



基于半监督少样本学习的高速列车故障诊断方法

汪航, 吴昀璞, 陈建华, 雷霞
(西华大学 电气与电子信息学院, 四川 成都 610039)

摘要: 高速列车作为轨道交通系统的重要装备, 其安全运行水平直接影响整个系统的可靠性与安全性。车辆故障诊断技术通过对关键部件健康状态的监测与诊断, 保障设备安全可靠运行。然而在实际运行中, 高速列车故障样本存在数量有限且类型不完备的问题, 导致传统监督学习方法的建模能力与泛化性能受到严重制约。因此, 文章提出一种基于半监督少样本学习的高速列车故障诊断方法, 通过构建伪损失置信度机制对未标注样本进行筛选与利用, 挖掘潜在信息以增强模型的学习效果。该方法通过模型对未标注样本生成伪标签, 根据其损失率分布动态评估样本的置信水平, 进而筛选可信样本扩充训练集, 最终提升有限标注数据条件下模型的泛化能力与故障识别精度。基于高速列车故障数据集与公开滚动轴承故障数据集的试验结果显示, 即便在样本数量有限、标签信息稀缺的情况下, 文章所提方法仍实现了优异的诊断性能, 展现出良好的泛化能力, 为复杂工况下列车的状态感知与智能运维提供了切实可行的技术方案。

关键词: 深度学习; 故障诊断; 少样本学习; 高速列车; 半监督学习

中图分类号: U292.91⁺4

文献标志码: A

文章编号: 1000-128X(2025)05-0073-11

0 引言

随着现代化铁路网的日趋完善与高速列车设计运行速度的不断提升, 列车系统的安全性、稳定性和智能化运维能力面临更严苛的要求。其中, 车载状态监测与故障诊断系统作为保障高速列车关键部件安全运行的重要系统, 发挥着不可替代的作用。高速列车作为结构高度集成的复杂系统, 其走行部的部件间存在紧密的力学耦合, 且运行工况多变, 因此状态监测与故障诊断面临较大挑战^[1]。尤其是列车走行部, 转向架作为连接车体与轨道的关键承载部件, 其减振系统直接影响列车运行的平稳性和安全性; 关键部件性能退化或发生故障可能引发列车异常振动、轮轨冲击加剧等问题, 甚至造成严重安全隐患。因此, 在复杂运行环境下实现对转向架减振系统故障的及时识别, 是提

升列车安全保障能力的重要方面。

现有高速列车故障诊断方法主要包括基于专家知识设定规则、基于物理机制建模, 以及近年来发展迅速的数据驱动方法^[2-3]。其中, 深度学习作为数据驱动方法的核心代表, 凭借其强大的特征提取与非线性建模能力, 已在机械系统状态监测与故障识别领域展现出广阔的应用前景。相比传统方法, 深度学习能突破对人工经验与先验模型的依赖, 从海量监测数据中挖掘复杂系统的隐含模式, 进而提升诊断的准确性与泛化能力。近年来, 针对高速列车不同部件的深度学习诊断研究不断涌现, 涵盖了制动系统^[4]、悬挂系统^[5]、转向架关键部件^[6]等多个子系统。虽然深度学习方法在多类子系统应用中取得了一定成效, 但其性能高度依赖大量高质量的标注样本, 而这一条件在实际高速列车运行中往往难以满足。一方面, 高速列车运行中的故障事件具有随机性和偶发性, 为避免列车因非计划

基金项目: 国家自然科学基金项目 (62203368); 四川省自然科学基金项目 (2023NSFSC1440)

通信作者: 吴昀璞, 男, 博士, 副教授, 硕士生导师, 研究方向为轨道交通装备的故障诊断与健康监测; E-mail: wu_yunpu@mail.xhu.edu.cn

引用格式: 汪航, 吴昀璞, 陈建华, 等. 基于半监督少样本学习的高速列车故障诊断方法[J]. 机车电传动, 2025(5): 73-83.DOI:10.13890/j.issn.1000-128X.2025.05.008.

Citation: WANG Hang, WU Yunpu, CHEN Jianhua, et al. A fault diagnosis method for high-speed trains based on semi-supervised few-shot learning [J]. Electric drive for locomotives, 2025(5): 73-83.DOI:10.13890/j.issn.1000-128X.2025.05.008.

停运而造成运营损失, 现行运维体系普遍采用预防性维修策略, 这导致典型故障样本极为稀缺; 另一方面, 虽然部分部件已出现性能退化或隐性故障, 但通常因难以及时感知并准确定位这些故障而造成故障样本在实际数据中的遗漏; 同时, 已有故障数据的人工标注过程通常依赖专家经验, 成本高、周期长, 进一步增加了样本集构建的难度。在此背景下, 如何在有限标注样本数量条件下高效挖掘未标注数据蕴含的潜在信息, 构建泛化能力更强、可靠性更高的故障诊断模型, 成为当前智能运维研究的重要方向。

针对故障诊断中样本稀缺问题而开展的研究, 当前主要分为3类范式: 无监督学习、监督学习与半监督学习^[7-10]。三者的核心差异在于对数据标注的依赖程度及其学习范式的构建逻辑。传统监督学习方法在样本数量充足时具备较高精度, 但在标注样本数量稀缺场景下往往难以充分训练; 无监督学习完全不依赖标签信息, 但其在复杂工况下的判别能力有限; 半监督学习通过整合少量标注样本与大量未标注样本, 在保留模型判别能力的同时提升泛化能力。因此, 半监督学习成为当前解决样本数量不足问题的重要研究方向。目前, 已有学者将半监督学习方法应用于旋转机械故障诊断任务, 并取得初步成效。文献[11]提出一种结合数据增强与度量学习的多阶段半监督滚动轴承故障诊断方法, 并在测试平台与公开退化数据集上验证了其有效性; 文献[12]针对风力发电齿轮箱设计了加权质心原型网络以优化伪标签使用策略, 该方法在多个对比试验中展现出优越性能; 文献[13]通过构建深度卷积对抗生成网络, 在少样本轴承故障诊断场景中引入数据增强与改进特征提取结构, 利用生成器模拟训练样本分布, 结合密集块与扩容卷积提升故障判别能力, 在特定工况与变转速条件下表现出良好的稳健性; 文献[14]面向分布外样本干扰问题, 提出一种改进半监督原型网络, 设计标签分配机制与修正代价函数以抑制未知干扰并提升跨工况适应能力, 在齿轮箱少样本诊断任务中表现出优越的鲁棒性与泛化性能。当前研究虽已在样本利用效率与模型泛化能力方面取得进展, 但在样本信息质量控制方面仍存在不足。如何在弱监督条件下准确评估未标注样本的有效性, 并抑制低质量信息对模型训练的干扰, 在一定程度上决定了诊断结果的可信度与实用性。

为解决实际场景中数据标注不足导致的诊断性能下降问题, 本文提出一种基于伪损失置信度 (pseudo-loss confidence metric, PLCM) 的高速列车故障诊断方法。该方法在半监督学习框架下, 利用PLCM建模机制, 对多任务诊断中样本与标签的多重不确定性进行设计。具体而言, 首先通过伪损失评估模型将不同任务的未标注样本映射至同一度量空间, 并基于其历史预测损失构建先验分布; 然后利用该分布中样本位置

的概率特征估计其可信度, 筛选高置信度样本参与训练, 从而动态抑制低质量信息的干扰。该方法在不依赖大量标注样本的前提下, 通过引入基于伪损失的置信度建模机制, 可实现对未标注样本有效性的动态评估与筛选, 增强模型在弱监督条件下的辨别能力。相较于传统全监督方法, 该方法在样本获取受限场景中具有更强的适应性与实用性, 同时具备良好的任务泛化能力, 在不同故障类型、不同运行工况及标签分布不均的情况下均能保持稳定的诊断性能。凭借对少样本、高不确定性、多任务特征的协同建模能力, 该方法可为复杂轨道交通装备的状态感知与智能诊断提供兼具可靠性与可迁移性的解决方案。

1 高速列车故障的半监督识别方法

针对高速列车故障诊断中标注样本数量有限、未标注样本利用难度大及故障类型分布不均等问题, 本文将提出一种基于PLCM估计^[15]的半监督故障诊断方法。该方法以深度神经网络为基础, 结合伪损失建模、自训练机制与样本筛选策略, 在弱监督条件下提升模型对故障样本的学习能力与泛化性能。故障诊断流程包括以下4个关键阶段:

①初始训练与伪标签生成: 利用支持集所包含的有限的已标注故障样本训练初始分类器, 对未标注样本进行预测并生成伪标签及其预测概率, 用于后续置信度估计。

②伪损失建模与置信度评估: 构建伪损失空间, 引入半监督高斯混合模型 (semi-supervised Gaussian mixture model, ss-GMM) 对伪标签样本的损失分布进行建模, 依据其后验概率估计样本的置信度水平。

③高置信度样本筛选与支持集扩展: 根据置信度评估结果, 从未标注数据集中筛选高可信样本, 连同其伪标签一同加入支持集, 实现训练数据规模的扩充与分布多样性的提升。

④自训练迭代优化: 基于更新后的支持集对分类器进行多轮训练与伪标签更新, 逐步提升模型对未见类别与复杂故障样本的识别能力。

上述方法给出了一套完整的半监督少样本故障识别框架, 涵盖从伪标签生成、置信度建模到支持集扩展与迭代优化的全过程, 整体流程如图1所示。为进一步阐明该方法的实现细节与核心组件, 下文将分别从问题构建、伪损失建模、置信度量度、多步策略优化及支持集扩展等方面进行介绍。

1.1 故障诊断问题的表示

在实际运行过程中, 高速列车故障事件具有突发性, 导致可获取的故障样本数量极少, 且标注成本较高。考虑到该任务具有带标签样本稀缺、未标注样本




图1 基于PLCM的半监督故障诊断方法框架

Fig. 1 Framework of semi-supervised fault diagnosis method based on PLCM

丰富的特点, 可将其抽象为典型的半监督少样本分类问题, 并在此基础上设计相应的故障类别辨识及分类策略。

具体而言, 诊断任务可视为一个包含了 W 个故障类别的分类问题, 其中每类仅有少量带标签的历史故障样本。将每类已标注样本划为支持集 (Support Set, S), 作为模型中类内表示的参考; 从同一类标注样本中划分部分样本构成查询集 (Query Set, Q), 用于评估当前任务下的识别性能; 同时, 从运行监测数据中选取大量与上述类别匹配但无标签的样本数据构成未标注集 (Unlabeled Set, U), 用于模型的伪标签优化与泛化训练。上述任务可定义为 S -shot W -way Q -query U -unlabeled 少样本分类问题, 其中支持集包括 W 个故障类别, 每个类别有 S 个标注样本, 总计 $S \times W$ 个已知故障类型样本; 查询集由每类 Q 个样本组成, 总计 $Q \times W$ 个样本; 未标注集包含 W 个故障类别, 每个类别有 U

个未标注样本, 总计 $U \times W$ 个未知故障样本。

在高速列车故障诊断模型的训练阶段, 首先给定一个包含故障类型集合 C_{tra} 的数据集 D_{tra} , 其由标注子集 D_{label} 和未标注子集 $D_{unlabel}$ 组成, 且两者具有相同的故障类型集合 C_{tra} , 其中 $D_{label} = \{(X, y), y \in C_{tra}\}$, $D_{unlabel} = \{X_{unlabel}\}$ 。在每个训练周期内, 从 C_{tra} 中随机选择 W 个故障类别, 并从标注子集 D_{label} 中提取每个类别的 $(S+Q)$ 个标注样本, 得到查询集和支持集; 未标注子集则由从标注子集 D_{label} 对应类别的未标注样本中选取的 U 个样本组成。在不同训练周期中, 持续提供支持集、未标注集和查询集对模型进行训练。

在评估与检测阶段, 给定测试数据集 D_t , 令其包含与 C_{tra} 交集为空集类别集 C_t , 即测试集与训练集类别不重合。每个测试任务按照与训练相同的方式, 从测试集中随机选取 W 个类别, 并构建对应的支持集、未标注集与查询集。此时, 模型需在完全未见类别的

情况下, 依托有限支持样本与未标注样本完成快速适应, 并在查询集中进行预测评估。最终, 以模型在所有测试任务中的平均分类准确率作为性能指标。通过上述设置, 可有效增强模型在实际列车运行工况下对故障类型的快速识别与泛化判别能力。

1.2 伪损失估计

在处理带有噪声标签的数据时, 损失函数常被用于衡量样本的可信度, 从而实现干净样本与噪声样本的区分。此思路可应用于高速列车故障诊断中对未标注样本的处理, 即通过伪损失建模机制识别可靠的伪标签样本。本文构建基于深度神经网络的伪损失计算模型, 将带有伪标签的未标注样本映射至伪损失空间, 以度量分类器对伪标签样本判别的一致性, 进而体现其预测结果的可信程度。通过挖掘伪损失空间中低损失区域内的样本, 筛选出高置信度的伪标签数据以扩展支持集。此方法不仅有助于提高模型的鲁棒性, 而且在标注样本有限的情况下可提高模型整体性能。

设支持集 $s=\{(X_s, y_s)\}$, $y_s \in C_{\text{tra}}$, 未标注集 $u=\{(X_u)\}$ 。支持集可帮助分类器更好地适应特定任务, 通过支持集对分类器进行预训练, 可得到一组优化后的分类器参数 $\theta_{\text{classifier}}$; 利用这些参数生成未标注集的伪标签, 可提高模型对未标注样本的理解与处理能力, 从而更准确地生成伪标签, 提升模型性能。伪标签表达式为

$$y_p^u = \arg \max (P_s(X_u; \theta_{\text{classifier}})) \quad (1)$$

式中: P_s 为分类器经 softmax 后的输出; $\theta_{\text{classifier}}$ 为初始分类器的训练参数; X_u 为未标注样本。

基于伪标签结果, 可进一步计算未标注样本的伪损失值, 衡量其在当前任务下的可信度。伪损失值表达式为

$$L(u|\theta_{\text{classifier}}) = \{-y_p^u \lg(P_s(X_u; \theta_{\text{classifier}})), X_u \in u\} \quad (2)$$

带有噪声的伪标签样本 X_u , 其伪损失值通常高于干净的伪标签样本 X_u , 因此通过对伪损失值进行置信度量, 可区分出具有干净伪标签的未标注样本, 即高可靠性伪标签。

1.3 PLCM 度量

模型在深度训练过程中更倾向于优先拟合干净样本, 因此被正确学习的样本往往对应较低的损失值, 带有噪声标签的样本会呈现更高的损失值。此外, 带有噪声的伪标签数据与干净的伪标签数据的伪损失分布不同, 且每个伪损失分量近似服从正态分布, 因此未选择集和选择集分别分为干净的伪标签数据和带有噪声的伪标签数据两部分。综上所述, 根据不同的伪损失, 将未标注集组成的空间划分为4个部分, 其具体关系可表示为

$$P(u) = \{l|l \in L(u|\theta_{\text{classifier}}, F_{\text{noise}}, F_{\text{selection}})\} \quad (3)$$

式中: F_{noise} 为伪标签的噪声状态; $F_{\text{selection}}$ 为样本的选择状态。

由于带有噪声的数据易对模型的学习过程造成干扰, 在该方法中引入选择器和过滤器模型, 采用 ss-GMM 拟合伪损失分布并设置4个分布分量, 其中两个分量用于选择器对干净的伪标签数据的识别, 另外两个分量用于过滤器对带有噪声的伪标签数据的过滤。ss-GMM 能捕获数据的多模态特性, 并在未标注数据背景下完成模型拟合; 通过拟合可估计每个样本属于某一类别的置信度, 从而为每个样本分配伪标签的置信度分数。伪损失 χ_X 的概率密度函数可基于 k 分量的高斯混合模型的概率密度函数表示, 即

$$p(l_X) = \sum_{k=1}^K \Omega_k g_k(\chi_X; \mu_k; \Sigma_k) \quad (4)$$

式中: Ω_k 为第 k 个高斯分量的权重, $\Omega_k \geq 0$, $\sum_{k=1}^K \Omega_k = 1$; χ_X 为给定样本 X 的伪损失实例; $\Omega_k g_k$ 为 χ_X 分类至第 k 个高斯分量的置信度; μ_k 为第 k 个高斯分量的均值向量, 表示数据分布的中心位置; Σ_k 为第 k 个高斯分量的协方差矩阵, 描述数据分布离散程度。

设收集的伪损失实例的训练周期数为 N , 从查询集获得的标注伪损失实例可表示为 D_L , 从未标注集获得的未标注伪损失实例可表示为 D_{UNL} 。最大化这些标注和未标注伪损失实例的对数似然值。ss-GMM 模型的最大似然值估计公式为

$$\hat{\beta} = \arg \max_{\beta} [\lg p(\{D_L, D_{\text{UNL}}\}|\beta)] \quad (5)$$

式中: $\beta = \{(\Omega_i; \mu_i; \Sigma_i) | 1 \leq i \leq K\}$ 。

对数似然可表示为

$$\lg p(D_L, D_{\text{UNL}}|\beta) = \lambda \sum_{i=1}^{|D_L|} \lg p(y_L^i|\beta) p(\chi_L^i|y_L^i, \beta) + (1-\lambda) \sum_{i=1}^{|D_{\text{UNL}}|} \lg p(\chi_U^i|\beta) \quad (6)$$

式中: λ 为权重系数, 用于表示参数估计中的标注数据和未标注数据的重要程度, 可通过公式 $|D_L|/(|D_L|+|D_{\text{UNL}}|)$ 计算。

通过调整 λ 的取值可有效融合两类数据信息, 优化模型的参数估计, 模型的整体性能和准确性可得到提升。由于最大似然估计的求解难度较大, 本文采用期望最大化 (expectation maximization, EM) 算法, 通过连续迭代寻找局部最优解的方式解决该问题: 在 E 步中, 根据当前 ss-GMM 计算 χ_U^i 属于第 k 个高斯分量的后验概率 $p(g_k|\chi_U^i)$; 在 M 步中, 利用这些后验概率更新 ss-GMM 的参数估计, 连续迭代从而逐步优化模型。

通过 ss-GMM 确定伪损失分布后, 可进一步利用后验概率 $p(g_k|\chi_U^i)$ 衡量伪标签数据的置信度。用 g_c 表示由干净伪标签生成的高斯分量, 其具有较高的后验概率。这类后验概率较高的伪标签数据更可能具有准确的伪标签, 因此可选择此类数据作为扩展支持集的一

部分。随后, 利用过滤后的混合数据集重新训练分类器, 进一步提升模型性能和泛化能力。混合数据集表达式为

$$S_{mix} = \left\{ \left(X_s^i, y_s^i \right) \right\}_{i=1}^{|S|} \cup \left\{ \left(X_{U_s}^i, y_p^i \right) \right\}_{i=1}^{|U_s|} \quad (7)$$

式中: U_s 为未标注集中选择的样本; y_p^i 为样本 $X_{U_s}^i$ 对应的伪标签。

为充分挖掘未标注样本数据中的潜在信息, 本文引入自训练机制, 通过连续迭代动态更新伪标签与伪损失分布。在每轮迭代中, 先利用当前分类器对未标注样本进行推理以生成新的伪标签, 再基于最新伪标签估计伪损失, 并通过 ss-GMM 重新评估样本置信度, 筛选出高可靠的伪标签样本加入扩展支持集用于模型再训练。通过预测—筛选—再训练的闭环迭代策略, 不断提升训练集质量, 增强分类器对未知样本的判别能力。该迭代过程将持续进行, 直至迭代中伪标签的选择结果趋于稳定, 以实现对未标注数据价值的充分挖掘与利用。

1.4 多轮迭代与样本选择策略优化

在高速列车故障诊断的半监督学习过程中, 伪标签质量对模型性能有显著影响。随着伪标签样本的不断筛选与分类器的迭代更新, 未标注样本的伪损失分布将发生动态变化。基于初始阶段构建的 ss-GMM 模型所划分的伪损失空间可能存在难以准确刻画不同阶段的数据分布特征的问题, 严重时甚至会引起误判。因此, 本文采用多轮迭代与动态筛选相结合的伪标签优化策略, 通过反复执行伪标签预测—置信筛选—分类器再训练的操作, 使模型逐步提升对未标注样本的判断能力、提升置信度评估的准确性。

具体而言, 将整个训练过程分为 T 步, 对应每个训练周期执行 T 次重新选择与重新训练。每一步专注于优化一个特定的 ss-GMM, 并用 G_t 表示在第 t 阶段学习到的 ss-GMM 的参数配置。用于拟合 G_t 的伪损失实例可基于第 t 次重新选择并训练后的分类器计算得出。根据第 k 阶段 ($k \leq t$) 生成的 G_k 筛选出更为可靠的伪标签样本。通过多次重新选择和训练, 逐步调整模型参数, 使其能更好地识别并利用伪标签数据。该过程有效捕捉了伪标签质量随模型迭代逐步优化的动态特性, 显著增强了模型在少样本条件下的学习能力和泛化性能。

此外, 由于未标注数据的自动选择过程不受人工干预, 不同故障类型的伪标签样本数量可能存在较大差异, 补充样本存在类别不均衡现象。为避免样本数量多的故障分类主导模型训练, 本文在损失函数中引入类别权重机制: 通过统计当前支持集所含的各类别样本数量, 动态计算权重系数, 通过为样本较少的故障类别赋予更高损失权重来引导模型关注罕见故障模式, 提升其识别能力。

综上所述, 通过多轮伪标签迭代, 结合类别感知加权策略, 可实现在有限标注样本条件下稳定提升模型对未标注样本的利用效率与诊断准确性, 增强模型对不平衡故障类型的适应能力。

2 试验设计与结果分析

2.1 高速列车转向架故障诊断试验

2.1.1 数据描述与故障类型

本文所用高速列车数据集是西南交通大学轨道交通运载系统全国重点实验室基于多体动力学仿真模型生成的, 该数据集主要用于模拟高速列车走行部悬挂系统关键部件在多种工况下发生典型结构故障时的动力学响应特征。在数据采集的过程中, 通过仿真构建多个典型运行状态场景, 并在车辆关键部位布设 58 个传感器通道, 用于记录列车横向、垂向加速度信号等信息, 从而获取具有代表性的时序监测数据。

该数据集覆盖了列车在正常运行状态时的信号样本, 以及 30 类悬挂系统故障振动信号, 主要涉及空气弹簧、轴箱弹簧、各类减振器的结构退化与性能失效。具体而言, 空气弹簧设置两类故障, 分别对应车辆前后位置的空气弹簧漏气情形; 轴箱弹簧设置 8 类故障, 模拟不同位置弹簧的断裂状态; 减振器共设置 20 类故障模式, 包括横向减振器 4 类、抗蛇行减振器 8 类及二系垂向减振器 8 类, 分别对应车辆构架系统的不同位置。Nor、Air、Spr、Lat、Yaw 和 Ver 分别表示正常状态、空气弹簧故障、轴箱弹簧故障、横向减振器故障、抗蛇行减振器故障和二系垂向减振器故障。这些设置覆盖了同一类型部件在不同空间分布下的故障状态, 能有效反映结构部件的运行异常特征。正常工况下部分典型监测通道的加速度波形如图 2 所示。

本文对高速列车故障数据集的设置如表 1 所示。高速列车数据集被构建为支持少样本任务动态抽取的数据池, 并根据训练集和测试集故障类型的不同划分方

表 1 高速列车故障数据集的试验设置

Table 1 Experimental settings for the fault dataset of high-speed trains

数据划分	训练集类型	测试集类型	训练集大小	测试集大小
HST-1	Nor, Air, Lat, Yaw	Spr, Ver	3 000(15×200)	3 200(16×200)
HST-2	Nor, Air, Lat, Spr	Ver, Yaw	3 000(15×200)	3 200(16×200)
HST-3	Nor, Air, Lat, Ver	Spr, Yaw	3 000(15×200)	3 200(16×200)
HST-4	Nor, Lat, Spr, Yaw	Air, Ver	4 200(21×200)	2 000(10×200)
HST-5	Nor, Lat, Ver, Yaw	Air, Spr	4 200(21×200)	2 000(10×200)
HST-6	Nor, Lat, Spr, Ver	Air, Yaw	4 200(21×200)	2 000(10×200)
HST-7	Nor, Air, Spr, Yaw	Lat, Ver	3 800(19×200)	2 400(12×200)
HST-8	Nor, Air, Ver, Yaw	Lat, Spr	3 800(19×200)	2 400(12×200)
HST-9	Nor, Air, Spr, Ver	Lat, Yaw	3 800(19×200)	2 400(12×200)

式分为9个试验子集（用HST-1~HST-9表示）。这种划分方式保证了训练集与测试集的故障类型完全不同，9种划分方式能进一步验证模型在面对样本有限、故障位置分布差异明显等复杂工况下的诊断泛化能力。其中每类故障样本池的样本数量固定为200个，以确保任务抽取过程中的数据均衡性及不同试验间的可比性。其中训练集与测试集的大小为故障类别数乘以每类故障样本数。




图2 数据集监测信号

Fig. 2 Monitoring signals in the dataset

2.1.2 试验设置与方法对比

针对本文设计的基于PLCM的故障诊断架构进行试验时，输入信号为传感器采集的高速列车不同位置的原始振动监测信号（主要包括横向、垂向加速度）。特征提取主干网络选用ResNet-12，分类器采用带L2正则化的逻辑回归模型，以增强模型泛化能力并抑制过拟合。在训练阶段，初始学习率设置为0.1，每经过30个训练周期（epoch）衰减为原值的1/10，整个训练过

程共计120个周期；为拟合伪损失分布，设定每轮训练中迭代生成伪标签并收集伪损失实例的次数为200次。在评估阶段，为提高样本选择与分类器训练的稳定性，对每组样本进一步执行以10轮为周期的重复选择与再训练操作。

为全面验证所提方法的有效性，本文设计了3类对比试验，涵盖归纳式方法、直推式方法及半监督方法。归纳式方法包括 Matching Networks^[16]和 Prototypical Networks^[17]：前者基于支持集与查询集样本的嵌入距离构建度量空间进行分类，后者通过学习类别原型向量，计算查询样本到各原型的距离实现分类。直推式方法（即不引入未标注样本）选取实例可信度推断（instance credibility inference, ICI）方法^[18]作为代表，该方法可通过构建实例可信度评分策略，迭代选取伪标签样本用于分类器训练。

半监督学习方法设定时，每类故障额外引入20个未标注样本，并选取 Semi-soft 方法^[19]和原型随机游走网络（prototypical random walk networks, PRWN）方法^[20]作为对比。其中，Semi-soft方法通过融合已标注样本的类别原型与未标注样本的分布特性生成软标签，用于后续模型更新；PRWN方法则引入原型随机游走机制对未标注样本进行标签传播，并基于生成的伪标签开展训练。这两种方法均未对伪标签的置信度进行显式建模，可能导致错误的伪标签干扰模型训练。

2.1.3 试验结果

为全面评估PLCM方法在不同工况下的故障诊断能力，本文在高速列车数据集的9种不同划分方式下分别进行5-way k -shot随机抽样测试：每轮测试包含测试样本池中的5个随机故障类别，5-way 1-shot表示每类仅1个样本构成支持集，5-way 5-shot表示每类仅5个样本构成支持集。每组试验采用200次随机采样的运行结果，计算95%置信区间下的平均准确率，以降低随机误差的影响。该设置可减少单次样本选取偶然性（尤其在1-shot情形下）带来的偏差，以客观反映模型性能。PLCM方法与多种典型对比方法在3类试验设定下的性能对比结果如表2所示。

表2中，In表示归纳式方法，包括 Matching Networks与 Prototypical Networks；Tran表示直推式设置下的方法，如ICI与PLCM（无未标注样本）；Semi表示引入未标注样本的半监督方法，如Semi-soft、PRWN及本文设计的PLCM方法。对比结果表明，PLCM在多个任务设定下均取得优越的性能表现，尤其在半监督设置中显著优于其他方法，体现了其在充分挖掘未标注数据价值、提升模型鲁棒性方面的有效性。表2中每组设置下的最优结果已用加粗的数字标注，进一步验证了PLCM在复杂工况和样本稀缺条件下的广泛适应性与诊断可靠性。

表2 高速列车故障数据集的故障分类性能

Table 2 Fault classification performance on the fault dataset of high-speed trains

类型	方法	准确率/%	
		5-way 1-shot	5-way 5-shot
In	Matching Networks	38.08±0.79	44.23±0.82
	Prototypical Networks	29.84±0.82	37.93±0.77
Tran	ICI	49.11±1.71	56.19±1.56
	PLCM	50.78±1.83	57.30±1.65
	Soft <i>k</i> -Means	43.30±1.55	53.29±1.55
	Soft <i>k</i> -Means+Cluster	36.16±1.43	47.54±1.42
	Masked Soft <i>k</i> -Means	44.85±1.72	51.77±1.55
Semi	ICI	49.48±1.82	55.18±1.56
	PLCM	51.22±1.85	57.09±1.64
	PRWN	45.38±1.62	54.52±1.53
	PRWN+filter	44.29±1.58	52.96±1.51

2.2 西储大学轴承故障诊断试验

为进一步验证本文方法在多种不同场景下的适用性, 本节选用美国凯斯西储大学 (case western reserve university,CWRU) 公开滚动轴承数据集进行对比试验。该数据集由西储大学轴承数据中心公开发布, 是故障诊断领域广泛使用的标准数据集之一, 包含多种典型的轴承损伤模式与工况条件。尽管该数据集所体现的实际情况与高速列车存在差异, 但其丰富的故障模式与高质量的标注信息仍然使其成为评估智能诊断方法泛化性能的重要补充。

本试验共设置 4 种任务划分方式 (CWRU-1 ~ CWRU-4), 用以模拟训练集与测试集存在类别差异的迁移诊断情境: 训练集与测试集在故障类型上不完全相同, 每个任务选取 200 个样本作为训练与测试数据。表 3 汇总了不同数据子集的设置, 其中 “Nor” 代表正常状态; “Drive End” 与 “Fan End” 分别表示驱动端与风扇端故障 (各 13 类); “Inner Race” 和 “Outer Race” 分别对应内圈与外圈故障 (6 类与 14 类); “Ball” 表示滚动体故障 (6 类)。通过在该公开数据集上的试验, 本文所提方法在不同场景和部件类型下的故障识别能力及稳定性得到进一步评估。

表 4 展示了各方法在西储轴承数据集上分类性能的对比结果。试验时, 针对不同故障类别的 4 种划分方式 (CWRU-1 ~ CWRU-4), 分别独立运行 200 次 5-way *k*-shot(*k*=1/5)进行测试, 并计算每个划分内的平均准确率。加粗的数字表示每组设置下的最优结果。试验结果显示, 本文方法在不同设置下均表现出优越性能, 尤其是在半监督场景下, 相较于现有伪标签方法, 本文方法更具鲁棒性。在归纳式设置下, PLCM 可在有限样本支持下准确识别故障类型; 在直推式设置下,

伪损失机制的应用有效缓解了标签缺失导致的性能退化; 在半监督设置下, 借助多步训练与置信度估计策略, 未标注样本的利用效率显著提升, 该方法在少样本、半监督与任务迁移环境中的实际应用潜力得到验证。

表3 西储轴承数据集的试验设置

Table 3 Experimental settings for the CWRU dataset

数据划分	训练集类型	测试集类型	训练集大小	测试集大小
CWRU-1	Nor, Drive End	Fan End	2 800 (14×200)	2 600 (13×200)
CWRU-2	Nor, Fan End	Drive End	2 800 (14×200)	2 600 (13×200)
CWRU-3	Nor, Inner Race, Ball	Outer Race	2 600 (13×200)	2 800 (14×200)
CWRU-4	Nor, Outer Race	Inner Race, Ball	3 000 (15×200)	2 400 (12×200)

表4 西储轴承数据集故障分类性能

Table 4 Fault classification performance on the CWRU dataset


类型	方法	准确率 %	
		5-way 1-shot	5-way 5-shot
In	Matching Networks	61.20±0.51	67.54±0.46
	Prototypical Networks	63.38±0.66	75.62±0.53
Tran	ICI	87.01±1.38	91.89±0.80
	PLCM	89.40±1.47	94.62±0.80
Semi	Soft <i>k</i> -Means	73.98±1.76	82.36±1.37
	Soft <i>k</i> -Means+Cluster	75.48±1.60	83.40±1.23
	Masked Soft <i>k</i> -Means	78.14±1.54	84.34±1.21
	ICI	87.09±1.45	91.91±0.80
	PLCM	90.03±1.61	94.92±0.75
	PRWN	77.51±1.67	86.41±1.11
	PRWN+filter	79.56±1.70	87.45±1.13

2.3 参数分析


为全面评估本文故障诊断方法在不同训练条件下的适应性和稳健性, 本节围绕多个关键超参数展开试验分析, 考察其对模型性能的影响。包括训练步数、测试类别数量、标注样本数量、平衡权重系数及类间不平衡处理策略在内, 均基于高速列车与西储轴承两个数据集开展对比。

不同伪损失迭代次数下 PLCM 方法的性能变化如图 3 所示。由图 3 可知, 在合理范围内调整训练步数时, PLCM 的准确率曲线整体平稳、起伏较小, 且各步数对应的置信带大幅重叠, 显示其对步数选择不敏感、结果稳定可复现。无论是西储轴承数据的多种划分, 还是高速列车数据中结构差异更明显的划分, 曲线均未出现系统性下滑, 仅存在局部小幅波动, 体现

出伪标签迭代与高置信样本筛选机制的持续收敛性与稳健性。综合来看, PLCM在跨数据域及不同划分条件下对训练步数具有良好鲁棒性, 采用中等步数即可在不增加计算负担的前提下获得稳定、可靠的诊断性能。



(a) 高速列车数据集




(b) 西储轴承数据集

图3 不同伪损失迭代次数下PLCM方法的性能变化


Fig. 3 Performance variations of the PLCM method under different pseudo-loss iterations

不同测试类别数 (way) 下 PLCM 方法的分类性能变化如图4所示。在少样本分类任务中, way 数的增加意味着模型需在更复杂的类间边界进行判别, 这对其

泛化能力提出了更高要求。试验结果显示, 尽管 PLCM 在 5-way 设置下表现优异, 但随着 way 数逐步增加, 模型准确率呈下降趋势。该现象可归因于两方面: 一方面, 多类别情况下每个类别在特征空间中的分布更密集, 类间区分度降低; 另一方面, 支持集总样本数固定时, 单类支持样本数量的减少进一步加剧了少样本学习的挑战。整体而言, PLCM 仍保持稳定性能, 说明其在应对多故障场景时具有较强的适应性。



(a) 高速列车数据集



(b) 西储轴承数据集

图4 不同测试类别数(way)下PLCM方法的分类性能变化

Fig. 4 Classification performance variations of the PLCM method under different test ways

不同标注样本数 (shot) 下 PLCM 方法的分类性能变化如图5所示。由图5可知, 随着标注样本数量的增加, PLCM 在各数据划分上的准确率整体稳步提升且逐渐趋于饱和: 少量标注即可带来显著改善, 标注数量增加带来的增益逐步递减, 体现出良好的样本效率与可扩展性。在结构更复杂、分布差异更大的高速列车数据划分中, 增加标注能有效抑制方差、稳定伪标签质量; 而在西储轴承数据划分中, 模型在极少标注下已具有较高基线性能, 更多的标注主要起到细化类别原型与边界的作用, 曲线呈现平滑上扬趋势并在较高准确率区间收敛。整体趋势一致且无异常波动, 说明所用伪标签与置信筛选机制对标注规模的变化具有

良好鲁棒性。





图5 不同标注样本数(shot)下PLCM方法的分类性能变化
Fig. 5 Classification performance variations of the PLCM method under different numbers of shots

不同伪损失平衡权重参数下PLCM方法的分类性能变化如图6所示。由图6可知,平衡系数 λ 在最大似然阶段用于调节标注与未标注样本对GMM参数估计的相对权重。整体而言,高速列车各数据划分对 λ 较为不敏感,其曲线在较宽范围内仅有轻微起伏,说明PLCM的伪标签迭代与置信筛选过程对参数估计形成稳定约束;西储轴承各数据划分在未标注样本权重增大时呈现缓慢走低趋势,提示当未标注样本占比过高时,少量噪声或边界样本会牵引类别均值与协方差,稀释标注信息的锚定作用。由此可见,在分布差异更明显或跨域迁移更强的场景中,应以标注样本为主、适度引入未标注样本;而在结构接近或样本更复杂的场景中,PLCM对 λ 具有较好的容忍度。

不同类权重设置下PLCM方法的分类性能变化如图7所示,该图展示了类别权重机制在解决样本不均衡




(b) 西储轴承数据集

图6 不同伪损失平衡权重参数 λ 下PLCM方法的分类性能变化

Fig. 6 Classification performance variations of the PLCM method under different values of the pseudo-loss balance weight (λ)

问题中的作用。在现实场景中,故障类别常存在分布不平衡现象,导致分类器更偏向多数类而忽视少数类,尤其在少样本情境下,这种偏差更易被放大。试验表明,引入类别权重后,模型对少数类的关注度显著提高,能更准确地捕捉其特征模式,从而大幅改善对少数类故障的识别效果。该策略提升了故障诊断系统在复杂运行环境中的适用性,尤其适合在类间分布偏斜的工业监测场景中推广应用。



(a) 高速列车数据集




图7 不同类权重设置下PLCM方法的分类性能变化

Fig. 7 Classification performance variations of the PLCM method under different way weights

3 结束语

针对高速列车故障样本稀缺的问题,本文设计了

一种基于半监督少样本学习的高速列车故障诊断方法。该方法充分挖掘未标注数据中的潜在信息,采用伪损失建模方式对伪标签样本进行可信度评估,并通过多步迭代与置信度筛选机制动态扩展高质量支持集,有效缓解了传统少样本方法中支持样本不足及伪标签噪声传播的问题。具体而言,先构建伪损失模型以量化分类器对未标注样本伪标签的接纳程度,再采用 ss-GMM 对伪损失空间进行建模,从而区分高可靠性与低可靠性的伪标签样本;在此基础上,通过多步迭代训练策略动态更新分类器与伪标签质量,进一步提升模型在复杂故障分布下的判别能力;同时,针对不同故障类型在空间位置上的分布差异与样本不均衡问题,引入类别权重调节机制,增强了模型对少样本故障类别的关注。

为验证所提方法的有效性,本文在高速列车悬挂系统仿真故障数据集与经典轴承故障公开数据集上开展了系统的对比试验和参数敏感性分析。结果表明,本文方法在不同试验设置下均优于现有主流归纳式、直推式和半监督少样本学习方法,展现出更强的鲁棒性与泛化能力;同时,参数分析结果进一步验证了多步策略、伪损失建模与类别平衡机制对模型性能的显著提升作用。

综上所述,本文设计的方法在故障样本稀缺、标签难以获取的现实背景下,为高速列车故障诊断任务提供了一种高效、可推广的故障辨识方案,具有良好的理论价值和工程应用潜力。未来研究可进一步结合物理先验或传感器结构信息,提升模型对未知故障与跨域任务的适应能力。

参考文献:

- [1] XIE Suchao, TAN Hongchuang, YANG Chengxing, et al. A review of fault diagnosis methods for key systems of the high-speed train[J]. Applied sciences, 2023, 13(8): 4790.
- [2] JIA Feng, LEI Yaguo, LIN Jing, et al. Deep neural networks: a promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data[J]. Mechanical systems and signal processing, 2016, 72/73: 303-315.
- [3] SKLIROS C, ESPERON MIGUEZ M, FAKHRE A, et al. A review of model based and data driven methods targeting hardware systems diagnostics[J]. Diagnostyka, 2019, 20(1): 3-21.
- [4] LIU Jie, LI Yanfu, ZIO E. A SVM framework for fault detection of the braking system in a high speed train[J]. Mechanical systems and signal processing, 2017, 87(Part A): 401-409.
- [5] WU Yunpu, CHEN Jianhua, LEI Xia, et al. A novel fault diagnosis method of high-speed train based on few-shot learning[J]. Entropy, 2024, 26(5): 428.
- [6] WU Xingtang, LIAN Wenbo, ZHOU Min, et al. A digital twin-based fault diagnosis framework for bogies of high-speed trains[J]. IEEE journal of radio frequency identification, 2023, 7: 203-207.
- [7] WANG Gang, LU Mingfeng. Multiscale deep subspace clustering network with hierarchical fusion mechanism for mechanical fault diagnosis[J]. IEEE transactions on instrumentation and measurement, 2024, 73: 1-15.
- [8] ZHAN Yifan, YANG Rui, ZHANG Yong, et al. Mitigating catastrophic forgetting in cross-domain fault diagnosis: an unsupervised class incremental learning network approach [J]. IEEE transactions on instrumentation and measurement, 2025, 74: 1-14.
- [9] BAI Yihao, CHENG Weidong, WEN Weigang, et al. Fault diagnosis of rotating machinery based on evolutionary convolutional neural network[J]. Shock and vibration, 2022, 2022(1): 5031941.
- [10] LEI Yaguo, YANG Bin, JIANG Xinwei, et al. Applications of machine learning to machine fault diagnosis: a review and roadmap[J]. Mechanical systems and signal processing, 2020, 138: 106587.
- [11] YU Kun, LIN Tianran, MA Hui, et al. A multi-stage semi-supervised learning approach for intelligent fault diagnosis of rolling bearing using data augmentation and metric learning[J]. Mechanical systems and signal processing, 2021, 146: 107043.
- [12] SU Zuqiang, ZHANG Xiaolong, WANG Guoyin, et al. The semisupervised weighted centroid prototype network for fault diagnosis of wind turbine gearbox[J]. IEEE/ASME transactions on mechatronics, 2024, 29(2): 1567-1578.
- [13] 郭伟, 邢晓松. 基于改进卷积生成对抗网络的少样本轴承智能诊断方法[J]. 中国机械工程, 2022, 33(19): 2347-2355.
- [14] 邵海东, 林健, 闵志闪, 等. 分布外样本干扰下基于改进半监督原型网络的齿轮跨域故障诊断[J]. 机械工程学报, 2024, 60(4): 212-221.
- [15] SHAO Haidong, LIN Jian, MIN Zhishan, et al. Improved semi-supervised prototype network for cross-domain fault diagnosis of gearbox under out-of-distribution interference samples[J]. Journal of mechanical engineering, 2024, 60(4): 212-221.
- [16] HUANG Kai, GENG Jie, JIANG Wen, et al. Pseudo-loss confidence metric for semi-supervised few-shot learning [C]//IEEE. 2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal: IEEE, 2021: 8651-8660.
- [17] VINYALS O, BLUNDEL C, LILLICRA T. Matching networks for one shot learning[C]//Curran Associates Inc.. Pro-

- ceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona: Curran Associates Inc., 2016: 3637-3645.
- [17] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C]//Curran Associates Inc.. Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017: 4080-4090.
- [18] WANG Yikai, XU Chengming, LIU Chen, et al. Instance credibility inference for few-shot learning[C]//IEEE. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 12833-12842.
- [19] REN M Y, TRIANTAFILLOU E, RAVI S, et al. Meta-learning for semi-supervised few-shot classification[C]//ICLR. International Conference on Learning Representations 2018. Washington DC: ICLR, 2018: 1-15.
- [20] AYYAD A, LI Yuchen, MUJAZ R, et al. Semi-supervised few-shot learning with prototypical random walks[C]//PMLR. 2021 AAAI Workshop on Meta-Learning and MetaDL Challenge. New York: PMLR, 2021: 45-57.

A fault diagnosis method for high-speed trains based on semi-supervised few-shot learning

WANG Hang, WU Yunpu, CHEN Jianhua, LEI Xia

(School of Electrical Engineering and Electronic Information, Xihua University, Chengdu, Sichuan 610039, China)

Abstract: High-speed trains are a critical component of rail transit systems, and their operational safety directly determines the system reliability and safety. Safe and reliable equipment operation depends on vehicle fault diagnosis technology applied to monitor and diagnose the health status of key components. However, in practice, fault samples for high-speed train are limited in number and incomplete in type, which severely constrains the modeling capability and generalization performance of traditional supervised learning methods. To address these limitations, this paper proposes a fault diagnosis method based on semi-supervised few-shot learning. This method introduces a pseudo-loss confidence mechanism (PLCM) to screen and exploit unlabeled samples, mining their latent information to enhance model learning. The method dynamically assesses the confidence level of samples based on the loss rate distribution of pseudo-labels generated by the model for unlabeled samples, and then screens reliable samples to expand the training set, thereby improving the generalization ability and fault recognition accuracy of the model under the condition of limited labeled data. Experimental results on high-speed train fault datasets and publicly available rolling bearing fault datasets show that, even with limited sample size and scarce labeled information, the proposed method achieves excellent diagnostic performance and exhibits good generalization ability, providing a practical technical solution for the state perception and intelligent operation and maintenance of trains under complex conditions.

Keywords: deep learning; fault diagnosis; few-shot learning; high-speed train; semi-supervised learning