

DOI: 10.19650/j.cnki.cjsi.J2514442

从传统诊断到广义零样本——工业故障诊断 范式转型与挑战*

蔡力^{1,2}, 尹宏鹏², 吴天舒^{2,3}, 林景栋², 柴毅²

(1. 西南交通大学电气工程学院 成都 611756; 2. 重庆大学自动化学院 重庆 400044;
3. 中国汽车工程研究院股份有限公司 重庆 401122)

摘要:有效的故障诊断是保障工业过程和工业设备安全稳定运行的关键环节。当前,我国正处于由工业大国向工业强国迈进的关键时期。在这一进程中,以数字化、智能化为特征的智能制造正加速推进,成为引领工业转型升级的重要支撑。随着智能制造的深入推进,工业过程日趋复杂,故障类型也日益多样化,这对诊断方法提出了更高的要求。传统基于监督学习的故障诊断方法依赖大量标注样本进行模型训练,侧重于对训练过程中出现过的故障(可见类故障)类别进行分类。工业故障诊断任务在实际场景中常面临故障类别不完备、分布差异显著等挑战,而零样本故障诊断因其无需目标故障训练样本即可实现对未见类故障的诊断,成为应对该类问题的重要研究方向。首先,将零样本场景分为传统零样本和广义零样本场景,在梳理工业故障诊断技术发展的基础上,阐述传统及广义零样本故障诊断的概念与内涵,明确其与传统方法的差异;随后,从辅助知识构建、方法实现与应用场景等方面系统综述面向零样本场景的工业故障诊断研究现状;进一步探讨当前方法面临的关键问题与研究任务拓展方向;最后,整理相关典型数据集与开源代码,并展望未来发展趋势与挑战,为零样本故障诊断研究提供理论参考与技术支持。

关键词: 工业故障诊断;零样本场景;传统零样本诊断;广义零样本诊断;辅助知识构建

中图分类号: TH133.33 TP277 **文献标识码:** A **国家标准学科分类代码:** 510.80

From tradition diagnosis to generalized zero-sample: Transformation and challenges of industrial fault diagnosis paradigm

Cai Li^{1,2}, Yin Hongpeng², Wu Tianshu^{2,3}, Lin Jingdong², Chai Yi²

(1. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 611756, China;
2. School of Automation, Chongqing University, Chongqing 400044, China; 3. China Automotive Engineering
Research Institute Co., Ltd., Chongqing 401122, China)

Abstract: Effective fault diagnosis is a key link in ensuring the safe and stable operation of industrial processes and equipment. Currently, China is undergoing a pivotal transition from an industrial powerhouse to an industrial leader. During this process, smart manufacturing, characterized by digitalization and intelligence, is accelerating, serving as a key support for industrial transformation and upgrading. As intelligent manufacturing advances, industrial processes are becoming increasingly complex, and fault types are becoming more diverse, which imposes higher demands on diagnosis methods. Conventional supervised learning-based fault diagnosis methods depend heavily on substantial labeled samples to train models, focusing on classifying faults that have encountered during training (seen faults). In real scenarios, industrial fault diagnosis often faces challenges such as incomplete fault categories and significant distribution discrepancies. Zero-sample fault diagnosis, which can diagnose unseen fault types without target fault training samples, has emerged as a crucial research direction to address these issues. First, zero-shot scenarios are categorized into traditional and generalized zero-shot settings. After reviewing the development of industrial fault diagnosis techniques, the concepts and connotation of traditional and generalized zero-sample fault diagnosis are combed, and their differences are clarified from conventional methods. Second, the current research on zero-shot fault diagnosis is systematically surveyed from perspectives such as auxiliary knowledge construction,

收稿日期: 2025-08-29 Received Date: 2025-08-29

* 基金项目: 国家重点研发计划(2023YFB3308800)项目资助

methodological implementation, and application scenarios. Furthermore, key challenges and potential research extensions are discussed for existing approaches. Finally, representative datasets and open-source code are compiled, while future trends and challenges are outlined to provide theoretical references and technical support for zero-sample fault diagnosis.

Keywords: industrial fault diagnosis; zero-shot scenarios; traditional zero-sample diagnosis; generalized zero-sample diagnosis; auxiliary knowledge construction

0 引 言

在现代工业系统中,故障通常被定义为系统特征或关键运行参数相对于其正常可接受状态的非允许偏差^[1-2],这种偏差将导致系统无法正常执行规定的功能。当前,我国正处于由工业大国向工业强国转型的关键历史阶段。面对全球产业格局深度调整和国内经济高质量发展的双重挑战,如何在新时期深入推进新型工业化已成为关系国家竞争力的重大时代命题。随着现代工业系统向大规模、高端化、复杂化方向发展,产业数字化和数字产业化成为推动智能制造与数字化转型的双轮驱动。特别值得注意的是,现代工业生产过程的连续性要求,以及各加工环节质量流、能量流和信息流的高度耦合,使得局部故障可能通过系统关联网络快速传播,进而影响产品质量,甚至引发安全事故。在此背景下,采取有效的故障诊断措施成为保障现代工业系统长期安全、稳定、高质、高效运行的关键路径,也是实现新型工业化的重要技术支撑^[3]。

传统故障诊断方法主要分为基于机理模型和数据驱动两大范式。在冶金、化工等复杂工业场景中,系统的非线性、动态变化以及多变量耦合特性使得精确机理建模面临巨大挑战,导致基于模型的故障诊断方法在实际应用中难以取得理想效果^[4-5]。随着工业设备的数字化发展,监控与数据采集系统积累了大量运行数据,这为构建数据驱动的故障诊断模型提供了可能^[6]。虽然数据驱动方法通过系统采集的海量运行数据展现出了优势^[6],但在实际应用中仍存在一定瓶颈。一方面,工业设备从健康状态到故障状态的长周期演变,导致标签故障样本获取困难且成本高昂;另一方面,受工况变化、设备老化、传感器故障等因素影响,采集数据常存在不完备问题,使得某些故障类别甚至可能出现样本完全缺失的情况^[7]。对于样本完全缺失的故障或训练阶段未曾出现的故障(未见类故障),由于缺乏相应样本用于普遍意义上的模型训练,基于完备数据训练的数据驱动诊断模型往往难以实现有效的诊断性能^[8-9]。

为突破上述限制,工业故障诊断技术正经历从传统范式向零样本及广义零样本诊断的范式转型。这种转型并非完全否定传统方法的价值,而是基于以下工业实际需求和技术发展趋势:

1) 工业设备的长周期特性决定了零样本场景的普遍性。大型压缩机、涡轮机组等关键工业设计寿命通常在 10 年左右,在其生命周期内可能出现训练阶段从未观测到的故障模式。例如,某炼化企业加氢反应器运行 5 年后首次出现“氢致开裂”故障,这类材料老化导致的故障在设备投用初期无法获取样本。

2) 工业系统的开放性本质要求零样本诊断能力。现代智能制造系统不断接入新设备、新工艺,新设备引入的故障模式必然属于未见类故障。此时,新工艺导致的独特故障模式在现有故障库中未被涵盖,使得传统基于历史数据的诊断方法完全失效。

3) 安全约束下的故障数据稀缺具有不可克服性。对于核电、连铸钢等安全关键领域,故意注入或故障诱发以获取样本既不现实也不经济。

4) 工业大数据的长尾分布特性凸显零样本价值。实际工业数据集中,例如在机械系统中,轴承磨损、轴系不对中等高频故障样本可能达数万条,而齿轮断齿、轴承保持架断裂等稀有故障样本较少,部分故障甚至零样本。这些处于长尾分布末端的零样本故障在历史数据中没有记录相关的故障样本。然而,随着设备老化或其他因素的影响,这类故障可能会突然出现。

5) 跨域诊断需求推动零样本技术发展。在设备制造商需要为不同客户提供诊断服务时,客户现场的特定故障模式,如某矿区特有的粉尘腐蚀、沿海风场的风机齿轮箱腐蚀+磨损/点蚀等复合故障,在制造商的标准故障库中往往没有样本。

当前工业故障诊断的发展呈现出明显的阶段性特征:第 1 阶段是基于完备标注数据的传统诊断方法;第 2 阶段是面向数据不均衡/小样本场景的诊断方法;第 3 阶段则是零样本/广义零样本诊断范式。这种阶段性划分反映了工业实际需求的演进过程:在工业数字化初期,设备运行数据积累有限,此时主要依赖专家知识和机理建模;随着传感器普及和数据采集系统的完善,数据驱动方法成为主流,但很快面临“数据长尾”问题;在智能制造和数字孪生时代,设备复杂度呈指数增长,新故障模式不断涌现,完全依赖历史数据的诊断方法已无法满足需求。因此,工业故障诊断方法从传统范式向零样本及广义零样本的范式转型不仅能够缓解诊断模型对故障样本的依赖,更重要的是为构建适应开放的智能诊断系统提供理论框架和技术路径。

需要特别说明的是,零样本及广义零样本故障诊断并非要完全取代传统方法,而是构建“可见类诊断+未见类推理”的完整能力体系。在实际应用中,系统会持续积累新故障样本,逐步将“零样本”转化为“少样本”最终成为“可见类”,形成诊断能力的动态进化闭环。这种持续学习的范式正是工业人工智能系统区别于传统方法的核心特征。

零样本故障诊断旨在通过样本充足的可见类样本训练模型,基于模型/知识迁移,学习并诊断样本缺失或无法获得的故障类别。由于在工业场景中,某些故障样本难以获取,零样本故障诊断技术展现出重要的应用前景,近年来受到广泛关注。该技术将零样本学习应用于工业故障诊断领域,为零样本故障诊断提供了新思路。此外,深度学习技术的快速发展,特别是生成对抗网络(generative adversarial network, GAN)和变分自编码器(variational autoencoder, VAE)等生成模型的成熟,使得零样本故障特征合成与迁移成为可能,进一步提升了模型在未见故障类别上的泛化能力。虽然零样本故障诊断的研究仍处于起步阶段,文献总量相对较少,但该领域文献数量总体上呈现上升趋势,这表明零样本学习在故障诊断中的应用正逐渐受到国内外学者的关注。因此,有必要对当前研究动态及存在问题进行分析与凝练,以厘清技术发展脉络,挖掘潜在挑战,并为未来研究方向提供参考。

本文全面综述零样本场景下工业故障诊断的研究现状及发展趋势,旨在系统梳理现有方法的理论框架,分析不同方法的优势与局限性,并探讨未来研究方向,推动零样本故障诊断在工业智能领域的创新与发展。本文第1章简要概述工业故障诊断领域的研究进展;第2章阐述零样本与现有方法的区别,从测试类是否包含可见类故障的角度出发,将零样本场景细分为传统零样本场景和广义零样本场景,并分别给出不同场景下故障诊断的具体定义;第3章介绍零样本工业故障领域中的辅助知识,并详细综述传统零样本故障诊断和广义零样本故障诊断的国内外研究现状;第4章对当前零样本故障诊断任务所面临的挑战进行总结,并对诊断任务进行拓展,使其能够涵盖开放集等场景的故障诊断问题,从而满足现代工业系统对未知故障鲁棒检测的需求;第5章梳理当前零样本工业故障诊断领域的基准数据集和开源工作;最后,对全文工作进行总结。

1 工业故障诊断技术的发展

随着现代制造业的发展,工业系统日益复杂化、自动化和智能化,其故障模式和原因也日趋复杂。工业故障诊断技术已成为保障工业系统高效、高质、安全、稳定运

行的重要手段。传统的故障诊断方法主要包括基于知识的方法和基于模型的方法。基于知识的方法依赖领域专家的知识 and 经验,通过制定规则或根据历史故障实例建立定性描述模型来进行诊断^[10-11]。这类方法适用于故障特征明确且专家知识完备的场景,但其诊断效果严重依赖于知识库的完整性和准确性^[12]。而基于模型的方法则利用系统输入输出建立状态观测器、参数估计器或输出观测器,通过构建精确的物理或数学模型实现故障诊断^[13]。这类方法在系统机理明确且运行工况稳定的条件下表现良好,但对于复杂工业系统往往难以建立精确的数学模型^[14]。随着工业大数据时代的到来,数据驱动和基于智能算法的故障诊断技术逐渐取代了传统方法,成为现代工业故障诊断领域的主流方向^[15-16]。

数据驱动的故障诊断方法通过分析设备或系统的运行数据来识别潜在故障模式,主要包括基于统计分析、机器学习和深度学习的诊断方法^[17-18]。基于统计分析的故障诊断方法,如谱分析、时频分析^[19]和主成分分析^[20],能够从工业数据中提取特征模式,实现故障检测和诊断。然而,这类方法在特征提取和复杂数据分析方面存在局限性,难以有效处理非线性、非平稳的工业数据。相比之下,机器学习方法通过训练历史数据来学习设备正常与异常状态的特征差异,从而实现更精准的故障诊断。常见的机器学习算法包括支持向量机(support vector machine, SVM)^[21-22]、随机森林^[23]和K近邻算法^[24]等。这些方法在小规模数据等特定工业场景上表现良好,但在工况多变或数据分布复杂时泛化能力有限,且通常依赖高质量标签样本。近年来,深度学习凭借其强大的特征提取和模式识别能力,在工业故障诊断领域得到广泛应用^[25]。例如,卷积神经网络(convolutional neural network, CNN)^[26-27]、循环神经网络^[28]及其长短期记忆网络(long short term memory, LSTM)^[29]等变种在时间序列故障数据分析中表现优异。此外,堆栈自编码器^[30]和生成对抗网络^[31]等模型能够自动学习高层次特征,减少了对人工特征工程的依赖,并通过端到端训练在机械故障诊断等领域取得了显著进展。然而,深度学习方法仍面临一定挑战:1)其性能高度依赖大量标注数据,且主要针对训练中出现过的故障(可见类故障)进行诊断;2)模型的“黑箱”特性使得其决策过程缺乏可解释性。

在数据驱动方法的进一步研究中,学者们逐渐关注到实际工业场景中的一个关键问题:由于传感技术的差异、操作条件的波动、设备类型的多样性以及外部环境的不确定性等诸多因素影响,源域(即训练阶段所获取的数据域)与目标域(即模型部署和测试所面向的数据域)之间往往存在显著分布差异,进而引发变分布问题^[32]。为应对数据异构性及分布不一致所带来的挑战,多源和跨域故障诊断逐渐成为研究重点。近年来,研究者提出了

多种方法,如迁移学习^[33-34]、领域自适应^[35-36]以及联邦学习^[37-38],以提升模型在新环境下的鲁棒性与泛化能力。迁移学习旨在从分布不同但任务相关的多个数据域中提取共享的判别信息,并构建能够适用于目标域的统一分类模型。其核心思想是通过挖掘源域和目标域之间的潜在关联性,实现知识迁移和再利用。常见策略包括迁移成分分析^[39-40]、对抗式训练^[41-43]和深度模型方法^[44]。领域自适应则通过特征分布对齐来提升模型对不同工况的适应性^[45-46],典型技术包括最大均值差异^[47-48]、多核最大均值差异^[49-51]及关联对齐方法^[52-53]。联邦学习是一种分布式建模范式,强调“数据不出本地,模型协同更新”的理念,尤其适用于对数据隐私保护和通信成本控制具有高要求的工业环境。其基本机制是由各边缘设备(客户端)在本地独立训练模型参数,并通过服务器端进行参数聚合,从而构建统一的全局模型,避免了数据在网络间的直接传输,降低了数据泄露风险。相关方法涵盖联邦平均^[54]、知识蒸馏^[55]、迁移式联邦策略^[38,56]、个性化机制^[57]以及对抗式联邦学习等。这类技术不仅促进了跨设备、跨工况和跨客户端的协同诊断,也在提升多域数据协同利用效率、保障工业数据隐私方面展现出重要应用价值。

在工业生产过程中,由于运行环境的复杂性和故障发生的随机性,真实采集到的数据分布往往呈现出显著的长尾效应^[58-60]。具体表现为:机械磨损、轻微过载等常见故障样本数量充足,而复合型故障突发性故障等复杂故障则位于分布尾端,样本稀少甚至完全缺失(即训练数据中不存在任何相应样本)。这种数据分布的不均衡性严重制约了传统数据驱动故障诊断方法的性能。针对这一挑战,零小样本学习技术近年来被引入故障诊断领

域^[61-62],为解决数据稀缺问题提供了新思路。小样本诊断通过知识迁移或特征共享机制,使模型能够在少量样本条件下实现有效诊断;零样本诊断则进一步通过利用故障属性描述等先验知识,在可见类故障和未见类故障之间建立语义关联,从而实现对完全无训练样本的故障类型的判断。为分析该领域的研究趋势,本文基于中国知网(China national knowledge infrastructure, CNKI)和 WoS (Web of Science)数据库,分别以“故障诊断”+“零样本”和“fault diagnosis”+“zero-shot or zero-sample”为关键词进行文献检索,统计了相关论文的年度发表数量,结果如图1所示(数据截止到2025年7月)。从统计数据可以看出,2020年发文量不足10篇,但2021年后呈现显著增长趋势。这一增长趋势主要得益于基于故障描述的属性迁移技术的提出。零小样本诊断技术的应用显著提升了诊断模型在数据稀缺场景下的泛化能力。工业故障诊断技术的发展脉络如图2所示,目前,零样本诊断凭借其知识迁移优势,已成为工业故障诊断领域的重要研究方向。




图1 CNKI和WoS数据库中零样本故障诊断文献数量
Fig. 1 Number of publications on zero-sample fault diagnosis in the CNKI and WoS databases



图2 工业故障诊断技术发展脉络

Fig. 2 The development trend of industrial fault diagnosis technologies

2 零样本故障诊断的定义

根据测试样本是否包含参与模型训练的故障类别,零样本故障诊断可分为传统零样本故障诊断和广义零样本故障诊断^[63-64]。本章分别阐述传统零样本故障诊断和广义零样本故障诊断模型与现有普遍意义上的数据驱动模型之间的区别,并给出诊断任务的数学表达,以及常见的模型评价指标。

2.1 零样本故障诊断与现有方法的差异

根据训练数据的标注信息,传统基于数据驱动的工业故障诊断方法通常可分为3类:监督学习、半监督学习和无监督学习^[65-66]。基于监督学习的故障诊断要求训练数据和测试数据的故障类别完全一致,利用完全标注的训练数据(即每个样本都有明确的故障类别标签)训练分类模型,使模型能够学习故障特征与类别之间的映射关系。基于半监督学习的故障诊断方法的核心思想在于在训练数据中,部分样本有标签,部分样本无标签,利用少量标注数

据和大量无标签数据共同训练模型。该类方法减少了对标注数据的依赖,但仍假设测试故障类别在训练数据中出现过(即使部分样本无标签)。基于无监督学习的故障诊断完全不依赖标签信息,仅通过数据本身的分布特性(如聚类、异常检测)发现潜在的故障模式。该方法通常只能判断样本是否异常,而无法精确分类故障类型。

传统基于监督学习、基于半监督学习和基于无监督

学习的故障诊断方法依赖训练数据覆盖所有测试故障类别,无法处理类别不相交的诊断问题。与传统依赖数据驱动故障诊断方法(监督/半监督/无监督)不同,零样本工业故障诊断的关键在于训练类标签和测试类标签完全不相交,通过辅助信息进行知识迁移,如表 1 所示(符号“√”表示对应集合中存在该类故障,“×”表示对应集合中不存在该类故障)。

表 1 故障诊断方法的区别
Table 1 Differences of fault diagnosis methods

方法	训练集		测试集		训练要求及方法适应场景
	可见类故障	未见类故障	可见类故障	未见类故障	
传统监督学习故障诊断	√	×	√	×	全标注数据,适用于故障类别固定且已知
半监督学习故障诊断	√	×	√	×	部分标注数据,适用于部分故障样本无标签
无监督学习故障诊断	√	×	√	×	无标签数据,适用于完全无标签,仅检测异常
传统零样本故障诊断	√	×	×	√	可见类数据+属性/描述,适用于未见故障类别无样本但有描述
广义零样本故障诊断	√	×	√	√	可见类数据+属性/描述,适用于可见类和未见类故障的同步诊断

其中,“可见类”是指在模型训练阶段能够提供实际样本数据并参与模型训练的故障类别,“未见类”是指在模型训练阶段完全未曾出现的故障类别。直接能参与模型训练的故障称为“可见类故障”,缺失训练样本的故障称为“零样本故障”,根据其故障类别是否已知,零样本故障又可分为“未知故障”和“未见类故障”,如图 3 所示^[67]。对于训练阶段零样本且类别信息完全缺失的未知故障,由于没有任何先验信息,现有模型无法对其进行有效诊断。不同于未知故障,未见类故障虽然同样在训练过程中缺乏实际样本,但其故障类别信息可以通过其他途径获取。例如,同一类的故障可能在其他设备或工厂发生过,其故障属性可以通过故障发生位置、故障影响或外部信息源(如文本描述、故障手册)等确定。因此,未见类故障并非未知故障,且具备完整的类别属性信息,故障属性也是已知的^[8,66-69]。在没有特别说明的情况下,本综述所讨论的零样本故障特指未见类故障。这种界定有助于更精确地开展零样本场景下工业故障诊断的研究,同时也为后续方法和性能评估提供清晰的概念框架。

在故障诊断领域,传统零样本故障诊断方法通常仅关注对未见类故障的诊断问题。然而,这种设定与实际的工业场景存在一定差距,因为在真实的生产环境中,诊断系统需要同时对可见类和未见类故障进行准确识别与分类,这正是广义零样本诊断任务所要解决的核心问题^[70-71]。如表 1 所示,广义零样本故障诊断任务不仅关注如何将可见类知识有效迁移到未见类中,还强调如何从可见类中处理不同类型的未见类故障。这种双重诊断需求虽然更加贴近工程实际,但同时也显著提升了诊断任务的复杂度。

造成这一挑战的原因在于,广义零样本诊断模型在训练阶段仅能利用可见类故障样本,而在测试阶段则需要同时处理可见类和未见类故障样本。这种训练与测试类别的不对称性往往会导致模型在测试时对未见类故障样本产生预测偏差,导致模型倾向于将未见类故障样本错误地归类为可见类别,即未见类故障映射域偏移^[72-73]。具体而言,由于模型在训练过程中仅学习了可见类故障的特征表示,其决策边界会自然地倾向于将特征空间中未见类故障样本划分到最近的可见类簇中。

值得注意的是,与传统零样本故障诊断方法相比,目前广义零样本故障诊断研究仍处于相对初期的阶段。这主要是因为广义零样本诊断需要解决两个相互关联的关键问题:1)如何实现从可见类到未见类故障知识的有效迁移,这涉及到故障特征的域不变表示学习;2)如何在诊断模型中建立可见类与未见类故障之间的语义关联,同时避免对未见类故障的预测偏见。这些挑战使得广义零样本故障诊断成为一个值得深入探索的研究方向。




图 3 工业故障诊断中不同故障类别

Fig. 3 Different fault categories in industrial fault diagnosis

2.2 传统零样本故障诊断的定义

在工业领域,传统零样本故障诊断通常利用故障辅助知识来建立未见类故障与可见类故障之间的联系,并采用知识迁移等策略实现对未见类故障的诊断。如图4所示,训练集由标签可见类故障构成,目标测试集由未标签的未见类故障构成;通过语义属性连接故障样本与类别,实现知识迁移和诊断推理。




图4 传统零样本故障诊断示意图

Fig. 4 A view of traditional zero-sample fault diagnosis

设可见类与未见类故障的标签集合分别为 $Y^s = \{1, 2, \dots, n_s\}$ 和 $Y^u = \{n_s + 1, n_s + 2, \dots, n_s + n_u\}$, 则所有故障标签集合可以表示为 $Y = Y^s \cup Y^u$, 其中, n_s 和 n_u 分别表示集合 Y^s 和 Y^u 的故障类别数量。设 $D_s = \{(x_i^s, y_i^s, a_i^s)_{i=1}^{N_s} \mid x_i^s \in X^s, y_i^s \in Y^s, a_i^s \in A^s\}$ 为可见类故障数据集, 其中 x_i^s 表示第 i 个标签为 y_i^s 的 D 维可见类样本, a_i^s 为样本 x_i^s 所对应的语义属性。 X^s, Y^s 和 A^s 分别表示可见类故障的样本空间、类别标签空间和语义属性空间, N_s 为样本数量。值得注意的是, 语义属性是类别级特征, 隐含着故障类别的信息。这些属性共同构成了语义空间, 其中每个维度代表一个不同的属性。语义属性在每个维度上的取值由相应故障中该属性的存在与否来决定。通过独热编码技术, 可以对可见类和未见类故障的语义属性进行稀疏化表示。具体而言, 每个故障类别的语义属性 $a^j, j = 1, 2, \dots, n_s + n_u$ 是一个 n_a 维向量, 其中, n_a 表示属性的数量。属性向量的每一维取值均为二进制 (即 0/1, “1” 表示故障具有相应属性, “0” 表示故障不具有相应属性)。 $A^s = [a^1, \dots, a^{n_s}]$ 包含所有可见故障类别的语义属性。相应地, 未见类故障数据集可以表示为 $D_u = \{(x_k^u, y_k^u, a_k^u)_{k=1}^{N_u} \mid x_k^u \in X^u, y_k^u \in Y^u, a_k^u \in A^u\}$, 其中, $A^u = [a^{n_s+1}, \dots, a^{n_s+n_u}]$ 。当满足条件 $X^s \cap X^u = \emptyset, Y^s \cap Y^u = \emptyset$, 和 $A^s \cap A^u = \emptyset$ 时, 对于给定的可见训练集 D_s , 传统零样本诊断旨在学习映射 $F: (X^s, A^s) \rightarrow Y^u$, 以对测试未见类故障集合 D_u 进行诊断。其数学表达如式(1)所示。

$$\min L(Y^u, \hat{Y}^u), \hat{Y}^u = F(X^s, Y^s, A | X^u) \quad (1)$$

其中, $A = A^s \cup A^u = [a^1, \dots, a^{n_s}, a^{n_s+1}, \dots, a^{n_s+n_u}]$ 表示故障的语义属性空间。

对于测试未见类故障样本 x , 可以通过映射

$F: (x, \hat{a}) \rightarrow \hat{y}$ 得到样本标签 $\hat{y}$, 其中 $\hat{a}$ 为预测的故障语义属性。

$$acc_u = \frac{N}{N_u} \times 100\% \quad (2)$$

其中, N 表示正确诊断的样本数。

2.3 广义零样本故障诊断的定义

广义零样本故障诊断旨在同时实现对可见类和未见类故障样本的诊断。如图5所示, 训练集由带标签的可见类故障样本构成, 而目标测试集则由未带标签的可见类与未见类故障样本共同组成。




图5 广义零样本故障诊断示意图

Fig. 5 A view of generalized zero-sample fault diagnosis

对于给定的可见训练集 D_s , 广义零样本诊断的目标是学习一个映射函数 $F: (X^s, A^s) \rightarrow Y$, 以便对包含所有类别的测试故障集合 $D = D_s \cup D_u$ 进行诊断。其数学形式如式(3)所示。

$$\min L(Y, \hat{Y}), \hat{Y} = F(X^s, Y^s, A | X) \quad (3)$$

在广义零样本故障诊断任务中, 目标测试集同时包含可见类样本和未见类样本。因此, 可以通过可见类故障的准确率 acc_s 以及未见类故障的准确率 acc_u 来评价模型的诊断性能。

此外, 调和平均值 H_1 与 top-1 准确率 H_1 也是两类具有代表性的评价指标。指标 H_2 常用于衡量方法在可见类故障和未见类故障之间的偏移程度。当某一类被过度偏向时, H_1 的值会显著降低。而 H_2 则提供了一种综合的诊断性能评估方法, 其数值越大, 说明在可见类和未见类之间的诊断平衡越好。其定义如式(4)~(5)所示。

$$H_1 = \frac{2 \times acc_s \times acc_u}{acc_s + acc_u} \times 100\% \quad (4)$$

$$H_2 = \frac{acc_s \times Q_s + acc_u \times Q_u}{Q_s + Q_u} \times 100\% \quad (5)$$

其中, Q_s 与 Q_u 分别表示测试集中可见类故障样本与未见类故障样本的总数。

3 零样本故障诊断研究现状

本章从基于零样本学习的图像分类任务出发, 引出零样本故障诊断, 并总结该领域常见的工业故障辅助知识。随后, 将零样本场景划分为传统零样本场景和广义

零样本场景两类,重点综述传统零样本诊断和广义零样本诊断研究现状。

3.1 零样本工业故障辅助知识

传统零样本学习最早由 Lampert 等^[74]于2009年在图像识别任务中提出。该方法通过引入属性学习的建模思路,首次实现了在训练集完全不包含目标类别样本的情况下,仍能对未见类别的图像进行有效识别。具体而言,提出了直接属性预测(direct attribute prediction, DAP)与间接属性预测两种经典方法。这两种方法均通过对图像中“颜色”、“形状”等语义属性的建模,实现对未见类的分类。与传统监督学习范式不同,零样本学习并不依赖于训练阶段与测试阶段类别的一致性,而致力于将可见类知识迁移到未见类中,以实现“所学即所推”的认知能力。即通过对可见类样本及其对应的语义属性信息进行建模,获得从视觉特征空间到语义空间(或隐空间)的映射关系,并结合所有类别的属性信息来构建通用分类器。该分类器在测试阶段能够接受未见类别的属性描述,进而完成其样本的识别任务^[75-76]。一个经典的零样本学习案例是斑马的识别任务,如图6所示^[77]。




图6 基于零样本学习的斑马识别案例

Fig. 6 A famous zero-shot learning example of zebra recognition

在该任务中,训练集并未包含斑马的图像,但模型通过学习与斑马相似动物类别(如马、老虎和熊猫)的图像和属性之间的关系,掌握了与斑马相关的关键属性特征。当模型接收到斑马的语义属性描述后,能够根据先前学习的属性知识,在视觉特征与语义信息之间建立关联,从而对斑马的图像做出合理的判别。这一基于属性迁移的推理机制,使得零样本学习在面对样本获取成本高或新类别频繁出现的实际场景中展现出巨大的应用潜力。

零样本工业故障诊断的关键在于通过引入额外的辅助信息(如属性描述)来建立可见类与未见类之间的关联。这些辅助信息能够有效地描述故障,实现信息共享或迁移,从而使得在可见类训练样本上构建的故障诊断模型具备对未见类故障的判别能力^[78]。

目前,辅助知识主要包括词向量(即文本的向量化表示)和语义属性^[60,79]。其中,文本描述通常蕴含丰富的语义信息,有助于模型对未知信息进行理解与推理^[80]。在图像识别领域,词向量被广泛用于刻画类别之间的语义关系,是引入外部知识的一种重要手段。如图7所示,词向量方法通过将词汇映射到一个高维语义空间,使得语义相近的词汇在向量空间中具有相似的表示。




图7 文本的向量化表示

Fig. 7 Vectorized representation of text

这类向量通常由深度学习模型如 Word2Vec^[81]、GloVe^[82]等生成,能够有效捕捉词汇的语义和语法特征。借助这类嵌入表示,即使缺乏目标类别的训练样本,模型也能利用语义信息实现对新类别的识别。然而,在工业故障诊断场景中,词向量的效果却不如在图像识别任务中显著。一方面,不同故障类别的自然语言命名在词向量空间中往往相距较近^[83],导致模型难以区分语义相似但实际差异较大的故障类型;另一方面,工业故障数据大多以时间序列形式存在,缺乏显著的视觉特征,使得基于通用词向量模型的语义信息难以充分表达实际故障特征。此外,零样本图像分类常依赖于大规模开源语料库训练自然语言模型,而这些语料库往往缺乏对工业领域的覆盖,特别是对某些专业术语的支持更是有限^[60]。这进一步限制了词向量在工业故障诊断中的应用效果。

在工业故障诊断领域,知识的来源主要包括系统或设备的运行状态、故障模式、工况条件及工艺参数等领域特定信息。这些知识通常依赖于工业专家,如设备工程师和维修技术人员的专业标注,或通过故障手册等技术文档进行提取。对于工业场景下的零样本学习任务,知识可被界定为能在可见类与未见类故障之间迁移,并有助于实现故障识别的通用性信息^[60]。因此,在进行知识提取时,应重点关注可见类与未见类共享的特征信息,如语义描述、物理属性或内在规律等。这些通用特征不仅有助于模型开展推理判断,也为识别未见故障提供支持。例如,“泵机轴承温度升高”故障和“汽轮机轴承温度升高”故障均表现出“温度升高”这一属性。基于现有的训练数据,可以将所有与“温度升高”相关的故障类别样本进行合并,对“温度升高”这一属性进行学习和建模,并将获得的知识应用于未见类故障的诊断中。正因如此,语义属性矩阵^[8,84-85]是目前零样本故障诊断任务中应用最为广泛的一种知识表示形式,如图8^[85]所示。




图 8 故障语义属性矩阵
Fig. 8 Fault semantic attribute matrix

基于预定义类别和故障语义属性列表,依据工业知识和语义描述确定每种故障类别所具有的属性,并将各属性稀疏化处理。即每种类别通过一个行向量进行表示,向量中的每个元素表示该类别是否具有相应的属性。而所有类别属性向量的串级连接便形成了故障语义属性矩阵,其中每一行表示一个故障类别,每一列对应一个属性。例如,Fan 等^[86]针对田纳西-伊斯曼化工过程,提取了 18 条与故障相关的属性信息,并采用二进制方式进行编码:若某一属性在故障中存在,则记为 1;反之则记为 0,从而构建了故障的二进制属性向量。赵晓平等^[87]则引入故障语义属性描述,构建了旋转机械轴承的故障语义属性矩阵。该矩阵包含 4 类运行负载属性、4 类故障尺寸属性及 5 类故障位置属性。若故障具备某一属性,赋值为 1,否则为 0。潘美琪等^[88]提出了一种基于故障机理的属性建模方法,融合风机领域的专业知识,构建了包括故障类别、原因等 12 项内容的风机属性矩阵。Qin 等^[89]则将故障类型及其脉冲特性作为语义属性,用于构建更具针对性的属性矩阵。此外,Chen 等^[90-91]指出,故障信息具有由高到低的语义层次结构,通过构建层次化的语义属性矩阵,可实现更精细的故障诊断。Wang 等^[92]关注故障发生时状态变量和操作变量是否发生变化这一表层知识,进一步建立了可见与未见故障之间的故障相似性矩阵,从而缓解了传统方法对深层知识过度依赖的问题。

此外,故障表征的组合方式作为一种具有针对性的辅助知识形式,广泛应用于传统零样本复合故障诊断,如图 9 所示。该方法基于复合故障的特点,利用已有单故障的表征信息,通过组合方式构建复合故障的特征表示。通过组合方式,模型能够将已学习的单类故障知识进行有效整合,从而实现对复合故障类别的识别与推理,提升在零样本场景下对复合故障的诊断能力^[83,93]。

3.2 传统零样本故障诊断现状

零样本故障诊断问题可以看作是小样本问题的一种极端情况,也是零小样本问题中最迫切需要解决的问题。目前,传统零样本故障诊断方法大致可以分为生成式传统零样本故障诊断和嵌入式传统零样本故障




图 9 复合故障的故障组合
Fig. 9 Fault composition for compound faults

诊断方法^[9,60]。如图 10(a)所示,生成式传统零样本故障诊断方法利用可见类故障样本及其语义属性训练生成模型,使模型能够学习语义属性与特征分布之间的映射关系,从而根据未见类故障的语义描述生成对应的伪样本。如图 10(b)所示,嵌入式传统零样本故障诊断方法将可见类故障样本特征及其语义属性映射到一个共同的嵌入空间,使得同类故障的特征和语义表示在该空间中尽可能接近,而不同类故障的样本则保持可分。在测试阶段,该方法将未见类故障的语义属性映射到同一嵌入空间,并通过余弦相似度或欧氏距离等度量学习进行最近邻搜索,从而匹配最接近的故障类别,实现零样本诊断。

1) 生成式传统零样本故障诊断

生成式传统零样本故障诊断方法利用 GAN^[94-95]、VAE^[96]等成熟的技术生成未见类样本,即伪样本,从而将该问题转化为传统的监督学习问题。一般而言,生成式方法主要包括生成器和判别器两个模块。生成器的主要任务是学习真实数据 x 的潜在分布 $p_{data}(x)$,并为未见类提供大量判别器难以区分的高质量伪样本 ($D(G(z)) \rightarrow 0$)。判别器的作用则是判断输入样本是真实样本还是伪样本,并最大化对真实样本 ($D(x) \rightarrow 1$) 和生成样本 ($D(G(z)) \rightarrow 0$) 的正确分类概率。生成器和判别器的优化目标如式(6)~(7)所示。

$$\min_c E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \tag{6}$$




图10 传统零样本故障方法

Fig. 10 Traditional zero-sample fault diagnosis methods

$$\max_D (E_{x \sim p_{\text{data}}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (7)$$

其中, $G(z)$ 表示与真实数据分布相近的伪样本, z 是从先验分布 (如高斯分布 $p_z(z)$) 采样的噪声向量。

生成式方法的训练过程可表述为极小极大博弈:

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (8)$$

通过交替优化 G 和 D , 最终使生成样本分布 $p_g(x)$ 逼近真实数据分布 $p_{\text{data}}(x)$ 。

Lyu 等^[78] 提出了一种混合属性条件对抗去噪自编码器 (conditional adversarial denoising autoencoder, CADAe), 用于零样本故障分类。该方法在 GAN 的基础上引入编码器模块, 将输入样本映射为隐空间向量, 从而提升了数据生成的多样性和分类精度。Zhuo 等^[84] 在样本生成过程中引入故障属性信息, 以增强生成样本的多样性和判别性, 实现了零样本和小样本场景下的故障学习与诊断。Xu 等^[97] 提出了一种基于标签信息向量 (label information vector, LIV) 的零样本复合故障诊断方法。该方法通过组合多个单一故障的属性向量来表示复合故障, 并以此作为先验知识, 利用生成对抗网络生成复合故障的伪样本, 从而实现未见复合故障的有效识别。然而, 该方法未对样本生成过程进行进一步优化, 导致所生成样本的质量仍存在一定局限。Xu 等^[98] 基于改进的 Wasserstein GAN 模型, 提出了一种基于语义对齐的生成式传统零样本复合故障诊断方法。该方法通过学习故障语义与故障特征之间的

映射关系, 生成了复合故障伪样本, 进一步提高了模型的诊断性能。Wang 等^[99] 在假设目标域与源域标签空间一致的前提下, 提出了一种基于改进稀疏约束生成对抗网络 (sparsity-constrained GAN, SC-GAN) 的零样本故障诊断方法。该方法通过建立健康状态与故障状态之间的类别关系模型, 生成适用于新工况条件的故障数据, 并结合迁移学习技术, 挖掘源工况与目标工况之间的关联性, 从而提升新工况下的故障诊断性能。Liao 等^[100] 提出了一种属性一致生成对抗网络 (attribute-consistent generative adversarial network with feature generation, ACGAN-FG), 具备良好的特征生成能力, 可用于实现零样本场景下的故障诊断。此外, 基于语义距离的生成网络 (cycle-consistent generating network based on semantic distance, CycleGAN-SD)^[101] 和融合物理知识生成的模型^[102] 也能实现有效的零样本工业故障诊断。Shao 等^[103] 设计了一种融合 GAN 与 VAE 模型的属性一致性特征生成网络, 在生成过程中引入属性一致性约束机制以及基于属性信息的特征变换策略。属性一致性约束确保生成数据能够准确表达其对应的语义属性, 而通过串联方式对生成样本进行特征转换, 有效提升了模型在故障分类任务中的表现性能。

此外, 基于扩散模型^[104] 和基于物理模型仿真故障数据的方法^[105] 也能应用于传统零样本故障诊断中。扩散模型的核心在于利用生成式学习能力处理复杂工业数据, 其技术路径主要包含两方面: 一方面在数据层面, 通过加噪-去噪训练学习正常样本的深层分布, 利用真实数据与重建数据的差异来识别故障; 另一方面在特征层面, 利用扩散模型的条件生成能力, 为特定的故障模式生成多样化的增强样本。例如, 扩散增强双域对抗网络 (diffusion-enhanced dual-domain adversarial network, DEDDAN)^[106] 利用扩散模型增强仿真模型的故障图像数据, 并结合真实正常数据训练域判别器, 在航空航天领域的电液作动器上实现了 95.71% 的零样本故障诊断准确率。知识引导的超大趋势扩散模型 (knowledge guided mega-trend diffusion, KG-MTD)^[107] 将领域知识转化为海量虚拟数据集, 减少了对有限真实样本的依赖, 并实现了建筑空调系统的零样本故障诊断。基于物理模型仿真故障数据的诊断方法核心思想是构建能够准确反映设备运行机理的物理模型, 通过故障注入生成覆盖“未见类”的仿真样本, 从而替代真实故障数据来训练诊断模型, 例如, 数字孪生驱动的零样本迁移诊断方法 (digital twin-driven zero-shot transfer diagnosis, DTD-ZSTD)^[108] 集成了虚拟现实特征融合和三模型迁移, 能够在无需物理样本的情况下实现准确诊断。物理信息辅助注意力辅助多自编码器 (physics-informed attention-aided multiple autoencoder, PI-AMAE)^[109] 建立了三维柔性齿轮-轴-轴承系统的动力学模型, 并根据动态模型计算仿真信号。

表 2 总结了生成式传统零样本故障诊断方法。目前,这类方法主要基于 GAN 及其变体实现,其核心思想是通过生成模型学习可见类故障样本与对应语义描述之间的映射关系,进而利用未见类的语义信息生成相应的伪样本或特征表示。然而,生成式方法在实际应用中仍面临一定挑战。最突出的问题是生成样本与真实样本之间的分布差异,即生成的伪样本难以保证与真实未见类故障样本处于相同的特征空间或具有相同的概率分布。

这种分布差异主要源于 3 个方面:(1)生成模型在训练阶段仅利用可见类数据,其学习到的数据分布必然存在偏差;(2)语义属性描述与样本特征之间的映射关系通常是非线性和多模态的,简单的生成模型难以准确建模这种复杂关系;(3)在故障诊断场景中,不同故障模式的特征分布往往存在显著差异,而生成模型容易受到可见类主导模式的影响,导致生成的未见类样本或特征出现模式坍塌现象。

表 2 生成式传统零样本工业故障诊断方法总结

Table 2 Summary of generative traditional zero-sample industrial fault diagnosis methods

方法	主要模型	年份	辅助信息	应用对象	贡献	$acc_u/\%$	优缺点
GAN	CADAE ^[78]	2020	语义属性矩阵	轴承设备	构建了语义-非语义混合属性	>95	能够处理各种类型数据,并生成多样化的未见类样本,但易出现模式崩塌,生成样本不完全符合实际故障分布
	FAGAN ^[84]	2021	语义属性矩阵	液压系统 化工过程	提出了故障属性空间的生成模型	85.28 65.01	
	LIV ^[97]	2023	故障表征组合	轴承设备	定义了符合故障的 LIV	65.48	
	WGANs-GP ^[98]	2024	故障表征组合	轴承设备	基于语义对齐的故障语义构建	75.35	
	SC-GAN ^[99]	2024	工作状态参数	轴承设备	提出了健康-故障类别关联模型	93.20	
	ACGAN-FG ^[100]	2025	语义属性矩阵	液压系统	属性一致性约束机制	68.37	
				化工过程		83.40	
	CycleGAN-SD ^[101]	2025	语义属性矩阵	三相输电系统	缓解了域偏移和语义学习不足	96.50	
				液压系统		84.06	
				化工过程		72.02	
PK-ZSF ^[102]	2025	语义属性矩阵	化工过程	结合工业过程物理知识,以过程变量反映故障信息	95.55		
GAV+VAE	FGNAC ^[103]	2024	语义属性矩阵	化工过程	提出了属性一致性诊断方法	82.10	训练过程较为复杂
扩散模型	SEDEP ^[104]	2025	语义属性矩阵	轴承设备	采用软语义学习增强语义表示	90.15	生成样本覆盖面广,但训练难度大
	DEDDAN ^[106]	2025	故障模拟数据	电液作动器	双域对抗机制实现特征对齐	95.71	
	KG-MTD ^[107]	2025	故障模拟数据	建筑空调系统	建立了通用知识框架	72.80	
物理模型 仿真数据法	DTD-ZSTD ^[108]	2025	物理模型	轴承设备	对齐知识跨域,提高了泛化能力并减少了负迁移差异	88.40	减少了模拟和测量数据间的分布差异
	PI-AMAE ^[109]	2026	物理模型	齿轮传动系统	减少了仿真与测量信号间的	86.27	

2) 嵌入式传统零样本故障诊断

嵌入式传统零样本故障诊断方法通过利用可见类故障样本及其语义属性构建嵌入空间。在该空间中,模型通过学习故障特征与属性之间的关联,实现特征空间与语义空间之间的映射。同时,借助共享的语义属性,模型能够推理并预测未见类故障的语义属性,从而使其在没有相关样本参与训练的情况下,依然能够完成对未见类故障的诊断。这一过程通过跨类知识迁移和语义属性嵌入,使得相似故障模式的特征向量与对应的语义向量能够保持几何上的一致性,进而提高对未见类故障的诊断能力。

根据嵌入空间构建策略的不同,可以将嵌入式传统零样本故障诊断方法划分为基于语义空间的诊断方法(直接将故障特征映射到语义属性空间进行分类)、基于特征空间的诊断方法(将语义属性嵌入到原始特征空间进行匹配)和基于共享空间的诊断方法(通过构建一个

独立于原始特征和语义的第三方空间,实现两种模态信息的对齐)^[9],如图 11 所示。语义空间方法便于利用丰富的先验知识,特征空间方法能保留更多原始信号特性,而共享空间方法则具有更好的灵活性和可扩展性。通过这种嵌入空间的构建和跨模态映射,嵌入式方法有效实现了从可见类到未见类故障的知识迁移,显著提升了模型对未见类故障的泛化诊断能力。

(1) 基于语义空间的故障诊断方法

基于语义空间的故障诊断方法是一类常见的嵌入式诊断策略,其核心思想是将故障特征映射至语义空间,通过度量测试样本嵌入向量与各类故障原型(即故障类别在语义空间中的表示)之间的相似性,实现对故障类型的判断。基于语义空间的故障诊断方法一般包括 3 个步骤:特征提取、语义属性矩阵构建、以及特征映射与故障识别。在特征提取阶段,常采用 CNN^[69,110]、堆栈自编码




图 11 嵌入式零样本故障诊断方法

Fig. 11 Embedding zero-sample fault diagnosis method

器^[111-112]等深度学习技术对原始故障数据进行高层次抽象表征。语义属性矩阵的构建则通过对所有类别的属性向量进行级联生成,相关内容已在 3.1 节中详述,此处不再赘述。特征映射与故障识别的实质是实现知识迁移,即通过建立可见类与未见类故障之间的语义关联,利用从可见类中学习到的知识对未见类故障进行推理。该过程通常依赖于相似性度量方法与学习算法^[113]。

在基于语义空间的传统零样本故障诊断方法中,最具代表性的策略是 DAP 方法^[74]。该方法通过故障类别的属性信息建立可见类与未见类之间的关联,利用带有属性标签的样本训练属性判别器,从而实现对未见类样本属性的预测。Feng 等^[8]在 DAP 模型基础上,首次将零样本学习引入工业故障诊断领域,提出了基于故障描述的属性迁移技术(fault description based attribute transfer, FDAT),为传统零样本故障诊断提供了新的研究思路。此后,大量基于故障描述的传统零样本故障诊断方法相继被提出。Hu 等^[66]提出了一种语义一致性嵌入方法(semantic-consistent embedding, SCE),通过学习故障样本与属性向量之间的语义一致性映射,实现了在语义空间中对未见类故障的诊断。Fan 等^[86]提出了属性融合迁移网络(attribute fusion transfer, AFT),通过将故障属性知识从可访问的故障模式迁移至不可访问的故障模式,实现了知识的有效迁移与诊断性能的提升。Zhang 等^[69]设计了一种基于语义空间的一维 CNN 零样本故障诊断方法(semantic space based with 1D CNN, SSB-1DCNN),将语义描述作为可见类与未见类之间的共享属性,利用双线性兼容性函数实现故障类别的判别。此外,Cai 等^[144]提出了一种基于多属性学习的传统零样本故障诊断方法(multiattribute learning, MAL),该方法通过引入故障语义属性矩阵作为辅助信息,构建了包括故障程度、负载状态等多维属性的分类模型,提升了对未见类故障属性的预测能力,从而为诊断任务提供了更加丰富的信息支持。

Chen 等^[115]提出了一种基于显式与隐式联合属性迁移的零样本工业过程故障诊断模型(zero-sample model based on joint explicit and implicit attribute transfer, ZSJEIAT),该方法将属性空间划分为显式与隐式两部分,并通过部分可见类样本实现对未见类故障的识别。进一步地,Zhang 等^[116]结合故障类别树结构,设计了一种分类树导向的层次知识迁移故障诊断方法(category-tree-guided zero-shot diagnosis, CTZSD),通过将粗粒度任务的诊断结果与模型参数迁移至细粒度任务,实现了从粗到细的层级式故障诊断。类似地,Chen 等^[90]提出了模糊层次零样本故障诊断方法(fuzzy hierarchical zero-shot learning, FHZSL)和金字塔型零样本学习方法(pyramid-type zero-shot learning, PZSL),基于知识迁移策略实现粗粒度属性到细粒度属性的迁移,提升了未见类属性的预测精度。综上所述,基于语义空间的传统零样本诊断方法普遍将从可见类中学习到的属性知识迁移至未见类,并通过将未见类样本映射至共享语义嵌入空间,实现对未见故障的有效诊断。

此外,迁移学习技术也被广泛应用于传统零样本故障诊断中,以提升模型在未知域下的泛化能力。例如,Shang 等^[117]提出了一种混合语义属性的零样本学习模型(hybrid semantic attribute-based zero-shot learning model, HSAZLM),该模型通过融合语义属性与非语义属性,构建出具有更强表征能力的混合属性向量。在已知工况下完成训练后,该模型能够有效适应未知工况,实现了未知域故障的准确诊断。Qin 等^[89]进一步结合迁移学习与传统零样本学习的优势,引入了一种属性一致性损失的故障诊断方法(zero-shot attribute consistent, ZSAC)。该方法通过建立已知域中属性与特征之间的映射关系,引导模型学习属性空间的一致性,显著减少属性误分的风险,从而提升了模型在未知域中的故障诊断精度。基于图结构的诊断方法(LSTM-mutual information neural estimation graph network, LMG)^[118]、基于信号敏感特征和加权语义的改进小波零样本学习模型(improved wavelet zero-shot learning, IWZSL)^[119]、属性嵌入模型(zero-shot attribute embedded model for compound fault diagnosis, ZSAECFD)^[120]等方法在旋转机械零样本故障诊断领域具有一定效果。

(2) 基于特征空间的故障诊断方法

基于特征空间的故障诊断方法旨在将语义属性信息从语义空间嵌入到特征空间,并学习得到故障类别在特征空间中的表示(即特征原型),从而在特征空间中实现对未见类故障的识别与分类。该方法目前主要应用于旋转机械中的复合故障诊断任务。例如,Xing 等^[121]提出了一种在特征空间与运行状态标签空间之间构建标签描述空间(label description space embedded model for intelligent fault diagnosis, LDS-IFD)的方法,用于刻画不同故障模式间的语义关系。该方法利用线性监督自编码建

立特征空间与标签描述空间之间的映射关系,通过在特征空间中进行相似性评估,实现了对轴承和行星齿轮箱未见复合故障的有效诊断。Xu 等^[83]则采用小波变换将一维时序信号转换为二维图像,并将故障语义特征嵌入至视觉特征空间,借助相似度量实现未见复合故障的诊断(zero-shot learning compound fault diagnosis model, ZLCFDM)。在此基础上,Xu 等^[122]进一步提出了传统零样本复合故障语义学习模型(zero-shot fault semantics learning, ZSFL),以及结合语义嵌入与判别性特征提取的传统零样本复合故障诊断方法(semantic learning and discriminative features, SLDF)^[123],提升了对机械系统中复杂故障类型的诊断准确率。

(3) 基于共享空间的故障诊断方法

基于共享空间的故障诊断方法通过将语义空间中的类别原型与特征空间中的故障特征映射到同一共享空

间,从而在该空间中实现故障类别的判别与诊断。该方法旨在消除语义空间与特征空间之间的分布差异,提升模型对未见类故障的诊断能力。Long 等^[124]提出了一种基于掩码自编码器的端到端的零样本轴承故障诊断方法(masked autoencoder via end-to-end zero-shot learning, MAE_EZSL)。该方法通过引入掩码自编码器深入挖掘可见类故障的潜在特征,并对齐传感信号与故障语义分布,构建了可推广至未见类故障的共享特征表示。目前,此类方法主要应用于零样本图像分类任务中,相关研究正逐步拓展至工业故障诊断领域,展现出良好的发展潜力。

嵌入式传统零样本工业故障诊断方法已经将语义属性知识等间接经验应用于故障诊断领域,这类方法已在轴承故障诊断、电力设备故障等多个工业场景中进行验证。

表 3 总结了嵌入式传统零样本工业故障诊断方法。

表 3 嵌入式传统零样本工业故障诊断方法总结

Table 3 Summary of embedded traditional zero-sample industrial fault diagnosis methods

方法	主要模型	年份	辅助信息	应用对象	贡献	$acc_u/\%$	优缺点
语义空间	FDAT ^[8]	2021	语义属性矩阵	火电过程 化工过程	提出故障描述的属性迁移技术	92.13 69.86	模型结构简单,计算效率高,但在跨域迁移时可能存在较大偏差,枢纽点问题相对严重
	SCE ^[66]	2023	语义属性矩阵	电力设备 化工过程	提出语义一致性嵌入诊断方法	95.30 76.50	
	AFT ^[86]	2023	语义属性矩阵	化工过程	多高斯假设以计算故障属性迁移的后验概率	63.46	
	SSB-1DCNN ^[69]	2023	语义属性矩阵	轴承设备 化工过程	微小故障样本训练模型,诊断未见故障	74.91 75.94	
	MAL ^[114]	2024	语义属性矩阵	轴承设备	提出多属性学习诊断方法	81.15	
	ZSJEIAT ^[125]	2023	语义属性矩阵	化工过程 输送机	提出显式-隐式属性联合迁移技术	78.20 92.50	
	CTZSD ^[116]	2024	语义属性矩阵	火电过程	提出类别树引导的层次化知识迁移技术	80.20	
	FHZSL ^[90]	2024	语义属性矩阵	火电过程	考虑了属性的多粒度特征	91.40	
	PZSL ^[91]	2024	语义属性矩阵	火电过程	首次提出属性信息粒度的概念,探索不同粒度属性的层次关系	90.63	
	HSAZLM ^[117]	2024	语义属性矩阵	轴承设备	改善专家知识局限性引起的语义信息缺陷	96.82	
	ZSAC ^[89]	2024	语义属性矩阵	轴承设备 轴承设备	提出了细粒度属性描述方法,构建了属性一致性损失	91.85 89.77	
	LMG ^[118]	2025	语义属性矩阵	化工过程 球磨机	学习了工业多维变量间的潜在相关性	90.63 93.09	
	IWZSL ^[119]	2025	语义属性矩阵	轴承设备	提出了新的激活函数放大特征差异,并定义了单一故障属性	77.44	
	ZSAECFD ^[120]	2025	故障表征组合	轴承设备	从特征提取和语义构建角度解决 ZSFD 问题	74.43	
特征空间	LDS-IFD ^[121]	2022	故障表征组合	轴承设备 齿轮箱	构建标签描述空间以表示故障间的语义关系	86.60 100.00	可利用知识进行有效推断,但存在信息损失,复杂度增加
	ZLCFDM ^[83]	2022	故障表征组合	轴承设备	利用单一故障的振动信号构造故障语义	64.03	
	ZSFL ^[122]	2023	故障表征组合	轴承设备	构建了无需手动属性标签的故障语义	64.25	
	SLDF ^[123]	2023	故障表征组合	轴承设备	手动构造原始振动信号的低维特征,并通过 CNN 学习高维隐藏特征	66.64	
共享空间	MAE_EZSL ^[124]	2024	语义属性矩阵	轴承设备	利用掩码自编码器探索可见故障特征	79.95	模型适应性强,但复杂度较高

其中,基于语义空间的诊断方法因其模型结构简单等特点,在工业故障诊断中应用最为广泛。该方法通过构建语义属性矩阵,学习可见类样本和属性信息的映射,即可迁移特征,并将其迁移到未见类中,以实现有效的故障诊断。但该方法在跨域应用时,模型精度往往会出现较大偏差。这种偏差主要源于特征-属性映射关系在不同域中可能发生变化,以及工业现场数据往往存在较强的噪声干扰。因此需结合领域自适应等技术手段加以改进。

3.3 广义零样本故障诊断现状

与传统零样本故障诊断方法相比,目前该领域的研究相对较少。现有方法主要通过构建判别模型(也称分布外模型)或生成模型,将广义零样本故障诊断任务转换为传统零样本学习和监督学习任务。根据模型构建方式的不同,现有方法可分为两类:生成式广义零样本故障诊断方法和嵌入式广义零样本故障诊断方法^[9]。

1) 生成式广义零样本故障诊断

生成式广义零样本故障诊断方法通过合成未见类故障的特征或伪样本,以增强模型对该类故障的识别能力,解决未见类样本缺失所带来的训练困难。该类方法在训练阶段利用生成模型构建未见类的特征表示,从而使诊断模型同时具备对可见类和未见类故障的判别能力。Huang等^[71]提出了一种基于条件变分自编码器(conditional VAE, CVAE)的门控模型,通过 CVAE 生成可见类和未见类故障的伪样本,将广义零样本故障诊断任务分解为传统监督学习任务与零样本学习任务,从而统一故障诊断流程并提高诊断性能。Mou等^[68]设计了跨模态重构变分自编码器(VAE based on distributional semantic embedding and cross-modal reconstruction, DSECMR-VAE),利用语义属性描述信息与属性知识迁移策略生成故障样本,实现了对未见类工业故障的有效诊断。Zhao等^[125]利用语义属性描述作为辅助知识,引入了广义零样本故障诊断知识空间共享模块(knowledge space sharing, KSS),并结合生成机制来生成未见类故障样本,从而将广义零样本故障诊断任务转换为监督学习任务,在一定程度上缓解了由于缺乏未见类故障样本而造成的模型映射域偏移问题。随后,为提高生成样本质量,Zhao等^[126]构建了故障属性驱动的偏差校准模型(fault attribute-driven bias calibration, FAIR)。该模型从可见类故障中提取故障属性特征,并在故障属性的指导下进行重新组合,缓解了映射域偏移问题,提高了工业故障诊断性能。Qin等^[127]提出了一种融合可见类数据特征提取与未见类特征生成的广义零样本故障诊断方法。该方法基于去噪扩散概率模型(denoising diffusion probabilistic model, ResDDPM),生成未见类故障的高质量特征表示,实现了对高铁转向架复合故障的诊断。Cen等^[128]构建了一种集语义生成、特征匹配与故障判别于一体的广义零样本

复合故障诊断框架(generative generalized zero-shot learning, GGZSL)。该方法通过语义生成模块和判别器生成复合故障的语义向量,并匹配故障语义,实现了对单一故障及未见复合故障的诊断。Liu等^[129]提出一种联合低秩流形分布语义嵌入和多模态变分自动编码器(joint low-rank manifold distributional semantic embedding and multimodal variational autoencoder, JLMDSSE-mVAE),用于批处理过程的广义零样本故障诊断,在青霉素发酵过程和半导体刻蚀过程上验证了方法的有效性。

生成式方法试图将广义零样本故障诊断问题转化为一个传统的监督学习问题,其主要关注如何找到实例级样本特征与类别级属性之间的关系,并且只使用一种原型(如类别原型)进行推理,这不利于补偿自然存在的语义差异问题,即人工定义的语义属性与实际故障特征之间复杂的非线性关系。此外,这类方法在模型训练和构建过程中通常需要大量可见类故障样本才能学习到可靠的特征分布,特别是在处理复杂工业故障时,由于故障模式的高度非线性和工况的时变性,生成样本的有效性往往难以保证,这直接制约了该类方法在工业场景中的可靠性。

2) 嵌入式广义零样本故障诊断

嵌入式广义零样本故障诊断方法的核心思想在于通过映射函数构建故障类别的语义嵌入空间,将特征空间中的样本映射至该语义空间,进而建立不同故障类别特征与其语义嵌入之间的对应关系。基于相似性度量,模型能够借助可见类别的语义信息,推理并识别未见类故障。Pan等^[130]提出了一种结合异常检测与压缩堆栈自编码器的故障诊断框架(contractive stacked autoencoder, CSA)。该框架通过计算所提取的特征与输入数据重建结果之间的误差,构建了针对零样本故障的鉴别器,有效地将广义零样本故障诊断问题转化为监督学习问题与传统零样本诊断问题。Zhang等^[131]描述了转向架故障模式的各类属性,并为每个属性设计了独立的分类器。通过所有属性分类器与故障模式间的映射,实现了单一故障和复合故障的广义零样本诊断。Huang等^[67]在 DAP 模型的基础上,提出了一种用于广义零样本故障诊断任务的二分类端到端框架(end-to-end neural network, e2eNN)。该框架基于故障语义描述和域判别器,将测试样本进行可见/未见判别,并在不同空间中根据预测属性对判别后的测试样本进行近邻搜索,以识别出测试样本。为缓解未见类故障映射域偏移问题,Yue等^[63]通过引入额外的未标签数据集作为辅助信息,提出了一种半监督混合三重网络(semisupervised hybrid triplet network, SHTN)。该方法在相似空间中定义了可见类和未见类故障的相对边界,构建了半监督相似度学习和门控判别机制,从而实现了广义零样本工业故障诊断。Ren等^[132]基于不确定元域理论,构建了语义属性驱动的本原型,

并在原型层面与分布层面实现样本与属性的对齐,提出了一种张量化的广义零样本故障诊断框架(meta learning evolver, MetaEvolver)。该方法通过联合优化多个损失函数,有效促进了知识在可见类与未见类之间的迁移,提升了模型在未见域中的泛化能力。Zhang 等^[133]提出了一种融合信号处理与深度学习的广义零样本诊断方法(improved GSZL based on SVM and extended DenseNet model, IGZSL-SEDM)。该方法设计了一种基于信号时域特征的故障模式属性描述策略,并借助属性描述矩阵,将传统数据驱动方法中“样本到标签”的直接映射过程转化为“样本-属性-标签”的渐进式映射路径。Cai 等^[134]提出了一种基于分布阈值判别机制的广义零样本故障诊断方法(distribution threshold discrimination mechanism, DTDM)。该方法将广义零样本故障诊断任务分解为传统零样本故障诊断任务和子广义零样本故障诊断任务,以在不同空间中进行故障学习和诊断。值得注意的是,该方法执行子广义零样本故障诊断而非传统监督学习诊断,并构建子判别器,进一步缓解了映射域偏移问题。

此外,生成式与嵌入式方法的融合近年来也得到一定关注。这类方法通过结合生成模型的样本合成能力与嵌入式方法的语义对齐优势,能够在一定程度上缓解未见类样本缺失导致的映射域偏移问题。Li 等^[135]针对全局未见故障诊断问题,提出了一种联邦广义零样本故障诊断框架。该方法设计了一种通用的语义知识库构建策略,用于提供不同故障类别的辅助判别描述。基于两个耦合的变分自编码器,构建了一个双向对齐网络(bidirectional alignment network, BAN),实现了故障数据与属性信息的融合,进而利用属性描述和未见类伪样本辅助完成故障诊断任务。类似地, Xu 等^[136]结合生成式与嵌入式诊断方法的优势,提出了一种基于原始振动信号的统计指标特征与深度提取特征对齐的故障语义构建方法(contrast generation and adaptive smoothing network, CGASNet)。该方法通过训练对比嵌入生成模块,充分利用语义信息与特征的关系,在广义零样本设置下实现了对轴承复合故障的诊断。

表 4 总结了现有广义零样本故障诊断方法。

表 4 广义零样本工业故障诊断方法总结							
Table 4 Summary of generalized zero-sample industrial fault diagnosis methods							
方法	主要模型	年份	辅助信息	应用对象	贡献	$H_1/\%$	优缺点
生成式	CVAE ^[71]	2021	语义属性矩阵	化工过程	首次提出基于 GZSL 的故障分类方法	36.40	适合复杂多变的工业环境,减少数据共享的隐私风险,但训练资源要求高,难以生成高保真的故障样本
	DSECMR-VAE ^[68]	2023	语义属性矩阵	青霉素发酵 化工过程	构建了分布式语义嵌入与跨模态 重构 VAE,缓解了域偏移	36.72 42.05	
	KSS ^[125]	2023	语义属性矩阵	化工过程	提出知识空间共享模型缓解域偏移	50.07	
	FAIR ^[126]	2024	语义属性矩阵	化工过程 液压系统	提出基于属性特征 重组的偏差校准模块	52.20 76.10	
	ResDDPM ^[127]	2024	故障表征组合	轴承设备	利用扩散生成模型增强数据生成能力	83.96	
	GGZSL ^[128]	2024	故障表征组合	轴承设备	利用单一故障的低维语义,线性推导出 复合故障的低维语义	72.54	
	JLMDSE-mVAE ^[129]	2025	语义属性矩阵	青霉素发酵 半导体蚀刻	缓解了人为定义的语义偏差	75.94 76.80	
嵌入式	CSA ^[130]	2022	工作状态参数	轴承设备	设计了无监督学习的零样本故障判别器	-	具有较强的泛化能力和较高的计算效率,但依赖于门控模型分类边界和属性表示的准确性
	DenseNet ^[131]	2023	语义属性矩阵	高铁转向架	建立了高铁转向架的属性描述系统	95.91	
	e2eNN ^[67]	2023	语义属性矩阵	化工过程	预测属性误差纠正可见故障语义描述	48.86	
	SSHTN ^[63]	2024	语义属性矩阵	化工过程 火电过程	定义了辅助集,缓解了域漂移	53.50 64.31	
	MetaEvolver ^[132]	2024	语义属性矩阵	化工过程	学习演化不确定的元域样本和属性原型	47.74	
	IGZSL-SEDM ^[133]	2024	语义属性矩阵	高铁转向架	利用属性描述空间缓解投影域漂移	98.05	
	DTDM ^[134]	2025	语义属性矩阵	轴承设备 化工过程	构建了未见故障判别器,引入了 未见故障知识缓解了域偏移	57.39 72.48	
生成式+ 嵌入式	BAN ^[135]	2023	语义属性矩阵	火电过程	设计了双向对齐网络融合数据和知识	77.08	诊断精度较高,但计算开销更大
	CGASNet ^[136]	2024	故障表征组合	轴承设备	构建基于特征对齐网络的故障语义	79.14	

其中,生成式广义零样本故障诊断方法通过构建生成模型,在一定程度上解决了未见类数据缺失的问题,但该方法对训练资源要求较高,需要大量的可见类样本和多轮次训练才能获得稳定的生成效果。此外,由于工业故障数据的复杂性和噪声干扰,难以生成高质量的故障样本,表现为特征模糊、模式单一等问题。嵌入式广义零样本故障诊断方法通过构建判别模型来区分可见类和未见类样本,具有较强的诊断能力。然而,由于模型只能访问可见类样本,无法获取未见类样本信息,因此两者的分类边界难以精确划分。综合来看,两类方法在工业故障诊断中呈现出明显的互补特性:生成式方法通过数据扩充缓解样本不足问题,但受限于生成样本质量;嵌入式方法具有更强的判别能力,却面临决策边界模糊的挑战。因此,未来研究可集中如何通过生成-判别协同优化、跨模态对齐等策略,构建更鲁棒的广义零样本故障诊断框架。

4 零样本故障诊断的挑战及任务拓展

随着工业智能化的发展,零样本故障诊断技术因其在未见类故障诊断方面的潜力而备受关注,逐渐成为保障工业过程/设备安全稳定运行的重要手段。然而,当前研究仍面临故障语义描述不充分,域偏移与域漂移现象显著,以及枢纽点问题导致的诊断性能下降等关键挑战。针对这些问题,亟需探索更具适应性和泛化能力的诊断方法。与此同时,工业场景的复杂性和多样性也推动着零样本故障诊断向更广义的任务范畴拓展,例如任意样本场景和开放集环境下的诊断需求。后文将首先剖析零样本故障诊断中存在的 key 问题,继而探讨该技术向更开放、更灵活工业场景延伸的可能路径,为构建新一代工业故障诊断体系提供思路。

4.1 零样本故障诊断存在的问题

通过对现有零样本故障诊断方法的系统梳理,本研究将其核心挑战归纳:首先,故障语义描述的精细化程度不足会显著影响知识迁移效果;其次,未见类故障映射域偏移及训练域与测试域之间存在的域漂移现象导致语义失真;此外,枢纽点问题进一步加剧了诊断模型的偏差积累。这些关键问题严重制约了零样本故障诊断模型的性能表现,后文将针对这些问题展开详细分析。

1) 故障语义属性精细化描述问题

在零样本场景下的故障诊断任务中,语义属性描述是连接可见类故障与未见类故障的关键信息。然而,人工定义的“振动幅度高”、“温度异常”等粗粒度语义属性虽能为故障分类提供一定的线索,但存在主观性强、泛化性弱的缺陷,往往只能提供对故障类别的整体性和概括性的描述,难以精准刻画故障的细粒度特征差异。例如,

在连续式搅拌釜系统中,“温度异常”这一粗粒度描述无法区分温度过高与过低的具体原因,而这些因素可能分别对应热交换器故障或温控系统故障等不同类型的故障模式。又如在轴承故障中,“振动幅度高”可能对应轴承磨损或转子失衡,但二者的频域特征和故障机理存在差异。粗粒度描述方式无法对这些细节进行有效区分,导致可见类与未见类故障在语义空间中的关联性不足,影响模型对故障的推理能力。相反,通过基于知识图谱或基于大语言模型的语义解耦等方法,可以生成更加精细化的属性描述。这种方法能够从振动信号、热成像、维修记录等多源数据中提取多层次、可量化的语义特征,进而建立更准确的故障属性-特征映射关系,从而有效减少人为归纳偏差,并增强可见类与未见类故障在语义空间中的可迁移性。

2) 零样本故障诊断域偏移问题

传统零样本故障诊断方法假设测试类仅包含未见类故障。在广义零样本场景下,由于模型训练时仅接触可见类故障数据,而在测试阶段需同时诊断可见类和未见类故障,导致模型过度依赖可见类故障的特征,将未见类故障错误映射到可见类的语义空间,即未见类故障映射域偏移。例如,在化工厂离心泵群中,其训练数据仅包含3种常见故障:轴承磨损A、叶轮腐蚀B、轴不对称C,但测试时需同时诊断这3种可见故障和2种未见故障(机械密封泄漏D、耦合器损坏E)。而密封泄漏故障因振动能量与轴承磨损相近而被误判,如图12所示。




图12 未见类故障映射域偏移

Fig. 12 Domain bias for unseen faults

未见类故障映射域偏移的核心矛盾在于:传统方法通常通过对抗训练或语义嵌入对齐可见类与未见类的全局分布,但缺乏对未见类样本的显式区分机制,使得判别器在分类时倾向于将未见类故障误判为可见类别。尽管部分研究通过生成式模型合成未见类样本或引入判别检测模块在一定程度上缓解了该问题,但多数方法主要优化生成器的特征真实性,而未对判别器的分类边界进行

校准(如未约束可见类与合成未见类样本的决策置信度差异),导致模型无法平衡可见类与未见类故障的识别精度。此外,多数方法忽略了判别器对未见类故障的判别精度,主要针对判别后的可见类故障样本进行监督学习,导致部分未见类故障仍存在误判。解决该问题需联合优化生成-判别过程,一方面利用故障语义的层次化属性构建细粒度生成约束,确保合成未见类样本的多样性;另一方面引入动态阈值机制或不确定性度量,迫使判别器在保持可见类分类性能的同时,对偏离可见分布的样本保持低置信度输出,以有效判别未见类故障并修正其偏移,从而减少误判并提升工业场景中广义零样本故障诊断的整体性能。

3) 零样本故障诊断域漂移问题

在工业环境中,原材料的更换、控制系统设定值的调整等因素往往会导致多工况现象,从而不可避免地引发训练源域(历史数据)和测试目标域(新工况)之间的分布差异,导致域漂移问题,如图13所示。




图13 未见类故障映射域漂移

Fig. 13 Domain shift for unseen faults

例如,在石化催化裂化装置中,当原料油从低硫原油切换为高硫原油时,装置运行工况发生显著变化。传统基于历史数据训练的诊断模型在新工况下对“催化剂结焦”这类常见故障的诊断准确率骤降。这种性能下降主要源于硫含量变化导致温度、压力等过程参数的基准值偏移以及高硫环境下故障表征模式发生改变。广义零样本故障诊断在此场景中面临双重挑战:既要识别新工况可能引发的硫腐蚀等未见类故障,又要处理可见故障类别的跨域迁移(如特征分布偏移)。现有跨域诊断方法通常基于闭集假设,主要关注源域与目标域之间的整体分布迁移,通过最大均值差异或对抗训练等方式减少整体域间差异,从而对齐源域与目标域共享故障类的特征分布。但这类方法忽略了目标域中存在的未见类故障,导致模型难以全面覆盖实际可能出现的故障类型。零样本故障诊断的难点在于:一方面需通过子空间对齐或生

成对抗网络等域适应技术消除可见类别工况间的分布漂移;另一方面需构建基于未见类检测阈值或语义嵌入空间泛化等未见类故障判别机制,利用故障属性或图结构等可见类故障的先验知识推断未见类故障的特征,从而实现跨域场景下可见类故障准确迁移与未见类故障主动发现的平衡,提升模型在复杂工业场景中的泛化性。

4) 零样本故障诊断枢纽点问题

零样本故障诊断中的枢纽点问题是指在高维语义嵌入空间中,由于“维度诅咒”效应,某些常见故障类别的特征向量会不平衡地成为多邻近样本的最近邻,即枢纽点,导致模型在分类时过度预测枢纽类别,而对非枢纽类别的预测不足。具体表现为:当模型将未见类故障映射到共享语义空间时,其特征向量会倾向于聚集在某些主导性的枢纽点周围,使得这些枢纽点类别(通常是训练集中频率较高的可见类故障)被过度预测,而真实的未见类故障则被错误归类。该问题的核心矛盾在于,传统基于最近邻搜索的零样本分类方法(如DAP或语义相似度匹配)未能有效约束嵌入空间的几何结构,导致特征分布呈现非均匀的“星形拓扑”,其中少量枢纽点与过多样本形成伪近邻关系。这不仅会降低模型对未见类故障的诊断准确率,还会因误分类的累积效应严重影响模型的整体诊断性能。未来研究可考虑从3个方面进行:(1)通过对比学习或流形学习优化嵌入空间的均匀性;(2)采用生成对抗网络合成更具判别性的未见类样本以平衡数据分布;(3)设计基于图神经网络或注意力机制的动态邻居选择策略,以削弱枢纽点的主导性影响。

4.2 零样本故障诊断任务拓展

尽管零样本故障诊断面临诸多挑战,工业场景的复杂需求仍在持续催生新的研究范式。在解决基础性问题的基础上,诊断模型应向更贴近实际工程场景的任务延伸:一方面需要突破固定样本量的约束,构建动态适应机制;另一方面需应对开放环境中未知故障类型的持续涌现。此外,随着大模型技术的发展,零样本工业故障诊断也将迎来范式变革:未来研究也应进一步着眼于如何利用大规模预训练模型的能力来应对工业场景中的复杂性与多样性。后文将阐述这些拓展任务的技术内涵,为未来方向提供参考。

1) 任意样本场景下的工业故障诊断任务

在实际工业场景中,所收集的故障样本数量可能因故障发生概率及采样条件的限制而存在差异。在训练阶段,一些故障类别可能完全没有对应样本(零样本情况),一些故障类别可能仅有极少量样本(小样本情况),而在测试阶段,故障类别可能既包括训练中出现过的可见类别,也包括未见过的类别(广义零样本情况)。这种小样本、零样本与广义零样本共存的任意样本场景更常见更实际,给工业故障诊断提出了全新的挑战。因此,在

未来研究中,如何设计一种统一的诊断模型,能够在任意样本场景下有效处理不同类别的样本不足或缺失问题,实现精准故障诊断,是一个值得深入研究和持续关注方向。基于元学习框架可以提供一个潜在的解决路径,通过“学习如何学习”的机制,允许模型从少量样本中快速适应不同场景,避免传统模型对样本量的过度依赖。基于度量学习的原型网络,为各类故障构建可扩展的特征空间,通过在训练阶段模拟不同样本数量和类别的分布,模型能够在实际应用中灵活应对各种样本问题。提升故障诊断的准确性。

2) 开放集场景下的工业故障诊断任务

在更加实际的工业场景中,可能会出现全新的未知故障类别,这些类别既没有训练样本,也缺乏对应的先验属性知识,即开放集场景故障诊断问题。与零样本故障诊断不同,开放集场景故障诊断任务未提供任何关于未知类别的信息,测试阶段只需从已知故障类别中辨识出未知故障类别样本,而无需对该类故障样本的标签进行进一步诊断;零样本诊断虽然没有测试类别的训练样本,但可以通过语义属性描述等先验信息对未见类故障进行诊断。因此,有必要拓展零样本场景的研究范畴,使其能够涵盖开放集场景的故障诊断问题,从而满足现代工业系统中对未知故障鲁棒检测的需求。在开放集场景中,未知故障检测的核心挑战在于设置“未知故障”的判定阈值。通过设定某一特定的置信度阈值,当模型对某个测试样本的预测置信度低于该阈值时,便将其归类为“未知故障”,从而实现了对未知类别故障的检测。未来可从3方面进行未知故障阈值设定:(1)构建基于能量分数的判别模型,通过密度估计设定动态阈值;(2)采用开集识别器 OpenMax 替代传统 Softmax,在特征空间预留未知类区域;(3)结合对抗自编码器生成潜在未知故障特征,增强决策边界鲁棒性。

3) 大模型驱动的零样本故障诊断任务

在图像和自然语言处理领域,大模型技术的快速发展为零样本工业故障诊断带来了范式变革的可能。对比语言-图像预训练、生成式预训练等基于大规模预训练的零样本模型展现了强大的跨模态理解和泛化能力。若将这种预训练-微调范式迁移到工业领域,大模型有望通过海量工业设备、系统和环境数据的学习,获取丰富的故障知识表征,突破基于人为构建语义或浅层语义嵌入方法的局限,从而显著提升对未知故障和零小样本故障的诊断能力。然而,工业数据收集难、质量低、标注成本高等因素,导致难以形成类似机器视觉或自然语言处理领域的大规模数据集,这直接制约了大模型预训练技术的应用效果。此外,大模型方法仍需解决工业场景的特殊约束:(1)联邦学习与隐私保护:由于工业现场数据涉及商业机密和隐私,无法集中存储和训练。联邦学习技术通

过本地训练和参数共享的方式,极大地提升了模型的适应性和泛化能力。在大模型框架下,通过分布式学习各设备的本地数据,有望提升在零样本场景下的诊断准确度。(2)实时性要求与嵌入式设备部署:工业现场对故障诊断的实时性要求极高,而大模型在计算资源和延迟方面面临严峻考验。通过模型压缩、量化和剪枝等技术可降低计算负担,同时结合边缘计算将推理任务分配到近设备节点,有望满足实时性需求。(3)动态知识库更新与维护:工业设备的迭代更新和故障模式演变要求诊断模型具备持续学习能力。大模型需要建立自适应学习和持续训练机制,通过动态知识库更新和知识图谱增强,在不断积累的新数据和反馈中优化故障语义表征和诊断模型,从而提升零样本诊断的鲁棒性和准确性。综上所述,大模型驱动的零样本故障诊断拓展任务,不仅需要应对传统方法中的挑战,还需突破隐私保护、实时性以及知识库更新等实际问题。未来可探索“大模型+数字孪生”的闭环诊断框架,通过虚拟仿真持续生成未见类故障数据,从而突破工业场景中样本稀缺的固有限制。

5 数据集与开源代码

本章系统梳理面向零样本工业故障诊断的数据集与开源工具,以为该领域相关研究提供基础支撑。

5.1 基准数据集

目前,零样本工业故障诊断领域的数据集主要涵盖工业过程数据集和工业设备数据集两大类。工业过程数据集通常基于仿真模型构建,通过模拟真实工业场景中的动态过程(如化工过程、液压系统等)生成故障数据。例如,经典的田纳西-伊斯曼过程数据集通过仿真化工反应过程,模拟了阀门堵塞、传感器偏移等多种故障模式,为研究零样本故障诊断提供了标准测试平台。工业设备数据集以旋转机械部件为主,其中轴承故障数据集占据主导地位。这类数据集通常通过实验台进行加速实验,收集轴承的不同故障类型,包括内圈、外圈、滚动球等单点故障,以及内圈+外圈等复合故障^[137-138]。表5详细总结了部分代表性的开源数据集,并给出了数据集描述、故障类型数、数据集网址等关键信息。这些数据集为零样本故障诊断算法的开发与验证提供了重要支持,尤其在数据稀缺或新故障类型未知的工业场景中具有显著价值。

5.2 开源代码

开源代码作为推动零样本工业故障诊断研究的重要工具,为算法验证、模型复现和技术落地提供了关键支持。目前开源代码集中在传统零样本故障诊断领域,广义零样本故障诊断开源代码未见报道。如表6所示,开源项目主要涵盖两个方面:1)基于知识和语义嵌入的迁

表 5 面向零样本场景的公开故障数据集
Table 5 Public fault datasets for zero-sample scenarios

数据集	数据集描述	故障类型数	数据集网址
凯斯西储大学轴承数据集 ^[69, 114]	由凯斯西储大学轴承数据中心提供,包含 0、1、2、3 马力 4 种电机负载工况下正常运行、滚动球、内圈和外圈故障的振动加速度信号,每个信号数据量大于 12 万条	9	https://engineering.case.edu/bearing-datacenter/download-data-file
帕德博恩大学轴承数据集 ^[114, 139]	由帕德博恩大学轴承数据中心提供,包含 4 种工况下正常运行、内圈、外圈和内外圈复合故障的电机电流、振动信号等数据,每个信号数据量为 256 823 条	3	https://groups.uni-paderborn.de/kat/BearingDataCenter/
田纳西-伊斯曼过程数据集 ^[8, 68, 86, 140]	由美国伊士曼化学公司提供,模拟了实际化工生产过程,包含正常工况及 21 种故障场景,每种故障包含 41 个测量变量和 11 个操作变量,每种故障训练集包含 480 个样本,测试集包含 960 个样本	21	http://depts.washington.edu/control/LARRY/TE/download.html
田纳西-伊斯曼过程拓展数据集 ^[63, 141]	由美国伊士曼化学公司提供,模拟了实际化工生产过程,包含正常工况及 21 种故障场景,每种故障包含 41 个测量变量和 11 个操作变量,每种故障训练集包含 480 个样本,测试集包含 960 个样本	21	https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/6C3JR1
三相输电系统数据集 ^[66]	由 4 台位于输电线路末端的 110 kV 的发电机组成,用于模拟电气故障。收集测量电压和电流,包含 1 个正常类别和 5 个故障类别,每个类别包含 7 861 个样本	5	https://www.kaggle.com/esathya-prakash/datasets
青霉素发酵过程数据集 ^[68, 142]	基于伊利诺伊州立理工学院的 Pensim 模拟平台, Cinar 等开发了 Pensim2.0 用于模拟青霉素批量生产过程。每种故障从第 100 个采样点开始,共采集 300 个样本。每个样本包含搅拌器功率、温度等 10 个过程变量	10	http://www.chee.iit.edu/~control/software.html
三相流工业过程数据集 ^[85, 134, 143]	由克兰菲尔德大学设计的一个复杂加压系统,在 4 个稳定工况和 2 个变化工况下采集空气管道堵塞、水管道堵塞等故障,每类故障包含 24 个过程变量和 2 个过程输入,每类故障样本量在 2 541~10 608	6	http://www.mathworks.com/matlab-central/fileexchange/50938-a-benchmark-case-for-statistical-process-monitoring-cranfield-multiphase-flow-facility
连续式搅拌釜反应过程仿真数据集 ^[102, 144]	通过输入流引入反应物,在催化剂的作用下发生一级不可逆反应,生成产物并通过输出流输出。通过调节温度获得不同操作条件下的过程数据	10	https://ww2.mathworks.cn/matlab-central/fileexchange/66189-feedback-controlled-cstr-process-for-fault-simulation
酸性水处理装置数据集 ^[145-146]	由里约热内卢联邦大学提供,涉及石油加工过程中含 H ₂ S 和 NH ₃ 酸性废水的化学处理过程,包含 13 个受控过程变量,训练和测试集分别包含 37 519 和 22 525 个样本	6	https://github.com/nogueira-ju/SWTU_FDD
杭州电子科技大学轴承数据集 ^[147]	涉及 13 种工况,包括正常状态、4 种单一故障(内圈、外圈、滚动球、保持架故障)和 5 种复合故障的振动加速度信号,每个信号包含至少 20 万个样本	9	https://github.com/HDUIoTSCLab/PT500min_bearing_data
江南大学轴承数据集 ^[148-149]	涉及 3 种工况下的振动信号,每种工况包含由线切割引起的滚动球、内圈和外圈故障,采样频率为 50 kHz,每种故障包含 500 500 个样本	9	https://github.com/ClarkGableWang/JNU-Bearing-Dataset
西安交通大学变速箱数据集 ^[150-151]	涉及单工况下采样频率为 20 480 Hz 的 4 种轴承故障(内圈、外圈、滚动球及其复合故障)和 3 种工况下频率为 10 kHz 的 4 种行星齿轮故障(齿面磨损、缺齿、根部裂纹、断齿)	8	https://drive.google.com/drive/folders/1ejGZu9oeL1D9nKN07Q7z72O8eFrWQTay
渥太华大学轴承数据集 ^[140, 152]	包含在时变转速(加速、减速、加速后减速、减速后加速)下的轴承振动信号,共 36 个数据集。每个数据集包含正常数据、内圈、以及外圈故障数据,每个故障包含 200 万个样本	2	https://data.mendeley.com/datasets/v43hmbwxpm/1
液压系统故障数据集 ^[84, 100, 153]	在 4 类液压部件(冷却器、阀门、泵和蓄能器)状态变化时,同步测量压力、流量和温度等过程值,包含 4 类状态属性:冷却器(3 种)、阀门(4 种)、泵泄漏(3 种)和蓄能器(4 种),原始数据包含 17 维的 2 205 个样本	256	https://archive.ics.uci.edu/ml/datasets/Condition+monitoring+of+hydraulic+systems

表6 零样本工业故障诊断开源代码
Table 6 Open code of zero-sample industrial fault diagnosis

作者	主要模型	年份	验证对象	广义场景	开源网址
Feng 等 ^[8]	FDAT	2021	火电/化工过程	否	https://github.com/LiangjunFeng/Industrial_ZSL
Fan 等 ^[86]	AFT	2023	化工过程	否	https://github.com/foryichuanqi/ADVEI-Paper-2023.11-Zero-shot-fault-diagnosis-by-attribute-fusion-transfer
Hu 等 ^[66]	SCE	2023	电力设备/化工过程	否	https://github.com/htz-ecust/Semantic-consistent-Embedding
Xu 等 ^[97]	LIV	2023	轴承设备	否	https://github.com/CoVIS-UNT/Label-Information-Vector-Generative-Zero-shot-Model
Liao 等 ^[100]	ACGAN-FG	2025	液压系统/化工过程	否	https://github.com/jie3040/ACGAN-FG
Liao 等 ^[101]	CycleGAN-SD	2025	电力设备/液压系统/化工过程	否	https://github.com/jie3040/CycleGAN-SD

移学习工具包,实现跨类别的故障知识迁移。例如,Feng 等^[8]开源了基于故障描述的属性迁移工业零样本故障诊断代码,并在田纳西-伊斯曼过程上进行了实验验证。Fan 等^[86]提出了一种基于属性融合迁移网络的零样本故障诊断方法,在田纳西-伊斯曼过程上进行了实验验证。Hu 等^[66]提供了零样本故障诊断的语义一致性嵌入开源代码。2)基于生成对抗网络和变分自编码器的特征生成框架,通过生成未见类故障伪样本缓解数据稀缺问题。例如,Xu 等^[97]公开了基于标签信息向量的零样本复合故障诊断代码。

这些开源代码有利于相关研究的开展,但工业场景中的代码鲁棒性优化及隐私保护机制仍需持续完善。未来开源生态需进一步融合物理模型先验知识,并加强工业界与学术界的协作共建。

6 结 论

零样本工业故障诊断作为解决未见类故障诊断问题的主要研究范式,在减少对训练样本的依赖、提升模型泛化能力方面展现出巨大潜力。本文简要概述了工业故障诊断领域的研究进展,系统梳理了传统与广义零样本故障诊断的定义。在传统零样本故障诊断方面,现有研究主要聚焦于未见类故障的识别,而广义零样本故障诊断则进一步考虑测试数据中可能包含可见类故障的情况,两类方法在模型架构和优化策略上存在一定差异。此外,总结了诊断方法及其关键技术优缺点;针对现有零样本故障诊断方法面临的挑战,本文重点分析了故障语义属性精细化描述不足、未见类故障映射域偏移、零样本故障诊断域漂移以及枢纽点问题,并给出了相应的研究策略及建议。本综述旨在系统总结零样本故障诊断的研究进展,为该领域未来的理论探索和工业应用提供参考。

参考文献

[1] CHIANG L H, RUSSELL E L, BRAATZ R D. Fault diagnosis in chemical processes using fisher discriminant analysis, discriminant partial least squares, and principal component analysis [J]. Chemometrics and Intelligent Laboratory Systems, 2000, 50(2): 243-252.

[2] 吴昊, 田文德, 崔哲, 等. 基于数据驱动的微小故障诊断研究进展[J]. 化工自动化及仪表, 2023, 50(4): 399-405.

WU H, TIAN W D, CUI ZH, et al. Progress in research of the micro-fault diagnosis based on data driving[J]. Control and Instruments in Chemical Industry, 2023, 50(4): 399-405.

[3] 马亮, 彭开香, 董洁. 工业过程故障根源诊断与传播路径识别技术综述[J]. 自动化学报, 2022, 48(7): 1650-1663.

MA L, PENG K X, DONG J. Review of root cause diagnosis and propagation path identification techniques for faults in industrial processes [J]. Acta Automatica Sinica, 2022, 48(7): 1650-1663.

[4] 牟森, 赵小强. 基于RLANPE的工业过程故障诊断算法研究[J]. 控制与决策, 2025, 40(2): 590-598.

MOU M, ZHAO X Q. Industrial process fault diagnosis algorithm based on RLANPE[J]. Control and Decision, 2025, 40(2): 590-598.

[5] 刘强, 柴天佑, 秦泗钊, 等. 基于数据和知识的工业过程监视及故障诊断综述[J]. 控制与决策, 2010, 25(6): 801-807, 813.

LIU Q, CHAI T Y, QIN S ZH, et al. Progress of data-driven and knowledge-driven process monitoring and fault diagnosis for industry process[J]. Control and Decision, 2010, 25(6): 801-807, 813.

[6] CHADHA G S, PANAMBILLY A, SCHWUNG A, et al.

- Bidirectional deep recurrent neural networks for process fault classification [J]. *ISA Transactions*, 2020, 106: 330-342.
- [7] 汤健, 崔璨麟, 夏恒, 等. 面向复杂工业过程的虚拟样本生成综述[J]. *自动化学报*, 2024, 50(4): 688-718.
- TANG J, CUI C L, XIA H, et al. Survey on virtual sample generation for complex industrial processes [J]. *Acta Automatica Sinica*, 2024, 50(4): 688-718.
- [8] FENG L J, ZHAO CH H. Fault description based attribute transfer for zero-sample industrial fault diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(3): 1852-1862.
- [9] 刘俊孚, 岑健, 黄汉坤, 等. 零小样本旋转机械故障诊断综述[J]. *计算机工程与应用*, 2024, 60(15): 42-54.
- LIU J F, CEN J, HUANG H K, et al. Review on zero or few sample rotating machinery fault diagnosis[J]. *Computer Engineering and Applications*, 2024, 60(15): 42-54.
- [10] ANGELI C. Online expert systems for fault diagnosis in technical processes[J]. *Expert Systems*, 2008, 25(2): 115-132.
- [11] LAVASANI S M, ZENDEGANI A, CELIK M. An extension to fuzzy fault tree analysis (FFTA) application in petrochemical process industry[J]. *Process Safety and Environmental Protection*, 2015, 93: 75-88.
- [12] ISERMANN R. Model-based fault-detection and diagnosis-status and applications[J]. *Annual Reviews in Control*, 2005, 29(1): 71-85.
- [13] LI Y X, CHAI Y, YIN H P. Autoencoder embedded dictionary learning for nonlinear industrial process fault diagnosis[J]. *Journal of Process Control*, 2021, 101: 24-34.
- [14] ZHOU H, YIN H P, CHAI Y. Multi-grained mode partition and robust fault diagnosis for multimode industrial processes [J]. *Reliability Engineering & System Safety*, 2023, 231: 109011.
- [15] 黎国强, 魏美容, 吴德烽, 等. 零故障样本下小波知识驱动的工业机器人故障检测[J]. *仪器仪表学报*, 2024, 45(9): 166-176.
- LI G Q, WEI M R, WU D F, et al. Wavelet knowledge-driven mechanical equipment fault detection with zero-fault samples [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(9): 166-176.
- [16] CHAI ZH, ZHAO CH H, HUANG B. Multisource-refined transfer network for industrial fault diagnosis under domain and category inconsistencies [J]. *IEEE Transactions on Cybernetics*, 2022, 52(9): 9784-9796.
- [17] MELO A, CAMARA M M, PINTO J C. Data-driven process monitoring and fault diagnosis: A comprehensive survey[J]. *Processes*, 2024, 12(2): 251.
- [18] SAHU A R, PALEI S K, MISHRA A. Data-driven fault diagnosis approaches for industrial equipment: A review[J]. *Expert Systems*, 2024, 41(2): 13360.
- [19] LEI Y G, YANG B, JIANG X W, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap [J]. *Mechanical Systems and Signal Processing*, 2020, 138: 106587.
- [20] MISRA M, YUE H H, QIN S J, et al. Multivariate process monitoring and fault diagnosis by multi-scale PCA[J]. *Computers & Chemical Engineering*, 2002, 26(9): 1281-1293.
- [21] DENG F, GUO S, ZHOU R, et al. Sensor multifault diagnosis with improved support vector machines [J]. *IEEE Transactions on Automation Science and Engineering*, 2015, 14(2): 1053-1063.
- [22] ZHOU CH J, LI H, YANG J T, et al. Fuzzy regular least squares twin support vector machine and its application in fault diagnosis[J]. *Expert Systems with Applications*, 2023, 231: 120804.
- [23] TIAN J L, JIANG Y CH, ZHANG J S, et al. A novel data augmentation approach to fault diagnosis with class-imbalance problem[J]. *Reliability Engineering & System Safety*, 2024, 243: 109832.
- [24] TRAN D A T, HO T K P, NGUYEN V T. Fault diagnosis in vehicle air conditioning systems via comparison of K-nearest neighbors and random forest classification models[J]. *International Journal of Mechanical Engineering and Robotics Research*, 2025, 14(5): 534-541.
- [25] 文成林, 吕菲亚. 基于深度学习的故障诊断方法综述[J]. *电子与信息学报*, 2020, 42(1): 234-248.
- WEN CH L, LYU F Y. Review on deep learning based fault diagnosis[J]. *Journal of Electronics & Information Technology*, 2020, 42(1): 234-248.
- [26] BAI R X, MENG Z, XU Q SH, et al. Fractional fourier and time domain recurrence plot fusion combining convolutional neural network for bearing fault diagnosis under variable working conditions[J]. *Reliability Engineering & System Safety*, 2023, 232: 109076.
- [27] SHAO H D, XIA M, HAN G J, et al. Intelligent fault

- diagnosis of rotor-bearing system under varying working conditions with modified transfer convolutional neural network and thermal images[J]. *IEEE Transactions on Industrial Informatics*, 2021,17(5): 3488-3496.
- [28] ZHU J J, JIANG Q SH, SHEN Y H, et al. Application of recurrent neural network to mechanical fault diagnosis: A review[J]. *Journal of Mechanical Science and Technology*, 2022,36(2): 527-542.
- [29] GAO D W, ZHU Y SH, REN ZH J, et al. A novel weak fault diagnosis method for rolling bearings based on LSTM considering quasi-periodicity [J]. *Knowledge-Based Systems*, 2021,231: 107413.
- [30] SUN M D, WANG H, LIU P, et al. Stack autoencoder transfer learning algorithm for bearing fault diagnosis based on class separation and domain fusion[J]. *IEEE Transactions on Industrial Electronics*, 2022, 69(3): 3047-3058.
- [31] LIU SH W, JIANG H K, WU ZH H, et al. Machine fault diagnosis with small sample based on variational information constrained generative adversarial network [J]. *Advanced Engineering Informatics*, 2022,54: 101762.
- [32] LI F D, CHEN J L, PAN J, et al. Cross-domain learning in rotating machinery fault diagnosis under various operating conditions based on parameter transfer [J]. *Measurement Science and Technology*, 2020, 31(8): 085104.
- [33] 石明宽, 丁传仓, 王锐, 等. 面向变工况下工业流数据故障诊断的持续迁移学习系统[J]. *仪器仪表学报*, 2024,45(4): 10-16.
- SHI M K, DING CH C, WANG R, et al. Continuous transfer learning system for fault diagnosis of industrial stream data under variable operating conditions [J]. *Chinese Journal of Scientific Instrument*, 2024,45(4): 10-16.
- [34] QIN AI S, MAO H L, HU Q. Cross-domain fault diagnosis of rolling bearing using similar features-based transfer approach[J]. *Measurement*, 2021,172: 108900.
- [35] WANG B, ZHANG M, XU H, et al. Adversarial domain adaptation with dual auxiliary classifiers for cross-domain open-set intelligent fault diagnosis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2024,73: 3529014.
- [36] XU H Y, LIU J, PENG X Y, et al. Discriminative subspace embedded dynamic geometrical and statistical alignment based on pseudo-label correction for cross-domain bearing fault diagnosis[J]. *Measurement Science and Technology*, 2024,35(1): 015001.
- [37] XU SH, MA J, SONG D W. Open-set federated adversarial domain adaptation based cross-domain fault diagnosis [J]. *Measurement Science and Technology*, 2023,34(11): 115004.
- [38] LI ZH N, LI Z D, GU F SH. Intelligent diagnosis method for machine faults based on federated transfer learning [J]. *Applied Soft Computing*, 2024, 163: 111922.
- [39] PAN S J, TSANG I W, KWOK J T, et al. Domain adaptation via transfer component analysis [J]. *IEEE Transactions on Neural Networks*, 2010, 22(2): 199-210.
- [40] XIE J Y, ZHANG L B, DUAN L X, et al. On cross-domain feature fusion in gearbox fault diagnosis under various operating conditions based on transfer component analysis[C]. 2016 IEEE International Conference on Prognostics and Health Management, 2016: 1-6.
- [41] CHEN ZH Y, HE G L, LI J P, et al. Domain adversarial transfer network for cross-domain fault diagnosis of rotary machinery[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020,69(11): 8702-8712.
- [42] LONG M SH, CAO Y, WANG J M, et al. Learning transferable features with deep adaptation networks[C]. *International Conference on Machine Learning*, 2015: 97-105.
- [43] WANG Q, MICHAU G, FINK O. Domain adaptive transfer learning for fault diagnosis[C]. 2019 Prognostics and System Health Management Conference, 2019: 279-285.
- [44] ZHANG R, TAO H Y, WU L F, et al. Transfer learning with neural networks for bearing fault diagnosis in changing working conditions[J]. *IEEE Access*, 2017,5: 14347-14357.
- [45] ALI H, CHEN D, HARRINGTON M, et al. A survey on attacks and their countermeasures in deep learning: Applications in deep neural networks, federated, and transfer learning[J]. *IEEE Access*, 2023,11: 120095-120130.
- [46] ZHENG H L, WANG R X, YANG Y T, et al. Cross-domain fault diagnosis using knowledge transfer strategy: A review[J]. *IEEE Access*, 2019,7: 129260-129290.
- [47] GRETTON A, BORGWARDT K M, RASCH M J, et al. A kernel two-sample test [J]. *Journal of Machine Learning Research*, 2012,13(1): 723-773.

- [48] ZHANG Y CH, DING J L, LI Y B, et al. Multi-modal data cross-domain fusion network for gearbox fault diagnosis under variable operating conditions[J]. Engineering Applications of Artificial Intelligence, 2024, 133: 108236.
- [49] AN Z H, LI SH M, WANG J R, et al. Generalization of deep neural network for bearing fault diagnosis under different working conditions using multiple kernel method[J]. Neurocomputing, 2019,352: 42-53.
- [50] ZHAO ZH B, ZHANG Q Y, YU X L, et al. Applications of unsupervised deep transfer learning to intelligent fault diagnosis: A survey and comparative study[J]. IEEE Transactions on Instrumentation and Measurement, 2021,70: 3525828.
- [51] JIA N, HUANG W G, CHENG Y, et al. A cross-domain intelligent fault diagnosis method based on multi-source domain feature adaptation and selection[J]. Measurement Science and Technology, 2024,35(4): 046108.
- [52] WANG X X, HE H B, LI L S. A hierarchical deep domain adaptation approach for fault diagnosis of power plant thermal system[J]. IEEE Transactions on Industrial Informatics, 2019,15(9): 5139-5148.
- [53] SHAO X R, KIM C S. Adaptive multi-scale attention convolution neural network for cross-domain fault diagnosis[J]. Expert Systems with Applications, 2024, 236: 121216.
- [54] MCMAHAN H B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data[C]. International Conference on Artificial Intelligence and Statistics, 2017: 1273-1282.
- [55] GUO SH, CHEN H, LIU Y, et al. Heterogeneous federated learning framework for IIoT based on selective knowledge distillation[J]. IEEE Transactions on Industrial Informatics, 2024,21(2): 1078-1089.
- [56] WAN L J, NING J E, LI Y Y, et al. Intelligent fault diagnosis via ring-based decentralized federated transfer learning[J]. Knowledge-Based Systems, 2024, 284: 111288.
- [57] DENG D SH, ZHAO W, WU X G, et al. DecFFD: A personalized federated learning framework for cross-location fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2024,20(5): 7082-7091.
- [58] CHEN ZH H, CHEN J L, FENG Y, et al. Imbalance fault diagnosis under long-tailed distribution: Challenges, solutions and prospects[J]. Knowledge-Based Systems, 2022, 258: 110008.
- [59] PENG P, LU J X, TAO SH T, et al. Progressively balanced supervised contrastive representation learning for long-tailed fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 3506112.
- [60] 赵健程, 冯良骏, 岳嘉祺, 等. 从零样本学习理论模型到工业应用——动机、演变与挑战[J]. 控制与决策, 2024,39(9): 2833-2857.
- ZHAO J CH, FENG L J, YUE J Q, et al. From zero-shot learning theoretical model to its industrial application: Motivation, evolution and challenges[J]. Control and Decision, 2024,39(9): 2833-2857.
- [61] 张星泽, 赵爽耀, 温创辉, 等. 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[J]. 电子测量与仪器学报, 2025,39(12): 19-33.
- ZHANG X Z, ZHAO SH Y, WEN CH H, et al. Small-sample cross-domain fault diagnosis method based on attribute-guided fine-grained feature contrast[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(12): 19-33.
- [62] 吴天舒, 尹宏鹏, 赵丹丹, 等. 基于迁移学习的零样本故障诊断[J]. 电子学报, 2023,51(9): 2572-2577.
- WU T SH, YIN H P, ZHAO D D, et al. Zero sample fault diagnosis based on transfer learning[J]. Acta Electronica Sinica, 2023,51(9): 2572-2577.
- [63] YUE J Q, ZHAO J CH, ZHAO CH H. Similarity makes difference: SSHTN for generalized zero-shot industrial fault diagnosis by leveraging auxiliary set[J]. IEEE Transactions on Industrial Informatics, 2024, 20(5): 7598-7607.
- [64] WANG Z, ZHANG J, MA K, et al. Toward unsupervised domain adaptation fault diagnosis: A multisource multitarget method[J]. IEEE Sensors Journal, 2025, 25(1): 1994-2007.
- [65] CHEN X, CHEN Z G. Cross-domain fault diagnosis of induction motor based on an improved unsupervised generative adversarial network and fine-tuning under limited labeled data[J]. Measurement, 2025, 249: 116988.
- [66] HU ZH W, ZHAO H T, YAO L J, et al. Semantic-consistent embedding for zero-shot fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2023, 19(5): 7022-7031.
- [67] HUANG J CH, LI Z X, ZHOU ZH. A simple framework to generalized zero-shot learning for fault diagnosis of industrial processes[J]. IEEE/CAA Journal of Automatica Sinica, 2023,10(6): 1504-1506.

- [68] MOU M, ZHAO X Q, LIU K, et al. Variational autoencoder based on distributional semantic embedding and cross-modal reconstruction for generalized zero-shot fault diagnosis of industrial processes[J]. *Process Safety and Environmental Protection*, 2023, 177, 1154-1167.
- [69] ZHANG S Y, WEI H L, DING J L. An effective zero-shot learning approach for intelligent fault detection using 1D CNN [J]. *Applied Intelligence*, 2023, 53 (12): 16041-16058.
- [70] REN Z L, TANG Y Q, ZHANG W SH. Quality-related fault diagnosis based on K-nearest neighbor rule for non-linear industrial processes [J]. *International Journal of Distributed Sensor Networks*, 2021, 17 (11): 15501477211055931.
- [71] HUANG J CH, LI Z X, YE L J, et al. Fault classification of industrial processes based on generalized zero-shot learning [C]. 2021 IEEE 10th Data Driven Control and Learning Systems Conference, 2021: 887-892.
- [72] POURPANAH F, ABDAR M, LUO Y X, et al. A review of generalized zero-shot learning methods [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(4): 4051-4070.
- [73] GUPTA A, NARAYAN S, KHAN S, et al. Generative multi-label zero-shot learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(12): 14614-14624.
- [74] LAMPERT C H, NICKISCH H, HARMEILING S. Learning to detect unseen object classes by between-class attribute transfer [C]. 2009 IEEE Conference on Computer Vision and Pattern Recognition, 2009: 951-958.
- [75] 徐晓峰. 基于属性的零样本学习方法研究[D]. 南京: 南京理工大学, 2020.
- XU X F. Research on attribute based on zero-shot learning approaches[D]. Nangjing: Nangjing University of Science & Technology, 2020.
- [76] CHEN X, DENG X L, LAN Y B, et al. Explanatory object part aggregation for zero-shot learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46(2): 851-868.
- [77] LU J, LI J, YAN Z ANG, et al. Attribute-based synthetic network (ABS-Net): Learning more from pseudo feature representations[J]. *Pattern Recognition*, 2018, 80: 129-142.
- [78] LYU H X, CHEN J L, PAN T Y, et al. Hybrid attribute conditional adversarial denoising autoencoder for zero-shot classification of mechanical intelligent fault diagnosis[J]. *Applied Soft Computing*, 2020, 95: 106577.
- [79] 宋杰. 基于深度模型的零样本迁移学习[D]. 杭州: 浙江大学, 2020.
- SONF J. Zero-shot transfer learning based on deep models[D]. Hangzhou: Zhejiang University, 2020.
- [80] BA J L, SWERSKY K, FIDLER S, et al. Predicting deep zero-shot convolutional neural networks using textual descriptions[C]. 2015 IEEE International Conference on Computer Vision, 2015: 4247-4255.
- [81] MIKOLOV T, SUTSKERVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality [C]. *Advances in Neural Information Processing Systems*, 2013: 3136-3144.
- [82] PENNINGTON J, SOCHER R, MANNING C D. Glove: Global vectors for word representation[C]. 2014 Conference on Empirical Methods in Natural Language Processing, 2014: 1532-1543.
- [83] XU J, ZHOU L, ZHAN W H, et al. Zero-shot learning for compound fault diagnosis of bearings [J]. *Expert Systems with Applications*, 2022, 190: 116197.
- [84] ZHUO Y, GE ZH Q. Auxiliary information-guided industrial data augmentation for any-shot fault learning and diagnosis [J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(11): 7535-7545.
- [85] CAI L, YIN H P, LIN J D, et al. Federated generalized zero-sample industrial fault diagnosis across multisource domains[J]. *IEEE Internet of Things Journal*, 2024, 11(23): 38895-38906.
- [86] FAN L CH, CHEN X L, CHAI Y, et al. Attribute fusion transfer for zero-shot fault diagnosis [J]. *Advanced Engineering Informatics*, 2023, 58: 102204.
- [87] 赵晓平, 吕凯扬, 邵凡, 等. 基于属性描述的零样本滚动轴承故障诊断[J]. *振动与冲击*, 2022, 41(15): 105-115.
- ZHAO X P, LYU K Y, SHAO F, et al. Zero sample rolling bearing fault diagnosis based on attribute description[J]. *Journal of Vibration and Shock*, 2022, 41(15): 105-115.
- [88] 潘美琪, 贺兴. 基于零样本学习的风机故障诊断方法[J]. *上海交通大学学报*, 2025, 59(5): 561-568.
- PAN M Q, HE X. A fault diagnosis method for wind turbines based on zero sample learning[J]. *Journal of Shanghai Jiaotong University*, 2025, 59(5): 561-568.
- [89] QIN Y, WANG L, QIAN Q, et al. Zero-shot attribute

- consistent model for bearing fault diagnosis under unknown domain [J]. *IEEE Transactions on Instrumentation and Measurement*, 2024,73: 3515811.
- [90] CHEN X, ZHANG B L, ZHAO CH 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.
- [91] CHEN X, ZHAO CH H, DING J L. Pyramid-type zero-shot learning model with multi-granularity hierarchical attributes for industrial fault diagnosis [J]. *Reliability Engineering and System Safety*, 2023, 240: 109591.
- [92] WANG S Q, LIU Y, WANG F L, et al. Generalized zero-shot fault diagnosis based on fault similarity for hydrometallurgical process [J]. *Control Engineering Practice*, 2025,156: 106199.
- [93] MA CH Y, WANG X ZH, LI Y B, et al. Broad zero-shot diagnosis for rotating machinery with untrained compound faults[J]. *Reliability Engineering and System Safety*, 2024,242: 109704.
- [94] LI Y X, SHI ZH Y, LIU CH ANG, et al. Augmented time regularized generative adversarial network (ATR-GAN) for data augmentation in online process anomaly detection[J]. *IEEE Transactions on Automation Science and Engineering*, 2022,19(4): 3338-3355.
- [95] YAN K, SU J Y, HUANG J, et al. Chiller fault diagnosis based on VAE-enabled generative adversarial networks[J]. *IEEE Transactions on Automation Science and Engineering*, 2022,19(1): 387-395.
- [96] WANG Q, BRECKON T P. Generalized zero-shot domain adaptation via coupled conditional variational autoencoders[J]. *Neural Networks*, 2023,163: 40-52.
- [97] XU J, LI K, FAN Y Q, et al. A label information vector generative zero-shot model for the diagnosis of compound faults[J]. *Expert Systems with Applications*, 2023,233: 120875.
- [98] XU J, KONG H, LI K, et al. Generative zero-shot compound fault diagnosis based on semantic alignment[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024,73: 3508713.
- [99] WANG Q B, LIU N, WANG J J, et al. A zero-sample intelligent fault diagnosis method for bearings based on category relationship model[J]. *Engineering Applications of Artificial Intelligence*, 2024,130: 107739.
- [100] LIAO W J, WU L K, XU SH H, et al. A novel zero-shot learning method with feature generation for intelligent fault diagnosis [J]. *IEEE Transactions on Industrial Informatics*, 2025,21(4): 3386-3395.
- [101] LIAO W J, WU L K, XU SH H, et al. Cycle-consistent generating network based on semantic distance for zero-shot fault diagnosis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2025,74: 3518413.
- [102] MU G Q, LIU CH L, CHEN J H. Integrating physical knowledge for generative-based zero-shot learning models in process fault diagnosis [J]. *Reliability Engineering and System Safety*, 2025,258: 110852.
- [103] SHAO L X, LU N Y, JIANG B, et al. Feature generating network with attribute-consistency for zero-shot fault diagnosis [J]. *IEEE Transactions on Industrial Informatics*, 2024,20(5): 7787-7796.
- [104] LI CH, YAN L J, WANG P, et al. Zero-shot fault diagnosis using soft semantic embedding of diffusion-encoded probability [J]. *Advanced Engineering Informatics*, 2025,56: 103319.
- [105] YU X L, YANG Y, DU M G, et al. Dynamic model-embedded intelligent machine fault diagnosis without fault data[J]. *IEEE Transactions on Industrial Informatics*, 2023,19(12): 11466-11476.
- [106] HE X S, ZHAO CH, LI SH L, et al. Diffusion-enhanced dual-domain adversarial network: A zero-shot fault diagnosis method for electrohydrostatic actuators [J]. *IEEE Transactions on Instrumentation and Measurement*, 2025,74: 3553709.
- [107] SUN ZH, YAO Q W, SHI L, et al. Virtual sample diffusion generation method guided by large language model-generated knowledge for enhancing information completeness and zero-shot fault diagnosis in building thermal systems [J]. *Journal of Zhejiang University-Science A*, 2025,26: 895-916.
- [108] XIAO S H, HOU J Q, KHAN M J, et al. Digital twin-driven zero-shot transfer diagnosis for rolling bearing faults under data-scarce conditions [J]. *Measurement Science and Technology*, 2025,36(10): 106111.
- [109] YUE K, LI Z CH, YAO X L, et al. Physics-informed attention-aided multiple autoencoder for gear anomaly detection under zero-shot condition [J]. *Measurement*, 2026,257: 118725.
- [110] CAO H R, SHAO H D, ZHONG X, et al. Unsupervised domain-share CNN for machine fault transfer diagnosis from steady speeds to time-varying speeds[J]. *Journal of Manufacturing Systems*, 2022,62: 186-198.
- [111] YUAN X F, HUANG B, WANG Y L, et al. Deep learning-based feature representation and its application

- for soft sensor modeling with variable-wise weighted SAE[J]. *IEEE Transactions on Industrial Informatics*, 2018,14(7): 3235-3243.
- [112] CHAI ZH, ZHAO CH H. A fine-grained adversarial network method for cross-domain industrial fault diagnosis[J]. *IEEE Transactions on Automation Science and Engineering*, 2020,17(3): 1432-1442.
- [113] SHIGETO Y, SUZUKI I, HARA K, et al. Ridge regression, hubness, and zero-shot learning[C]. *Joint European Conference on Machine Learning and Knowledge Discovery in databases*, 2015: 135-151.
- [114] 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.
- [115] CHEN ER D, WANG ZH B, ZHENG J. A zero-sample industrial process fault diagnosis model based on joint explicit and implicit attribute transfer[J]. *Measurement*, 2023,218: 113236.
- [116] ZHANG B L, ZHAO J CH, CHEN X, et al. Category-tree-guided hierarchical knowledge transfer framework for zero-shot fault diagnosis[J]. *Journal of Process Control*, 2024,141: 103267.
- [117] SHANG ZH W, TANG L T, PAN C L, et al. A hybrid semantic attribute-based zero-shot learning model for bearing fault diagnosis under unknown working conditions[J]. *Engineering Applications of Artificial Intelligence*, 2024,136: 109020.
- [118] YU B, YANG ZH M, YU Y, et al. From seen to unseen: Harnessing temporal dependencies and graph structures for zero-sample fault diagnosis in industrial systems[J]. *IEEE Transactions on Instrumentation and Measurement*, 2025,74: 3525013.
- [119] YANG X, GUO T Y, HUANG J, et al. Improved wavelet zero-shot learning model with signal-sensitive features and weighted semantics for compound fault diagnosis of rolling bearing[J]. *IEEE Transactions on Instrumentation and Measurement*, 2025,74: 3518610.
- [120] WANG L, CHEN D L, MAO Y F, et al. A zero-shot attribute-embedded model with a feature difference mapping sigmoid function for compound fault diagnosis of rotating machinery[J]. *ISA Transactions*, 2025,157: 451-465.
- [121] XING S B, LEI Y G, WANG SH H, et al. A label description space embedded model for zero-shot intelligent diagnosis of mechanical compound faults[J]. *Mechanical Systems and Signal Processing*, 2022,162: 108036.
- [122] XU J, LIANG SH K, DING X, et al. A zero-shot fault semantics learning model for compound fault diagnosis[J]. *Expert Systems with Applications*, 2023,221: 119642.
- [123] XU J, ZHANG H Q, ZHOU L, et al. Zero-shot compound fault diagnosis method based on semantic learning and discriminative features[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023,72: 3518313.
- [124] LONG J Y, LIN J, JIANG L L, et al. Masked autoencoder via end-to-end zero-shot learning for fault diagnosis of unseen classes[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024,73: 3536410.
- [125] ZHAO J CH, FENG L J, ZHAO CH H, et al. Addressing domain shift via knowledge space sharing for generalized zero-shot industrial fault diagnosis[J]. *ArXiv preprint arXiv:2306.02359*, 2023.
- [126] ZHAO J CH, YUE J Q, ZHAO CH H. Make gating fairer: Fault attribute-driven bias calibration for generalized zero-shot industrial fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024,73: 3530612.
- [127] QIN N, YIN Y R, HUANG D Q, et al. Generalized zero-shot learning for fault diagnosis in high-speed train bogies based on enhanced diffusion generative models[J]. *IEEE Transactions on Reliability*, 2024,74(2): 2867-2879.
- [128] CEN J, ZHAO B CH, LIU X, et al. An intelligent compound fault diagnosis method using generalized zero-shot model of bearing[J]. *Measurement Science and Technology*, 2024,35(9): 096134.
- [129] LIU K, ZHAO X Q, MOU M, et al. A generalized zero-shot semantic learning model for batch process fault diagnosis[J]. *Measurement Science and Technology*, 2025,36: 016228.
- [130] PAN P, LI Y, ZHAO D. Generalized zero-shot learning fault diagnosis framework based on anomaly detection and contractive stacked autoencoder[C]. *2022 China Automation Congress*, 2022: 2427-2432.
- [131] ZHANG Y M, HU Y, YIN Y R, et al. Densenet extension under the generalized zero-shot learning framework: A novel strategy for bogie fault diagnosis of high-speed train[C]. *2023 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes*,

- 2023; 1-6.
- [132] REN B CH, YANG L T, NIE X, et al. Zero-shot fault diagnosis for smart process manufacturing via tensor prototype alignment [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2025; 36(8): 13983-13994.
- [133] ZHANG Y M, QIN N, HUANG D Q, et al. Generalized zero-shot approach leveraging attribute space for high-speed train bogie [J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 3512412.
- [134] CAI L, DENG X H, YIN H P, et al. Generalized zero-sample industrial fault diagnosis with domain bias [J]. *Reliability Engineering and System Safety*, 2025, 253: 110571.
- [135] LI B X, ZHAO CH H. Federated zero-shot industrial fault diagnosis with cloud-shared semantic knowledge base [J]. *IEEE Internet of Things Journal*, 2023, 10(13): 11619-11630.
- [136] XU J, ZHANG H Q, CHEN W W, et al. CGASNet: A generalized zero-shot learning compound fault diagnosis approach for bearings [J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 2513111.
- [137] WANG X X, LU S L, CHEN K, et al. Bearing fault diagnosis of switched reluctance motor in electric vehicle powertrain via multisensor data fusion [J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(4): 2452-2464.
- [138] XIN G, LI ZH, JIA L M, et al. Fault diagnosis of wheelset bearings in high-speed trains using logarithmic short-time fourier transform and modified self-calibrated residual network [J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(10): 7285-7295.
- [139] CHEN Z Y, WU J, DENG CH, et al. Deep attention relation network: A zero-shot learning method for bearing fault diagnosis under unknown domains [J]. *IEEE Transactions on Reliability*, 2023, 72(1): 79-89.
- [140] CAI L, YIN H P, LIN J D, et al. A relevant variable selection and SVDD-based fault detection method for process monitoring [J]. *IEEE Transactions on Automation Science and Engineering*, 2023, 20(4): 2855-2865.
- [141] RIETH C A, AMSEL B D, TRAN R, et al. Issues and advances in anomaly detection evaluation for joint human-automated systems [C]. *International Conference on Applied Human Factors and Ergonomics*. Cham: Springer International Publishing, 2017: 52-63.
- [142] BIROL G, UNDEY C, CINAR A. A modular simulation package for fed-batch fermentation: Penicillin production [J]. *Computers and Chemical Engineering*, 2002, 26(11): 1553-1565.
- [143] RUIZ-CÁRCEL C, CAO Y, MBA D, et al. Statistical process monitoring of a multiphase flow facility [J]. *Control Engineering Practice*, 2015, 42: 74-88.
- [144] PILARIO K E S, CAO Y. Canonical variate dissimilarity analysis for process incipient fault detection [J]. *IEEE Transactions on Industrial Informatics*, 2018, 14(12): 5308-5315.
- [145] LIU Y, HUANG J J, JIA M M. Knowledge distillation-based zero-shot learning for process fault diagnosis [J]. *Advanced Intelligent Systems*, 2025, 7(6): 202400828.
- [146] NOGUEIRA J N P, MELO P A, DE SOUZA J R M B. Faulty scenarios in sour water treatment units: Simulation and AI-based diagnosis [J]. *Process Safety and Environmental Protection*, 2022, 165: 716-727.
- [147] CHEN H, HONG J, CHENG C, et al. Zero-shot compound fault diagnosis method using semantic construction and embedding [J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 3535013.
- [148] TANG H J, JIN W, TANG D, et al. Global-local attention-aware zero-shot learning for industrial fault diagnosis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 3517916.
- [149] LI K, PING X L, WANG H Q, et al. Sequential fuzzy diagnosis method for motor roller bearing in variable operating conditions based on vibration analysis [J]. *Sensors*, 2013, 13(6): 8013-8041.
- [150] LI T F, ZHAO ZH B, SUN CH, et al. Domain adversarial graph convolutional network for fault diagnosis under variable working conditions [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 3515010.
- [151] LI T F, ZHOU ZH, LI S N, et al. The emerging graph neural networks for intelligent fault diagnostics and prognostics: A guideline and a benchmark study [J]. *Mechanical Systems and Signal Processing*, 2022, 168(1): 108653.
- [152] HUANG H, BADDOUR N. Bearing vibration data under time-varying rotational speed conditions [J]. *Data in Brief*, 2018, 21: 1745-1749.
- [153] HELWIG N, PIGNANELLI E, SCHUTZE A. Condition monitoring of a complex hydraulic system using multivariate statistics [C]. *2015 IEEE International Instrumentation and Measurement Technology Conference*, 2015: 210-215.

作者简介



蔡力, 2019 年于海南师范大学获得学士学位, 2025 年于重庆大学获得博士学位, 现为西南交通大学电气工程学院讲师, 主要研究方向为故障检测与诊断、剩余寿命预测、(广义)零样本学习等。

E-mail: Caili@swjtu.edu.cn.

Cai Li received his B.Sc. degree from Hainan Normal University in 2019, and his Ph.D. degree from Chongqing University in 2025. He is currently a lecturer at the School of Electrical Engineering, Southwest Jiaotong University. His main research interests include fault detection and diagnosis, remaining useful life prediction, and (generalized) zero-shot learning.



尹宏鹏 (通信作者), 2003 年于重庆大学获得学士学位, 2009 年于重庆大学获得博士学位, 现为重庆大学自动化学院教授, 主要研究方向模式识别与智能系统、工业故障诊断等。

E-mail: yinhongpeng@cqu.edu.cn

Yin Hongpeng (Corresponding author) received his B.Sc. and Ph.D. degrees both from Chongqing University in 2003 and 2009, respectively. He is currently a professor at the School of Automation, Chongqing University. His main research interests include pattern recognition and intelligent systems, and industrial fault diagnosis. Corresponding author of this paper.



吴天舒, 2011 年于重庆邮电大学获得学士学位, 2020 年于重庆大学获得博士学位, 现为中国汽车工程研究院股份有限公司算法测试高级工程师。主要研究方向为数据挖掘、分布式计算、工业视觉等。

E-mail: tswu@cqu.edu.cn

Wu Tianshu received his B.Sc. degree from Chongqing

University of Posts and Telecommunications in 2011, and his Ph.D. degree from Chongqing University in 2020. He is currently a senior algorithm testing engineer at China Automotive Engineering Research Institute Co., Ltd. His main research interests include data mining, distributed computing, and industrial vision.



林景栋, 1989 年于重庆大学获得学士学位, 1992 年于重庆大学获得硕士学位, 2002 年于重庆大学获得博士学位, 现为重庆大学自动化学院副教授, 主要研究方向为工业自动化生产线设计、智能家居控制系统的设计等。

E-mail: linzhending@163.com

Lin Jingdong received his B.Sc., M.Sc., and Ph.D. degrees all from Chongqing University in 1989, 1992, and 2002, respectively. He is currently an associate professor at the School of Automation, Chongqing University. His main research interests include industrial automation line design, and smart home control system design.



柴毅, 1982 年于国防科技大学获得学士学位, 1994 年于重庆大学获得硕士学位, 2001 年于重庆大学获得博士学位, 现为重庆大学自动化学院教授, 主要研究方向为信息处理、融合与控制、故障诊断、智能控制系统等。

E-mail: chaiyi@cqu.edu.cn

Chai Yi received his B.Sc. degree from National University of Defense Technology in 1982, his M.Sc. and Ph.D. degrees both from Chongqing University in 1994 and 2001, respectively. He is currently a professor at the School of Automation, Chongqing University. His main research interests include information processing, integration and control, fault diagnosis, and computer intelligent control system.