

DOI: 10.13382/j.jemi.B2508092

基于属性引导细粒度特征对比的小样本 跨域故障诊断方法*

张星泽¹ 赵爽耀^{1,2} 温创辉¹ 闫生茂¹ 蔡正阳^{1,2}

(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)

摘要: 在实际工业场景中,由于故障数据难以获取,且变工况条件下新的细粒度故障模式不断涌现,小样本变工况下跨域故障诊断的需求逐渐凸显。然而,在大规模细粒度故障分类情境下,当前小样本跨域故障诊断方法存在特征甄别能力弱、模型泛化效果差、新类别识别困难等短板。为此,提出了一种基于属性引导细粒度特征对比学习的小样本跨域故障诊断方法,在多任务学习方法的基础上整合有监督对比学习和多属性学习,通过属性学习过程引导故障诊断模型有效区分源域已知细粒度故障特征,同时基于提取的跨类别属性语义信息,采用少样本微调的方式实现目标域未知新故障的精准识别。通过对比各故障诊断方法在少样本、多分类轴承故障数据集上的性能表现,验证了所提方法在小样本细粒度情境下具有优越的跨域诊断性能。

关键词: 小样本跨域故障诊断; 细粒度故障诊断; 有监督对比学习; 多属性学习; 多任务学习

中图分类号: TH17; TH133; TN911.7 **文献标识码:** A **国家标准学科分类代码:** 460.2020

Small-sample cross-domain fault diagnosis method based on attribute-guided fine-grained feature contrast

Zhang Xingze¹ Zhao Shuangyao^{1,2} Wen Chuanghui¹ Yan Shengmao¹ Cai Zhengyang^{1,2}

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

Abstract: In real industrial scenarios, due to the difficulty in obtaining fault data and the continuous emergence of new fine-grained fault modes under variable operating conditions, the demand for small-sample cross-domain fault diagnosis under variable operating conditions has gradually come to the fore. However, in the context of large-scale fine-grained fault classification, the current small-sample cross-domain fault diagnosis methods have shortcomings such as weak feature screening ability, poor model generalization, and difficulty in identifying new categories. To this end, this paper proposes a small-sample cross-domain fault diagnosis method based on attribute-guided fine-grained feature comparison learning, integrating supervised contrastive learning and multi-attribute learning on the basis of multi-task learning method, guiding the fault diagnosis model to efficiently differentiate the known fine-grained fault features in the source domain through the attribute learning process, and realizing the accurate identification of unknown new faults in the target domain based on the extracted semantic information on cross-category attributes and the fine-tuning of fewer samples. In this paper, by comparing the performance of each fault diagnosis method on the sample-small, multi-classification bearing fault dataset, we verify that the proposed method has superior cross-domain diagnosis performance in small-sample fine-grained scenarios.

Keywords: small sample cross-domain fault diagnosis; fine-grained fault diagnosis; supervised contrastive learning; multi-attribute learning; multi-task learning

0 引言

由于无需建立复杂的物理模型,数据驱动的故障诊

断方法具有较强的灵活性和自适应能力^[1],在提高设备可靠性、降低维护成本方面展现出显著优势。然而,实际设备运行过程中故障发生的频率往往较低,故障数据样本稀少^[2],且故障发生后设备往往需要停机检修,故障数

据难以采集^[3]。此类故障诊断问题的共通点在于每种故障类别可供训练的样本数量通常只有几十个甚至更少,难以支撑模型的学习过程,导致小样本问题,这严重阻碍了数据驱动的故障诊断方法在实际工业场景中的应用。当前解决小样本问题的方法主要有数据增强方法^[4-5]、模型优化方法^[6]和基于生成模型的数据生成方法^[7-9]。这些方法通过扩充样本量、改进学习策略的方式,在一定程度上解决了小样本的问题,但生成的样本质量往往较低,难以适应模型的学习过程。

在小样本情境下,由于设备的实际运转环境和工况条件不断发生变化,即使是同一故障类型在不同工况下的数据分布也存在着很大的差异。由于样本数量限制导致模型倾向于学习简单特征、难以提升跨领域变工况下的泛化能力^[3],小样本跨域故障诊断问题因而成为研究热点。当前的小样本跨域故障诊断方法主要采用了“预训练”和“微调”的两阶段范式:在与故障诊断任务相似的前置任务中,通过模型的预训练,得到具有初步泛化能力的特征提取器;之后用少量样本微调故障诊断模型,以快速适应新的工况条件和故障模式。迁移学习方法^[10]通过在相关源域数据中进行有监督的模型预训练,随后在目标域中进行小样本的微调实现跨域诊断;自监督学习方法^[11]采用大规模无标注数据构建伪标签和少量标签数据微调,实现小样本跨域诊断。这两种方法很依赖故障信息和领域知识,如源域数据的规模和伪标签的质量,因此效果和通用性难以保证^[12]。而对比学习方法则利用正负样本对的构建自适应挖掘原始样本的相似差异规律,以此作为预训练的任务目标,提取可判别故障特征表示,实现了少样本信息的深度挖掘,一定程度上摆脱了先验依赖。相关研究分别采用了动量对比^[13]、对抗对比^[14]、领域对比^[15]等方式提取域不变特征和可判别特征以解决各种情境下的小样本跨域故障诊断问题。

虽然对比学习等小样本跨域诊断方法进一步提升了模型的故障识别能力,但由于设备的高度集成与耦合性、工况的深度复杂与多变性,使得新的故障模式不断增长、快速涌现,现有方法难以应对此类大规模故障分类的挑战;同时这些新故障与已知的故障模式之间存在潜在联系,故障类别间的特征差异十分细微,产生了已有方法难以甄别的细粒度故障特征。区别于一般故障特征,细粒度故障特征是在同一种数据分布相似的大类故障之下,进一步根据环境工况、严重程度、故障机制等更细化的属性对故障进行精确区分,从而形成更多、且彼此间差异更微弱的子类故障模式,致使所提取故障特征的判别能力较差。因此如何获取更可区分的故障分类边界,实现细粒度故障特征的精准甄别,以及众多类别故障情境下的精准诊断,是当前小样本跨域诊断问题的难点^[16]。考虑到当下的故障诊断方法大多数是粗粒度的,使用单个属

性划分故障模式难以有效定位故障的程度、原因、位置等详情信息,因而从多个维度和属性视角划分故障类别、获取细粒度故障特征细节、实现细粒度的故障诊断方法具有显著的现实意义。同时,细粒度故障诊断问题作为小样本故障诊断问题的一个重要研究方向^[17],致力于通过已知的细粒度故障知识推断不断出现的新的细粒度故障类型,具有重要的理论研究意义。

当前细粒度故障诊断的研究相对较少,大致可分为元学习方法和零样本学习方法。相关研究将基于故障机制训练的方法^[17]和参数迁移的方法^[18]引入元模型以实现细粒度故障诊断,同时基于单一复合故障的属性关联^[19]和多粒度属性的故障推理^[20]等多标签学习方法识别目标域中新的故障类型。然而,元学习的任务设计过程和数据划分方式对模型学习有很大影响,难以找到能够泛化到多个任务工况的最优元参数^[21];而零样本学习方法依赖于伪标签定义与多属性设计,需要找到能够充分协同源域和目标域故障类别知识的语义信息^[22]。这些方法需要充分依托领域知识和专家判断,也十分依赖细粒度故障的先验信息。

综上所述,在面对大规模细粒度故障分类问题时,当前小样本跨域故障诊断方法难以应对。为此,本文提出了一种属性引导细粒度特征对比的小样本跨域故障诊断方法,区别于传统小样本细粒度故障诊断方法,所设计的故障信息挖掘策略能够充分捕捉细粒度故障类别之间的属性结构规律与语义关联关系,同时能够引导对比学习过程对细粒度故障特征进行更加显著的判别,从而实现细粒度故障类别的有效区分。本文首先改造了有监督对比学习的应用模式,通过引入额外的多标签学习网络分支,在自适应特征对比的过程中嵌入故障语义属性作为先验知识,以引导对比学习更加细致地区分差异微弱的故障特征。其次,基于多任务学习策略,同时整合对比学习和多标签学习两种学习方式,甄别已知的细粒度故障类型,同时结合细粒度故障属性固有的公共语义信息实现新故障的跨域诊断,实现区别于传统细粒度故障诊断方法的高效学习模式。最后,在小样本细粒度的故障诊断情境下,分析了各小样本故障诊断方法在源域、目标域不同类别比例和样本数量下的诊断精度差异,验证了本文所提方法在跨域诊断方面的优越性。

1 相关理论

1.1 对比学习

当前的对比学习方法主要有自监督和有监督两种形式。自监督对比学习通过两种数据增强视图构建正负样本对,以学习原始样本的多视角不变性^[23],将同一样本的数据增强视图作为正样本、不同样本的数据增强视图

作为负样本,通过优化编码后正负样本的特征距离,以此作为自监督任务从未标记数据中提取可判别特征表示。对于样本集合 $\{\mathbf{x}_k, \mathbf{y}_k\}_{k=1}^N$,通过数据增强生成扩展样本集 $\{\tilde{\mathbf{x}}_i, \tilde{\mathbf{y}}_i\}_{i=1}^{2N}$,其中 $\tilde{\mathbf{x}}_{2k-1}$ 和 $\tilde{\mathbf{x}}_{2k}$ 是针对原始样本 x_k 进行两种数据增强后得到的扩展样本,则自监督对比学习的损失函数如式(1)所示。

$$L_{self} = - \sum_i \log \frac{\exp(\mathbf{z}_i \cdot \mathbf{z}_{j(i)} / \tau)}{\sum_{a \in A(i)} \exp(\mathbf{z}_i \cdot \mathbf{z}_a / \tau)} \quad (1)$$

式中: \mathbf{z}_i 表示原始样本 \mathbf{x}_i 的编码特征; $\mathbf{z}_{j(i)}$ 表示样本 \mathbf{x}_i 对应的正样本特征; $A(i)$ 表示样本 \mathbf{x}_i 所有正负样本的索引集合; τ 为正则化温度参数。在损失函数中引入温度参数 τ 是因为其能够调节相似性分布程度,提升特征对比的效果。较小的温度值 τ 会使得相似度差异变得更大,让模型更倾向于提升相似样本对的相似度、降低不相似样本对的相似度,以调节训练过程中的正负样本区分程度。

由于自监督对比学习没有充分利用标签信息,即使同属一类的样本也会在特征空间中彼此分离。有监督对比学习则基于类别标签的异同构建正负样本对,获取更加可分的分类边界和更加具有可判别性的泛化特征表示,以提升故障分类效果^[24]。有监督对比学习的整体目标如式(2)所示,旨在减少同类正样本的特征差异、增加异类负样本的特征差异,使得同类故障样本在特征空间中更加聚集^[25]。

$$L_{sup} = \sum_i \left(- \frac{1}{|P(i)|} \sum_{p \in P(i)} \log \frac{\exp(\mathbf{z}_i \cdot \mathbf{z}_{j(i)} / \tau)}{\sum_{a \in A(i)} \exp(\mathbf{z}_i \cdot \mathbf{z}_a / \tau)} \right) \quad (2)$$

其中, $P(i) = \{p \in A(i); \tilde{\mathbf{y}}_p = \tilde{\mathbf{y}}_i\}$ 表示与原始样本有相同类别标签的正样本集合; $|P(i)|$ 为集合中正样本的数量。

1.2 多标签学习

在多标签学习中,一个样本拥有多个标签,这些标签共同构成原始样本的属性描述,因此也称为多属性学习。区别于单标签的类别学习,多标签学习将人工标注的多个属性伪标签作为模型的学习对象和训练目标,以优化各个属性的联合学习过程,理解多个属性之间的语义联系和内在结构规律。在此基础上,通过利用已知类别的样本训练模型,并通过类别间的语义关系作为辅助信息,使得模型在微调过程中能够识别未见类别的样本^[26],适用于解决跨域故障诊断问题。对于多标签样本集 $\{[x_i, (\mathbf{a}_i^1, \mathbf{a}_i^2, \dots, \mathbf{a}_i^L)]\}_{i=1}^N$,共有 N 个样本和 L 个属性标签,第 l 种属性共有 C_l 个值。将每个属性匹配到对应 C_l 个属性值的过程视为单标签的有监督分类问题,则通过多标签学习可以整合所有属性的学习过程,其整体目标如

式(3)所示。

$$L_{multilabel} = \sum_{i=1}^L \left(- \frac{1}{N} \sum_{i=1}^N \sum_{c=1}^{C_l} \mathbf{a}_i^l(c) \log \hat{\mathbf{a}}_i^l(c) \right) \quad (3)$$

式中: $\mathbf{a}_i^l \in \{0,1\}^{C_l}$ 为样本 x_i 第 l 种属性的标签向量,采用独热编码的方式进行标注; $\mathbf{a}_i^l(c) \in \{0,1\}$ 表示向量的第 c 维度值。而 $\hat{\mathbf{a}}_i^l \in [0,1]^{C_l}$ 为输出特征 \mathbf{z}_i^l 经过 softmax 归一化的概率向量,代表原始样本 x_i 属于第 l 种属性各个取值的概率分布; $\hat{\mathbf{a}}_i^l(c)$ 和 $\mathbf{z}_i^l(c)$ 分别表示向量的第 c 维度值,计算方法如式(4)所示。

$$\hat{\mathbf{a}}_i^l(c) = \frac{\exp[\mathbf{z}_i^l(c)]}{\sum_{k=1}^{C_l} \exp[\mathbf{z}_i^l(k)]} \quad (4)$$

1.3 多任务学习

多任务学习的核心思想在于用一个统一网络联合多个相关任务,使任务中包含的知识或学习能力可以被其他任务利用,从而充分提升模型的学习效果和泛化能力。最常见的多任务学习设计是基于特征层共用的方式,多个任务在共享层进行参数的共享,对于 k 种任务,其学习目标如式(5)所示。

$$L_{multitask} = \sum_{k=1}^K \alpha_k L_k \quad (5)$$

式中: α_k 为第 k 个任务的权重; L_k 为第 k 个任务的损失函数。由于共享参数是完全相同的,可以在保证任务独立性的同时,提升模型的学习速度与训练效率,并能够充分降低模型过拟合的风险^[27]。此外,多个损失函数整体联合优化能够确保模型实现既定的多目标需求,同时通过损失权重平衡主要任务和辅助任务的不同作用,使模型发挥预期的性能。

2 方法框架

2.1 方法整体框架

有监督对比学习旨在学习原始数据的相似与差异分布规律,更聚焦两个样本是否属于同一类,而不关注它们具体属于哪个类别,对于数据分布极度相似、特征差异极度微弱的两类细粒度故障样本,很容易出现特征难以区分和边界样本误分类的现象,难以适用于细粒度故障诊断问题。而通过属性引导对比学习的过程,不仅能够让模型充分考虑样本是否同属一类,还能根据两类样本的故障属性是否相同,有针对性地优化边界样本的特征表示,从而对比区分出属性相近、特征差异细微的两类困难样本,因此能够实现更细粒度的故障特征甄别。

同时,相较于对比学习更加聚焦特征的可分能力,属性学习更注重提取带有语义信息的域不变特征,因而能够引导对比学习兼顾泛化性和判别性特征的提取,对于

跨越的新故障识别具有更好的适应性。此外,由于所学习的故障属性能够在源域的已知故障与目标域的未知故障之间共享,因此通过属性引导特征对比的过程,即便目标域的故障类别未知,也能够确保模型在样本有限时挖掘到足够丰富的故障知识,避免过度拟合已知类别而忽视潜在新故障的语义信息,使模型更易通过少量样本学习快速泛化到新故障中。

有监督对比学习具有提取判别性特征的能力,但是在细粒度的情境下难以区分差异微弱的故障特征,因此

需要引入属性这一先验知识增强模型对这些相似细粒度故障的区分效果。本文提出了一种完备的小样本细粒度跨域故障诊断框架,集成了多任务学习、对比学习和多属性学习等先进学习策略,如图 1 所示。所提方法采用多任务学习策略,使多属性学习网络与对比学习网络同时共享特征提取层,用属性推理方法引导对比学习过程从众多的故障类别中对比挖掘出更可分的细粒度故障特征表示。

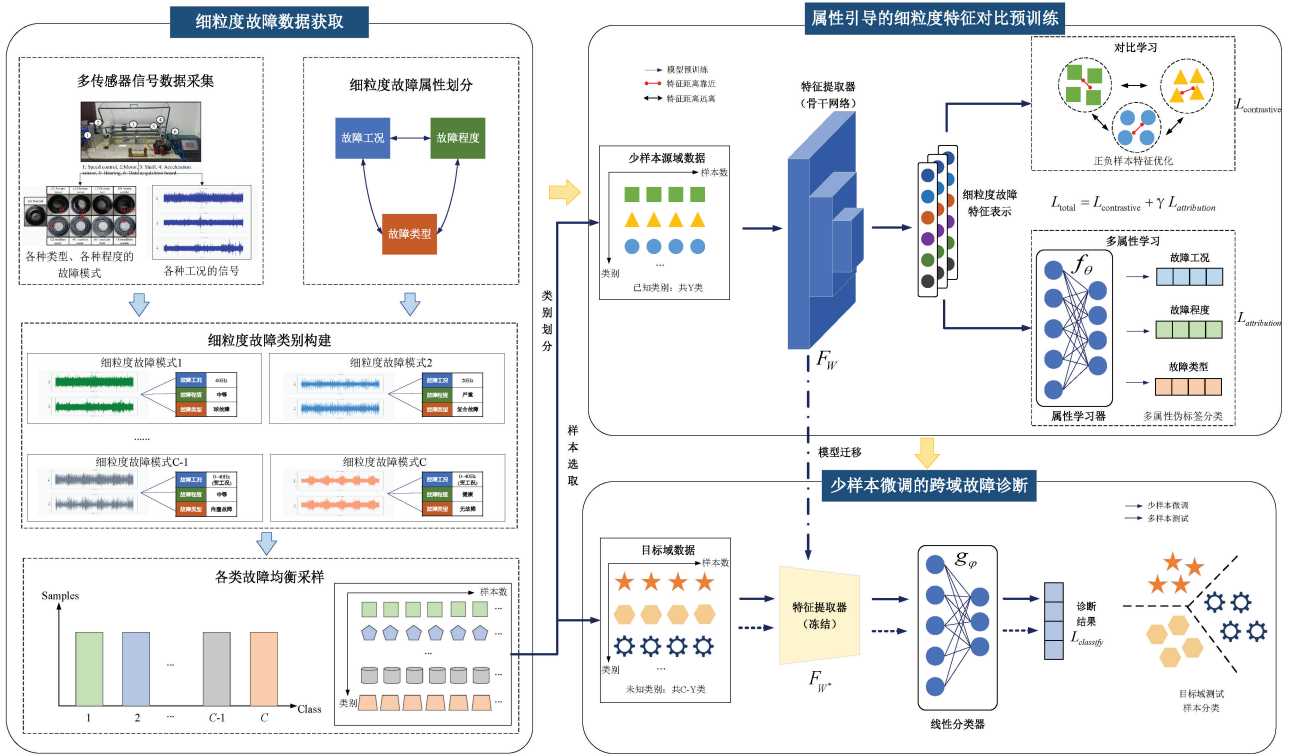


图 1 所提方法整体框架

Fig. 1 Overall framework of the proposed method

方法的整体目标是用源域的已知故障类别推断目标域的未知故障类别,在构造样本时基于多维度的细粒度属性进行故障类别划分,将各种故障属性下的每一组取值都视为一个细粒度故障类型。同时为了确保模型能够同等区分所有的细粒度故障模式,引入均衡采样策略,确保源域和目标域各类别的样本数量一致,以模拟小样本细粒度的跨域故障诊断情境。在此基础上,进一步划分故障标签,确保源域和目标域的故障类别完全不重叠,并进行少样本的选取,通过预训练和微调的两阶段方式逐步实现小样本细粒度的跨域故障诊断。

在模型预训练阶段,针对类别已知的源域少样本进行属性引导的细粒度特征对比学习。方法整体框架由带有两个分支结构的多任务学习网络构成,其中一个网络

采用有监督对比学习以提取可判别故障特征,另一个属性学习网络辅助对比学习从已知的细粒度类别中推断出故障属性知识,以引导对比学习过程更加关注属性分布相似但本质不同的两个故障类别,自适应挖掘更具泛化性和区分能力的细粒度故障特征表示,从而确保模型在特征对比的过程中识别故障类别间的可解释规律和共同语义信息,指导目标域细粒度故障的识别。

在少样本微调阶段,将预训练好的骨干模型作为特征提取器并冻结其参数,同时在特征输出层后引入全连接线性分类层,用目标域的少量新类别样本微调线性分类网络,得到最终的故障诊断模型。在预训练和微调完成之后,用目标域的大量新故障样本进行模型测试,验证模型在小样本跨域诊断情境下的故障识别效果与泛化能力。

2.2 细粒度故障数据获取

在各种工况条件、各种程度的故障类型下采集多传感器信号,同时基于各种属性取值划分细粒度故障类别,并针对每个类别的信号进行采样和标准化的预处理构建原始样本,得到包含 C 类、每类样本容量相等的全部细粒度故障数据集。在此基础上,从中抽取 Y 类、每类 N 个少样本作为源域数据,用于模型预训练; C - Y 类目标域数据,每类抽取 N 个少样本用于微调;其余的多个样本用于模型测试。将第 c 类第 i 个细粒度样本记为 $\mathbf{X}_i^c \in \mathbf{R}^{M \times L}$,其中 M 为传感器采集的信号通道数, L 为单个样本的信号长度。

2.3 属性引导的细粒度特征对比预训练

1) 对比学习网络

将源域中同一类别的细粒度故障作为正样本,不同类别的细粒度故障作为负样本,以优化正负样本对在编码特征空间中的距离,从而获取可判别特征空间和细粒度故障特征提取器。为确保在众多故障类别的对比是平衡且充分的,在样本构建时确保每个类别的样本数量均等。由此可以得到正样本对集合和负样本对集合如式(6)和(7)所示。

$$\{(\mathbf{X}_i^c, \mathbf{X}_j^c)\}, i \neq j, c = 1, 2, \dots, Y \quad (6)$$

$$L_{contrastive} = -\frac{1}{YN} \sum_{c=1}^Y \sum_{i=1}^N \log \frac{\sum_{j=1, j \neq i}^N \exp(\mathbf{z}_i^c \cdot \mathbf{z}_j^c / \tau)}{\sum_{j=1, j \neq i}^N \exp(\mathbf{z}_i^c \cdot \mathbf{z}_j^c / \tau) + \sum_{c'=1, c' \neq c}^Y \sum_{k=1}^N \exp(\mathbf{z}_i^c \cdot \mathbf{z}_k^{c'} / \tau)} \quad (9)$$

2) 多属性学习网络

在模型预训练的过程中,使用故障工况、故障程度和故障类型这 3 种通用的故障属性划分细粒度故障类别。为保证模型从故障样本中充分学习这些细粒度的属性知识,采用 1.2 节多标签学习方式同时进行 3 种属性的分类。假设故障工况共有 R 种属性值,故障程度有 S 种属性值,故障类型有 T 种属性值,则原始样本 \mathbf{X}_i^c 的属性伪标签为 $(\mathbf{o}_i^c, \mathbf{p}_i^c, \mathbf{q}_i^c)$,其中 $\mathbf{o}_i^c \in \{0, 1\}^R$, $\mathbf{p}_i^c \in \{0, 1\}^S$, $\mathbf{q}_i^c \in \{0, 1\}^T$,分别表示 3 个长度分别为 R 、 S 和 T 的独热编码向量,表明其在 3 种故障属性下的取值分布。

由于多属性学习网络与对比学习网络共享特征提取层,将原始样本 \mathbf{X}_i^c 经过特征提取器 F_w 输出的特征 \mathbf{z}_i^c 注入到带有 3 个并行 softmax 线性分类层的属性学习器 f_θ 中,然后分别针对故障工况、故障程度、故障类型这 3 种属性执行特定的学习过程,过程如式(10)所示。

$$(\hat{\mathbf{o}}_i^c, \hat{\mathbf{p}}_i^c, \hat{\mathbf{q}}_i^c) = f_\theta(\mathbf{z}_i^c) \quad (10)$$

式中: $\hat{\mathbf{o}}_i^c$ 、 $\hat{\mathbf{p}}_i^c$ 、 $\hat{\mathbf{q}}_i^c$ 分别表示在故障工况、故障程度和故障类型学习下的属性推断向量,用于表征 3 种属性在各自不同取值下的概率分布。

在此基础上,采用属性分类的策略,构造如式(11)~(13)所示的交叉熵损失函数作为优化目标,分别对故障

$$\{(\mathbf{X}_i^c, \mathbf{X}_k^{c'})\}, c \neq c', i, k = 1, 2, \dots, N \quad (7)$$

考虑一维卷积神经网络(1D convolutional neural network, 1DCNN)模型适配信号数据的特性,采用基于 1DCNN 的骨干结构作为特征提取器 F_w ,从原始样本 \mathbf{X}_i^c 中提取特征 \mathbf{z}_i^c ,并将其用于细粒度特征对比学习,过程如式(8)所示。

$$\mathbf{z}_i^c = F_w(\mathbf{X}_i^c) \quad (8)$$

其中, $\mathbf{z}_i^c \in \mathbf{R}^d$, d 为骨干模型所编码特征的维度。

基于特征提取器获得的特征表示,计算正负样本在特征空间中的分布距离,采用有监督的信息对比损失^[28]作为细粒度特征对比的优化目标,如式(9)所示。同类故障样本在特征空间中更加靠近,其距离 $\mathbf{z}_i^c \cdot \mathbf{z}_j^c$ 缩小,同时异类故障样本在特征空间中彼此远离,其距离 $\mathbf{z}_i^c \cdot \mathbf{z}_k^{c'}$ 增大。温度参数 τ 旨在调节样本的对比区分程度^[29]。损失函数旨在提升 \mathbf{X}_i^c 所有正样本相似度 $\sum_{j=1, j \neq i}^N \exp(\mathbf{z}_i^c \cdot \mathbf{z}_j^c / \tau)$ 相较于 \mathbf{X}_i^c 所有正负样本对相似度的对数似然概率。最后针对全部 $Y \cdot N$ 个故障样本,优化不同细粒度故障的特征距离,以使模型学习到细粒度故障样本的全局特征表示和细粒度故障类别的整体相似性分布。

工况属性的 R 种取值进行分类、对故障程度属性的 S 种取值进行分类和对故障类型属性的 T 种取值进行分类。其中 $\hat{\mathbf{o}}_i^c(r)$ 表示样本在工况属性学习下取第 r 个属性值的概率, $\hat{\mathbf{p}}_i^c(s)$ 和 $\hat{\mathbf{q}}_i^c(t)$ 分别表示在故障程度和故障类型的属性学习下分别取第 s 个属性值和第 t 个属性值的推断概率。

$$L_{condition} = -\frac{1}{YN} \sum_{c=1}^Y \sum_{i=1}^N \sum_{r=1}^R \mathbf{o}_i^c(r) \log \hat{\mathbf{o}}_i^c(r) \quad (11)$$

$$L_{severity} = -\frac{1}{YN} \sum_{c=1}^Y \sum_{i=1}^N \sum_{s=1}^S \mathbf{p}_i^c(s) \log \hat{\mathbf{p}}_i^c(s) \quad (12)$$

$$L_{type} = -\frac{1}{YN} \sum_{c=1}^Y \sum_{i=1}^N \sum_{t=1}^T \mathbf{q}_i^c(t) \log \hat{\mathbf{q}}_i^c(t) \quad (13)$$

将所有的属性学习过程整合为一个统一的优化目标,进行多标签的故障属性分类,以充分捕捉各种属性间的结构规律和依赖关系,如式(14)所示。

$$L_{attribution} = L_{condition} + L_{severity} + L_{type} \quad (14)$$

3) 多任务学习网络

考虑到属性对于对比学习的重要引导作用,基于多任务学习框架同时整合对比学习网络和属性学习网络,提取关键可判别特征,以增强细粒度故障的甄别能力和模型的诊断效果。结构化的属性知识显式地定义了细粒度故障类别之间的语义差异和属性关系,区别于学习类

别标签本身,能够获取更加完备的可解释故障规律,使得对比学习过程更加准确地关注细微但关键的判别特征差异,提升对于两种高度相似故障类别的区分程度。在此过程中,基于属性推理的知识驱动方法将属性嵌入的语义信息 $L_{attribution}$ 作为额外监督信号,放大两个相似但不同类别的对比损失 $L_{contrastive}$,提升数据驱动的对比学习过程对于相似类别的细粒度特征差异的敏感性,从而显著增强模型对于类别众多、差异细微故障模式的辨识能力。

整体优化目标如式(15)和(16)所示。

$$L_{total} = L_{contrastive} + \gamma L_{attribution} \quad (15)$$

$$W^* = \operatorname{argmin}_W L_{total} \quad (16)$$

其中, γ 为正则化参数,用来平衡属性学习的辅助目标对于细粒度特征对比这一主要目标的引导效果与贡献程度,同时确保对比损失和属性学习损失的尺度在学习过程中保持一致,提升模型的特征提取能力与优化效果。模型整体的优化过程正是搜索最优特征提取器参数 W^* 的过程。

2.4 基于少样本微调的跨域故障诊断

由于属性引导特征对比的过程使得模型学习到了跨类别的故障语义信息,模型已具备适应新的细粒度故障的能力。在获取到最优的特征提取器 F_{W^*} 后,将最优模型参数 W^* 迁移到目标域的故障诊断网络中。对于目标域的任意一个新故障样本 \mathbf{X}_i^c ,其标签为 y_i^c 。采用特征提取器 F_{W^*} 进行初步的特征编码,并将特征 z_i^c 输入到带有 softmax 层的全连接线性分类器 g_φ 中,得到故障推断向量 \hat{y}_i^c ,它表示该样本在各个故障类别下的概率分布。在此基础上,采用交叉熵分类损失函数 $L_{classify}$ 针对线性分类器 g_φ 进行少量样本的参数微调,以获得最优的故障诊断模型。这里的微调策略即为获取最优参数 φ^* 的过程,以精准识别发生在目标域中的 $C-Y$ 个新类别。

整体流程如式(17)~(20)所示。

$$z_i^c = F_{W^*}(\mathbf{X}_i^c) \quad (17)$$

$$\hat{y}_i^c = g_\varphi(z_i^c) \quad (18)$$

$$L_{classify} = - \sum_{c=Y+1}^C \sum_{i=1}^N \sum_{l=1}^{C-Y} y_i^c(l) \log \hat{y}_i^c(l) \quad (19)$$

$$\varphi^* = \operatorname{argmin}_\varphi L_{classify} \quad (20)$$

在微调结束后,采用大量的目标域样本进行测试,验证模型的跨域故障诊断能力与泛化效果。

3 实验设计

3.1 数据来源与预处理

实验所采用的数据集来源于华中科技大学轴承故障数据集^[30],使用 Spectra-Quest 机械故障实验台和人工注入的方式来模拟轴承的各种故障类型,所选用的轴承型

号为 ER-16K 深沟球轴承,采样频率为 25.6 kHz,每种转速下每种故障的采集时间为 10.2 s,采样点数均为 262 144。如表 1 所示,在 11 种工况、3 种故障程度和 5 种故障类型的属性划分下,共包含 99 个细粒度故障类别。每个故障类别采集 X 、 Y 和 Z 共 3 个方向加速度传感器的振动信号作为原始数据。在样本构建过程中,采用大小 4 096、步长 512 的滑动窗口针对原始信号进行采样,得到每一类 505 个样本,单个样本的尺寸大小为 $[3, 4 096]$,然后针对每个样本进行最大最小归一化处理以确保各样本的数据分布是一致的。

表 1 细粒度故障属性划分

故障属性	取值	属性描述
故障工况	20、25、30、35、40、60、65、70、75、80、0~40 Hz	轴承在不同运转条件下的工况,包括 10 种固定工况和 1 种变化工况
故障程度	X(严重故障)、0.5X(中等故障)、H(不严重故障)	轴承的严重程度
故障类型	I(内圈故障)、O(外圈故障)、B(球故障)、C(复合故障)、H(健康)	轴承故障发生的位置及具体类型,包括 4 种故障状态和 1 种健康状态

各种原始的细粒度故障信号示例如图 2 所示,相较于图 2(a),图 2(b)~(d) 分别有 1 种、2 种、3 种属性的取值有所不同。可以看出,对于仅有 1 种属性取值不同的两类故障信号,其振动模式、特征频率、缺陷形式和运作机理十分相似,在原始信号中很难进行区分;而对于属性取值差异更大的故障信号,观测到它们的时域特征差异较为明显。实验旨在通过提取细粒度故障特征,对这些极度相似或差异显著的细粒度故障信号进行全面分类。

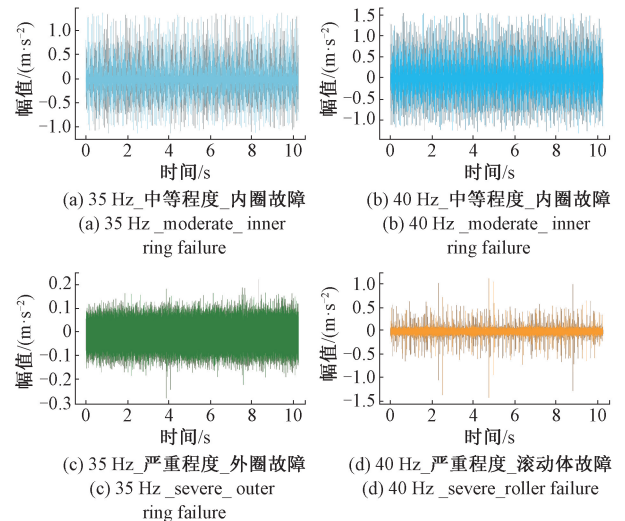


图 2 各种细粒度故障示例

Fig. 2 Examples of various fine-grained faults

图 3 所示为细粒度故障特征与一般故障特征的区别。相比于一般故障特征(图 3(a)),细粒度故障特征(图 3(b))在故障大类的基础上进一步细分子类,类别数量显著增加,诊断难度更大。且图 3(b)中故障模式相近的细粒度类别,其特征间的差异极其微弱,导致分类边界不明显,这使得模型很容易混淆各个相似类别,特征判别难度相比一般故障更大。此外,从图 3(b)观察到,由于细粒度类别较多而样本数量有限,模型会对故障模式显著差异的类别区分效果较好,而会减少其他相似类别的关注,极易过拟合少数类别而忽视整体差异规律。故相比一般故障特征的提取依靠数据规模,细粒度故障特征的质量更加依赖于故障知识和语义信息的引导,基于更强的可解释性与泛化能力,细粒度故障特征能够有效区分相似故障并适应新故障。因此,采用所提方法增强细粒度故障特征的判别力与泛化性,能够提升模型对于细粒度故障特征的甄别效果和相似故障的分类能力,有助于细粒度故障的跨域诊断过程。

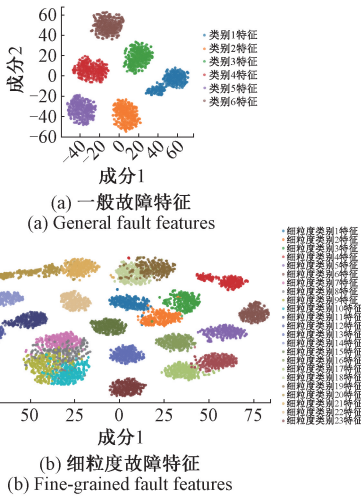


图 3 一般故障特征与细粒度故障特征的对比
Fig. 3 Comparison of general fault features and fine-grained fault features

3.2 训练策略与参数设置

在属性引导的细粒度特征对比学习过程中,从原始数据集选取指定类别及数量的少样本,输入模型中预训练 500 个 Epoch,学习率固定为 0.001,设置正则化的任务权重参数 $\gamma = 1$ 以平衡对比学习和属性学习在细粒度特征提取中的贡献性,并设置对比学习温度参数 $\tau = 0.05$ 。所采用 1DCNN 特征提取器参考文献[21],模型结构如表 2 所示,最终模型输出特征为 512 维。

跨域故障诊断过程如下:首先从目标域数据的每一类中随机抽取指定数量的少样本分别用于模型微调和精度验证,并保存验证集精度最高的一轮模型、使用除了训练样本之外的其他所有样本进行测试,最终测试结果用

表 2 特征提取器参数

Table 2 Parameters of the feature extractor

模型各层名称	卷积参数 (通道数 * 核大小 * 步长)	池化参数 (尺寸 * 步长)	输出维度	激活函数
输入层	—	—	[3, 4 096]	—
卷积层 1	32 * 64 * 16	—	[32, 256]	ReLU
最大池化层 1	—	2 * 2	[32, 128]	—
卷积层 2	32 * 4 * 1	—	[32, 128]	ReLU
最大池化层 2	—	2 * 2	[32, 64]	—
卷积层 3	64 * 4 * 1	—	[64, 64]	ReLU
最大池化层 3	—	2 * 2	[64, 32]	—
卷积层 4	64 * 4 * 1	—	[64, 32]	ReLU
最大池化层 4	—	2 * 2	[64, 16]	—
卷积层 5	128 * 4 * 1	—	[128, 16]	ReLU
最大池化层 5	—	2 * 2	[128, 8]	—
卷积层 6	128 * 4 * 1	—	[128, 8]	ReLU
最大池化层 6	—	2 * 2	[128, 4]	—
特征展平层	—	—	512	—

于验证模型性能。在此基础上,考虑细粒度故障诊断情境,构造源域和目标域不同类别比例下的各种实验组,以考察细粒度故障知识充分和缺乏时的模型跨域诊断能力。其中微调和验证 300 个 Epoch,学习率设置为固定的 0.01。

样本数据划分方法如下:从 99 个类别中随机抽取若干故障类别的少样本作为源域数据进行预训练,其余故障类别的少样本作为目标域数据用于微调,以验证所提方法在各种细粒度情境下的优越性。同时,由于显存能够负担全部少样本的容量,因此将批次大小设置为全部训练样本数。采取的实验组及对应样本划分策略如表 3 所示。

表 3 实验组信息

Table 3 Experimental group information

实验组代号	源域类别数:	源域样本数		目标域样本数	
	目标域类别数	预训练集	微调集	验证集	测试集
4 : 1 (10)	80 : 19 (~4 : 1)	10	10	10	
4 : 1 (20)	80 : 19 (~4 : 1)	20	20	20	
4 : 1 (50)	80 : 19 (~4 : 1)	50	50	50	
4 : 1 (100)	80 : 19 (~4 : 1)	100	100	100	
3 : 1 (10)	75 : 24 (~3 : 1)	10	10	10	
3 : 1 (20)	75 : 24 (~3 : 1)	20	20	20	
3 : 1 (50)	75 : 24 (~3 : 1)	50	50	50	
3 : 1 (100)	75 : 24 (~3 : 1)	100	100	100	其余所
2 : 1 (10)	66 : 33 (2 : 1)	10	10	10	有样本
2 : 1 (20)	66 : 33 (2 : 1)	20	20	20	
2 : 1 (50)	66 : 33 (2 : 1)	50	50	50	
2 : 1 (100)	66 : 33 (2 : 1)	100	100	100	
1 : 1 (10)	50 : 49 (~1 : 1)	10	10	10	
1 : 1 (20)	50 : 49 (~1 : 1)	20	20	20	
1 : 1 (50)	50 : 49 (~1 : 1)	50	50	50	
1 : 1 (100)	50 : 49 (~1 : 1)	100	100	100	

3.3 对比实验

考虑到实验是在细粒度故障诊断情境中进行的,各种故障类别之间包含一些内在的属性依赖关系。本文所提方法中的多属性学习网络正是用于识别这种属性之间的结构关系,将其引入对比学习的细粒度故障区分过程,能够取得更好的效果。本文围绕多属性学习和标签学习等关键方法开展对比实验,同时横向对比了简单对比学习框架(a simple framework for contrastive learning, SimCLR)^[31]和动量对比(momentum contrast, Moco)^[13]等经典的自监督对比学

习方法,以及多尺度动态对比^[25]等先进的有监督对比学习方法,采用了两阶段的跨域诊断方式。这些方法均在目标域中对新的故障类别进行少样本微调,只在源域的预训练过程有所区分,分别采用了不同的小样本学习策略。

为确保对比标准的一致性和实验结果的可靠性,对比实验采用相同的模型结构和参数设置。同时,为避免偶然因素对实验造成的影响,针对每种方法采用固定的随机种子重复 10 次实验,计算平均值和标准差。表 4 为各方法的训练策略。

表 4 各方法的训练策略

Table 4 Training strategies for each method

方法	源域训练策略		目标域训练策略	
	预训练		微调	测试
基于 SimCLR 的自监督对比学习 ^[31]	采用简单对比学习框架进行自监督的特征对比			
基于 Moco 的自监督对比学习 ^[13]	采用动量对比方法提升自监督特征对比的稳定性			
迁移学习 ^[32]	采用单标签的类别学习			
有监督对比学习 ^[28]	采用有监督的对比学习			
多属性学习 ^[22]	采用多标签的属性学习		采用新故障类别进行少样本的微调	用最优模型测试多样本的新故障
标签引导的细粒度特征对比学习	同时采用带有标签的监督学习和有监督对比学习,以验证属性学习较标签学习的优越性			
多尺度动态有监督对比学习 ^[25]	在有监督对比学习的损失函数和标签学习的分类损失中引入对不同类别的动态关注权重,提升对困难类别样本的分类效果			
属性引导的细粒度特征对比学习	同时采用多属性学习和对比学习,以充分凸显属性学习引导细粒度特征对比的有效性			

表 5 为方法在不同诊断情境下的精度对比。实验结果表明,在源域类别数较多时,标签引导的细粒度特征对比学习方法已经能够充分获取标签中蕴藏的故障信息和属性规律,相较所提方法更优;但在源域类别数量较少时,获取到的细粒度故障类别信息明显不足,相较于所提方法更难捕捉细粒度故障属性规律。而多尺度动态有监督对比学习方法也采用了标签信息在损失中给实时诊断精度较低类别赋予更高的权重,以促进困难样本的特征对比,但其诊断精度仍低于所提方法。因此,属性学习相较于标签学习更有助于引导模型进行小样本细粒度的故障诊断。

面对样本数较多的情形,如当样本数量为 100 时,标签学习的性能优于有监督对比学习和属性学习,这是因为样本数量增加更有助于有监督学习的过程,让模型能够从大量样本中获取更可通用的故障知识。当样本数较少时,有监督对比学习能够从有限的样本关系中挖掘数据结构规律和故障特征信息,从而发挥更明显的优势。而自监督对比学习方法由于没有采用任何的类别标签信息和故障先验知识,在故障类别很多的情况下难以提取

有效的判别性特征,因此诊断精度较低。

此外,随着样本数增加、源域类别数增加,各种方法的诊断精度也会逐渐提升,由此可见样本数量和标签信息对于模型训练至关重要,这有助于模型挖掘更多维度的故障特征表示、理解更加全面的细粒度故障信息。本文所提方法在各种细粒度诊断情境下的精度分布如图 4 所示,可以发现,随着细粒度故障知识增多、样本信息增多,其诊断精度会有明显的提升。图 4 红色区域表明,本文所提方法在大多数情境下都具有很好的诊断性能。各种细粒度诊断情境下的方法精度对比如图 5 所示。图 5 表明,在大多数跨域诊断情境下,本文所提方法相较于其他方法都取得了更好的效果,由此可见其精度和泛化能力方面的优越性。

在此基础上,以源域和目标域类别比为 3 : 1、少样本数量为 50 的小样本细粒度故障诊断情境为例,追溯相关的训练过程并展示可视化结果,进一步分析所提方法的优越性。各方法在微调过程中的精度变化趋势如图 6 所示。本文所提方法在微调过程中能够让诊断模型高效地拟合少量新故障样本,且收敛后精度波动很小,几乎趋

于平稳不变,可见模型能够较好地适应新工况,快速识别新故障模式,发挥稳定高效的跨域故障诊断性能。因此,

本文所设计的属性引导细粒度特征对比策略能够获得更具泛化性的特征提取器。

表 5 各方法在不同诊断情境下的精度对比

Table 5 Comparison of the accuracy of the methods in different diagnostic situations

源域类别数: 每类样本数	目标域类别数	方法精度/%							
		基于 SimCLR 的自监督对比学习	基于 Moco 的自监督对比学习	迁移学习	有监督对比学习	多属性学习	标签引导的细粒度特征对比学习	多尺度动态有监督对比学习	属性引导的细粒度特征对比学习(本文)
80 : 19 (~4 : 1)	10	52.47±5.46	56.02±5.02	64.85±5.39	73.92±6.29	69.68±4.41	77.48±3.84	77.73±3.96	85.88±4.37
	20	67.35±4.57	70.25±4.13	77.63±4.22	85.31±5.12	81.10±4.18	88.45±4.15	87.28±4.70	89.55±4.07
	50	84.12±3.66	86.52±3.42	90.30±3.29	91.11±4.28	90.84±3.51	94.62±3.38	92.91±3.54	94.14±3.18
	100	86.58±2.56	89.78±2.34	95.03±2.73	92.51±3.53	94.02±3.32	96.38±2.48	95.14±2.67	96.11±2.56
75 : 24 (~3 : 1)	10	48.55±4.81	51.25±4.42	60.92±4.04	70.32±4.79	64.51±3.44	73.82±3.47	73.86±3.54	76.55±3.63
	20	63.03±3.72	66.35±3.47	73.92±3.54	81.67±4.59	78.18±2.52	86.32±2.69	84.51±2.84	87.43±2.68
	50	82.75±3.43	84.59±3.04	88.22±2.19	88.26±4.10	88.79±2.60	93.28±2.29	91.83±2.23	93.02±2.42
	100	85.69±3.11	88.44±2.92	93.65±2.11	91.06±3.40	92.48±2.45	95.18±1.91	94.30±2.58	95.09±1.98
66 : 33 (2 : 1)	10	42.33±3.66	45.29±3.14	53.68±3.82	66.24±3.19	57.52±2.67	68.05±2.82	67.74±3.20	70.93±3.34
	20	58.58±3.61	62.02±3.26	67.86±3.23	78.19±3.83	72.09±3.01	82.60±1.85	80.47±2.59	83.48±2.35
	50	77.75±3.23	80.23±2.78	84.35±2.10	86.70±3.96	85.30±2.98	90.76±1.86	88.78±1.67	91.02±2.04
	100	82.88±3.02	85.23±2.39	91.80±2.77	90.82±2.47	90.31±2.44	93.54±1.70	91.36±1.60	93.65±2.04
50 : 49 (~1 : 1)	10	35.21±2.68	39.80±2.50	46.14±2.40	59.29±3.29	48.23±2.29	59.62±2.48	58.96±3.06	60.48±3.02
	20	49.24±3.50	53.87±3.08	59.76±3.12	72.27±3.58	62.32±3.07	75.13±2.96	71.71±2.98	75.95±2.68
	50	68.26±2.74	73.56±2.45	78.39±2.87	81.83±2.65	79.56±2.73	86.71±2.86	83.20±3.26	86.71±2.67
	100	78.53±4.24	81.26±3.45	87.52±2.37	85.13±4.17	85.89±2.60	90.46±2.33	87.53±3.02	91.17±3.03

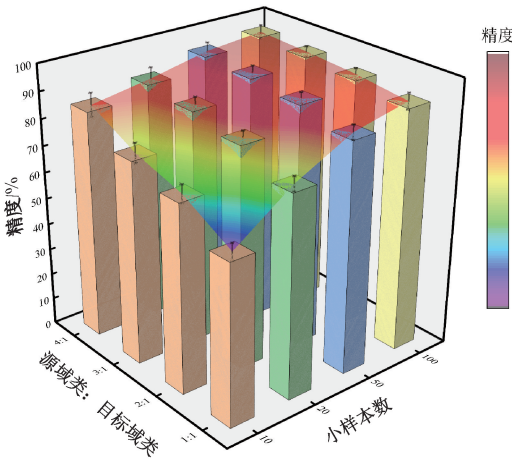


图 4 所提方法在各种诊断情境下的精度分布
Fig. 4 Accuracy distribution of the proposed method in various diagnostic scenarios

图 7 所示为各种方法在最终故障诊断模型输出的特征结果。从图 7 可以观察到,本文所提方法能够抽取到更加可判别性的特征表示,类别间分离程度和类内紧凑性更强,能够识别特征差异细微的困难样本,较为适用细粒度故障分类情境。具体而言,基于 SimCLR 的自监督对比学习方法的特征判别性较差且有部分类别的特征点互相重叠,因为其对比框架较为简单,且没有充分利用监督信息进行对比会导致模型更加关注区分各样本的通用




图 5 各种细粒度诊断情境下的方法精度对比
Fig. 5 Comparison of method accuracy in various fine-grained diagnostic scenarios

特征,而忽视能够区分各故障类别的判别特征;而基于 Moco 的自监督对比学习方法虽然对于部分故障类别的




图 6 各方法在类别比 3 : 1 (样本数 50) 下的微调过程对比
Fig. 6 Comparison of the fine-tuning process for each method with a category ratio of 3 : 1 (sample size 50)

特征可分性有所提升,但仍然难以避免会对极度相似的两种细粒度故障误分类。同时,虽然多尺度动态有监督对比学习方法相比传统对比学习更加聚焦困难样本的分类,

特征可分性有所提升,但当类别众多时仅着重识别少数极难区分的故障模式,难以关注所有的细粒度故障类别,而本文所提方法能够基于属性语义实现细粒度故障特征的全局优化和快速泛化,对于特征差异微弱和显著的新故障都能够有效区分,因此特征空间更具判别性。

此外,引入多任务学习策略(图 7(f)和(h))相对于传统的单任务学习方式(图 7(d)和(e)),不同类别特征的差异性更加明显,能够对细微差异的两个故障类别进行更加显著的区分。而属性引导的细粒度特征对比方法(图 7(h))相对于标签引导的细粒度特征对比方法(图 7(f))实现了更好的类内紧凑,这是因为属性信息相较于标签信息能够更好地捕捉故障属性的关联规律和细粒度故障知识的逻辑结构,更有助于特征对比过程的进行和判别性特征的抽取。

相较于迁移学习的仅采用标签学习的方式,对比学习和属性学习方法能够获得更加聚合的特征簇,因为它们是从样本的关系中进行学习,而非从离散的样本本身进行特征挖掘,因此类内紧凑性更强。

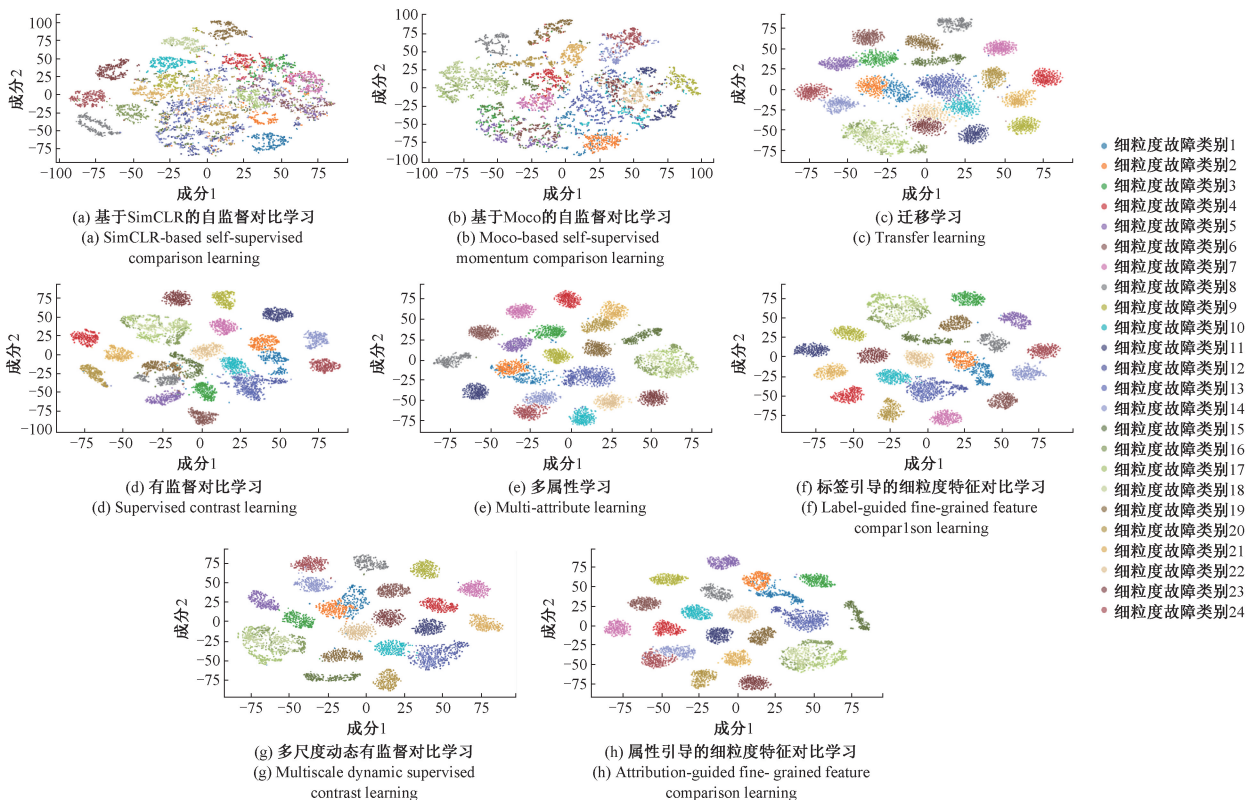


图 7 各方法在类别比 3 : 1 (样本数 50) 情境下的样本特征可视化

Fig. 7 Sample feature visualization for each method in a 3 : 1 category ratio (sample size 50) scenario

在此基础上,进一步分析每个类别样本的整体特征相关性,如图 8 所示,度量标签相同样本之间的平均特征距离。图 8 表明,自监督对比学习和有监督对比学习方法

法的平均特征相关性较低,且振荡较为明显,仅在几个少数故障类别中获得了最好的相关性,这是因为自监督对比学习方法完全没有利用类别标签信息进行特征

对比,而有监督对比学习方法仅区分样本是否同属一类而不关注它们具体所属类别,它们旨在从数据关系本身出发挖掘判别性结构特征,均没有先验信息和故障知识进行辅助,因此难以应对多故障模式、复杂故障机理的情形。迁移学习和标签引导的细粒度特征对比方法初步引入了标签作为辅助信息,多尺度动态有监督对比学习方法根据不同故障的实时分类难度,在监

督对比损失中动态地给不同类别赋权以提升对于困难样本的关注程度,因此它们使得模型更加深入地理解不同故障之间的特征关联规律。而其他两种结合属性学习的方法,进一步提升了特征相关性,可见属性学习相较于标签学习能够获取更多的故障知识,更好地捕捉细粒度故障模式的结构关系,从而提取更加可判别的特征,增强模型的可解释能力。




图 8 各方法在不同细粒度故障类别下的特征相关性

Fig. 8 Feature correlation of the methods under various fine-grained fault categories

图 9 所示为本文所提方法在类别比 3 : 1 (样本数 50) 情境下混淆矩阵。从图 9 可以看出,本文所提方法对于大多数细粒度故障都能够进行很好的甄别,具有在众多难以区分的故障中精准定位与快速识别的优势。

相连^[33]。该数据使用太阳轮和行星轮通过两个加速度计沿 X 方向和 Y 方向采集振动信号,其采样频率为 20 kHz,输入端处的转速从 20~40 Hz 不等。在 16 种工况下,齿轮有 5 种故障程度和 3 种故障类型,共涉及 144 个类别,其具体属性划分如表 6 所示。其中随机选取 108 个类别的样本作为源域数据用于模型的预训练,其余 36 个类别的目标域数据用于少样本微调 and 测试,同时从每一类中抽取指定数量的样本,采用滑动窗口采样构建单个样本的尺寸大小为 [2, 4 096]。同时为了确保对比的一致性,模型结构和参数设置参考第一个数据集的实验形式。

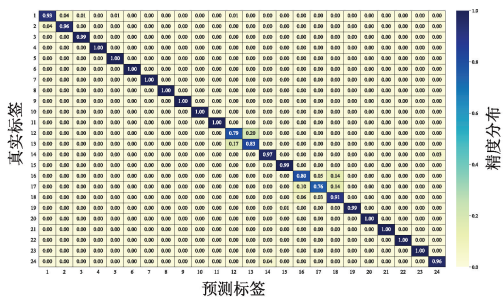


图 9 所提方法在类别比 3 : 1 (样本数 50) 情境下混淆矩阵
Fig. 9 Confusion matrix of the proposed method in the context of category ratio 3 : 1 (sample size 50)

3.4 方法进一步对比分析

为了进一步验证方法的通用性,在另一数据集上再次验证各方法的相关指标结果。清华大学齿轮箱数据集是变速的箱齿轮数据集,采集自 HS-200 单级行星齿轮箱试验台,用电机驱动的变速箱作为输入端,输出端与风轮

在此基础上将各方法的精度分布和 50 个样本的特征表现进行可视化,精度分布如图 10 所示,特征分布如图 11 所示,可以看出,所提方法仍然在大多数情况下有较好的性能,且自监督对比学习和迁移学习方法出现了较为明显的过拟合现象,这可能是由于类别更多导致细粒度故障属性结构关系更加复杂,因此特征甄别难度更大,模型在样本数量较少的情况下难以适应新样本。

有监督对比学习(图 11(d))实现了初步的特征聚合,但对于更细粒度的分类中有很多故障特征重叠而难以发挥效果,而多属性学习(图 11(e))虽然提取到了能够识别新故障的泛化特征,但是可分性还需要进一步提

表 6 齿轮箱数据集的细粒度故障属性划分

Table 6 Fine-grained fault attribute segmentation on the gearbox dataset

故障属性	取值	属性描述
故障工况	25、26、27、28、29、30、31、32、33、34、35、36、37、38、39、40 Hz	齿轮箱的不同转速,包括 16 种固定工况
故障程度	裂纹深度 1/8、裂纹深度 1/4、裂纹深度 1/2、断裂深度 1/3、无故障	齿轮的裂纹和断齿程度
故障类型	太阳齿轮故障、行星齿轮故障、健康	齿轮故障发生的位置,包括 2 种部件故障和 1 种健康状态




图 10 齿轮箱数据集的方法精度对比

Fig. 10 Comparison of method accuracy on the gearbox dataset

升。而属性引导的细粒度特征对比学习方法(图 11(h)),采用属性学习引导对比学习的策略,由于同时具备了这两种方法的优势,提升了特征甄别的效果,提取到兼具判别性和泛化能力的细粒度故障特征。此外,多属性学习(图 11(e))相比迁移学习方法(图 11(c))在更细粒度的分类场景中表现更加稳定,因此本文所提方法(图 11(h))注入属性知识,相较于仅学习标签知识的方法(图 11(f)和(g))能够在有限的样本数量情况下获取更多的信息,用于目标域新故障数据的精准分类。混淆矩阵如图 12 所示,可以看出所提方法仍然保持了在众多类别下的细粒度识别能力,能够有效区分特征差异显著和细微的各种故障类型。

综上所述,本文所提出的属性引导细粒度特征对比的小样本跨域故障诊断方法在小样本、多分类问题上具有明显的优越性,可以从有限的样本中捕捉更具判别性的泛化特征表示,用于细粒度的跨域故障诊断。

4 结 论

针对当前跨域故障诊断领域出现的少样本训练困

难、细粒度故障难以甄别和新故障不断增长等问题,本文提出了一种属性引导细粒度特征对比学习的小样本跨域故障诊断方法。首先,基于多任务学习方法整合有监督对比学习和多属性学习,在源域的已知故障中预训练特征提取模型,通过先验属性知识增强模型对于差异微弱的细粒度故障特征的理解程度和甄别能力,引导对比学习以进一步提升特征的判别效果。其次,基于已知故障和未见故障的公共属性语义,采用少样本微调特征提取模型,以识别目标域中新的细粒度故障类别,增强特征对于新故障的适应性和泛化能力。最后,在两个故障数据集中验证了所提方法在小样本细粒度故障分类情境中的优势,表明通过属性引导对比学习的方法能够更加有效地区分已知的细粒度故障,同时精准识别未见的细粒度故障,从而实现类别众多的跨域故障诊断。相比其他小样本跨域故障诊断方法,本文所提方法在各种诊断情境下都有更好的验证精度、特征判别效果和故障区分能力,具备更好的通用性,因此适用于有新故障发生的少样本细粒度故障诊断情境,且该情境下能够充分获取已知故障和未见故障的先验属性信息。而虽然该方法具有一定优越性,但在样本数量更少、类别比例更加失衡的情况下

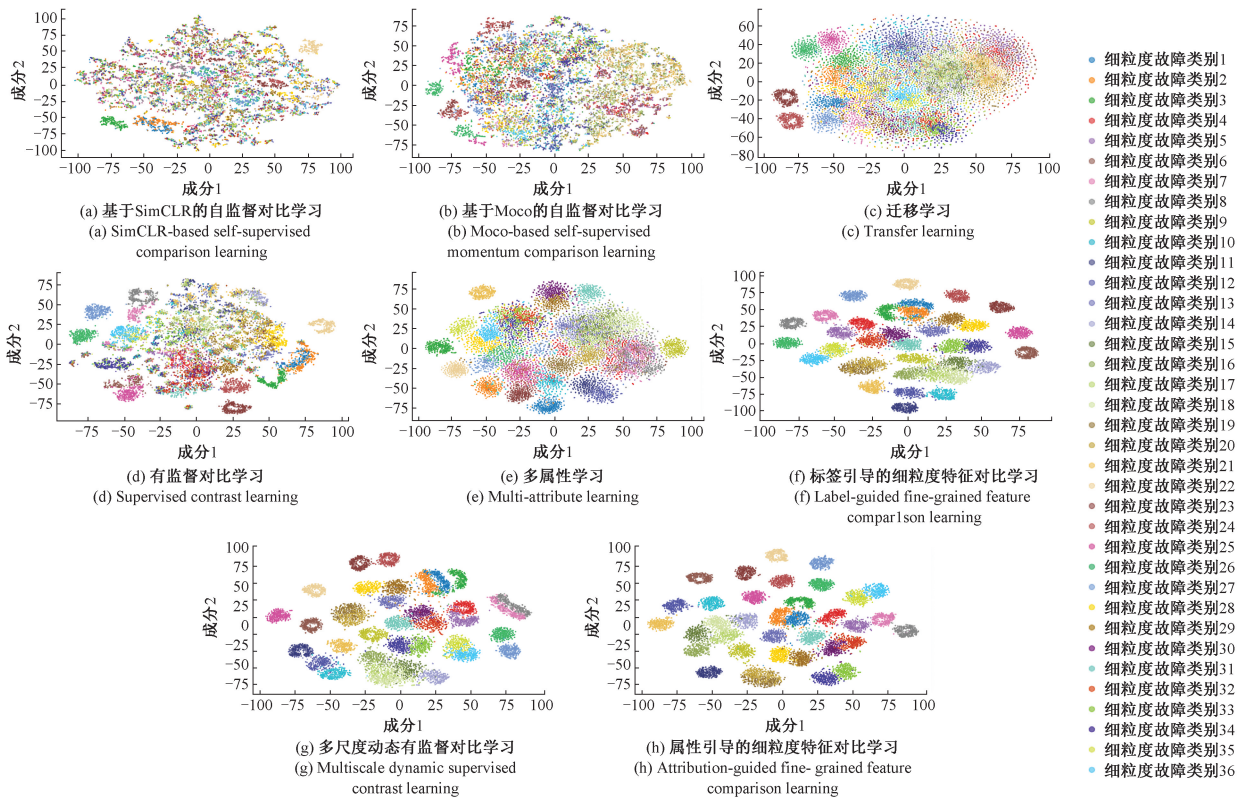


图 11 各方法在齿轮箱数据集的样本特征可视化

Fig. 11 Sample feature visualization for each method on the gearbox dataset

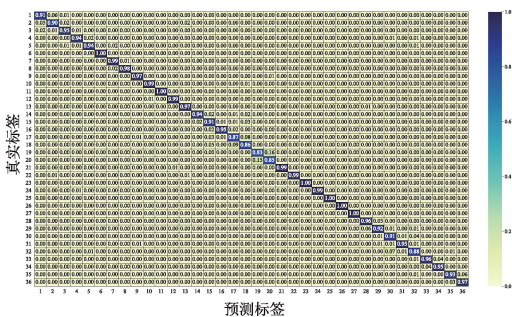


图 12 所提方法在齿轮箱数据集的混淆矩阵

Fig. 12 Confusion matrix of the proposed method on the gearbox dataset

可能存在所获取的属性知识不充分导致模型难以识别新故障等问题,因此需要进一步考虑与元学习、度量学习等少样本学习方法的整合。此外,该方法将各种属性的重要程度视为一致而没有考虑不同层次属性对于诊断结果的贡献性,后续将考虑引入注意力机制等可解释性深度学习学习方法区分各个属性的权重,以提升属性作为细粒度故障先验知识的可靠性。

参考文献

[1] LI W J, LIU X P, WANG D N, et al. MITDCNN: A

multi-modal input Transformer-based deep convolutional neural network for misfire signal detection in high-noise diesel engines [J]. Expert Systems with Applications, 2024, 238 (A) : 121797.

[2] ZHAO K, JIANG H K, WANG K B, et al. Joint distribution adaptation network with adversarial learning for rolling bearing fault diagnosis [J]. Knowledge-Based Systems, 2021, 222: 106974.

[3] ZHANG T C, CHEN J L, HE S L, et al. Prior knowledge-augmented self-supervised feature learning for few-shot intelligent fault diagnosis of machines [J]. IEEE Transactions on Industrial Electronics, 2022, 69 (10) : 10573-10584.

[4] ZHANG T C, CHEN J L, LI F D, et al. Intelligent fault diagnosis of machines with small & imbalanced data: A state-of-the-art review and possible extensions [J]. ISA Transactions, 2022, 119: 152-171.

[5] 邹德旭, 徐赫, 权浩, 等. 基于 DGA 和改进 SMOTE 的小样本变压器故障诊断方法 [J]. 广东电力, 2024, 37 (7) : 118-126.

ZOU D X, XU H, QUAN H, et al. Small sample transformer fault diagnosis method based on DGA and enhanced SMOTE [J]. Guangdong Electric Power,

- 2024, 37(7): 118-126.
- [6] ZHAO B, ZHANG X M, LI H, et al. Intelligent fault diagnosis of rolling bearings based on normalized CNN considering data imbalance and variable working conditions [J]. Knowledge-Based Systems, 2020, 199: 105971.
- [7] DIXIT S, VERMA N K. Intelligent condition-based monitoring of rotary machines with few samples [J]. IEEE Sensors Journal, 2020, 20(23): 14337-14346.
- [8] 李东泽, 齐咏生, 刘利强, 等. 基于双流生成对抗网络数据增强的风电机组智能故障诊断 [J]. 电力自动化设备, 2024, 44(11): 94-102.
- LI D Z, QI Y SH, LIU L Q, et al. Intelligent fault diagnosis of wind turbine unit based on dual-stream generative adversarial network data augmentation [J]. Electric Power Automation Equipment, 2024, 44(11): 94-102.
- [9] YANG X Y, YE T Y, YUAN X F, et al. A novel data augmentation method based on denoising diffusion probabilistic model for fault diagnosis under imbalanced data [J]. IEEE Transactions on Industrial Informatics, 2024, 20(5): 7820-7831.
- [10] HE Z Y, SHAO H D, ZHANG X Y, et al. Improved deep transfer auto-encoder for fault diagnosis of gearbox under variable working conditions with small training samples [J]. IEEE Access, 2019, 7: 115368-115377.
- [11] KONG D P, HUANG W D, ZHAO L B, et al. Mining knowledge from unlabeled data for fault diagnosis: A multi-task self-supervised approach [J]. Mechanical Systems and Signal Processing, 2024, 211: 111189.
- [12] 温江涛, 刘仲雨, 孙洁婧, 等. 自监督学习结合对抗迁移的跨工况轴承故障诊断 [J]. 计量学报, 2024, 45(9): 1360-1369.
- WEN J T, LIU ZH Y, SUN J D, et al. Self-supervised learning combined with adversarial transfer for cross-conditions bearing fault diagnosis [J]. Acta Metrologica Sinica, 2024, 45(9): 1360-1369.
- [13] WANG W C, LI C, LI A M, et al. One-stage self-supervised momentum contrastive learning network for open-set cross-domain fault diagnosis [J]. Knowledge-Based Systems, 2023, 275: 110692.
- [14] AN Y Y, ZHANG K, CHAI Y, et al. Domain adaptation network base on contrastive learning for bearings fault diagnosis under variable working conditions [J]. Expert Systems with Applications, 2023, 212: 118802.
- [15] 乔万, 刘秀丽, 吴国新, 等. 时变小样本条件下基于对比学习的故障诊断 [J]. 电子测量与仪器学报, 2024, 38(8): 113-123.
- QIAO W, LIU X L, WU G X, et al. Fault diagnosis based on contrastive learning under time-varying small sample conditions [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(8): 113-123.
- [16] XU Y, MA X Y, WANG X, et al. Relation awareness network for few-shot fine-grained fault diagnosis [J]. IEEE Sensors Journal, 2024, 24(13): 20949-20958.
- [17] ZHOU Y H, ZHANG Q, HUANG T, et al. Prior knowledge-augmented meta-learning for fine-grained fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2024, 20(6): 8115-8124.
- [18] LI C J, LI S B, WANG H, et al. Attention-based deep meta-transfer learning for few-shot fine-grained fault diagnosis [J]. Knowledge-Based Systems, 2023, 264: 110345.
- [19] XU J, ZHOU L, ZHAO W H, et al. Zero-shot learning for compound fault diagnosis of bearings [J]. Expert Systems with Applications, 2022, 190: 116197.
- [20] CHEN X, ZHANG B L, ZHAO C H, et al. From coarse to fine: Hierarchical zero-shot fault diagnosis with multigrained attributes [J]. IEEE Transactions on Fuzzy Systems, 2024, 32(5): 2837-2849.
- [21] ZHANG T C, CHEN J L, LIU S, et al. Domain discrepancy-guided contrastive feature learning for few-shot industrial fault diagnosis under variable working conditions [J]. IEEE Transactions on Industrial Informatics, 2023, 19(10): 10277-10287.
- [22] CAI L, YIN H P, LIN J D, et al. A multiattribute learning model for zero-sample mechanical fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2024, 20(7): 9633-9643.
- [23] YAO Y, FENG J, LIU Y. Domain knowledge-guided contrastive learning framework based on complementary views for fault diagnosis with limited labeled data [J]. IEEE Transactions on Industrial Informatics, 2024, 20(5): 8055-8063.
- [24] LIN Y Z, WANG Y, ZHANG M Q, et al. Information-guided signal multi-granularity contrastive feature learning for fault diagnosis with few labeled data [J]. Advanced Engineering Informatics, 2024, 61: 102471.
- [25] DONG Y T, JIANG H K, YAO R H, et al. Rolling bearing intelligent fault diagnosis towards variable speed and imbalanced samples using multiscale dynamic supervised contrast learning [J]. Reliability Engineering & System Safety, 2024, 243: 109805.
- [26] 张永宏, 邵凡, 赵晓平, 等. 基于多标签零样本学习的滚动轴承故障诊断 [J]. 振动与冲击, 2022, 41(11): 55-64, 89.

- ZHANG Y H, SHAO F, ZHAO X P, et al. Rolling bearing fault diagnosis based on multi-label zero-shot learning [J]. *Journal of Vibration and Shock*, 2022, 41(11): 55-64, 89.
- [27] ZHANG Q, HUO R P, ZHENG H D, et al. A fault diagnosis method with bitask-based time- and frequency-domain feature learning [J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3527211.
- [28] ZHANG J Y, ZOU J X, SU Z H, et al. A class-aware supervised contrastive learning framework for imbalanced fault diagnosis [J]. *Knowledge-Based Systems*, 2022, 252: 109437.
- [29] HOU R J, CHEN J L, FENG Y, et al. Contrastive-weighted self-supervised model for long-tailed data classification with vision transformer augmented [J]. *Mechanical Systems and Signal Processing*, 2022, 177: 109174.
- [30] ZHAO C, ZIO E, SHEN W M. Domain generalization for cross-domain fault diagnosis: An application-oriented perspective and a benchmark study [J]. *Reliability Engineering & System Safety*, 2024, 245: 109964.
- [31] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations [C]. *Proceedings of the 37th International Conference on Machine Learning*, 2020, 149: 1597-1607.
- [32] SHAO S Y, MCALEER S, YAN R Q, et al. Highly

accurate machine fault diagnosis using deep transfer learning [J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(4): 2446-2455.

- [33] HAN T, LI Y F, QIAN M. A hybrid generalization network for intelligent fault diagnosis of rotating machinery under unseen working conditions [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 3520011.

作者简介



张星泽, 2022 年于合肥工业大学获得学士学位, 现为合肥工业大学硕士研究生, 主要研究方向为智能故障诊断。

E-mail: 2023110999@mail.hfut.edu.cn

Zhang Xingze received his B. Sc. degree from Hefei University of Technology in 2022.

Now he is a M. Sc. candidate in Hefei University of Technology. His main research interest includes intelligent fault diagnosis.



蔡正阳 (通信作者), 2018 年于北京航空航天大学获得博士学位, 现为合肥工业大学副研究员, 主要研究方向为航空宇航制造工程。

E-mail: zycail@hfut.edu.cn

Cai Zhengyang (Corresponding author), received his Ph. D. degree from Beijing University of Aeronautics and Astronautics in 2018. Now he is an associate researcher in Hefei University of Technology. His main research interest includes aerospace manufacturing engineering.