



基于数据增强的判别元学习方法在跨设备少样本故障诊断中的应用

夏鹏程^{1,2}, 黄亦翔^{1,2*}, 王誉翔^{1,2}, 刘成良^{1,2}, LIU Jie³

1. 上海交通大学机械系统与振动国家重点实验室, 上海 200240;

2. 上海交通大学人工智能教育部重点实验室, 上海 200240;

3. Department of Mechanical and Aerospace Engineering, Carleton University, Ottawa, ON K1S 5B6, Canada

* E-mail: huang.yixiang@sjtu.edu.cn

doi: [10.1360/SST-2023-0136](https://doi.org/10.1360/SST-2023-0136)

在现代化的智能制造中, 关键机械部件的故障往往会导致复杂的工业设备出现损坏甚至停机. 智能故障诊断可为高效的设备维护提供指导, 进而减少停机, 降低生产损失, 已成为当下学术界与工业界的研究热点^[1,2]. 其中, 基于深度学习的方法近年来取得了显著的效果. 然而, 实际工业场景中往往难以获取充足的故障数据样本用于深度诊断模型的训练, 进而限制了此类方法的实际应用.

针对目标工业设备故障样本稀少的问题, 尽管迁移学习方法的研究^[3]已取得了不少进展, 但其一方面需要足够的包含故障信息的目标设备无标签样本; 另一方面源域数据需要包含相同的甚至更丰富的故障类型, 实际使用时仍具有一定的局限性. 小样本学习(few-shot learning, FSL)摆脱了上述限制, 能够仅从少量几个样例中识别之前未见的类别, 更贴近实际生产应用场景, 因而正逐渐受到研究者的关注^[4]. 现阶段开展的研究主要针对设备未见的工况下的诊断或对设备未见的故障类型的诊断, 但在实际应用中, 获取服役工业设备的充足故障样本是不可行且不安全的. 因此, 跨设备的少样本故障诊断问题更为贴近工业生产应用, 亟待开展研究.

目前针对跨设备少样本故障诊断问题开展的研究

尚少, 少量研究使用元学习方法取得了一定的效果^[5], 但同其他小样本学习方法类似, 未考虑跨设备造成的数据分布偏移问题, 导致诊断结果不够理想. 针对这一问题, 本研究提出了一种基于数据增强的判别元学习方法, 提升跨设备少样本故障诊断效果.

如图1所示, 所提出方法包括源域数据集准备、在源域开展元训练、以及在目标域开展元测试三个阶段. 首先, 从源设备获取实验数据并通过数据切分构成源域数据集. 其次, 从源域数据集中随机选取样本构成一系列元任务用于后续元训练. 在训练前, 将所有的样本进行一系列的随机变换, 包括添加高斯白噪声、随机伸缩、随机局部反转, 用以增加元任务的多样性进而使特征学习更具鲁棒性. 此外, 通过结合多尺度学习与原型网络构成特征嵌入模型, 用于学习更具适应性的特征表示. 之后, 从目标设备获取少量支撑样本, 基于随机变换对所有支撑样本进行样本增强, 以增强样本为查询样本对模型进行元训练, 实现模型在目标域上的适应性, 之后再对未知样本进行测试. 在此基础上, 本研究提出一种双曲原型损失(hyperbolic prototypical loss, HB-Proto loss)用于训练, 通过在不同故障类别的决策边界间引入边缘区域, 将决策边界由传统平面转变为双曲面, 促使模型在目标域上产生的不同

英文全文见: Xia P C, Huang Y X, Wang Y X, et al. Augmentation-based discriminative meta-learning for cross-machine few-shot fault diagnosis. Sci China Tech Sci, 2023, 66: 1698–1716, <https://doi.org/10.1007/s11431-022-2380-0>




图 1 (网络版彩图)所提出的基于数据增强的判别元学习方法框架示意图

Figure 1 (Color online) Framework illustration of the proposed augmentation-based discriminative meta-learning method.

故障样本的特征表示更具判别性。

本研究使用来自三类不同机器的数据集, 包括轴承、电机和齿轮, 对所提出方法在跨设备少样本故障诊断方面的有效性进行实验验证。在所有各类故障仅提供1个训练样本的1-shot跨设备诊断任务中, 所提出方法均达到了70%以上的诊断准确率, 并在5-shot任务

中均获得90%以上的准确率。通过消融实验和对比研究, 方法的准确率、精确率、假阳率、F1分数指标结果都表明所提出的数据变换、基于数据增强的自适应方法以及双曲原型损失都有效提高了模型性能, 与一些先进的元学习方法相比, 所提出方法也展现出了性能的优越性, 具有一定的应用前景。

参考文献

- 1 Lei Y, Yang B, Jiang X, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mech Syst Signal Process*, 2020, 138: 106587
- 2 Jin Y R, Qin C J, Zhang Z N, et al. A multi-scale convolutional neural network for bearing compound fault diagnosis under various noise conditions. *Sci China Tech Sci*, 2022, 65: 2551–2563
- 3 Li W, Huang R, Li J, et al. A perspective survey on deep transfer learning for fault diagnosis in industrial scenarios: Theories, applications and challenges. *Mech Syst Signal Process*, 2022, 167: 108487
- 4 Wu J, Zhao Z, Sun C, et al. Few-shot transfer learning for intelligent fault diagnosis of machine. *Measurement*, 2020, 166: 108202
- 5 Luo M, Xu J, Fan Y, et al. TRNet: A cross-component few-shot mechanical fault diagnosis. *IEEE Trans Ind Inf*, 2023, 19: 6883–6894