. 不同于 Dempster 合成规则, 证据推理规则通过混合权重  $\tilde{w}_j$  对证据的基本概率分配进行赋权, 使得合成过程满足概率推理过程. 证据推理规则通过递归的方式对所有证据进行融合, 其递归过程可表示为

$$\tilde{m}_{\theta,e(j)} = \begin{cases} 0, \theta = \emptyset; \\ \frac{\hat{m}_{\theta,e(j)}}{\sum_{D \subseteq \Theta} \hat{m}_{D,e(j)} + \hat{m}_{p(\Theta),e(j)}}, & \theta \subseteq \Theta, \theta \neq \emptyset; \end{cases} \quad (18)$$

$$\hat{m}_{\theta,e(j)} = [(1 - r_j)m_{\theta,e(j-1)}m_{p(\Theta),e(j-1)}m_{\theta,j}] + \sum_{B \cap C = \theta} m_{B,e(j-1)}m_{C,j}, \quad \forall \theta \subseteq \Theta; \quad (19)$$

$$\hat{m}_{p(\Theta),e(j)} = (1 - r_j)m_{p(\Theta),e(j-1)}; \quad (20)$$

$$p_{\theta,e(j)} = \begin{cases} 0, \theta = \emptyset; \\ \frac{\hat{m}_{\theta,e(j)}}{\sum_{D \subseteq \Theta} \hat{m}_{D,e(j)}}, & \theta \subseteq \Theta, \theta \neq \emptyset. \end{cases} \quad (21)$$

## 2.5 模型训练

所提出 MAERAN 模型的总损失由源域分类损失  $L_{\text{cls}}$ 、浅层特征对齐损失  $L_f$ 、多视图子域对齐  $L_d$  和类分布对齐  $L_{\text{class}}$  共 4 部分组成, 可表示为

$$L_{\text{total}} = L_{\text{cls}} + \lambda(L_{\text{class}} - L_f - L_d), \quad (22)$$

其中  $\lambda \in [0, 1]$  为权衡参数. 表 2 为所提出 MAERAN 模型的训练过程.

表2 本文 MAERAN 模型的训练过程

算法1 基于多粒度对齐和证据推理规则的多源无监督域自适应故障诊断方法 (MAERAN) 训练过程.
输入: 含标签的多源域数据 $\{D_{s_j}\}_{j=1}^N = \{\{(x_i^n, y_i^n)\}_{i=1}^{n_s}\}_{j=1}^N$ , 无标签目标域数据 $D_t$ ;
迭代训练(epoch = 1):
1. 随机从多源域 $D_{s_j}$ 和目标域 $D_t$ 中采集批次源域样本 $\{x_i^{s_j}, y_i^{s_j}\}_{i=1}^b$ 和目标域样本 $\{x_i^t\}_{i=1}^b$ ;
2. 将批次源域样本和目标域样本输入共享特征提取器 $F$ , 得到浅层特征表示 $F(x_i^{s_j})$ 和 $F(x_i^t)$ ;
3. 将源域和目标域浅层特征表示输入浅层域判别器 $f$ , 由式(4)计算浅层域判别损失;
4. 将源域和目标域浅层特征表示输入特定源特征提取器 $G_{s_j}$ , 得到特定域高级特征表示 $G_{s_j}(F(x_i^{s_j}))$ 和 $G_{s_j}(F(x_i^t))$ ;
5. 将特定源域高级特征表示 $G_{s_j}(F(x_i^{s_j}))$ 输入特定源分类器 $C_{s_j}$ 得到 $C_{s_j}(G_{s_j}(F(x_i^{s_j})))$ , 由式(3)计算源域分类损失;
6. 将特定域高级特征表示 $G_{s_j}(F(x_i^{s_j}))$ 和 $G_{s_j}(F(x_i^t))$ 输入特定域判别器 $D_{s_j}$ , 由式(5)计算特定域损失;
7. 将特定域高级特征表示 $G_{s_j}(F(x_i^t))$ 输入特定源分类器得到的目标域样本的概率分布 $C_{s_j}(G_{s_j}(F(x_i^t)))$ , 由式(6) ~ (9) 计算类损失;
8. 由式(22)计算总损失 $L_{\text{total}}$ ;
9. 更新网络参数;
达到最大迭代训练次数, 结束
输出: 目标域样本预测标签 $y_i^t$ .

## 3 实验验证与结果分析

### 3.1 实施细节

为增强实验结果的可靠性, 减少随机性带来的

影响, 所有方法均进行了 5 次重复实验. 实验参数设置如下: 使用 SGD 优化器, 迭代轮数 epoch 设置为 100, 批样本大小为 32. 初始学习率  $\eta_0 = 0.01$ , 而共享特征提取器的初始学习率是  $\eta_0$  的 1/10. 学习率  $\eta$  的动态调整策略为  $\eta = (\eta_0 / ((1 + 10p)^{0.75}))$ , 权衡参数的动态调整策略为

$$\lambda = (2 / (1 + \exp(-10p'))) - 1,$$

其中  $p$  和  $p'$  遵循从 0 ~ 1 线性变化. 为更全面地评估所提出方法的有效性, 使用 Accuracy 和  $F_1$ -score 作为模型评估指标. 实验环境为 Windows 11 操作系统, CPU 为 i7-13700k, 频率为 3.40 GHz, GPU 为 NVIDIA RTX 4060, 采用 Python 3.8 和深度学习框架 PyTorch 2.0.1 编写.

### 3.2 对比方法描述

为验证所提出方法的优越性和鲁棒性, 将 MAERAN 方法与其他几种的故障诊断方法进行对比, 其对比方法的结构描述如下:

1) 无领域自适应网络 —— CNN: 利用第 2.1 节中描述的一维卷积神经网络作为基线模型, 以单一源作为 CNN 输入进行训练后, 直接用目标域数据进行测试;

2) 单源域/多源合并域自适应网络 —— 深度适配网络 (DAN)<sup>[7]</sup>: 以 AlexNet 网络为特征提取器, 使用 MK-MMD 度量源域与目标域间的距离, 并通过最小化域差损失对齐特征分布;

3) 单源域/多源合并域自适应网络 —— 域对抗网络 (DANN)<sup>[8]</sup>: 以卷积神经网络作为特征提取器, 并通过特征提取器与域判别器间的博弈来生成域不变表示;

4) 多源域自适应网络 —— 多特征空间自适应网络 (MFSAN)<sup>[21]</sup>: 以 Resnet18 网络作为特征提取器, 使用 MMD 度量特定特征空间下不同源域与目标域间的距离, 同时使用 L1 损失对齐分类器;

5) 多源域自适应网络 —— 多源子域自适应 (MSSA)<sup>[12]</sup>: 以卷积神经网络为特征提取器, 使用 LMMD 最小化以缩小每对源域与目标域的分布差异, 并以 LMMD 为权重实现多源分类器诊断信息融合;

6) 多源域自适应网络 —— 多源域多头注意力自适应网络 (MDMAAN)<sup>[14]</sup>: 以含多头注意力机制的卷积神经网络为特征提取器, 使用 MK-MMD 度量不同源域与目标域间的距离, 同时使用 L1 约束多分类器.

此外, 设置了 3 个评估标准, 分别为单源最佳

(single best)、多源合并迁移 (source combine)、多源迁移 (multi-source).

### 3.3 CWRU 数据集验证

#### 3.3.1 CWRU 轴承数据集

美国凯斯西储大学 (CWRU) 轴承数据集<sup>[21]</sup>是轴承故障诊断研究中应用最为广泛的数据集之一. 以 12 kHz 的采样频率分别在 4 种负载下采集不同故障类型的振动信号, 以电火花放电的方式生成 3 种故障, 每种故障类型有 3 种故障直径, 共 9 种损伤状态和 1 种健康类别. 本实验中, 设每个样本长度为 2048, 并以步幅为 1180 个采样点的滑动窗口对原始信号进行划分, 表 3 为 CWRU 数据集的详细信息.

表3 CWRU 数据集说明

工况编号	负载/HP	标签	故障模式	故障尺寸/inch	样本长度	训练样本	测试样本
A/B/C/D	0/1/2/3	0	健康	—	2048	70	30
		1	滚动体故障	0.007	2048	70	30
		2	滚动体故障	0.014	2048	70	30
		3	滚动体故障	0.021	2048	70	30
		4	内圈故障	0.007	2048	70	30
		5	内圈故障	0.014	2048	70	30
		6	内圈故障	0.021	2048	70	30
		7	外圈故障	0.007	2048	70	30
		8	外圈故障	0.014	2048	70	30
9	外圈故障	0.021	2048	70	30		

#### 3.3.2 实验验证及结果分析

所有方法在 CWRU 数据集上的诊断结果如表 4 所示. 从中可得出如下结论: 1) 单源域自适应方法 DAN 与 DANN 相较于 CNN 的平均诊断结果分别提升了 6.02%、6.32% 和 6.70%、7.43%, 这表明领域自适应方法能够有效缓解源域与目标域间的分布差异. 2) 多源合并域自适应方法 DAN 与 DANN 相较于单源域任务中的平均诊断结果分别提高了 2.90%、3.27% 和 2.47%、2.28%, 这表明从多源域可获得丰富的诊断信息, 以实现较好的迁移诊断能力. 3) 多源域自适应方法的诊断结果优于多源合并方法. 所提出方法 MAERAN 相较于两个多源域合并方法的平均准确率分别提高了 2.71% 和 2.46%, 这表明由于分布差异不仅存在于源域与目标域间, 还存在于各源域间, 若将所有域直接混合并强制对齐, 则会导致信息损失. 4) MAERAN 方法的平均诊断准确率为 99.60%, 相较于对比方法 MFSAN、MSSA 与 MDMAAN 分别提高了 1.81%、1.95% 和 1.59%, 验证了所提出 MAERAN 方法的领域自适应性, 诊断能力优于对比方法, 且在 A, B, D → C 的迁移任务中取得了 100% 的迁移诊断能力, 这首先归因于多粒度对齐模块的有效性, 通过细粒度对齐促进了模型提取域不变特征和判别性特征, 实现了知识的有效迁移. 其次是多源信息协同决策模块实现了对多源诊断信息的有效自适应融合, 增强了模型的泛化性和判别能力.

表4 所有方法在 CWRU 数据集上多源迁移任务下的诊断结果

标准	模型	%									
		A, B, C → D		A, B, D → C		A, C, D → B		B, C, D → A		AVG	
		Accuracy	F <sub>1</sub> -score	Accuracy	F <sub>1</sub> -score	Accuracy	F <sub>1</sub> -score	Accuracy	F <sub>1</sub> -score	Accuracy	F <sub>1</sub> -score
single best	CNN	88.76±0.81	88.47±0.49	87.22±1.11	86.97±1.07	89.29±1.09	88.35±0.92	86.59±0.53	85.14±0.64	87.97	87.23
	DAN	92.73±1.25	91.91±1.60	94.37±1.31	93.71±1.71	94.61±1.22	94.40±1.31	94.26±0.56	94.18±0.64	93.99	93.55
	DANN	92.96±1.39	92.86±1.54	96.49±0.79	96.35±0.64	94.92±1.32	94.87±1.47	94.29±0.80	94.56±0.77	94.67	94.66
source combine	DAN	96.48±0.62	96.43±0.66	97.19±0.70	97.12±0.72	96.93±0.73	96.88±0.76	96.97±0.87	96.85±0.88	96.89	96.82
	DANN	96.94±0.57	96.89±0.63	97.68±1.03	97.16±0.91	96.95±0.43	97.00±0.39	96.97±1.04	96.72±1.08	97.14	96.94
multi-source	MFSAN	97.16±0.42	97.08±0.55	98.78±0.77	98.81±0.89	97.65±0.87	97.60±0.96	97.57±0.52	97.55±0.86	97.79	97.76
	MSSA	97.77±0.87	97.73±0.88	97.75±0.71	97.75±0.72	98.05±0.76	97.98±0.81	97.01±1.09	96.96±1.18	97.65	97.61
	MDMAAN	97.92±0.67	97.90±0.63	98.40±0.99	98.39±1.01	97.66±1.00	97.15±0.98	98.05±0.39	98.01±0.36	98.01	97.86
	MAERAN	<b>99.72±0.27</b>	<b>99.72±0.25</b>	<b>100.00±0.00</b>	<b>100.00±0.00</b>	<b>99.16±0.62</b>	<b>99.14±0.63</b>	<b>99.51±0.46</b>	<b>99.51±0.47</b>	<b>99.60</b>	<b>99.59</b>

#### 3.3.3 CWRU 轴承数据集可视化分析

为进一步验证所提出 MAERAN 方法的有效性, 图 3(a) ~ 图 3(c) 展示了不同多源域自适应方法在 A, B, C → D 任务训练过程中的准确率曲线. 由图 3 可见, 对比方法收敛速度较慢且曲线波动较大, 这

是由于对比方法通过约束多分类器来减少分类器预测差异, 若多分类器在不同源域上的诊断能力存在较大差异, 则易导致其对同一目标域样本的诊断受到影响, 从而引入更多误差. 而 MAERAN 方法通过多粒度对齐模块提取域不变特征和判别特征, 并对




图3 不同方法在 CWRU 数据集上的诊断精度曲线

多源诊断信息进行协同决策, 不仅实现了更高的诊断精度, 且在训练过程中收敛速度更快, 表现出较高的稳定性.

采用 t-分布随机邻域嵌入 (t-SNE)<sup>[22]</sup> 方法对特征进行可视化分析. 图 4 为各标准下代表方法在 A, B, C → D 任务中的特征可视化结果. 其中: “●” 为源域类别, “■” 为目标域类别, 不同颜色和数字对应不同的故障类别. 图 4(a) 为 DANN 在单源域迁移任务下的可视化结果. 由图 4(a) 可见, 不同故障类别间存在明显的混叠, 且有较多的样本误分情况. 图 4(b) 和图 4(c) 分别为 DAN 和 DANN 在多源合并迁移任务下的可视化结果. 由图 4(b) 和图 4(c) 可见: DAN 方法存在明显的样本误分类和类别边界混淆

现象, 而 DANN 方法存在明显的域对齐不足现象. 这表明由于不同源域间存在明显的分布差异, 简单多源合并会导致模型在冗余信息的干扰下诊断精度提升有限. 图 4(d) 和图 4(e) 为 MFSAN 和 MDMAAN 的可视化结果. 由图 4(d) 和图 4(e) 可见, 两种对比方法存在明显的样本误分类, 同类故障的特征分布相对较为分散. 图 4(f) 为 MAERAN 方法的可视化结果. 由图 4(f) 可见, 同一故障类别的源特征和目标特征呈聚拢状态, 而不同故障类别互相分离, 这表明 MAERAN 方法提取的不变特征具有类别区分性和领域不变性, 并为诊断提供了更清晰的决策边界, 验证了所提出方法在提升诊断准确性和鲁棒性的有效性.

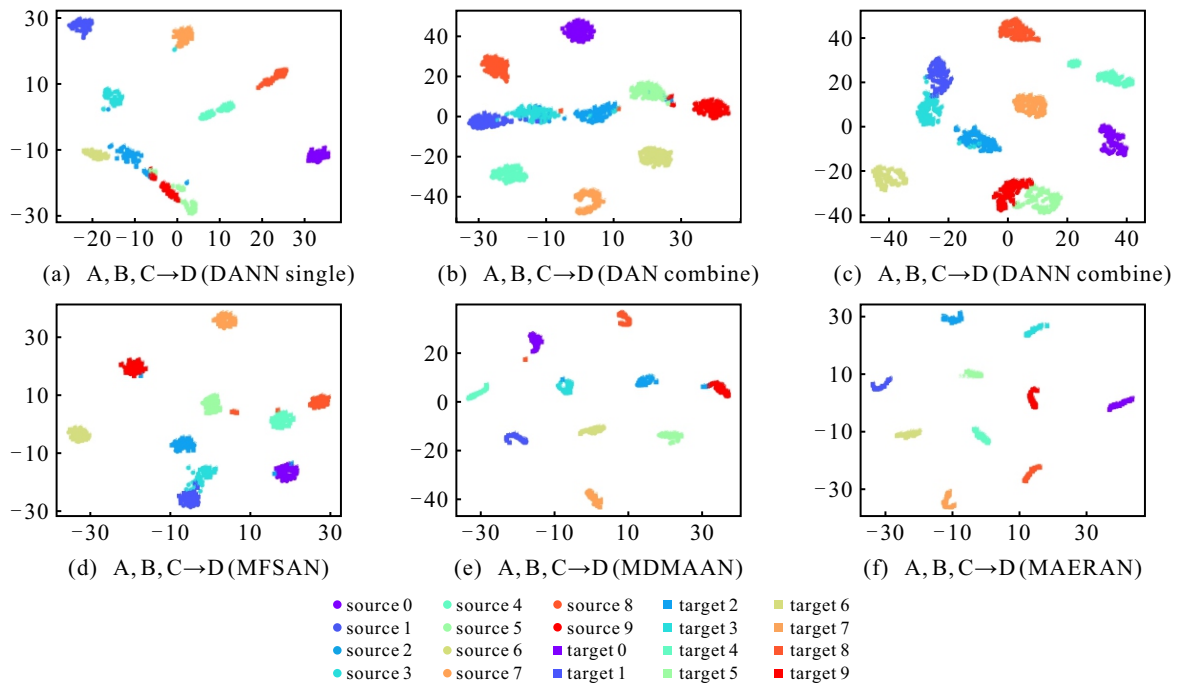


图4 不同方法在迁移任务 A, B, C → D 中特征可视化

### 3.4 PU 轴承数据集验证

#### 3.4.1 PU 轴承数据集

德国帕德博恩大学 (PU) 轴承数据集<sup>[23]</sup> 是在 3 个不同变量采集的振动信号和电流信号, 分别将不同故障类型的滚动轴承安装在滚动轴承测试模块并

以 64 kHz 采样频率的加速度传感器和电流传感器采集信号. 为了更接近工业应用, 本实验选用具有真实损坏的振动信号, 设定每个样本长度为 2560, 并以步幅为 1000 个采样点的滑动窗口进行划分, 数据集描述如表 5 和表 6 所示.

表5 PU 轴承数据集工况说明

工况	转速/rpm	负载扭矩/(N·m)	径向力/N	名称
E	1500	0.7	1000	N15_M07_F10
F	1500	0.1	1000	N15_M01_F10
G	1500	0.7	400	N15_M07_F04

表6 PU 轴承数据集描述

标签	轴承编号	故障模式	损伤程度	损伤组合	训练样本	测试样本
0	K004	健康	—	—	70	30
1	KI18	内圈故障1	1	多次损伤	70	30
2	KI21	内圈故障2	1	单点损伤	70	30
3	KA04	外圈故障1	1	单点损伤	70	30
4	KA16	外圈故障2	2	重复性损伤	70	30
5	KB24	复合故障	3	多次损伤	70	30

3.4.2 实验验证及结果分析

所有方法在 PU 轴承数据集上的诊断结果如表 7 所示. 表 7 结果表明: 由于 PU 数据集的分布差异较大, 一些故障模式特征相似且包含复合故障, 导致

各方法在该数据集上的诊断精度低于 CWRU 数据集上的诊断结果, 其中单源域自适应方法和多源合并域自适应方法在该数据集上的诊断精度降低得更为明显; 而所提出 MAERAN 方法在该数据集中不同迁移任务上仍然能够实现稳定且优异的跨域诊断精度, 这表明了该方法具有较强的鲁棒性和泛化性. 虽然对比方法 MDMAAN 在 E, G → F 迁移任务中诊断精度比 MAERAN 方法略高, 但是在整体上, MAERAN 方法在 3 种迁移任务的平均诊断精度达到了 99.61%, 对比方法 MFSAN、MSSA 与 MDMAAN 的平均诊断精度分别提高了 3.05%、1.25% 和 0.80%, 且在 F, G → E 迁移任务中, 所提出方法诊断精度达到了 100%, 验证了所提出 MAERAN 方法在多源迁移任务中的优越性和泛化性. 同时, 所提出模型在评估指标上的标准差更小, 表明 MAERAN 方法在多源域自适应诊断任务中具有更高的稳定性和鲁棒性.

表7 所有方法在 PU 数据集不同多源迁移任务下的诊断结果

标准	模型	E, F → G		E, G → F		F, G → E		AVG	
		Accuracy	F <sub>1</sub> -score	Accuracy	F <sub>1</sub> -score	Accuracy	F <sub>1</sub> -score	Accuracy	F <sub>1</sub> -score
single best	CNN	76.42±1.36	76.14±0.91	83.50±1.34	83.07±1.23	87.75±1.39	85.91±1.48	82.56	81.71
	DAN	86.72±1.70	86.43±1.58	85.50±1.19	85.27±1.49	91.99±1.79	91.39±1.82	88.07	87.70
	DANN	83.69±1.37	83.32±1.39	91.71±1.80	91.60±1.91	92.97±1.10	92.80±1.34	89.46	89.24
source combine	DAN	93.00±1.56	92.99±1.54	90.26±1.93	90.35±1.84	95.87±1.43	95.64±1.31	93.04	92.99
	DANN	93.75±1.35	93.27±1.32	94.75±1.74	94.72±1.82	96.25±1.02	96.21±0.99	94.92	94.73
multi-source	MFSAN	96.97±0.65	96.44±0.78	95.37±0.44	95.48±0.52	97.35±0.51	97.57±0.54	96.56	96.50
	MSSA	96.75±0.68	96.82±0.67	98.59±0.32	98.61±0.31	99.75±0.33	99.75±0.34	98.36	98.39
	MDMAAN	98.25±0.51	98.29±0.42	<b>99.18±0.30</b>	<b>99.17±0.29</b>	99.00±0.56	98.98±0.57	98.81	98.81
	MAERAN	<b>99.75±0.24</b>	<b>99.75±0.22</b>	99.08±0.75	99.09±0.74	<b>100.00±0.00</b>	<b>100.00±0.00</b>	<b>99.61</b>	<b>99.61</b>

3.4.3 PU 轴承数据集可视化分析

图 5 为不同多源域自适应方法在 PU 数据集上的诊断准确率曲线. 由图 5 可见, 相较于其他对比方法, 所提出 MAERAN 方法能够在较少的训练轮次

内迅速达到较高的诊断准确率, 且在模型收敛后准确率曲线波动较小, 表现出稳定的故障诊断能力. 这验证了多粒度对齐模块和多源诊断信息协同模块两者的有效结合显著提升了模型的训练效率和稳定性.




图5 不同方法在 PU 数据集上的诊断精度曲线

图 6 为不同标准下代表方法在 E, F → G 迁移任务中的特征可视化结果. 其中: “●”为源域类别, “■”为目标域类别, 不同颜色和数字对应不同的故

障类别. 由图 6 可见, 单源域自适应方法 DANN 存在明显分类边界混淆和样本误分问题. 多源合并域自适应方法 DAN 也存在明显的决策边界不清晰问

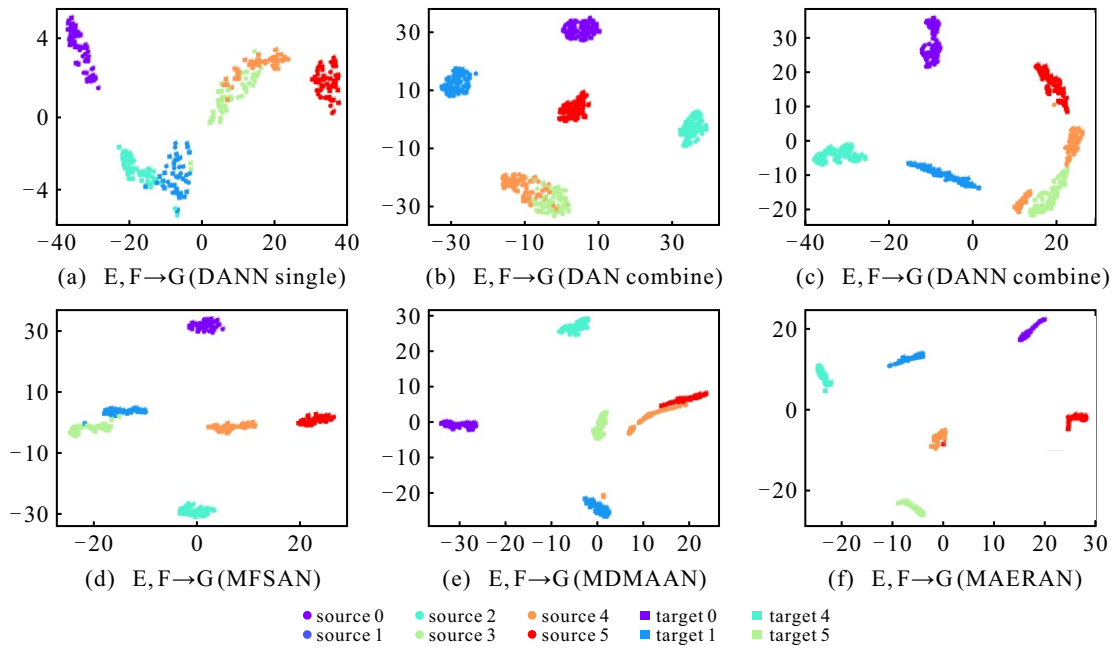


图6 不同方法在迁移任务 E, F → G 中特征可视化

题, 而 DANN 存在域对齐不足问题. 多源域自适应方法 MFSAN 和 MDMAAN 存在轻微的分类边界混淆和样本误分问题. 相比之下, 所提出 MAERAN 方法除出现一例样本误分, 整体分类边界清晰, 且同类故障特征的特征簇更加紧凑, 这表明 MAERAN 能够通过增强具有域一致性和故障可区分性的可迁移特征, 显著提升了诊断性能.

3.5 消融实验

为了验证 MAERAN 方法中各模块在多源无监督迁移任务中的有效性, 本节从 MAERAN 模型中去除浅层特征对齐模块、类对齐模块、多源协同模块

以及不含以上 3 个模块的基准模型, 并分别命名为 MAERAN-1、MAERAN-2、MAERAN-3 和 MAERAN-4, 各方法的实验结果如表 8 所示. 表 8 结果表明, 去除任何一个组件均会导致模型诊断性能下降. 相较于基准模型 MAERAN-4 下的结果, 所提出 MAERAN 方法在两个数据集上的诊断准确率分别提升了 9.72% 和 11.75%, 这表明模型在 3 个组件的作用下能够更有效地学习域不变特征和判别特征, 从而在多源迁移任务中表现出更强的泛化能力和更高的诊断性能.

表8 消融实验结果

方法	浅层特征对齐模块	类对齐模块	多源信息协同模块	A, B, C → D		E, F → G	
				Accuracy	F <sub>1</sub> -score	Accuracy	F <sub>1</sub> -score
MAERAN	√	√	√	99.72±0.27	99.72±0.25	99.75±0.24	99.75±0.22
MAERAN-1		√	√	97.75±0.84	97.54±0.76	97.66±0.93	97.63±0.96
MAERAN-2	√		√	95.18±0.92	95.12 ±0.93	95.32±0.36	95.12±0.39
MAERAN-3	√	√		98.38±0.39	98.20±0.45	98.33±0.36	98.35±0.33
MAERAN-4				90.00±1.47	90.06±1.32	88.00±1.34	87.98±1.21

3.6 多源信息协同模块有效性分析

为了验证多源信息协同模块的有效性, 本节使用信息熵指标分别对 A, B, C → D 任务中各子分类器、平均融合方法和多源信息协同融合方法下测试样本的预测概率分布情况进行评估, 结果如图 7 所示. 由图 7 可见, 不同分类器对相同目标域样本进行决策时做出的预测概率分布不同. 采用平均融合方法虽然在一定程度上降低了不确定性, 但是其结果并不总低于各子分类器, 因此, 不能有效地降低模型

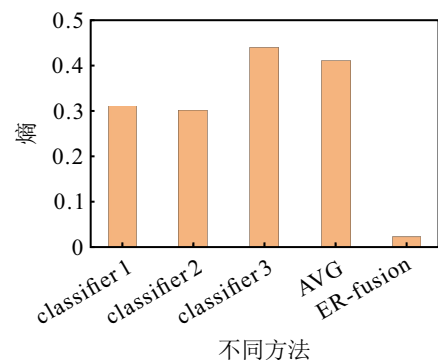


图7 不同方法下的概率分布结果

预测的不确定性. 而多源信息协同融合方法能够更好地利用多源诊断信息, 通过自适应加权融合各子分类器的预测结果, 显著提升了模型预测的稳定性和可靠性.

### 3.7 模型复杂度分析

为全面评估模型诊断性能, 表 9 列出了 A, B, C → D 任务下的 4 种多源域自适应方法的参数量、训练时间和推理时间. 其中: 训练时间是指在 100 次迭代下模型对所有训练样本的平均耗时, 推理时间是指模型对目标域样本进行预测的平均耗时. 表 9 结果表明, 在模型复杂度评估指标上, MAERAN 方法的参数量低于对比方法 MFSAN 与 MDMAAN. 在运行效率指标上, 由于所提出方法在浅层特征、深层域以及类级 3 个维度上实现细粒度分布对齐, 导致模型训练计算复杂度略高于对比方法 MSSA 与 MDMAAN, 但是仍然低于 MFSAN, 且 MAERAN 方法的推理速度较快. 总体而言, MAERAN 方法仍然能够以较低的复杂度和较高的运行效率实现更高的诊断精度, 适用于实际工业故障诊断任务.

表9 模型计算复杂度分析

模型	Params/M	训练时间/(s/epoch)	推理时间/(s/epoch)
MFSAN	5.48	72.10	0.94
MSSA	0.55	2.35	0.08
MDMAAN	5.36	12.87	0.20
MAERAN	3.29	71.95	0.19

## 4 结论

基于现有的多源域自适应智能故障诊断算法的不足, 本文提出了一种基于多粒度对齐和证据推理的多源域自适应网络 MAERAN, 用于多源无监督迁移故障诊断. 首先, 通过多粒度对齐策略来提高领域知识的有效正迁移, 实现了浅层特征级、多视图子域级和类级的多细粒度对齐; 然后, 利用证据推理规则自适应融合多源诊断信息, 促进多分类器协同决策, 从而实现了精准故障诊断; 最后, 通过在两个公开数据集上的实验结果验证了所提出 MAERAN 方法的优越性和泛化性. 然而, 随着设备的复杂性增加, 目标域可能会出现未知故障类型, 现有的模型易将目标域中未知的样本错误地识别为源域中已知类别, 导致诊断性能下降. 因此, 未来的工作将在所提出模型的基础上进一步拓展, 通过设置未知类别判别机制来提升模型对未知故障类型的识别和隔离, 以实现在开集场景下的多源域自适应诊断.

### 参考文献 (References)

[1] Guo J Y, Yang Y L, Li H, et al. A parallel deep neural

network for intelligent fault diagnosis of drilling pumps[J]. *Engineering Applications of Artificial Intelligence*, 2024, 133: 108071.

[2] 李康, 李爽, 高小永, 等. 多变量时序标记 Transformer 及其在电潜泵故障诊断中的应用[J]. *控制与决策*, 2025, 40(4): 1145-1153.

(Li K, Li S, Gao X Y, et al. Multivariate time series tokenized Transformer and its application in fault diagnosis of electric submersible pump[J]. *Control and Decision*, 2025, 40(4): 1145-1153.)

[3] Zhong J H, Lin C, Gao Y, et al. Fault diagnosis of rolling bearings under variable conditions based on unsupervised domain adaptation method[J]. *Mechanical Systems and Signal Processing*, 2024, 215: 111430.

[4] Qian Q, Qin Y, Luo J, et al. Deep discriminative transfer learning network for cross-machine fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2023, 186: 109884.

[5] Ding Y F, Jia M P, Zhuang J C, et al. Deep imbalanced domain adaptation for transfer learning fault diagnosis of bearings under multiple working conditions[J]. *Reliability Engineering & System Safety*, 2023, 230: 108890.

[6] 刘小峰, 金燕, 柏林. 从仿真到现实的多层级虚实域适应的滚动轴承故障诊断方法[J]. *控制与决策*, 2025, 40(3): 889-898.

(Liu X F, Jin Y, Bo L. Simulation-to-reality fault diagnosis based on multi-level joint adaptive network in virtual and real domains of rolling bearing[J]. *Control and Decision*, 2025, 40(3): 889-898.)

[7] Long M, Cao Y, Wang J, et al. Learning transferable features with deep adaptation networks[C]. *Proceedings of the 32nd International Conference on Machine Learning*. Lille, 2015: 97-105.

[8] Ganin Y, Ustinova E, Ajakan H, et al. Domain-adversarial training of neural networks[J]. *Journal of Machine Learning Research*, 2016, 17(59): 1-35.

[9] 文利燕, 陈金陵, 姜斌, 等. 基于联合对抗域自适应网络的跨工况故障诊断方法[J]. *控制与决策*, 2025, 40(5): 1503-1511.

(Wen L Y, Chen J L, Jiang B, et al. A joint adversarial domain adaptive network based cross working conditions fault diagnosis method[J]. *Control and Decision*, 2025, 40(5): 1503-1511.)

[10] Wang Y Q, Zhao Y P. A novel inter-domain attention-based adversarial network for aero-engine partial unsupervised cross-domain fault diagnosis[J]. *Engineering Applications of Artificial Intelligence*, 2023, 123: 106486.

[11] 王嘉铭, 蔡浩原, 柳雅倩, 等. 变负载条件下电机故障的 Transformer-DANN 诊断方法研究[J]. *控制与决策*, 2025, 40(10): 3096-3105.

(Wang J M, Cai H Y, Liu Y Q, et al. Research on motor faults under variable load conditions based on transformer-DANN model[J]. *Control and Decision*, 2025, 40(10): 3096-3105.)

- [12] Tian J H, Han D Y, Li M D, et al. A multi-source information transfer learning method with subdomain adaptation for cross-domain fault diagnosis[J]. *Knowledge-Based Systems*, 2022, 243: 108466.
- [13] 周旷, 覃文博, 孙天宇. 基于可信多源领域自适应的跨域滚动轴承故障诊断[J]. *控制与决策*, 2025, 40(7): 2251-2260.  
(Zhou K, Qin W B, Sun T Y, et al. Cross-domain fault diagnosis of rolling bearings based on trusted multi-source domain adaptation[J]. *Control and Decision*, 2025, 40(7): 2251-2260.)
- [14] 王亚萍, 高圣延, 王新生, 等. 多源域下 MAAN 与 MK-MMD 的滚动轴承跨工况复合故障诊断[J]. *振动工程学报*, 2025, 38(3): 1-12.  
(Wang Y P, Gao S Y, Wang X S, et al. Composite fault diagnosis of rolling bearings across operating conditions with MAAN and MK-MMD in multi-source domains[J]. *Journal of Vibration Engineering*, 2025, 38(3): 1-12.)
- [15] 李晨昀, 景旭文, 李炳强, 等. 基于深度多源子域适应网络的滚动轴承跨域故障诊断[J]. *控制与决策*, 2024, 39(3): 877-884.  
(Li C Y, Jing X W, Li B Q, et al. Cross-domain fault diagnosis of rolling bearings based on deep multi-source sub-domain adaptation networks[J]. *Control and Decision*, 2024, 39(3): 877-884.)
- [16] Chen X K, Shao H D, Xiao Y M, et al. Collaborative fault diagnosis of rotating machinery via dual adversarial guided unsupervised multi-domain adaptation network[J]. *Mechanical Systems and Signal Processing*, 2023, 198: 110427.
- [17] Ganin Y, Lempitsky V. Unsupervised domain adaptation by backpropagation[C]. *Proceedings of the 32nd International Conference on Machine Learning*. Lille, 2015: 1180-1189.
- [18] Gretton A, Borgwardt K M, Rasch M J, et al. A kernel two-sample test[J]. *Journal of Machine Learning Research*, 2012, 13: 723-773.
- [19] Zhang D, Ye M, Liu Y G, et al. Multi-source unsupervised domain adaptation for object detection[J]. *Information Fusion*, 2022, 78: 138-148.
- [20] Yang J B, Xu D L. Evidential reasoning rule for evidence combination[J]. *Artificial Intelligence*, 2013, 205: 1-29.
- [21] Smith W A, Randall R B. Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study[J]. *Mechanical Systems and Signal Processing*, 2015, 64: 100-131.
- [22] van der Maaten L, Hinton G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9(11): 2579-2605.
- [23] Lessmeier C, Kimotho J K, Zimmer D, et al. Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification[C]. *PHM Society European Conference*. Bilbao, 2016: 5-8.

#### 作者简介

陈洋洋 (2000-), 女, 硕士生, 主要研究方向为智能故障诊断, E-mail: [chenyangyang@mail.hfut.edu.cn](mailto:chenyangyang@mail.hfut.edu.cn);

周谧 (1983-), 男, 教授, 博士, 主要研究方向为决策科学与技术、质量评价, E-mail: [zhoumi83@163.com](mailto:zhoumi83@163.com);

张永斌 (1982-), 男, 教授, 博士, 主要研究方向为振动噪声测试、分析与控制, E-mail: [ybzhang@hfut.edu.cn](mailto:ybzhang@hfut.edu.cn).