

基于迁移学习的航天器故障诊断方法综述

周苗¹, 屈辰², 向刚², 俞洋¹

(1 哈尔滨工业大学 哈尔滨 150001;

2 北京航天自动控制研究所 北京 100854)

摘要: 针对航天器在轨运行环境中故障样本稀缺、工况多变及传统诊断方法对模型精度和标注数据依赖度高的挑战, 本文旨在系统综述基于迁移学习的航天器故障诊断技术及其发展趋势。文章分类梳理了四大迁移学习策略——基于实例、基于特征、基于模型和领域自适应, 并结合重要性加权、自适应批量归一化、参数微调与对抗性训练等关键技术, 分析了各策略的原理、优劣与典型应用场景; 同时探讨了多策略融合框架在复杂工况下的协同作用及创新要点。综述表明: 通过源域与目标域知识迁移, 迁移学习方法可有效缓解数据不足与分布偏移问题。多源域适应与对抗性域自适应的迁移学习为航天器智能故障诊断提供了有力支撑。后续工作应聚焦无源域自适应、多模态数据融合、半监督迁移学习及模型可解释性, 以推动该领域技术在实际航天任务中的应用与发展。

关键词: 迁移学习; 故障诊断; 航天器; 深度学习; 域适应

中图分类号: V447; TP181

文献标志码: A

文章编号: 2095-1000(2025)06-0001-17

DOI: 10.12347/j.ycyk.20250622001

CSTR: 32406.14.ycyk.20250622001

引用格式: 周苗, 屈辰, 向刚, 等. 基于迁移学习的航天器故障诊断方法综述[J]. 遥测遥控, 2025, 46(6): 1-17.

A Survey of Spacecraft Fault Diagnosis Methods Based on Transfer Learning

ZHOU Miao¹, QU Chen², XIANG Gang², YU Yang¹

(1. Harbin Institute of Technology, Harbin 150001, China;

2. Beijing Aerospace Automatic Control Institute, Beijing 100854, China)

Abstract: In the orbital environment, spacecraft face challenges such as scarce fault samples, varying operating conditions, and a strong reliance on accurate models and labeled data in traditional diagnostic methods. This paper systematically reviews transfer learning techniques for spacecraft fault diagnosis, highlights their recent advancements, and outlines future research trends. Transfer learning strategies are categorized into four types: instance-based, feature-based, model-based, and domain-adaptive. The principles, advantages, limitations, and representative applications of each strategy are analyzed, along with key enabling techniques such as importance weighting, adaptive batch normalization, parameter fine-tuning, and adversarial training. The review shows that transfer learning effectively mitigates issues of data insufficiency and distribution shift by enabling knowledge transfer from source to target domains. In particular, multi-source domain adaptation and adversarial domain adaptation significantly improve cross-condition diagnostic performance by enhancing model generalization and robustness. It is concluded that transfer learning provides a promising framework for intelligent spacecraft fault diagnosis. Future research should focus on source-free domain adaptation, multi-modal data fusion, semi-supervised transfer learning, and model interpretability, aiming to support practical deployment in real-world aerospace missions.

Keywords: Transfer learning; Fault diagnosis; Spacecraft; Deep learning; Domain adaptation

Citation: ZHOU Miao, QU Chen, XIANG Gang, et al. A Survey of Spacecraft Fault Diagnosis Methods Based on Transfer Learning[J]. Journal of Telemetry, Tracking and Command, 2025, 46(6): 1-17.

0 引言

航天器作为人类探索宇宙的关键载体, 其运

行可靠性关乎航天任务的成败。航天器由多个高度耦合子系统组成, 处于极端的运行环境, 常会面临部件老化、环境干扰等复杂故障诱因, 且样

本采集困难, 传统基于模型或数据的诊断方法面临适应性与实时性瓶颈^[1]。航天器系统具有典型的多子系统耦合特性, 包含姿态控制、轨道控制、电源管理、热控制、通信等多个关键子系统, 各子系统间存在复杂的信息交互和功能依赖关系^[2,3]。然而, 由于航天器在轨运行环境的复杂性和特殊性, 其故障诊断面临诸多挑战, 如数据稀缺性、高噪声干扰、实时性要求高等。及时且精准的故障诊断, 不仅能保障航天器安全运行, 降低任务风险, 还能有效优化资源配置, 延长航天器使用寿命。由于航天器运行环境的极端性、系统架构的复杂性以及任务执行的不可逆性, 传统的故障诊断方法在航天器应用中暴露出显著的局限性, 如基于模型的参数估计与状态估计^[4,5], 虽在理论上有一定优势, 但依赖精确的系统模型, 难以适应航天器复杂多变的运行工况; 基于信号处理的方法对噪声敏感, 且特征提取依赖人工经验, 在复杂故障模式下诊断准确率受限; 基于人工智能的传统机器学习方法则需大量标注数据进行训练^[6,7], 而航天器故障样本稀缺, 难以满足其数据需求。此外, 在轨航天器运行环境复杂多变, 涉及的子系统如姿态控制系统、热控系统、通信与电源系统等在长期运行中易发生多类型故障, 如反作用轮机械磨损、太阳能电池阵脱锁、控制信号干扰等。这些故障样本不仅发生频率低、获取难度大, 且其工况依赖性强, 导致诊断模型在不同任务阶段间存在显著性能衰减。因此, 构建可泛化至多工况和低样本环境下的智能诊断模型成为当前研究重点。

迁移学习算法^[8-11]作为一种能够利用已有知识来提高新任务学习性能的技术, 为解决航天器故障诊断中的数据不足和特征提取难题提供了新的思路。它通过将源域(如地面测试数据、其他航天器历史数据或仿真数据)的知识迁移至目标域(在轨航天器实时数据), 有效缓解目标域数据不足的困境, 提升模型对新工况、新故障类型的泛化能力。近年来, 随着深度学习的发展, 基于深度神经网络的迁移学习方法在航天器故障诊断中崭露头角, 通过预训练-微调^[12,13]、域适应^[14,15]等技术, 实现了跨域知识的高效复用, 在姿态控制系统^[16]、电源系统^[17,18]、机械部件^[19-22]等故障诊断场景取得初步成效, 为解决航天器故障诊断难题带来新希望。

针对当前该领域缺乏系统性理论梳理和技术发展脉络分析的现状, 本文首次从迁移策略分类的角度, 系统性地综述了基于迁移学习的航天器故障诊断方法的研究进展。与以往单纯罗列相关工作的综述不同, 本文构建了“大策略+关键技术+融合框架”的分析体系, 深入剖析了基于实例、基于特征、基于模型和领域自适应四大迁移学习策略在航天器故障诊断中的原理机制、技术优势、应用局限性及典型应用场景; 系统梳理了重要性加权、自适应批量归一化、参数微调与对抗性训练等关键技术的作用机制和实现路径; 首次探讨了多策略融合框架在复杂工况下的协同机制及其在解决单一策略局限性问题的创新价值。本文还从数据质量、领域差异、模型泛化能力和多源异构等维度深入分析了当前面临的技术挑战, 并前瞻性地提出了数据增强与合成技术、多模态融合与协同学习、无监督与半监督迁移学习、模型可解释性及鲁棒性等未来发展趋势。这一系统性的理论分析框架不仅为航天器故障诊断领域的研究人员提供了全面的技术发展脉络和方法选择指南, 更为推动迁移学习技术在航天器智能故障诊断中的深度应用与工程实践提供了重要的理论支撑和发展方向。

1 迁移学习

1.1 迁移学习的定义

迁移学习是一种机器学习方法, 它通过将在源域(source domain)学到的知识应用到目标域(target domain), 以提高目标域的学习性能^[23,24]。在航天器故障诊断应用中, 源域通常指具有丰富标注数据的环境(如地面测试数据、仿真数据或其他航天器历史数据), 而目标域则代表实际应用场景(如在轨实时数据), 通常因标注成本高或环境动态性而缺乏充足的标签数据。

迁移学习的核心优势在于解决目标域中数据稀缺或无标签的问题, 特别适用于航天器故障诊断中面临的实际挑战。与传统机器学习需要为每个新任务重新训练模型不同, 迁移学习仅需要对预训练模型进行适当调整即可适应新的故障诊断任务, 如图1和图2所示。传统机器学习对每一个新任务都需要重新进行训练从而提高诊断精度, 而迁移学习仅需要细微的调整即可对新任务进行故障诊断。




图1 传统的机器学习分类

Fig. 1 Traditional machine learning classification




图2 基于迁移学习的分类

Fig. 2 Transfer learning-based classification

在航天器故障诊断应用中, 受限于空间环境的特殊性和高昂的数据收集成本, 实际在轨故障案例的获取难度远超地面模拟和仿真数据的采集, 因此只有少量的目标域数据可用来微调迁移模型。对比可知, 传统深度学习方法的特征学习能力在小样本环境下急剧下降, 无法有效识别和提取关键的故障模式; 而采用跨域知识迁移策略的诊断框架则展现出显著优势, 该方法通过整合大规模的源域知识库 (包括地面试验数据、数值建模结果及同类航天器运行记录) 与珍贵的目标域实测数据, 从而获得更好的性能^[25]。

1.2 迁移学习的分类

从迁移的内容角度, 迁移学习可分为基于实例的迁移学习、基于特征的迁移学习、基于模型的迁移学习和基于关系的迁移学习。基于实例的迁移学习, 通过对源域实例进行重新加权或选择, 将与目标域相关的实例迁移过来辅助目标域模型的训练; 基于特征的迁移学习专注于提取源域和目标域之间的共同特征表示, 以实现知识迁移; 基于模型的迁移学习则是将在源域上训练好的模型参数或结构迁移到目标域, 并进行适当的调整; 基于关系的迁移学习利用源域和目标域数据实例

之间的关系结构进行知识迁移。根据源域数量的不同, 迁移学习还可分为单源迁移学习和多源迁移学习。单源迁移学习利用单一源域的知识和经验来改善目标域任务性能的机器学习方法, 通过在源域和目标域之间建立知识映射关系来减少目标域所需的标注数据量。而多源迁移学习则是通过同时利用多个相关源域的互补知识来增强目标域的学习效果, 能够更好地处理源域与目标域之间的分布差异。在航天器故障诊断中, 多源迁移学习能够更好地应对复杂多变的航天器运行环境和故障模式。

根据源域和目标域的任务和数据分布情况, 迁移学习还可分为同构迁移学习和异构迁移学习。在同构迁移学习中, 源域和目标域具有相同的特征空间和任务类型, 但数据分布可能不同; 而异构迁移学习中, 源域和目标域的特征空间或任务类型存在差异, 这对迁移学习算法提出了更高的挑战。例如, 在从图像数据到文本数据的迁移中, 就涉及到异构迁移学习。此外, 按照是否有监督信息, 迁移学习可分为有监督迁移学习、无监督迁移学习和半监督迁移学习。有监督迁移学习在源域和目标域都有一定的标注数据, 无监督迁移学习则主要处理目标域无标注数据的情况, 半监督迁移学习介于两者之间, 目标域部分数据有标注。这些不同的分类方式有助于根据具体的应用场景和数据条件选择合适的迁移学习策略, 为基于迁移学习的故障诊断方法提供了多样化的技术基础。

2 基于迁移学习的航天器故障诊断方法

航天器故障诊断中的迁移学习应用本质上是在解决知识如何跨域传递的核心问题。与传统工业设备故障诊断不同, 航天器故障诊断面临三个独特挑战: 一是故障样本的极端稀缺性 (在轨故障发生概率低且代价巨大); 二是工况环境的不可重现性 (地面测试与在轨环境存在本质差异); 三是故障模式的隐蔽性和渐进性 (航天器故障往往表现为微弱信号变化)。这三个特点决定了航天器故障诊断的迁移学习策略必须在保证知识传递有效性的同时, 最大程度地减少对目标域数据的依赖。

随着迁移学习的有关算法被不断优化和提出, 相关研究人员在航天器故障诊断领域也对迁移学

习的应用进行了探索。从知识迁移的层次分析, 现有方法可归纳为四个递进层次: 实例层迁移(数据重用)、特征层迁移(表征共享)、模型层迁移(参数复用)和分布层迁移(域对齐)。这四个层次反映了从表层数据利用到深层知识抽象的渐进过程, 其中分布层迁移最接近人类专家跨领域知识迁移的认知模式。

2.1 基于实例的方法

基于实例的方法通过调整源域样本的权重或选择与目标域更相似的源域样本来实现知识迁移^[26-28]。常用的技术包括重要性加权法和样本选择。重要性加权法通过为源域样本分配不同的权重, 使得与目标域更相似的样本在训练过程中获得更高的权重, 从而使得模型更加关注目标域的特性。样本选择则是从源域中挑选出与目标域最相似的样本进行训练, 以减少领域间的差异。这种方法适用于源域和目标域之间存在样本分布差异的情况, 典型方法包括 TrAdaBoost、TrBagg 与 KMM 等。

TrAdaboost 算法是一种常见的基于实例的迁移学习方法。在训练迭代过程中, 根据神经网络分类器在目标训练数据上的误差表现, 对辅助样本和目标样本的权重进行不同方式的调整。对于辅助样本, 若分类器误差相关情况满足一定条件, 其权重朝着某个方向调整; 对于目标样本, 依据类似但不同的判断条件, 对权重进行相反方向的调整。如此一来, 在目标训练数据量不足时, 利用大量辅助数据辅助模型训练, 有效提升了故障诊断模型的准确性, 充分体现出迁移学习在故障诊断领域解决数据匮乏难题、优化模型性能的重要价值。

另一种常见的方式是结合自适应批量归一化(Adaptive Batch Normalization, AdaBN)技术, AdaBN 主要用于解决域偏移问题, 在训练过程中, 它用目标域的统计信息替换源域的批量归一化层的统计信息, 确保模型在不同域的数据上都能保持稳定的训练过程, 进而提高模型在目标域的泛化能力。通过这种方式, 模型可以更好地适应源域和目标域之间的数据分布差异, 使得从源域迁移过来的实例能够更有效地辅助目标域的故障诊断。

此外, 还有研究采用样本/特征混合迁移的方式。例如, Li 等人^[29]在跨域故障诊断问题中, 通过

探索不同工况下样本和特征的迁移策略, 综合考虑了样本的质量和特征的相关性, 对源域实例进行筛选和加权, 进一步提高了基于实例的迁移学习在故障诊断中的效果, 为解决复杂工况下的航天器故障诊断问题提供了新的思路和方法。

2.1.1 重要性加权法

重要性加权法是基于实例的迁移学习在故障诊断中的重要应用手段。其核心思想在于依据源域实例与目标域的相关性, 为每个实例赋予相应的权重, 从而突出对目标域模型训练具有重要价值的实例, 同时降低可能产生负面影响的实例的影响。例如, 在针对航天测控任务动力系统数据的特征建模和态势评估中, 张晨曦^[30]运用了一种基于最大平均差异(Maximum Mean Discrepancy, MMD)和多变量分布差异(Multivariate Distribution Divergence, MVD)的权重估计方法。在处理不同工况下的航天发动机氧泵转速的遥测数据时, 该方法通过精确计算源域实例与目标域数据在特征空间中的分布差异, 为源域实例分配合理的权重。对于与目标域数据分布相似、能够有效反映目标域故障特征的源域实例, 赋予较高权重, 使其在模型训练中发挥更大的作用; 而对于与目标域差异较大的实例, 则降低其权重, 减少其对模型训练的干扰。通过这种方式, 显著提升了模型在不同工况下的诊断准确性和适应性, 有效利用了源域数据中的有用信息, 增强了模型对目标域故障的识别能力。

2.1.2 样本选择法

通过直接从源域中挑选与目标域更为相似的样本, 样本选择法构建新的训练集, 以优化目标域模型的性能。在相关的航天测控系统建模研究中, 文献[30]还采用了样本选择策略以应对目标域样本稀缺问题, 即从源域中筛选与目标域物理设计相似、工况匹配的样本子集, 直接扩充训练数据规模。该方法通过“源域样本补充-目标域微调”模式, 缓解了新型航天器发动机因飞行任务少导致的样本不足问题, 尤其适用于型号迭代初期的故障检测场景。

2.1.3 方法分析与总结

从航天器故障诊断的实践角度分析, 基于实例的方法存在一个根本性矛盾: 源域实例的可靠性与目标域适用性的权衡问题。地面测试数据虽然标注完整、噪声可控, 但其物理条件(重力、大气、温度等)与在轨环境存在本质差异; 仿真

数据虽然可模拟在轨环境，但其保真度受限于建模精度。这种矛盾使得单纯的实例迁移方法在航天器应用中呈现“近域高效、远域失效”的特点。

重要性加权法和样本选择法在实际应用中还面临权重标定的客观性问题。当前研究多采用基于分布距离的权重计算方法，但这种方法隐含假

设源域和目标域的故障机理具有相似性，而航天器不同子系统间的故障机理往往差异显著。例如，电源系统的电压波动故障与姿控系统的执行机构卡死故障，二者的信号特征上可能相似，但其物理机理完全不同，简单的分布距离度量可能导致错误的知识迁移。上述两种基于实例的方法对比如表1所示。

表1 基于实例的方法对比

Table 1 Comparison of methods based on instances

对比维度	重要性加权法	样本选择法
核心原理	为源域样本分配权重,突出相似样本	直接筛选与目标域相似的源域样本
计算复杂度	中等(需计算权重)	较低(一次性筛选)
数据利用率	高(利用全部源域数据)	中等(仅利用筛选后的数据)
航天器应用优势	适合处理传感器漂移问题	适合跨工况故障诊断
航天器应用劣势	地面与在轨环境差异导致权重失效	可能丢失稀有故障模式
实时性	中等(在线权重计算)	高(离线预筛选)
可解释性	中等(权重含义相对清晰)	高(样本选择逻辑直观)

2.2 基于特征的方法

基于特征的方法通过学习或选择能够在源域和目标域之间共享的特征表示来实现迁移。常用的技术包括特征选择、特征变换和特征映射。特征选择是从源域的特征集中选择出对目标域最有用的特征子集，常用统计方法（如卡方检验、互信息）或基于模型的方法（如决策树、随机森林）来评估特征的重要性。特征变换通过数学变换将源域特征映射到一个新的特征空间，使得源域和目标域在该空间中的分布更加相似，如主成分分析（Principal Component Analysis, PCA）、线性判别分析（Linear Discriminant Analysis, LDA）、核方法（Kernel Principal Component Analysis, KPCA）等。

基于特征的方法在故障诊断中的应用主要体现在通过特征选择、特征变换和特征映射等技术来实现源域和目标域之间的特征对齐。常见方法包括最大均值差异（MMD）、联合分布自适应（Joint Distribution Adaptation, JDA）及深度相关对齐（Deep Correlation Alignment, Deep CORAL）等。其中，MMD作为无参数分布距离度量广泛应用于迁移学习模型中，JDA则进一步联合边缘与条件分布，提升迁移效果。近年来，深度学习的发展推动了基于对抗损失的特征迁移方法，例如深度域自适应网络（Deep Domain Confusion, DDC）和Deep CORAL已在多工况航天电机和控制器数据迁

移中取得良好效果。文献[30]提出通过联合分布自适应（JDA）和DDC实现跨域特征对齐。在特征提取层面，利用长短期记忆自编码器（Long Short-Term Memory Autoencoder, LSTM-AE）捕捉时序数据的动态特征，并通过域适应层对抗训练，迫使特征提取器生成与领域无关的通用表示。以YF-100与YF-115航天器发动机跨工况诊断为例，通过JDA算法将燃烧室压力、流量等特征的域间最大均值差异（MMD）降低28%，结合DDC网络后，跨转速工况的轴承故障诊断准确率从传统CNN的72.2%提升至92.6%，这为跨域特征迁移提供了可解释的特征工程范式。

2.2.1 特征选择

特征选择旨在从源域和目标域的原始特征中精心挑选出对故障诊断具有关键作用且在两个域中具有较高相关性和稳定性的特征子集，去除冗余和噪声特征，提高模型的泛化能力和计算效率。在航天器故障诊断的迁移学习场景中，特征选择面临着跨域特征重要性评估的挑战。

2.2.2 特征变换

特征变换是将源域和目标域的特征映射到一个新的公共特征空间，以减小特征分布差异。该类方法的关键在于设计合适的变换函数和优化目标，以平衡特征的判别性和域不变性。针对航天器姿态控制系统故障诊断中故障样本稀缺的问题，

文献[31]针对卫星姿态控制系统在零故障样本情况下的故障定位难题, 提出了一种基于迁移学习的解决方案。该研究将设计阶段的标称系统作为源域, 在轨运行卫星作为目标域, 通过迁移标称系统的知识来实现目标域的故障诊断。具体地, 研究首先提出了结合反向传播网络和迁移成分分析的故障特征迁移方法, 通过特征变换减小域间分布差异。进而, 为更好地处理时序信息, 又提出了长短期记忆自动编码器与深度域混淆网络相结合的特征与模型联合迁移改进算法。通过半物理仿真试验验证, 该方案为解决航天器在轨故障样本不足的工程问题提供了有效的技术路径, 对提高系统可靠性和任务成功率具有重要意义。

2.2.3 方法分析与总结

基于特征的方法在航天器故障诊断中体现了抽象层次与迁移效果的正相关关系。浅层特征(如时域统计特征、频域功率谱特征)虽然计算简单, 但其物理意义明确, 容易受到传感器特性和

环境噪声的影响, 跨域迁移效果有限。深层特征(如卷积神经网络高层特征、自编码器潜在表示)虽然抽象程度高, 迁移性能好, 但其物理意义不明确, 在故障机理解释方面存在困难。

特征选择与特征变换的本质差异在于对源域知识的利用策略: 特征选择假设源域和目标域共享部分关键特征, 通过筛选实现知识迁移; 特征变换则假设源域和目标域存在某种映射关系, 通过学习映射函数实现知识迁移。在航天器故障诊断中, 不同子系统间往往更适合特征变换策略, 而同一子系统的不同工况间更适合特征选择策略。值得注意的是, 航天器故障特征往往具有多尺度耦合特性。例如, 卫星太阳能帆板的微振动故障既表现为高频振动信号(局部特征), 又影响整星姿态稳定性(全局特征)。传统的单尺度特征提取方法难以捕捉这种跨尺度的故障传播机制, 需要发展多尺度特征融合的迁移学习方法。上述两种基于特征的方法对比如表2所示。

表2 基于特征的方法对比
Table 2 Comparison of methods based on feature

对比维度	特征选择	特征变换
核心原理	筛选源域与目标域共同的重要特征	将特征映射到新的公共空间
理论假设	存在域不变的特征子集	存在域间的映射关系
计算复杂度	低(特征重要性评估)	高(学习变换函数)
特征维度变化	降维(选择子集)	可升维/降维/保维
跨域泛化能力	中等(依赖特征稳定性)	高(通过变换对齐分布)
实时性	高(计算量小)	中等(变换计算开销)
可解释性	高(特征-故障直接关联)	低(变换空间难以解释)

2.3 基于模型的方法

基于模型的方法通过调整或微调预训练模型的参数来适应目标域。常用的技术包括微调(Fine-tuning)、参数共享、多任务学习等。微调使用在源域上预训练的模型作为起点, 在目标域的小量标注数据上进行参数微调, 以增强模型对目标域特征的适应能力。参数共享通过在不同域间复用部分网络结构, 从而降低模型复杂度与训练开销。多任务学习通过联合优化相关任务, 使模型在共享特征表示的同时具备更强的泛化能力。

基于模型的方法在故障诊断中的应用主要体现在通过微调、参数共享、多任务学习等技术来实现知识迁移^[32]。例如, 在2022年, 何漫丽^[31]提出了一种基于微调的故障诊断方法, 该方法使用在源域上预训练的模型作为起点, 在目标域上进

一步优化模型参数, 从而显著提升目标域的诊断性能。此外, 参数共享机制能够在源域与目标域之间实现知识迁移, 有效降低模型复杂度与训练成本。多任务学习技术也能够有效地实现知识迁移, 通过在多个相关任务上共享底层模型, 提高模型的泛化能力, 从而提高目标域的诊断性能。为解决航天器故障诊断面临的在轨故障样本稀缺问题, 付松等人^[33]提出一种基于深度自动编码器(Deep Autoencoder, DAE)迁移学习的小样本故障诊断方法。该方法首先利用航天器大量的正常运行遥测数据对DAE进行预训练, 建立航天器系统状态特征提取模型; 然后将该特征提取模型迁移到具有少量数据的航天器故障样本中, 充分利用预训练模型的特征表示能力对这些稀缺故障样本进行深度特征提取; 最后采用支持向量机(Sup-

port Vector Machine, SVM) 实现小样本故障分类。该方法能够有效缓解航天器故障样本不足的问题,提高小样本条件下的故障诊断精度。

2.3.1 参数微调

参数微调是基于模型的迁移学习中常用的方法。文献[34]针对航天器在轨运行中面临的数据样本稀缺和无标签数据的关键挑战,提出了基于深度迁移学习的航天器智能故障诊断方法,有效解决了传统故障诊断方法无法适应在轨航天器数据特征的难题。该方法在技术路径上实现了三个关键创新:首先通过数据预处理将一维时域信号转换为二维图像信号,为深度学习模型提供合适的输入格式;其次构建基于深度卷积神经网络的故障诊断框架,利用地面测试数据进行预训练,建立源域知识基础;最为重要的是采用联合分布适配的迁移学习策略,通过设计卷积神经网络的代价函数并进行参数重调,实现了从地面测试环境到在轨运行环境的知识迁移,使模型能够适应在轨航天器的故障诊断任务。该研究在方法论上为航天器在轨故障诊断提供了从数据预处理、网络构建到域适应的完整技术框架,特别是在解决航天器领域中地面数据丰富但在轨数据稀缺这一典型迁移学习场景中具有重要的实用价值。

2.3.2 参数共享

参数共享通过在多个相关任务或域之间共享部分模型参数,实现知识的迁移和利用。在卫星姿态控制系统故障诊断中,Li等人^[35]提出了基于跨域知识迁移的深度学习诊断框架。该框架针对卫星在轨运行期间姿态控制系统面临的多元化故障模式,构建了源域-目标域的迁移学习架构。通过利用地面测试环境下积累的大量故障样本作为源域数据,将预训练的深度卷积神经网络的底层特

征提取模块参数冻结并共享至在轨实际运行环境的目标域任务中,从而提高了模型在不同工况下对行星齿轮箱故障的诊断性能,增强了模型的泛化能力,有效应对了复杂多变的航天器运行环境下的故障诊断难题。

2.3.3 多任务学习

多任务学习通过同时训练模型处理多个相关任务,利用任务间的关联性提升模型性能。在航天器故障诊断场景中,有研究构建了包含故障类型识别、故障严重程度评估等多任务的深度神经网络架构。模型在学习故障类型分类任务时,同时考虑不同故障对航天器运行稳定性影响的程度评估任务。在训练过程中,不同任务的梯度信息相互影响和促进,使得模型能够学习到更具通用性和代表性的特征表示。通过共享模型的部分参数和隐藏层,模型在面对新的故障诊断任务时,能够更快地收敛并提高诊断准确性,有效增强了对航天器复杂运行环境下的故障诊断的能力,降低了过拟合风险,提高了模型的泛化性能。

2.3.4 方法分析与总结

基于模型的迁移学习在航天器故障诊断中体现了差异化迁移策略。参数微调属于表层知识迁移,主要调整决策边界以适应目标域的数据分布特征;参数共享属于结构知识迁移,通过共享特征提取层实现跨域特征表示的一致性;多任务学习属于关联知识迁移,通过任务间的相互促进实现知识的交叉强化。这三种策略在航天器故障诊断中的适用性存在显著差异。上述三种基于模型的方法对比如表3所示。

基于模型的方法在航天器应用中面临独特的负迁移风险。航天器系统的高度集成性使得源域模型中的偏差容易在目标域中被放大。例如,地

表3 基于模型的方法对比

Table 3 Comparison of methods based on model

对比维度	参数微调	参数共享	多任务学习
知识迁移层次	表层(决策边界调整)	结构层(特征提取复用)	关联层(任务间交叉强化)
对源域信任度	中等(需要适应性调整)	高(假设特征空间相同)	高(任务间相互促进)
目标域数据需求	少量标注数据	无标注要求	多任务标注数据
负迁移风险	高(可能破坏源域知识)	低(共享参数稳定)	中等(任务冲突可能)
模型复杂度	中等(部分参数更新)	低(参数固定)	高(多任务架构)
故障检测精度	高(针对性优化)	中等(通用性强)	最高(多任务协同)
实时性	高(模型轻量)	最高(无额外计算)	中等(多任务推理)
可解释性	中等(微调过程可追溯)	高(继承源域解释)	低(任务间耦合复杂)

面测试环境下训练的电源系统故障诊断模型, 其决策边界可能过度拟合了地面环境的噪声特征, 在迁移到在轨环境时出现误报率激增。因此, 航天器故障诊断中的参数微调需要采用保守策略: 优先冻结高层特征提取参数, 仅微调分类层参数, 以避免破坏源域学到的通用故障模式。参数共享与参数微调的本质区别在于对源域知识的信任程度。参数共享假设源域和目标域具有相同的特征空间结构, 适用于同类型航天器的跨工况迁移; 参数微调则假设源域知识需要适应性调整, 适用于不同类型航天器间的知识迁移。多任务学习的价值在于其能够利用航天器多子系统间的耦合关系, 通过同时学习多个诊断任务(如故障检测、故障定位、严重程度评估)实现知识的交叉验证和互补强化。

2.4 领域自适应方法

领域自适应方法^[36,37]通过调整特征空间或模型参数, 使得源域和目标域的分布更加相似, 从而提高模型在目标域上的性能。常用的技术包括特征对齐、对抗性训练^[38,39]、多源域适应^[40,41]、无源域适应^[42]和基于度量学习^[43,44]的方法。特征对齐通过特征映射或对抗性训练等方法, 使得源域和目标域的特征分布更加相似。对抗性训练利用对抗学习的思想, 训练特征提取器以生成难以被领域分类器区分的特征表示。当存在多个源域时, 多源域适应的方法通过整合多个源域的知识来更好地适应目标域。在源数据不可访问的情况下, 无源域适应方法从预训练的源模型到无标记的目标域进行知识迁移。基于度量学习的方法通过学习一个适应目标领域的度量函数, 来减小领域之间的差异。

领域自适应方法在故障诊断中的应用主要体现在通过特征对齐、对抗性训练、多源域适应等技术来实现源域和目标域之间的分布对齐。在文献[45]中, 提出了一种基于对抗性训练的故障诊断方法, 该方法利用对抗学习的思想, 训练特征提取器以生成难以被领域分类器区分的特征表示, 从而实现了源域和目标域之间的分布对齐, 提高了目标域的诊断性能。

2.4.1 特征对齐

特征对齐致力于缩小源域和目标域特征分布的差异, 使模型能更好地迁移知识。针对航天器部件加工装备面临的变工况运行和数据稀缺挑战,

有研究^[46]提出了基于生成对抗网络(Generative Adversarial Network, GAN)的变工况暨数据不齐备情况下的故障诊断方法, 有效解决了传统迁移学习在航天器相关设备故障诊断中面临的两大核心问题——源域与目标域分布不一致的域偏移问题, 以及标签化数据不足导致的模型训练困难问题。该方法突破了常规迁移学习对充足标签数据的依赖限制, 通过 GAN 的数据生成能力增强样本多样性, 实现了在航天器制造装备复杂工况和数据受限环境下的有效故障诊断, 为航天器相关系统在数据稀缺和跨工况条件下的智能故障诊断提供了新的技术路径, 特别是在解决航天领域高可靠性要求与数据获取困难这一矛盾问题上具有重要的方法论价值。

2.4.2 对抗性训练

对抗性训练利用域鉴别器和特征提取器之间的对抗博弈, 促使特征提取器学习到域不变特征。在航天器故障诊断中, 域对抗神经网络(Domain-Adversarial Neural Network, DANN)被广泛应用。针对卫星姿态控制系统变工况下的微小故障诊断难题, 顾彧行^[47]提出深度域自适应对抗网络(Deep Adversarial Adaptation Network, DAAN)及分布式域协同对抗网络(Distributed Domain Collaborative Adversarial Network, DDCAN)。通过引入域自适应机制, 有效减小了因工况变化导致的数据域分布偏移, 提升了故障诊断模型的泛化性能和诊断精度。该方法结合了对抗训练与分布式、协同式域自适应策略, 为航天器在复杂多变工况下的故障诊断提供了新的解决方案, 具有重要的理论意义和实际应用价值。通过这种对抗训练机制, 模型能够提取出不受域差异影响的故障特征, 增强了模型在不同域之间的适应性, 提高了故障诊断的准确性和鲁棒性, 有效应对了航天器姿态控制系统在变工况条件复杂的数据分布变化。

针对航天器在变工况下数据分布差异导致的智能故障诊断难题, Xiang 等人^[48]提出了基于 Wasserstein 距离的深度对抗迁移学习方法(Wasserstein Deep Adversarial Transfer Learning, WDATL)。该方法采用带梯度惩罚的 Wasserstein 生成对抗网络(Wasserstein GAN with Gradient Penalty, WGAN-GP)框架, 通过域判别器学习域不变特征表示, 最小化源域和目标域特征分布间的 Wasserstein 距离实现跨域对抗训练。作者设计了改进的一维卷积神

神经网络特征提取器,采用指数线性单元(Exponential Linear Unit, ELU)激活函数和宽核设计,能够自动提取原始时序数据的潜在特征并抑制高频噪声。通过预训练阶段初始化网络参数,再通过对抗训练使故障分类器在源域训练后能够泛化到标签不足的目标域。该方法有效解决了航天器在不同工况条件下训练数据和测试数据分布不一致的问题,通过学习域不变且具有故障区分性的特征表示,显著提升了模型的泛化能力。

航天器在轨运行过程中遥测数据量大、参数多、波形差异显著、故障样本稀缺,传统人工判读方式效率低下,难以通过人工编码实现特征的自动化提取与分析。针对复杂时序遥测数据的快速分析和故障诊断需求,文献[49]研究采用了基于迁移学习的故障诊断方法。首先对航天器遥测时序数据进行对齐与校准预处理,然后将处理后的数据转换为波形图像格式,构建了基于VGG16的迁移学习故障诊断模型。考虑到航天器故障样本的稀缺性,进一步采用生成对抗网络技术对小样本故障数据进行增广扩充。基于历史航天器故障数据开展的仿真试验表明:该迁移学习模型能够有效利用预训练网络的特征提取能力,显著提升了航天器故障诊断的准确性和效率,验证了迁移学习方法在航天器故障诊断领域的有效性和实用性。

2.4.3 多源域适应

多源域适应通过整合多个源域的知识,提升模型在目标域的性能。在航天器故障诊断中,当目标域数据有限时,可利用多个相似类型航天器的源域数据。例如,对于某卫星故障诊断,研究人员收集了多个同类型但不同批次或不同使用环境下机床的运行数据作为源域。通过设计特定的多源域适应算法,如基于多源域锚定适配器和集成学习的方法,对不同源域数据进行融合和利用。在训练过程中,模型学习不同源域与目标域之间的共性和差异,综合多个源域的优势,增强了对目标机床故障的诊断能力,有效解决了单源域数据不足或偏差导致的诊断困难问题。

2.4.4 无源域适应

无源域适应在仅有目标域数据的情况下,利用无监督学习方法挖掘数据自身的结构和规律进行域适应。在一些实际航天器运行场景中,可能难以获取合适的源域数据。例如在某些特殊定制

设备的故障诊断初期,只有设备自身运行产生的无标注数据。此时,可采用如基于聚类 and 自编码器的无源域适应方法。通过对目标域数据进行聚类分析,将相似的数据样本聚为一类,然后利用自编码器对这些类别的数据进行特征提取和重构,学习数据的内在表示和结构。这种方式能够在缺乏源域参考的情况下,发现目标域数据中的故障相关特征和模式,为故障诊断提供一定的依据,提高了在无源域数据场景下的诊断可行性。考虑航天器源域数据的隐私和不可访问性,LIU等人^[50]提出了一种无源域自适应诊断算法的混合注意力网络,通过混合注意力网络生成具有强大异常检测能力的源模型,充分利用仅一次的源故障信息,在航天器轴承数据集上能出色地完成故障诊断任务,为源模型参数不足的非均匀目标域的域适应研究提供了很高的参考价值。

2.4.5 基于度量学习的方法

基于度量学习的方法通过设计合适的度量准则来衡量源域和目标域数据的相似性和差异,指导模型学习和迁移。在航天器故障诊断中,常用的如最大平均差异(MMD)及其变体——多核最大平均差异(Multi-Kernel Maximum Mean Discrepancy, MK-MMD)。对于不同工况下的航天器运行数据,通过计算MMD或MK-MMD值,模型可以了解数据在特征空间中的分布差异情况。在训练过程中,以减小这些度量值为目标优化模型参数,使得模型学习到能够缩小域间差异的特征表示,从而提高在不同工况下的故障诊断性能,增强了模型对数据分布变化的适应性,使得诊断模型能够更准确地识别航天器各类故障,即使在源域和目标域数据存在一定差异的情况下,也能有效利用源域知识辅助目标域的故障诊断。

针对航天器在轨运行过程中部分工作模式下故障样本数据充足、而某些关键工作模式下故障样本稀缺的实际情况,杨可^[51]提出了一种基于卷积神经网络(CNN)的航天器故障诊断模型。该模型采用相关对齐方法(CORAL)和最大均值差异方法(MMD)两种域适应技术,在CNN模型的多个特征提取层分别计算源域(样本充足的工作模式)与目标域(样本稀缺的工作模式)之间的分布距离,并通过梯度下降算法逐步最小化这一距离差异,从而实现模型对航天器不同工作模式和运行状态的有效适应,提高了航天器故障诊断在

多样化工作条件下的准确性和鲁棒性。

Yang 等人^[52]提出了一种新的度量方法——多项式核诱导 (PK-MMD), 并将其引入到 ResNet 中实现跨域自适应。该方法通过在全连接层引入多项式核诱导最大均值差异 (PK-MMD) 作为自适应损失, 度量并对齐源域与目标域的特征分布差异。该方法在机械设备的跨域故障诊断中得到了有效验证, 其思想为如何解决航天器在轨故障样本稀缺情况下的知识迁移问题提供了重要参考。

2.4.6 方法分析与总结

领域自适应方法在航天器故障诊断中的应用效果与源域-目标域的差异类型密切相关。根据差异来源, 可将航天器故障诊断中的域差异分为三类: 第一类是环境差异驱动的域偏移, 如地面重力环境与在轨微重力环境的差异, 这种差异是系统性的, 影响所有信号特征, 需要采用全局域适应策略; 第二类是设备差异驱动的域偏移, 如不同批次传感器的性能差异, 这种差异是局部的, 主要影响特定频段或幅值范围, 适合采用局部域

适应策略; 第三类是工况差异驱动的域偏移, 如不同任务阶段的工作模式差异, 这种差异是动态的, 需要采用在线域适应策略。表 4 将上述领域自适应方法进行了九个维度的对比。

对抗性训练与特征对齐方法的适用边界值得深入分析。对抗性训练假设存在一个域不变的特征空间, 但在航天器故障诊断中, 某些故障模式本身就具有强烈的域相关性 (如热真空环境下的材料性能退化), 强制域对齐可能丢失关键的故障信息。因此, 在航天器应用中, 应优先考虑有选择的域适应, 而非直接全面的域对齐。

多源域适应在航天器故障诊断中的独特价值在于其能够利用多个异质源域的互补信息。例如, 结合地面测试数据 (高保真度、低环境相似性)、数值仿真数据 (高环境相似性、低保真度) 和历史在轨数据 (高相似性、数据稀缺), 可以构建更加鲁棒的故障诊断模型。但这种多源融合也带来了权重分配的复杂性问题, 需要根据具体故障类型和诊断要求动态调整各源域的贡献权重。

表 4 基于领域自适应的方法对比

Table 4 Comparison of methods based on domain adaptation

对比维度	特征对齐	对抗性训练	多源域适应	无源域适应	度量学习
核心机制	最小化特征分布距离	域判别器 对抗博弈	多源域 知识融合	仅利用 目标域数据	学习域适应度量函数
理论基础	统计学习理论	博弈论	集成学习	无监督学习	度量空间理论
源域依赖性	高	高	最高	无	高
域差异适应能力	中等	高	最高	低	高
负迁移风险	中等	高	低	最低	中等
计算复杂度	中等	高	最高	低	中等
实时在轨 计算适应性	高	低	最低	最高	中等
可解释性	高	低	中等	中等	高

2.5 多策略融合方法

随着航天器系统复杂性的不断提升和故障模式的多样化, 单一的迁移学习方法往往难以充分应对复杂的故障诊断任务^[53]。基于实例的方法虽然能够有效处理样本分布差异, 但在特征表征能力方面存在局限; 基于特征的方法具有良好的泛化能力, 但对源域和目标域的相似性要求较高; 基于模型的方法能够实现知识的深层次迁移, 但容易出现负迁移现象; 领域自适应方法在处理域间差异方面表现出色, 但计算复杂度相对较高。因此, 近年来越来越多的研究开始探索将多种迁移

学习策略有机融合的方法, 以充分发挥各种方法的优势, 提高故障诊断的准确性和鲁棒性。

多策略融合方法是指在迁移学习框架下, 同时采用两种或多种不同的迁移策略, 通过协同优化实现优势互补的故障诊断方法。这类方法的核心思想是: 在保持各个策略相对独立性的基础上, 通过合理的融合机制实现信息的有效整合。与传统的单一方法相比, 多策略融合方法具有以下显著优势: 一是能够从多个维度同时减小源域与目标域之间的差异, 提高迁移效果; 二是通过不同策略间的相互制约和协调, 降低了单一方法可能

产生的偏差和不稳定性；三是具有更强的适应性，能够根据具体的应用场景和数据特点灵活调整各策略的权重。

在航天器故障诊断应用中，多策略融合方法表现出了良好的实用价值。航天器运行环境的复杂性、故障模式的稀有性以及数据获取的困难性，使得传统的单一迁移策略往往无法满足实际需求，而多策略融合方法能够有效缓解这些问题。

针对航天轴承在极端空间环境下训练样本不足和数据域偏移导致的诊断模型泛化能力差的核心问题，文献[54]研究以航天器空间机械臂减速器的关键部件——航天轴承为研究对象，提出了基于深度迁移学习的航天轴承智能故障诊断方法。将联合分布自适应（JDA）算法与基于模型的迁移学习方法相结合，有效解决了源域（实验平台数据）与目标域（航天轴承仿真数据）分布不一致的关键问题，实现了跨工况条件下的有效故障分类。该方法充分发挥了深度学习的特征提取能力、JDA算法的域适应能力和基于模型迁移学习的泛化能力，为航天器关键部件在数据稀缺和环境差异条件下的智能故障诊断提供了新的技术路径，特别是在解决航天器部件从地面实验环境到空间运行环境的知识迁移问题上具有重要的工程应用价值。

在航天器姿态系统故障诊断领域，Tang等人^[55]提出了基于深度迁移学习的故障诊断方法。该方法针对在轨航天器故障数据样本稀少、噪声干扰严重以及缺乏标签信息的现实困境，构建了深度迁移网络（Deep Transfer Network, DTN）诊断框架。研究者采用联合分布自适应（JDA）策略，通过同时调整边缘分布和条件分布来缓解源域与目标域之间的分布差异问题。该框架首先将航天器一维状态数据（四元数、角速度、控制信号）转换为二维图像格式，然后利用改进的卷积神经网络进行深层特征提取。通过最大均值差异（MMD）度量不同域间的分布距离，并构建融合交叉熵损失与分布自适应正则化项的新目标函数进行网络优化。该研究有效利用地面测试数据的丰富标签信息，为解决在轨航天器故障诊断中的域适应问题提供了新的技术路径。

多策略融合方法的兴起反映了航天器故障诊断复杂性的本质特征。单一迁移策略往往只能解决特定类型的域差异问题，而航天器系统的多子

系统、多层次、多时空尺度特性要求故障诊断方法具备多维度适应能力。从发展趋势看，多策略融合正在从“简单叠加”向“智能协同”演进。早期的融合方法多采用加权组合或级联结构，各策略间缺乏有机联系。新兴的智能协同融合方法通过引入注意力机制、强化学习等技术，能够根据输入数据特点和诊断任务需求，动态选择和组合不同的迁移策略，实现策略间的智能协同。

融合策略的选择原则应基于航天器故障诊断的特殊需求：对于关键任务期间的实时故障诊断，应优先选择计算效率高的实例加特征的融合策略；对于非关键任务期间的深度故障分析，可采用模型加域适应的融合策略以获得更高的诊断精度；对于新型航天器的故障诊断，应采用全策略融合以最大化知识迁移效果。未来的多策略融合方法将更加注重可解释性与迁移效果的平衡。航天器故障诊断不仅要求高准确率，更要求诊断结果的可解释性，以支持故障定位和维修决策。这要求融合方法不仅要优化诊断性能，还要保持各策略贡献的可追溯性。

3 当前挑战与未来研究方向

3.1 存在的问题

随着航天技术的飞速发展，航天器作为执行复杂太空任务的关键平台，其可靠性、安全性和自主性要求日益提高。航天器故障诊断技术作为保障航天器稳定运行的重要手段，近年来得到了广泛关注。特别是基于迁移学习的航天器故障诊断方法，通过利用源领域的知识来辅助目标领域的故障诊断，有效缓解了数据稀缺和标注成本高的问题。然而，由于航天器在轨任务存在不可复现性高、传感器校准难、环境不确定性强等问题，源数据和目标数据之间存在严重分布偏移。同时，高轨任务周期长，故障采集机会有限，常依赖地面模拟数据进行先验训练。在此背景下，如何实现不同平台、工况或任务阶段间的模型迁移，成为迁移学习方法落地应用的关键挑战。

3.1.1 数据质量问题

首先是数据的稀缺性和不平衡性的问题，航天器在轨运行期间产生的故障数据极为有限，且正常数据与故障数据之间存在严重的不平衡性。这种数据稀缺性和不平衡性导致基于深度学习的故障诊断模型容易过拟合，迁移学习固然可以在

一定程度上缓解数据稀缺问题, 但如何有效处理数据不平衡性, 提高模型对少数类故障样本的识别能力, 仍是亟待解决的问题。例如, 在文献[56]中, 提到在处理小样本飞行器导航传感器故障诊断任务时, 由于目标域数据的稀缺性, 模型容易出现过拟合现象, 导致诊断准确率下降。

其次是数据噪声与干扰问题, 航天器遥测数据中不可避免地存在噪声和干扰, 这些噪声和干扰可能来源于传感器误差、环境变化等多种因素。噪声和干扰的存在会严重影响故障诊断模型的性能, 导致误报率和漏报率的增加。在迁移学习过程中, 如何有效滤除噪声和干扰, 提取有用的故障特征, 是提高诊断准确性的关键。

最后, 数据标注成本高也是故障诊断领域常见的问题, 航天器故障数据的标注需要专业的领域知识和大量的时间成本, 且标注过程中可能存在主观性和不确定性。迁移学习通过利用源领域的知识来辅助目标领域的诊断, 可以在一定程度上减少对目标领域数据标注的依赖。然而, 如何选择合适的源领域数据, 以及如何有效融合源领域和目标领域的知识, 仍是降低数据标注成本、提高诊断效率的重要课题。

3.1.2 领域差异问题

航天器在不同任务、不同工况下的运行数据存在显著差异, 这些差异导致源领域和目标领域之间的数据分布不一致。在迁移学习过程中, 如何有效减小领域差异, 提高模型在目标领域的适应性, 是跨领域迁移面临的主要挑战。例如, 从某型卫星电源系统迁移至另一型号时, 因器件参数差异, 电压波动范围变化达 20%, 传统域自适应方法难以有效对齐分布。

3.1.3 模型泛化能力问题

迁移学习模型在源域上表现良好, 但在目标域上的泛化能力可能不足。特别是在目标域数据有限的情况下, 模型容易出现过拟合现象, 导致在目标域上的诊断性能下降^[57]。

传统迁移学习方法如深度域自适应对抗网络(DANN), 假设源域与目标域共享全局特征, 但航天器故障特征可能仅存在于局部层级(如传感器噪声频段或特定工况下的动力学模式)。例如, 卫星动量轮微小磨损故障的特征仅在高频振动信号(>500 Hz)中显现, 全局域适配无法捕捉此类局部差异, 导致迁移后模型对该故障的诊断精度下

降 40% 以上^[58]。

3.1.4 多源异构问题

航天器故障诊断通常涉及多源异构数据, 如遥测数据、图像数据、文本数据等。如何有效融合这些多源异构数据, 提取有用的故障特征, 是跨领域迁移学习中的一个重要问题。航天器包含姿控、电源、推进等多个分系统, 各系统数据采样频率、维度和物理意义差异显著。例如姿控系统的陀螺仪数据为高频时序(100 Hz), 而电源系统电压数据为低频采样(1 Hz)。不同工况(如变轨、对日定向)下数据分布差异大, 传统方法难以直接融合异构数据特征。多源异构数据间采样频率、物理含义差异显著, 加之传感器噪声与时间偏移问题, 给统一特征提取与模型迁移带来挑战。

3.2 未来发展的趋势

3.2.1 数据增强与合成技术的发展

为了缓解目标域数据不足的问题, 数据增强与合成技术以及元学习等新领域在迁移学习中的应用将得到进一步发展。通过生成对抗网络(GANs)、数据增强算法等技术, 可以生成更多的目标域数据, 提高模型的训练样本量, 增强模型在目标域上的泛化能力。

3.2.2 多模态融合与协同学习的发展

随着航天器设备的智能化和信息化发展, 多模态数据在故障诊断中的应用越来越广泛。多模态融合与协同学习技术将得到进一步发展, 通过融合不同模态的数据(如振动信号、声音信号、温度数据等), 可以更全面地反映设备的运行状态, 提高故障诊断的准确性和鲁棒性。

3.2.3 无监督与半监督迁移学习的发展

在目标域标注数据稀缺的情况下, 无监督与半监督迁移学习方法将得到更广泛的应用。通过利用无监督学习技术挖掘目标域数据的潜在特征和结构信息, 结合少量的标注数据进行半监督学习, 可以提高模型在目标域上的性能。例如, 在文献[59]中, 通过引入迁移学习, 提出了一种改进的故障定位方法, 将BP神经网络学习到的源域数据结构转移到目标域。通过理论分析, 当满足源域模型与目标域模型之差在一定范围内时, 该方法可实现无故障样本的航天器系统故障定位。

3.2.4 模型的可解释性和鲁棒性将成为研究的重点

随着迁移学习在故障诊断中的应用不断深入,模型的可解释性和鲁棒性将成为研究的重点^[60],成为智能故障诊断系统落地的重要指标。尤其在航天任务中,模型输出需具备可追溯性和可信度。为提升诊断透明度,可引入类激活映射(Class Activation Mapping, CAM)、注意力机制可视化及SHAP(SHapley Additive exPlanations)提高模型性能,也能够增强泛化能力值解释机制,对网络输出的关键特征通道进行分析。此外,结合物理模型先验进行显著特征归因,有望实现模型结构与航天器系统状态之间的关联映射,增强诊断结果的可理解性。通过解释模型的决策过程和知识迁移机制,可以更好地理解模型的性能和可靠性,提高模型在实际应用中的可信度。同时,研究如何提高模型对噪声、异常数据和领域变化的鲁棒性,也是未来的一个重要发展方向。由于航天器的高度智能化以及技术集成性的特点^[61],科研人员将更加重视可解释性方面的研究。例如,在文献[31]中,向刚等人阐述了通过结合领域知识、设计可解释性强的网络结构、采用注意力机制等技术手段,提高模型的可解释性,可以帮助用户理解故障原因、制定维修策略,为模型的改进和优化提供依据。

4 结论

本文系统回顾了基于迁移学习的航天器故障诊断技术,围绕实例迁移、特征迁移、模型迁移与领域自适应四大策略进行了分类分析,并结合重要性加权、自适应批归一化、参数微调、对抗性训练等关键方法,探讨了其在应对在轨复杂工况、样本稀缺与数据分布偏移等问题中的适用性与挑战。

研究表明:迁移学习在故障样本有限、工况变化剧烈的航天任务中具备显著优势。特别是多源域适应与迁移方法,能够有效提升诊断模型的泛化能力与鲁棒性,已成为提升航天器智能诊断性能的重要技术路径。同时,多策略融合框架展现出在跨平台、跨任务场景下的协同增益潜力。

然而,当前方法仍面临若干瓶颈,如迁移过程中源目标域间差异估计不准确、多模态特征融

合效率低、伪标签噪声干扰及模型可解释性不足等问题。为此,未来研究可重点聚焦以下几个方向:①无源域迁移与跨分布自适应机制,以减少对源数据依赖;②多模态特征融合与异构信号协同处理技术;③结合半监督与主动学习的低标签迁移方法;④引入可解释性机制提升模型在工程应用中的可追溯性与可信度。

总体而言,迁移学习为实现航天器故障诊断的智能化、轻量化与可部署化提供了有力支撑,未来其将在实际空间任务中的落地应用前景广阔。

参考文献

- [1] 张利彬,易航,李璨,等. 动力系统故障诊断技术[J]. 导弹与航天运载技术, 2016(1): 40-44.
ZHANG Libin, YI Hang, LI Can, et al. Power system fault diagnosis technology[J]. Missiles and Space Vehicles, 2016(1): 40-44.
- [2] 苏林,尚朝轩,刘文静. 航天器姿态控制系统故障诊断方法概述[J]. 长春理工大学学报(自然科学版), 2010, 33(4): 23-27, 35.
SU Lin, SHANG Chaoxuan, LIU Wenjing. Survey on the technology of fault diagnosis for spacecraft attitude control system[J]. Journal of Changchun University of Science and Technology (Natural Science Edition), 2010, 33(4): 23-27, 35.
- [3] 耿飞龙,李爽,黄旭星,等. 基于深度神经网络的航天器姿态控制系统故障诊断与容错控制研究[J]. 中国空间科学技术, 2020, 40(6): 1-12. DOI: 10.16708/j.cnki.1000-758X.2020.0066.
GENG Feilong, LI Shuang, HUANG Xuxing, et al. Research on fault diagnosis and fault-tolerant control for spacecraft attitude control system based on deep neural network[J]. Chinese Space Science and Technology, 2020, 40(6): 1-12. DOI: 10.16708/j.cnki.1000-758X.2020.0066.
- [4] LI X, ZHANG T, LIU Y. Detection of voltage anomalies in spacecraft storage batteries based on a deep belief network[J]. Sensors, 2019, 19: 4702. DOI: 10.3390/s19214702.
- [5] AHN H, JUNG D, CHOI H L. Deep generative models-based anomaly detection for spacecraft control systems [J]. Sensors, 2020, 20(7): 1991. DOI: 10.3390/s20071991.
- [6] HUANG Y X, LI S, SUN J. Mars entry fault-tolerant control via neural network and structure adaptive model in-

- version[J]. *Advances in Space Research*, 2019, 63(1): 557-571. DOI: 10.1016/j.asr.2018.09.016.
- [7] VALDES A, KHORASANI K. A pulsed plasma thruster fault detection and isolation strategy for formation flying of satellites[J]. *Applied Soft Computing*, 2010, 10(3): 746-758. DOI: 10.1016/j.asoc.2009.09.005.
- [8] 樊家伟, 郭瑜, 伍星, 等. 基于 LSTM 神经网络和故障特征增强的行星齿轮箱故障诊断[J]. *振动与冲击*, 2021, 40(20): 271-277. DOI: 10.13465/j.cnki.jvs.2021.20.034.
- FAN Jiawei, GUO Yu, WU Xing, et al. Fault diagnosis of planetary gearboxes based on LSTM neural network and fault feature enhancement[J]. *Journal of Vibration and Shock*, 2021, 40(20): 271-277. DOI: 10.13465/j.cnki.jvs.2021.20.034.
- [9] CHEN R, HUANG X, YANG L, et al. Intelligent fault diagnosis method of planetary gearboxes based on convolution neural network and discrete wavelet transform[J]. *Computers in Industry*, 2019, 106: 48-59. DOI: 10.1016/j.compind.2018.11.003.
- [10] 李继光, 苏燕辰, 任继炜, 等. 迁移学习在轴承保持架故障诊断中的研究[J]. *机械设计与制造*, 2023(11): 17-20. DOI: 10.19356/j.cnki.1001-3997.20230525.006.
- LI Jiguang, SU Yanchen, REN Jiwei, et al. Research on transfer learning in bearing cage fault diagnosis[J]. *Machinery Design & Manufacture*, 2023(11): 17-20. DOI: 10.19356/j.cnki.1001-3997.20230525.006.
- [11] 傅光旭, 毛凯, 蒋沁宇, 等. 基于深度迁移学习的小样本故障诊断方法[C]//中国自动化学会. 2023 中国自动化大会论文集. 航天科工集团第三研究院磁电总体部. 北京: 中国自动化学会. 2023: 348-353. DOI: 10.26914/c.cnkihy.2023.092647.
- [12] 李政, 汪凤翔, 张品佳. 基于图像融合与迁移学习的永磁同步电机驱动器强泛化性故障诊断研究[J]. *中国电机工程学报*, 2024, 44(12): 4933-4945. DOI: 10.13334/j.0258-8013.pcsee.230139.
- LI Zheng, WANG Fengxiang, ZHANG Pinjia. Research on strong generalization fault diagnosis of permanent magnet synchronous motor drive based on image fusion and transfer learning[J]. *Proceedings of the CSEE*, 2024, 44(12): 4933-4945. DOI: 10.13334/j.0258-8013.pcsee.230139.
- [13] 刘徐洲, 李孝忠. 基于深度残差收缩网络和迁移学习的变工况轴承故障诊断[J]. *天津科技大学学报*, 2023, 38(4): 76-80. DOI: 10.13364/j.issn.1672-6510.20230001.
- LIU Xuzhou, LI Xiaozhong. Bearing fault diagnosis under variable working conditions based on deep residual shrinkage network and transfer learning[J]. *Journal of Tianjin University of Science and Technology*, 2023, 38(4): 76-80. DOI: 10.13364/j.issn.1672-6510.20230001.
- [14] 张文兴, 张林林, 刘文婧, 等. 多表示域适应的滚动轴承故障诊断方法研究[J/OL]. *机械设计与制造*. [2025-06-10]. <https://doi.org/10.19356/j.cnki.1001-3997.20250521.031>.
- ZHANG Wenxing, ZHANG Linlin, LIU Wenjing, et al. Research on rolling bearing fault diagnosis method based on multi-representation domain adaptation[J/OL]. *Machinery Design & Manufacture*. [2025-06-10]. <https://doi.org/10.19356/j.cnki.1001-3997.20250521.031>.
- [15] WANG X, LIU F. Triplet loss guided adversarial domain adaptation for bearing fault diagnosis[J]. *Sensors*, 2020, 20(1): 320. DOI: 10.3390/s20010320.
- [16] 何漫丽, 程月华, 韩笑冬, 等. 一种卫星姿态控制系统故障定位研究方法[J]. *航天控制*, 2022, 40(2): 28-34. DOI: 10.16804/j.cnki.issn1006-3242.2022.02.005.
- HE Manli, CHENG Yuehua, HAN Xiaodong, et al. A Research method for fault localization in satellite attitude control systems[J]. *Aerospace Control*, 2022, 40(2): 28-34. DOI: 10.16804/j.cnki.issn1006-3242.2022.02.005.
- [17] 刘勇, 吴伟丽, 刘俊, 等. 基于元学习和迁移学习的小电流系统接地故障快速诊断方法[J]. *电气技术与经济*, 2024, (1): 103-106, 109.
- LIU Yong, WU Weili, LIU Jun, et al. Fast diagnosis method for ground fault in small current system based on meta-learning and transfer learning[J]. *Electric Technology and Economy*, 2024, (1): 103-106, 109.
- [18] 赵波, 刘相万, 章雷其, 等. 基于 Goog Le Net 与迁移学习的质子交换膜燃料电池集成系统故障诊断[J]. *中国电机工程学报*, 2024, 44(13): 5147-5158. DOI: 10.13334/j.0258-8013.pcsee.230210.
- ZHAO Bo, LIU Xiangwan, ZHANG Leiqli, et al. Fault diagnosis of proton exchange membrane fuel cell integrated system based on googleNet and transfer learning [J]. *Proceedings of the CSEE*, 2024, 44(13): 5147-5158. DOI: 10.13334/j.0258-8013.pcsee.230210.
- [19] 王子栋. 基于域自适应的轴承故障诊断方法研究及系统实现[D]. 成都: 电子科技大学, 2024. DOI: 10.27005/d.cnki.gdzku.2024.004818.
- [20] 王廷轩, 刘韬, 刘应东, 等. 平衡分布自适应的变工况

- 轴承故障迁移诊断研究[J]. 机械科学与技术, 2023, 42(8): 1316-1323. DOI: 10.13433/j.cnki.1003-8728.20220058.
- WANG Tingxuan, LIU Tao, LIU Yingdong, et al. Research on transfer diagnosis of bearing fault under variable working conditions based on balanced distribution adaptation[J]. Mechanical Science and Technology for Aerospace Engineering, 2023, 42(8): 1316-1323. DOI: 10.13433/j.cnki.1003-8728.20220058.
- [21] SHAO S, MCALEER S, YAN R, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. IEEE Transactions on Industrial Informatics, 2019, 15(4): 2446-2455. DOI: 10.1109/TII.2018.2864759.
- [22] 陈仁祥, 唐林林, 胡小林, 等. 不同转速下基于深度注意力迁移学习的滚动轴承故障诊断方法[J]. 振动与冲击, 2022, 41(12): 95-101, 195. DOI: 10.13465/j.cnki.jvs.2022.12.013.
- CHEN Renxiang, TANG Linlin, HU Xiaolin, et al. Rolling bearing fault diagnosis method based on deep attention transfer learning at different speeds[J]. Journal of Vibration and Shock, 2022, 41(12): 95-101, 195. DOI: 10.13465/j.cnki.jvs.2022.12.013.
- [23] 龙明盛. 迁移学习问题与方法研究[D]. 北京: 清华大学, 2014.
- [24] TAN C, SUN F, KONG T, et al. A Survey on deep transfer learning[C]//Artificial Neural Networks and Machine Learning-ICANN 2018. Cham: Springer, 2018. DOI: 10.1007/978-3-030-01424-7_27.
- [25] 刘笑炎. 基于深度迁移学习的飞机方向舵变工况故障诊断研究[D]. 武汉: 华中科技大学, 2024. DOI: 10.27157/d.cnki.gzhku.2024.003331.
- [26] 徐庸辉. 面向多实例分类的迁移学习研究[D]. 广州: 华南理工大学, 2017.
- [27] 张晓彤, 张宪超, 刘晗. 基于特征和实例迁移的加权多任务聚类[J]. 计算机学报, 2019, 42(12): 2614-2630.
- ZHANG Xiaotong, ZHANG Xianchao, LIU Han. Weighted multi-task clustering based on feature and instance transfer[J]. Chinese Journal of Computers, 2019, 42(12): 2614-2630.
- [28] ZHANG X, ZHANG X, LIU H, et al. Multi-task clustering through instances transfer[J]. Neurocomputing, 2017, 251: 124-132. DOI: 10.1016/j.neucom.2017.04.029.
- [29] LI Y, DONG Y, XU M, et al. Instance weighting-based partial domain adaptation for intelligent fault diagnosis of rotating machinery[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-14. DOI: 10.1109/TIM.2023.3276027.
- [30] 张晨曦. 针对航天测控任务动力系统数据的特征建模和态势评估[D]. 合肥: 中国科学技术大学, 2020. DOI: 10.27517/d.cnki.gzkju.2020.000803.
- [31] 何漫丽. 基于迁移学习的卫星姿态控制系统故障定位技术研究[D]. 南京: 南京航空航天大学, 2022. DOI: 10.27239/d.cnki.gnhhu.2022.001303.
- [32] 向刚, 韩峰, 周虎, 等. 数据驱动的航天器故障诊断研究现状及挑战[J]. 电子测量与仪器学报, 2021, 35(2): 1-16. DOI: 10.13382/j.jemi.B2003132.
- XIANG Gang, HAN Feng, ZHOU Hu, et al. Research status and challenges of data-driven spacecraft fault diagnosis[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 1-16. DOI: 10.13382/j.jemi.B2003132.
- [33] 付松, 钟诗胜, 林琳, 等. 基于迁移学习的民航发动机小样本故障诊断[J]. 计算机集成制造系统, 2021, 27(12): 3450-3461. DOI: 10.13196/j.cims.2021.12.007.
- FU Song, ZHONG Shisheng, LIN Lin, et al. Few-shot fault diagnosis of civil aviation engine based on transfer learning[J]. Computer Integrated Manufacturing Systems, 2021, 27(12): 3450-3461. DOI: 10.13196/j.cims.2021.12.007.
- [34] 唐艺璠. 航天器智能故障诊断与容错控制研究[D]. 天津: 天津大学, 2021. DOI: 10.27356/d.cnki.gtjdu.2021.002566.
- [35] LI J, LIU Y, LI Q. Generative adversarial network and transfer learning based fault detection for rotating machinery with imbalance data condition[J]. Measurement Science and Technology, 2022, 33(6): 065107. DOI: 10.1088/1361-6501/ac3945.
- [36] XIANG G, CHEN W, PENG Y, et al. Deep transfer learning based on convolutional neural networks for intelligent fault diagnosis of spacecraft[C]//2020 Chinese Automation Congress (CAC). New York: IEEE, 2020: 5522-5526. DOI: 10.1109/CAC51589.2020.9327214.
- [37] 武嘉琦, 季友昌, 袁伟伟. 基于迁移学习的飞机燃油系统故障检测方法研究[J]. 飞机设计, 2024, 44(4): 29-33, 68. DOI: 10.19555/j.cnki.1673-4599.2024.04.005.
- WU Jiaqi, JI Youchang, YUAN Weiwei. Research on air-

- craft fuel system fault detection method based on transfer learning[J]. *Aircraft Design*, 2024, 44(4): 29-33, 68. DOI: 10.19555/j.cnki.1673-4599.2024.04.005.
- [38] 韩松君. 基于领域自适应迁移学习的行星齿轮系统故障诊断研究[D]. 北京: 北京科技大学, 2024. DOI: 10.26945/d.cnki.gbjku.2024.000197.
- [39] 贾宝惠, 苏家成, 高源. 基于改进域对抗网络的齿轮箱跨工况故障诊断[J]. *电子测量技术*, 2025, 48(3): 83-91. DOI: 10.19651/j.cnki.emt.2417463.
- JIA Baohui, SU Jiacheng, GAO Yuan. Cross-condition fault diagnosis of gearbox based on improved domain adversarial network[J]. *Electronic Measurement Technology*, 2025, 48(3): 83-91. DOI: 10.19651/j.cnki.emt.2417463.
- [40] 时雪磊. 基于软阈值残差网络的多源域跨域故障诊断方法研究[J]. *电脑知识与技术*, 2024, 20(29): 74-77. DOI: 10.14004/j.cnki.ckt.2024.1480.
- SHI Xuelei. Research on multi-source domain cross-domain fault diagnosis method based on soft threshold residual network[J]. *Computer Knowledge and Technology*, 2024, 20(29): 74-77. DOI: 10.14004/j.cnki.ckt.2024.1480.
- [41] 范晶晶. 基于多源域迁移学习滚动轴承故障诊断方法研究[D]. 秦皇岛: 燕山大学, 2024. DOI: 10.27440/d.cnki.gysdu.2024.001988.
- [42] LU Z, ZHU Y, PAN S, et al. Source free transfer learning for text classification[C]//*Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence*. Québec City: AAAI Press, 2014: 122-128.
- [43] 路飞宇, 佟庆彬, 姜学东, 等. 一种基于条件度量迁移学习的机械故障诊断可解释方法[J]. *仪器仪表学报*, 2024, 45(7): 250-262. DOI: 10.19650/j.cnki.cjsi.J2312241.
- LU Feiyu, TONG Qingbin, JIANG Xuedong, et al. An interpretable method for mechanical fault diagnosis based on conditional metric transfer learning[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(7): 250-262. DOI: 10.19650/j.cnki.cjsi.J2312241.
- [44] 徐易芸, 马健, 陈良, 等. 基于相似性度量迁移学习的轴承故障诊断[J]. *振动与冲击*, 2022, 41(16): 217-223. DOI: 10.13465/j.cnki.jvs.2022.16.028.
- XU Yiyun, MA Jian, CHEN Liang, et al. Bearing fault diagnosis based on similarity metric transfer learning[J]. *Journal of Vibration and Shock*, 2022, 41(16): 217-223. DOI: 10.13465/j.cnki.jvs.2022.16.028.
- [45] AN Y, ZHANG K, CHAI Y, et al. Domain adaptation network base on contrastive learning for bearings fault diagnosis under variable working conditions[J]. *Expert Systems with Applications*, 2023, 212: 118802. DOI: 10.1016/j.eswa.2022.118802.
- [46] 毛刚. 无模砂型加工中心故障诊断及状态监测方法研究[D]. 西安: 西安电子科技大学, 2020. DOI: 10.27389/d.cnki.gxadu.2020.003017.
- [47] 顾彧行. 基于深度学习的卫星姿态控制系统微小故障诊断研究[D]. 南京: 南京航空航天大学, 2022. DOI: 10.27239/d.cnki.gnhhu.2022.000289.
- [48] XIANG G, TIAN K. Spacecraft intelligent fault diagnosis under variable working conditions via wasserstein distance-based deep adversarial transfer learning[J]. *International Journal of Aerospace Engineering*, 2021, 2021(1): 6099818. DOI: 10.1155/2021/6099818.
- [49] 林达, 袁焯, 吴伟, 等. 小样本条件下导弹时序遥测数据故障诊断方法[J/OL]. *计算机测量与控制*, 2025 [2025-06-10]. <http://kns.cnki.net/kcms/detail/11.4762.TP.20250521.1106.026.html>.
- LIN Da, YUAN Ye, WU Wei, et al. Fault diagnosis method for missile time-series telemetry data under few-shot conditions[J/OL]. *Computer Measurement & Control*, 1-9[2025-06-10]. <http://kns.cnki.net/kcms/detail/11.4762.TP.20250521.1106.026.html>.
- [50] LIU Y, YUAN Q, SUN K, et al. Mixed attention network for source-free domain adaptation in bearing fault diagnosis[J]. *IEEE Access*, 2024, 12: 93771-93780. DOI: 10.1109/ACCESS.2024.3424476.
- [51] 杨可. 基于迁移学习和深度神经网络的航空发动机故障诊断[D]. 南京: 南京航空航天大学, 2022. DOI: 10.27239/d.cnki.gnhhu.2022.001666.
- [52] YANG B, LEI Y, JIA F, et al. A polynomial kernel induced distance metric to improve deep transfer learning for fault diagnosis of machines[J]. *IEEE Transactions on Industrial Electronics*, 2020, 67(11): 9747-9757. DOI: 10.1109/TIE.2019.2953010.
- [53] 邬娜, 王健, 杨建伟, 等. 变工况及小样本情况下滚动轴承故障迁移学习方法综述[J]. *科学技术与工程*, 2024, 24(10): 3939-3951.
- WU N, WANG J, YANG J W, et al. A review of transfer learning methods for rolling bearing fault diagnosis un-

- der variable working conditions and small sample scenarios[J]. Science Technology and Engineering, 2024, 24(10): 3939-3951.
- [54] 徐志豪. 基于动力学仿真和迁移学习的航天轴承智能故障诊断研究[D]. 哈尔滨: 哈尔滨工业大学, 2023. DOI: 10.27061/d.cnki.ghgdu.2023.002932.
- [55] TANG Y, DOU L, ZHANG R, et al. Deep transfer learning-based fault diagnosis of spacecraft attitude system[C]//2020 39th Chinese Control Conference (CCC). New York: IEEE, 2020: 4072-4077. DOI: 10.23919/CCC50068.2020.9188710.
- [56] 张玉, 尹腾飞, 贾海云. 飞行器导航传感器故障诊断的应用研究[J]. 计算机仿真, 2012, 29(2): 68-71. ZHANG Yu, YIN Tengfei, JIA Haiyun. Application research on fault diagnosis of aircraft navigation sensors [J]. Computer Simulation, 2012, 29(2): 68-71.
- [57] MOHAMMED H, ABDOULHDI A, BORHANA O, et al. A systematic review of rolling bearing fault diagnoses based on deep learning and transfer learning: taxonomy, overview, application, open challenges, weaknesses and recommendations[J]. Ain Shams Engineering Journal, 2023, 14(4): 101945.
- [58] 白一皓. 面向行星齿轮箱故障诊断的深度学习适应性研究[D]. 北京: 北京交通大学, 2024. DOI: 10.26944/d.cnki.gbfnj.2024.000357.
- [59] HE M, CHENG Y, WANG Z, et al. Fault location for spacecraft ACS system using the method of transfer learning[C]//2021 40th Chinese Control Conference (CCC). 2021: 4561-4566. DOI: 10.23919/CCC52363.2021.9549760.
- [60] 陈超, 许琦, 宋正华, 等. 结合深度学习和迁移学习的行星齿轮箱故障诊断算法研究[J]. 机床与液压, 2025, 53(10): 40-49. CHEN Chao, XU Qi, SONG Zhenghua, et al. Research on planetary gearbox fault diagnosis algorithm combining deep learning and transfer learning[J]. Machine Tool & Hydraulics, 2025, 53(10): 40-49.
- [61] 张耀欣, 潘晓沛, 张京波. 智能航天器技术发展分析[J]. 航天返回与遥感, 2024, 45(3): 1-6. ZHANG Yaoxin, PAN Xiaopei, ZHANG Jingbo. Analysis of intelligent spacecraft technology development[J]. Spacecraft Recovery & Remote Sensing, 2024, 45(3): 1-6.

[作者简介]

- 周 苗 2001年生, 硕士研究生。
屈 辰 1988年生, 硕士, 高级工程师。
向 刚 1985年生, 博士, 研究员。
俞 洋 1979年生, 博士, 教授。

(本文编辑: 潘三英)