

# 控制与决策

Control and Decision

## 变负荷条件下压气机零样本性能退化评估方法

张堡霖, 赵健程, 岳嘉祺, 赵春晖, 闫月君, 陈辰

引用本文:

张堡霖, 赵健程, 岳嘉祺, 等. 变负荷条件下压气机零样本性能退化评估方法[J]. *控制与决策*, 2025, 40(9): 2868–2878.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.1448>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### [基于局部信息增量与MPLS的质量相关故障检测方法](#)

Quality-related fault detection method based on local information increment and MPLS

*控制与决策*. 2021, 36(7): 1647–1654 <https://doi.org/10.13195/j.kzyjc.2019.1402>

#### [带不相关并行机和有限缓冲MHFS调度的混合启发式算法](#)

Hybrid heuristic algorithm for multi-stage hybrid flow shop scheduling with unrelated parallel machines and finite buffers

*控制与决策*. 2021, 36(3): 565–576 <https://doi.org/10.13195/j.kzyjc.2019.0835>

#### [基于向量集逆区间滤波的故障观测器设计](#)

Vector set inversion interval filtering based fault observer design

*控制与决策*. 2021, 36(12): 2973–2981 <https://doi.org/10.13195/j.kzyjc.2020.0212>

#### [高超声速飞行器间歇故障改进自适应容错控制](#)

Improved adaptive fault-tolerant control of intermittent faults in hypersonic flight vehicle

*控制与决策*. 2021, 36(11): 2627–2636 <https://doi.org/10.13195/j.kzyjc.2020.0483>

#### [基于改进蛙跳算法的分布式两阶段混合流水车间调度](#)

An improved shuffled frog leaping algorithm for the distributed two-stage hybrid flow shop scheduling

*控制与决策*. 2021, 36(1): 241–248 <https://doi.org/10.13195/j.kzyjc.2019.0472>

# 变负荷条件下压气机零样本性能退化评估方法

张堡霖<sup>1,2</sup>, 赵健程<sup>1,2</sup>, 岳嘉祺<sup>1,2</sup>, 赵春晖<sup>1,2,3,4†</sup>, 闫月君<sup>5</sup>, 陈辰<sup>6</sup>

(1. 浙江大学 控制科学与工程学院, 杭州 310027; 2. 浙江大学 工业控制技术全国重点实验室, 杭州 310027;  
3. 湖州工业控制技术研究院, 浙江 湖州 313099; 4. 华东交通大学 电气与自动化工程学院, 南昌 330013;  
5. 阿里巴巴集团, 杭州 310024; 6. 中国人民解放军火箭军工程大学 智控实验室, 西安 710025)

**摘要:** 燃气轮机发电系统是火力发电装备的核心组成部分, 然而, 系统中压气机叶片的积垢等因素会导致其性能退化. 因此, 实时评估压气机性能退化程度, 并在适当时候进行水洗, 对于确保压气机的安全可靠运行至关重要. 但是, 出于安全性和经济性等因素的考虑, 电厂通常不允许压气机在严重退化的条件下运行, 故压气机严重退化状态数据获取困难, 传统数据驱动的性能退化评估模型难以建立, 从而无法预测退化程度以判断是否需要进行水洗. 进一步地, 考虑到压气机性能随燃机负荷不同而有不同表现, 这种差异对于评估压气机的实际退化程度产生了干扰, 增加了准确判断其性能退化情况的难度. 鉴于此, 首先, 提出压气机退化知识引导的退化差值生成对抗网络, 在严重退化数据完全缺失的零样本场景下, 利用专家标注的先验知识对性能轻微退化的数据特征实施定向劣化, 生成性能严重退化的数据特征, 进而有监督地训练退化评估模型; 然后, 为缓解负荷变化造成的干扰, 将不同负荷工况视为多个域, 从运行数据中提取消除变负荷影响的特征, 并通过设计知识预测器, 在这些特征中保留各类先验知识的信息, 提升退化差值生成对抗网络的生成质量; 最后, 使用真实压气机运行数据对所提出方法的有效性进行验证, 与其他零样本学习方法相比, 所提出方法退化等级评估调和平均准确率提升了 5.22%.

**关键词:** 压气机水洗; 零样本学习; 设备退化评估; 域对抗

中图分类号: TP277 文献标志码: A

DOI: 10.13195/j.kzyjc.2024.1448

引用格式: 张堡霖, 赵健程, 岳嘉祺, 等. 变负荷条件下压气机零样本性能退化评估方法 [J]. 控制与决策, 2025, 40(9): 2868-2878.

## Zero-shot performance degradation assessment method for compressors under variable load conditions

ZHANG Bao-lin<sup>1,2</sup>, ZHAO Jian-cheng<sup>1,2</sup>, YUE Jia-qi<sup>1,2</sup>, ZHAO Chun-hui<sup>1,2,3,4†</sup>, YAN Yue-jun<sup>5</sup>, CHEN Chen<sup>6</sup>

(1. College of Control Science and Engineering, Zhejiang University, Hangzhou 310027, China; 2. The State Key Laboratory of Industrial Control Technology, Zhejiang University, Hangzhou 310027, China; 3. Huzhou Institute of Industrial Control Technology, Huzhou 313099, China; 4. School of Electrical and Automation Engineering, East China Jiaotong University, Nanchang 330013, China; 5. Alibaba Group, Hangzhou 310024, China; 6. Laboratory of Intelligent Control, PLA Rocket Force University of Engineering, Xi'an 710025, China)

**Abstract:** The gas turbine power generation system is a core component of thermal power equipment. However, factors such as fouling on the compressor blades can lead to performance degradation. Therefore, real-time assessment of compressor performance degradation and timely implementation of water washing measures are crucial for ensuring the safe and reliable operation of the compressor. However, due to considerations of safety and economic efficiency, power plants typically do not allow compressors to operate under severe degradation conditions. As a result, acquiring data on severely degraded compressor states is challenging, making it difficult to establish traditional data-driven degradation assessment models. This limitation hinders the ability to predict the level of degradation and determine whether water washing measures are necessary. Furthermore, given that compressor performance varies under different turbine loads, this variability introduces interference when assessing the actual degradation level of the compressor, which increases

收稿日期: 2024-12-14; 录用日期: 2025-03-17.

基金项目: 国家自然科学基金杰出青年基金项目 (62125306); 浙江省“尖兵”“领雁”研发攻关计划项目 (2024C01163); 装备智能运用教育部重点实验室项目 (AAIE-2023-0101); 工业控制技术全国重点实验室开放课题项目 (ICT2024B19).

†通信作者. E-mail: chhzhao@zju.edu.cn.

the difficulty of accurately evaluating its performance degradation. To address these issues, a degradation knowledge-guided differential generative adversarial network for compressors is proposed. In the zero-shot scenario where data for severe degradation is entirely absent, expert-annotated prior knowledge is used to apply targeted deterioration to features of mildly degraded data, thereby generating features of severely degraded data. These generated features are then used to train a supervised degradation assessment model. To mitigate the interference caused by load variations, different load conditions are treated as multiple domains, and features that eliminate the impact of varying loads are extracted from operational data. Additionally, a knowledge predictor is designed to retain prior knowledge information in these features, enhancing the generation quality of the differential generative adversarial network. The effectiveness of the proposed method is validated using real-world compressor operational data. Compared to other zero-shot learning methods, the proposed method achieves a 5.22% improvement in the harmonic mean accuracy of degradation level assessment.

**Keywords:** compressor washing; zero-shot learning; equipment degradation assessment; domain adversarial

## 0 引言

燃气-蒸汽联合循环发电机组以其高效率 and 低污染特性在全球范围内被广泛应用. 作为联合循环发电系统的关键组成部分, 燃气轮机的性能优劣是决定整个发电厂运行状态的关键因素<sup>[1-2]</sup>. 压气机作为燃气轮机发电系统的核心部件, 承担着压缩空气和燃气以供燃烧使用的重要任务. 然而, 由于进气口的过滤系统无法完全去除空气中的所有杂质, 长期运行中压气机叶片的积垢等因素会降低其效率, 增加运行成本, 有时甚至会导致喘振现象, 对设备造成严重影响<sup>[3-4]</sup>. 为此, 定期进行压气机的离线水洗至关重要, 以确保发电过程的安全、可靠和环保.

目前, 许多电厂依然根据机组的运行时长来决定压气机是否需要水洗<sup>[5]</sup>, 然而, 运行时长并不能准确反映压气机的实际效能下降情况<sup>[6]</sup>, 从而导致因频繁水洗浪费水洗资源, 或水洗不及时引起压气机效率下降. 因此, 越来越多的研究人员开始采用数据驱动的方法研究压气机性能退化程度, 辅助水洗决策. Mund 等<sup>[7]</sup>提出了压气机水洗策略应取决于其性能指标损失, 如输出功率损失、质量流量减少量和压比降等; Zagorowska 等<sup>[8]</sup>提出了一种数据驱动的算法, 根据工业过程数据实时计算出性能指标, 并对未来性能指标的退化情况做出预测; Jin 等<sup>[9]</sup>提出了评价压气机污染程度的劣化指数, 结合长短期记忆网络(long short-term memory, LSTM), 实现了对压气机积垢的诊断和水洗周期的预测. 然而, 电厂通常不会允许压气机运行至严重退化的程度<sup>[10]</sup>, 因此, 高退化程度的数据难以获取, 无法根据数据进行对应退化阈值的设定, 从而导致传统基于性能指标损失的水洗决策方法失效.

在机器视觉领域中, 零样本学习(zero-shot learning)被提出以解决此类问题<sup>[11]</sup>, 该方法旨在利用部分数据丰富类别, 即已见类别的样本训练模型, 并通过知识作为桥梁<sup>[12]</sup>, 将模型从已见类别数据中

学到的分类能力迁移至数据缺失类别, 即未见类别, 从而实现未见类别样本的判别<sup>[13]</sup>, 其中图像分类任务的知识常常表现为图片中物体的属性标注, 如大小、颜色等<sup>[14]</sup>. Lampert 等<sup>[15]</sup>提出了直接属性迁移方法, 在已见类别上训练属性判别器, 在测试阶段基于属性判别器预测出测试样本属性, 通过最近邻方法匹配标签, 首次实现了零样本学习; Akata 等<sup>[16]</sup>和 Frome 等<sup>[17]</sup>则通过兼容性函数匹配了数据特征空间和属性空间, 以实现测试样本分类. 上述方法被称为嵌入式方法<sup>[18]</sup>, 在同时需要区分已见类别与未见类别的场景下, 此类方法易过拟合<sup>[19]</sup>, 从而将未见类别测试样本映射为已见类别, 效果不佳<sup>[20]</sup>. 生成式方法通过数据增强在一定程度上缓解了上述问题<sup>[21]</sup>. 生成式方法利用已见类别样本和全部类别的知识, 生成未见类别样本, 将零样本学习任务转化为有监督学习任务<sup>[22]</sup>. CVAE-ZSL (conditional variational autoencoders for zero-shot learning)<sup>[23]</sup>和 f-CLSWGAN (feature generating networks for zero-shot learning)<sup>[24]</sup>分别利用变分自编码器和生成式对抗网络生成未见类别样本. 在工业领域中, Feng 等<sup>[10]</sup>提出了一种结构化先验知识标注范式, 由专家标注的多个二值属性(如故障位置、故障原因等)来描述工业故障. 基于上述研究, 考虑到压气机高退化程度数据难以获取, 生成式方法有望在专家标注的先验知识的帮助下生成高退化程度数据, 有效完成传统以及广义零样本性能退化评估任务. 然而, 压气机性能退化随时间增长存在渐变特性, 当前生成式零样本方法同等看待所有类别, 没有考虑类别间的关联关系, 若直接用于性能退化评估任务, 没有利用压气机性能退化随着运行时间增长而愈发严重的渐变特性, 则生成过程将难以符合渐变退化规律, 从而不利于性能严重退化数据的生成.

现有数据驱动压气机性能退化评估方法通常采用基于性能评价指标设定水洗阈值的办法. 然而, 压

气机性能与发电负荷具有非常高的相关性,在最高负荷的运行工况下,燃气轮机的热力学循环更接近理想的热力学循环,此时燃气轮机中压气机的性能比相同条件下低负荷工况运行时更高<sup>[25]</sup>,因此,在燃气轮机频繁变负荷场景下基于性能指标建立的退化等级阈值也会发生改变.其次,压气机测点值随电网侧控制负荷的改变而改变,因此,模型需要考虑不同负荷工况下测点值与压气机性能的对应关系<sup>[26]</sup>.不同负荷工况可视为不同域,期望消除不同域间的特征分布差异.为解决多域特征分布不一致的问题,域对齐(domain alignment)方法应运而生,其旨在将具有不同分布的源域(source domain)和目标域(target domain)中的数据,映射至同一个特征空间,寻找某一种度量准则,使其在这个空间上的“距离”尽可能近<sup>[27]</sup>.随后,在含有标签的源域上训练好的分类器可直接用于目标域数据的分类.Ganin等<sup>[28]</sup>设计了域对抗(domain adversarial)策略,通过特征提取器提取数据特征,将其传入域判别器来判断特征来自源域还是目标域,并计算损失.域判别器的训练目标是尽量将输入的信息分到正确的域类别;而特征提取器的训练目标却恰恰相反,是生成使得域判别器不能正确判断来自哪个域的特征,因此形成了一种对抗关系<sup>[29]</sup>.在压气机性能退化评估过程中,域对抗策略可帮助模型训练出负荷影响消除的特征提取器,缓解不同负荷工况带来的特征分布差异,使得相同退化等级的数据分布趋于一致,从而避免负荷变化对性能退化评估任务的干扰.尽管如此,现有基于域对抗的特征提取方法仅通过类标签指示特征所属类别的异同<sup>[28]</sup>,类标签中缺乏类别的具体描述信息,然而,在零样本性能退化评估任务中,专家标注的先验知识从多种不同角度描述了类别的差异性和关联性,其中包含了数据样本中可能无法体现的额外语义信息来指导分类.

针对燃气轮机频繁变负荷特性以及高退化程度数据缺失导致的阈值难以设定问题,本文提出一种先验知识辅助的零样本学习策略来评估压气机性能退化程度.本文将压气机性能退化程度划分为多个等级.首先,为各退化等级设计由专家标注的先验知识,即属性向量,以描述压气机性能状态;然后,由于压气机性能与发电负荷具有非常高的相关性,为考虑变负荷对于压气机性能退化程度判断的影响,设计域对抗结构提取出消除变负荷影响的特征,并引入属性预测器以丰富特征的性能差异性表示;最后,在生成式零样本学习的基础上,引入压气机性能退化的渐变特性,在知识的辅助下利用较轻微退化程

度的特征生成较严重退化程度的特征,使得生成过程符合真实退化渐变规律.

本文内容主要包括:1)针对压气机水洗智能决策过程中的性能退化评估任务,不同于传统数据驱动方法依赖全退化过程的数据建模,本文引入专家标注的先验知识来降低对数据收集的依赖,并提出一种零样本压气机性能退化评估研究范式;2)考虑到压气机退化程度随燃气轮机负荷不同而有不同表现,从而对真实退化程度评估产生干扰,本文将不同负荷工况视为多个域,从运行数据中提取消除变负荷影响的特征,从而缓解负荷变化造成的干扰,并通过属性预测器保留这些特征中各类知识信息,能够提高性能退化等级的可区分性;3)为考虑在严重退化状态数据缺失的情况下建立退化评估模型,设计压气机退化知识引导的退化差值生成对抗网络,在先验知识的辅助下对性能轻微退化的数据特征实施定向劣化,生成性能严重退化的数据特征,从而将零样本评估问题转化为有监督学习问题.

## 1 变负荷条件下压气机零样本性能退化评估方法

本节首先介绍问题描述和符号定义,然后介绍负荷影响消除的特征提取方法以及知识辅助的退化差值特征生成方法,最后介绍零样本性能退化评估方法在线应用.

所提出变负荷条件下的压气机零样本性能退化评估框架如图1所示,其中分为负荷影响消除的特征提取方法、知识辅助的退化差值生成对抗方法以及分类器训练和在线应用3个模块.负荷影响消除的特征提取方法利用已见退化等级先验知识(即属性)和变负荷已见等级训练数据训练出负荷影响消除的特征提取器,供其他两个模块使用;知识辅助的

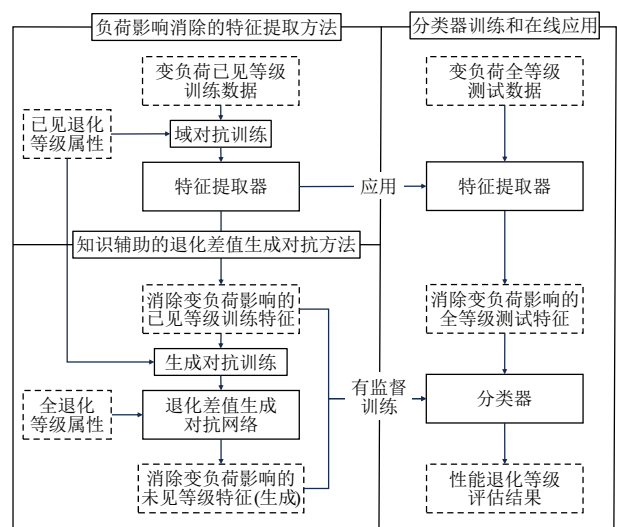


图1 变负荷条件下压气机零样本性能退化评估框架

退化差值生成对抗方法基于上一步提取的特征以及全退化等级知识训练退化差值生成对抗网络,然后生成消除变负荷影响的未见特征;分类器和在线应用阶段,使用消除变负荷影响的已见和未见等级特征有监督训练分类器,并利用特征提取器提取消除变负荷影响的全等级测试数据特征,最后通过分类器评估压气机性能退化等级。

### 1.1 问题描述与符号定义

本文将压气机退化程度划分为 $K$ 个等级,为了考虑变负荷对于压气机性能退化评估的影响,首次为各退化等级设计专家标注的先验知识来反映压气机性能状态,其中专家标注的先验知识来源于压气机设备结构和运行机理,包括如“玻纤脏污”“粗滤脏污”“叶片脏污”等 $M$ 个属性。由专家给出每个退化等级每个属性的具体值,如“优”“良”“中”等类别,一个包含所有属性的属性值组合称为一个属性向量,使用 $A$ 表示所有属性向量的集合。实际燃气轮机系统中,负荷工况直接体现在发电功率中,而发电功率受电网侧闭环控制,因此,设备时常切换于不同负荷工况之间。本文将功率分为 $Q$ 个负荷工况,对于每条压气机运行数据,均有负荷工况集合 $W = \{1, 2, \dots, Q\}$ 中的一个标签与之对应。

进一步地,如前文所述,在实际电厂运行环境中,压气机严重退化数据存在缺失的情况。因此,本文仅使用较轻微退化的数据作为训练集。将能够获取数据的退化较轻微等级称为已见等级,将数据缺失的严重退化等级称为未见等级,训练集表示为

$$D^{\text{tr}} = \{(\mathbf{x}^{\text{tr}}, y^{\text{tr}}, \mathbf{a}_s, w_s), A | \mathbf{x}^{\text{tr}} \in X_s^{\text{tr}}, y^{\text{tr}} \in Y_s, \mathbf{a}_s \in A, w_s \in W\}.$$

其中:  $\mathbf{x}^{\text{tr}} \in \mathbb{R}^{d_x}$  为压气机运行过程训练数据(均为已见等级数据),  $d_x$  为数据维度;  $X_s^{\text{tr}}$  为用于训练的已见类别数据集合;  $y^{\text{tr}}$  为  $\mathbf{x}^{\text{tr}}$  对应的等级标签;  $Y_s = \{1, 2, \dots, K_s\}$ , 这里  $K_s$  为已见等级的数量, 标签值越大, 对应的退化程度越高;  $\mathbf{a}_s \in \mathbb{R}^M$  和  $w_s$  分别为数据  $\mathbf{x}^{\text{tr}}$  对应的属性向量以及负荷工况标签。类似地, 测试集可表示为

$$D^{\text{te}} = \{(\mathbf{x}^{\text{te}}, y^{\text{te}}, \mathbf{a}_u, w_u), A | \mathbf{x}^{\text{te}} \in X_u \cup X_s^{\text{te}}, y^{\text{te}} \in Y_u \cup Y_s, \mathbf{a}_u \in A, w_u \in W\}.$$

这里:  $\mathbf{x}^{\text{te}} \in \mathbb{R}^{d_x}$  为压气机运行过程测试数据;  $X_u$  为未见类别数据集合;  $X_s^{\text{te}}$  为用于测试的已见类别数据集合;  $y^{\text{te}}$  为  $\mathbf{x}^{\text{te}}$  对应的等级标签;  $Y_u = \{K_s+1, \dots, K\}$ , 已见类别与未见类别互不重叠, 即  $Y_s \cap Y_u = \emptyset$ ;  $\mathbf{a}_u \in \mathbb{R}^M$  和  $w_u$  分别为数据  $\mathbf{x}^{\text{te}}$  对应的属性向量以及负荷工况标签;  $w_s$  和  $w_u$  均取自集合  $W$ , 且  $w_s$  覆盖集合

$W$  中所有元素。在传统零样本学习设定中, 需要训练分类器  $f_{zsl} : X_u \rightarrow Y_u$ , 即该分类器能够评估来自自己见等级的样本; 而在广义零样本学习设定中, 需要训练分类器  $f_{gzsl} : X_u \cup X_s^{\text{te}} \rightarrow Y_s \cup Y_u$ , 即该分类器能够同时评估来自自己见和未见等级的样本。

### 1.2 负荷影响消除的特征提取方法

本节主要介绍如何设计特征提取器的训练方式, 使其能够提取出消除变负荷影响的特征。

本文将不同工况视为不同域, 并设计域对抗结构提取消除变负荷影响的特征。如图2所示, 域对抗策略为模型训练特征提取器  $f(\cdot)$ , 有助于缓解不同域间特征分布差异, 使得相同退化等级的数据分布趋于一致, 从而简化分类器的训练难度, 实现更精准的性能评估。

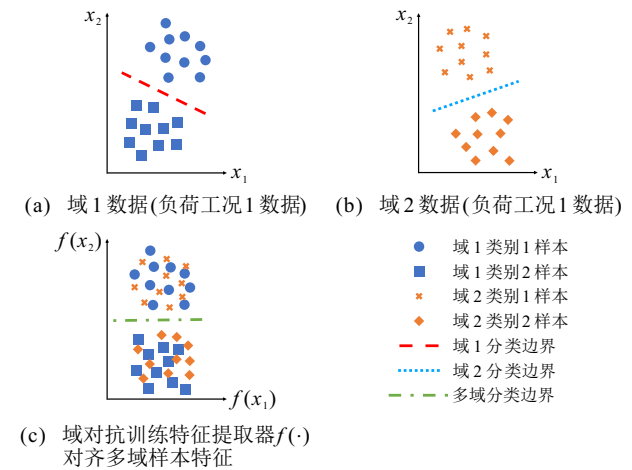


图2 域对抗训练缓解变负荷情况下特征分布差异示意图

所提出域对抗结构包含特征提取器、域对抗判别器和属性预测器, 如图3所示。其中: 在域对抗判别器与特征提取器中间使用一个梯度反转层 (gradient reversal layer, GRL)<sup>[28]</sup>, 其前向传播定义为一个恒等映射, 在反向传播中则对梯度进行反向缩放, 从而反转网络在 GRL 之前和之后的训练目标, 以实现对抗训练的效果。将梯度反转层视为函数  $R(x)$ , 所提出方法正向和反向传播计算方式分别为

$$R(\mathbf{x}) = \mathbf{x}, \frac{dR}{d\mathbf{x}} = -I, \quad (1)$$

这里  $I$  为单位矩阵。当引入梯度反转层后, 特征提取




图3 域对抗 (domain adversarial) 结构示意图

器的优化目标将与域对抗判别器的目标相反,即特征提取器的目标是提取特征,并尽可能令域对抗判别器难以判断其来自哪个域,而域对抗判别器的目标是尽可能判断正确特征的域标签,两者互相博弈,直至系统达到一个稳定状态.令 $f(\cdot)$ 表示特征提取器的输出, $D_d(\cdot)$ 表示域对抗判别器的输出,即预测域标签,利用交叉熵损失函数计算域判别损失 $L_D$ ,如下所示:

$$L_D = -\mathbb{E}_{\mathbf{x}^{\text{tr}} \sim X_s^{\text{tr}}} [\log P(w_s | D_d(f(\mathbf{x}^{\text{tr}})))] \quad (2)$$

其中: $\mathbb{E}_{\mathbf{x}^{\text{tr}} \sim X_s^{\text{tr}}}$ 为数学期望,表示在训练集 $X_s^{\text{tr}}$ 上的平均损失; $P(\cdot)$ 表示预测标签为真实标签的概率,通常是指计算分类器输出的对数概率.通过这种域对抗方式,特征提取器能够提取到消除变负荷影响的特征,为后续建模提供支撑.同时,在域对抗的基础上引入专家标注的先验知识,设计知识(即属性)预测器,尽可能保留各类先验知识的信息.属性预测器输出属性向量,令 $D_a(\cdot)$ 为属性预测器的输出,利用均方差损失函数计算域对抗属性判别损失 $L_A$ 为

$$L_A = -\mathbb{E}_{\mathbf{x}^{\text{tr}} \sim X_s^{\text{tr}}} \left[ \frac{1}{M} \sum_{j=1}^M (D_a(f(\mathbf{x}^{\text{tr}}))_j - a_{s,j})^2 \right] \quad (3)$$

这里: $D_a(\cdot)_j$ 为属性预测器输出中第 $j$ 个属性的值, $a_{s,j}$ 为数据 $\mathbf{x}^{\text{tr}}$ 对应的属性向量中第 $j$ 个属性的值, $M$ 为属性向量的维度.在训练过程中:针对域对抗判别器 $D_d(\cdot)$ ,优化损失函数 $L_D$ ;针对属性预测器 $D_a(\cdot)$ ,

优化损失函数 $L_A$ ;针对特征提取器 $f(\cdot)$ ,同时优化损失函数 $L_A$ 和经过梯度反转的 $L_D$ ,即

$$L_f = L_D + \beta L_A \quad (4)$$

其中: $L_f$ 为特征提取器优化总损失函数, $\beta$ 为可调节权重超参数,训练完成后可获得包含属性信息的负荷影响消除的特征提取器 $f(\cdot)$ .

### 1.3 知识辅助的退化差值生成对抗方法

本节主要介绍如何基于压气机性能退化随着运行时间增长而愈发严重的渐变特性,设计知识辅助的退化差值生成对抗方法,生成性能退化严重的数据特征.

在第1.2节中,特征提取器 $f(\cdot)$ 和属性预测器 $D_a(\cdot)$ 均训练完成.在此基础上,考虑到压气机性能退化的渐变特性,本文提出了退化差值生成对抗网络(differential generative adversarial network, DFGAN),该模型学习先验知识(即属性)与真实特征分布的关系,在属性的辅助下,通过性能退化较轻的特征生成性能退化严重的特征,从而将传统以及广义零样本学习问题转换为有监督学习问题.

DFGAN的结构如图4所示.其中:“高等级”为相对概念,表示两个样本标签中对应退化程度的较高者,即性能退化更严重的样本的标签;“低等级”则相反.DFGAN旨在利用属性与低等级特征生成高等级特征,以解决性能严重退化训练样本难以获取的难题.

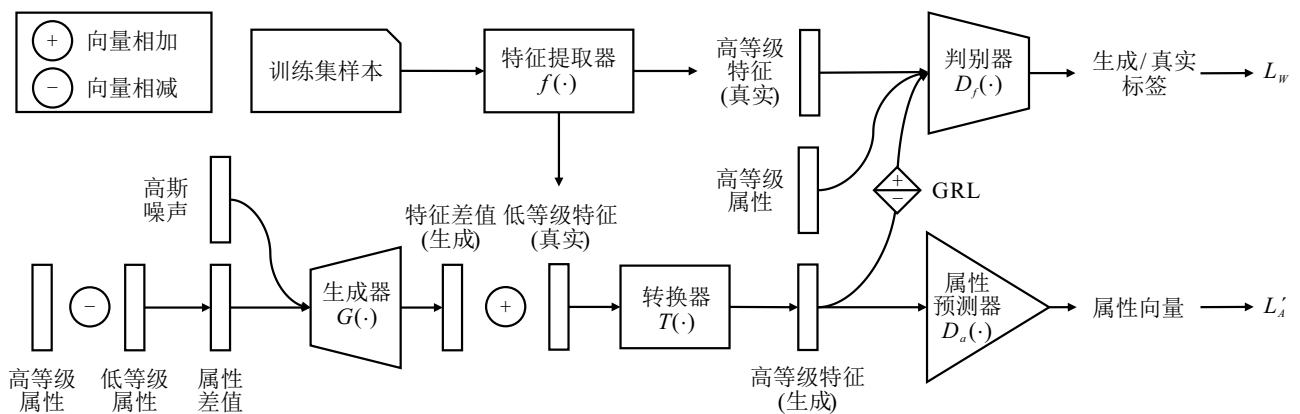


图4 退化差值生成对抗网络 (DFGAN) 结构示意图

DFGAN由生成器、转换器、生成对抗判别器以及前述特征提取器和属性预测器组成.其中:生成器通过高等级与低等级属性的差值来生成相应的特征差值;而转换器利用这些特征差值,将低等级特征转换为高等级特征.因此,生成器和转换器共同构成生成模块,借助专家标注的先验知识,对性能轻微退化的数据特征实施定向劣化,以生成性能严重退化的数据特征.

DFGAN的训练过程包括生成器、转换器和生成对抗判别器的训练.首先,对训练集所有样本进行随机采样,取出两个样本构成样本对,其中前者退化等级高于后者.重复上述随机采样步骤,并保证训练集中每个样本至少被采样一次,定义所有样本对的集合为 $O$ ,即

$$O = \{(\mathbf{x}_1^{\text{tr}}, \mathbf{y}_1^{\text{tr}}, \mathbf{a}_s^1), (\mathbf{x}_2^{\text{tr}}, \mathbf{y}_2^{\text{tr}}, \mathbf{a}_s^2) | \mathbf{y}_1^{\text{tr}} > \mathbf{y}_2^{\text{tr}}\} \quad (5)$$

这里: $\mathbf{x}_1^{\text{tr}}, \mathbf{x}_2^{\text{tr}} \in X_s^{\text{tr}}; \mathbf{y}_1^{\text{tr}}, \mathbf{y}_2^{\text{tr}} \in Y_s; \mathbf{a}_s^1, \mathbf{a}_s^2 \in A$ .进一步

地,计算高等级退化样本属性向量 $\mathbf{a}_s^1$ 与低等级退化样本属性向量 $\mathbf{a}_s^2$ 的差值,并拼接随机噪声,输入生成器,得到生成的特征差值,与真实低等级特征相加,通过转换器得到生成的高等级特征,即 $\mathbf{x}_1^{\text{tr}}$ 的虚拟特征 $\tilde{f}(\mathbf{x}_1^{\text{tr}})$ ,从而完成了特征的定向劣化过程,即

$$\tilde{f}(\mathbf{x}_1^{\text{tr}}) = T(G((\mathbf{a}_s^1 - \mathbf{a}_s^2), \mathbf{z}) + f(\mathbf{x}_2^{\text{tr}})). \quad (6)$$

其中: $\mathbf{x}_1^{\text{tr}}$ 为高退化程度数据; $\tilde{f}(\cdot)$ 为虚拟特征; $(\mathbf{x}_1^{\text{tr}}, y_1^{\text{tr}}, \mathbf{a}_s^1), (\mathbf{x}_2^{\text{tr}}, y_2^{\text{tr}}, \mathbf{a}_s^2) \in O$ ;  $G(\cdot)$ 为生成器的输出; $T(\cdot)$ 为转换器的输出; $\mathbf{z}$ 为随机高斯噪声. 总体而言,上述过程利用属性信息对性能轻微退化的数据特征实施定向劣化,生成了性能严重退化的虚拟特征. 如图4所示:为获取更加真实的虚拟特征,引入了生成对抗判别器 $D_f(\cdot)$ 对生成模块(生成器 $G(\cdot)$ 、转换器 $T(\cdot)$ )进行训练,模型的目标是使得生成器 $G(\cdot)$ 、转换器 $T(\cdot)$ 与生成对抗判别器 $D_f(\cdot)$ 在一个极大极小博弈中竞争. $D_f(\cdot)$ 尽可能准确地将真实样本与生成的样本区分开,而 $G(\cdot)$ 和 $T(\cdot)$ 则尽可能通过生成可被误认为真实的样本来欺骗生成对抗判别器,上述优化目标可表示为 $\min_{G,T} \max_D L_W$ ,其中损失函数 $L_W$ 如下所示:

$$L_W = \mathbb{E}_p[D_f(f(\mathbf{x}_1^{\text{tr}}), \mathbf{a}_s^1)] - \mathbb{E}_p[D_f(\tilde{f}(\mathbf{x}_1^{\text{tr}}), \mathbf{a}_s^1)] - \lambda \mathbb{E}_p[(\|\nabla_{\hat{\mathbf{x}}} D_f(\hat{f}(\mathbf{x}_1^{\text{tr}}), \mathbf{a}_s^1)\|_2 - 1)^2]. \quad (7)$$

这里: $\mathbb{E}_p := \mathbb{E}_{(\mathbf{x}_1^{\text{tr}}, y_1^{\text{tr}}, \mathbf{a}_s^1), (\mathbf{x}_2^{\text{tr}}, y_2^{\text{tr}}, \mathbf{a}_s^2) \sim O}$ 为数学期望,表示在前述采样出的样本对集合 $O$ 上的平均损失; $D_f(\cdot)$ 为生成对抗判别器的输出; $\mathbf{a}_s^1$ 为高等级退化样本属性向量; $\nabla_{\hat{\mathbf{x}}} D_f(\hat{f}(\mathbf{x}_1^{\text{tr}}), \mathbf{a}_s^1)$ 为 $D_f(\hat{f}(\mathbf{x}_1^{\text{tr}}), \mathbf{a}_s^1)$ 关于 $\hat{\mathbf{x}}$ 的梯度; $\tilde{f}(\mathbf{x}_1^{\text{tr}})$ 为前述 $\mathbf{x}_1^{\text{tr}}$ 的虚拟特征; $\hat{f}(\mathbf{x}_1^{\text{tr}}) = \alpha f(\mathbf{x}_1^{\text{tr}}) + (1 - \alpha) \tilde{f}(\mathbf{x}_1^{\text{tr}})$ ,  $\alpha \sim U(0, 1)$ ,  $\alpha$ 为权重系数, $U(0, 1)$ 表示定义在区间 $[0, 1]$ 上的均匀分布; $\lambda$ 为惩罚系数. $L_W$ 中的前两项近似于 Wasserstein 距离<sup>[30]</sup>,用于测量数据分布与生成分布间的差异;第3项则是梯度惩罚,强制生成对抗判别器 $D_f(\cdot)$ 的梯度具有沿真实与生成样本对间直线方向的单位范数. 此外,所提出方法将域对抗结构中训练好的属性预测器 $D_a(\cdot)$ 引入退化差值生成对抗网络中,辅助生成器生成更具属性判别性的特征,即引入前述均方误差损失函数,此处表示为生成对抗属性判别损失 $L'_A$ ,即

$$L'_A = -\mathbb{E}_p \left[ \frac{1}{M} \sum_{j=1}^M (D_a(\tilde{f}(\mathbf{x}_1^{\text{tr}}))_j - \mathbf{a}_{s,j})^2 \right]. \quad (8)$$

在训练过程中,冻结属性预测器 $D_a(\cdot)$ 的参数,针对判别器 $D_f(\cdot)$ ,优化损失函数 $L_W$ ;针对生成器

$G(\cdot)$ 和转换器 $T(\cdot)$ ,损失值 $L_W$ 的梯度需要首先经过梯度反转层,并与 $L'_A$ 梯度求和后反向传播,即

$$L_{\text{GT}} = L_W + \eta L'_A. \quad (9)$$

其中: $L_{\text{GT}}$ 为生成器和转换器优化总损失函数, $\eta$ 为可调节权重超参数. 退化差值生成对抗网络训练好后,获得能够利用属性以及低等级特征生成具有属性判别性特征的生成器 $G(\cdot)$ 和转换器 $T(\cdot)$ .

#### 1.4 零样本性能退化评估分类器训练和在线应用

经过第1.2节中的域对抗训练可得到特征提取器 $f(\cdot)$ ,经过第1.3节中知识辅助的退化差值生成对抗训练可得到生成器 $G(\cdot)$ 和转换器 $T(\cdot)$ ,本节将介绍最终的性能退化等级分类器训练和在线应用流程.

##### 1.4.1 分类器训练

广义零样本学习拟在未见退化等级样本缺失的情况下,利用专家标注的先验知识(即属性)信息以及已见退化等级特征生成未见退化等级特征,进一步利用已见退化等级特征以及生成特征训练一个分类器 $C(\cdot)$ ,以实现对所有退化等级的判别.

图5为所提出方法分类器训练和在线应用流程.

如图5上部所示:首先,在训练集中采样得到训练集数据 $\mathbf{x}^{\text{tr}}$ 及其对应的退化等级标签 $y^{\text{tr}}$ 和属性向量 $\mathbf{a}_s$ ,在未见退化等级中随机选取属性向量 $\mathbf{a}_u$ 及其对应的退化等级标签 $y^u$ ;然后,通过特征提取器 $f(\cdot)$ 、生成器 $G(\cdot)$ 和转换器 $T(\cdot)$ 生成未见退化等级特征,并与训练集已见退化等级特征共同训练分类器,基于交叉熵的损失函数 $L_C$ 为

$$L_C = -\mathbb{E}_{\mathbf{x}^{\text{tr}} \sim \mathbf{x}_s^{\text{tr}}} [\log P(y^{\text{tr}} | C(f(\mathbf{x}^{\text{tr}}))) + \log P(y^u | C(T(G((\mathbf{a}_u - \mathbf{a}_s), \mathbf{z}) + f(\mathbf{x}^{\text{tr}}))))], \quad (10)$$

其中 $P(\cdot)$ 表示预测标签为真实标签的概率. 通过优化损失函数 $L_C$ 得到训练好的分类器 $C(\cdot)$ ,具有同时分类已见、未见特征的能力.

##### 1.4.2 在线应用

如图5下部所示:将压气机各种负荷工况下用于测试的样本,包括已见和未见等级的原始测点数据输入训练好的特征提取器,当测试样本到来时,模型将样本输入训练好的分类器 $C(\cdot)$ 中. 此外,为缓解广义零样本中广泛存在的域偏移问题,即仅使用已见类别数据训练的模型对未见类别的泛化能力较差,针对分类器 $C(\cdot)$ 采用校准堆叠<sup>[31]</sup>(calibrated stacking)方法,即

$$\hat{y}^{\text{te}} = \arg \max_{c \in y_u \cup y_s, \mathbf{x}^{\text{te}} \in X_u \cup X_s^{\text{te}}} C(f(\mathbf{x}^{\text{te}})) - \gamma \mathbb{I}[c \in Y_s]. \quad (11)$$

其中: $\hat{y}^{\text{te}}$ 为对测试集数据 $\mathbf{x}^{\text{te}}$ 的退化等级评估结果,

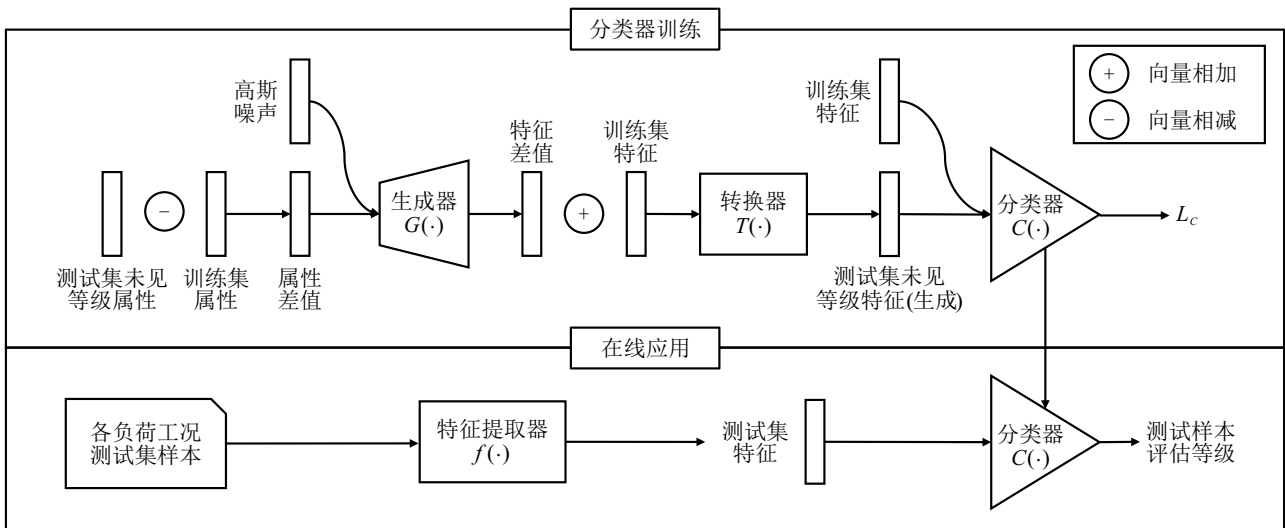


图5 本文方法分类器训练和在线应用流程

函数 $I[\cdot] \in \{0, 1\}$ 指示类别 $c$ 是否为已见退化等级,  $\gamma$ 为校准系数. 分类器输出即为测试样本在线评估性能退化等级, 等级越高, 压气机性能退化越严重, 即越有必要安排水洗.

## 2 案例分析

本节主要介绍案例中压气机的具体型号、传感器测点设置和属性信息, 以及相关的实验设置和最终的实验结果.

### 2.1 压气机案例介绍

本案例中的压气机来自于某真实火力发电厂西门口 SGT5-4000F 燃气轮机, 电厂已在前期改造中加装了多个重要部位的传感器测点以及数据采集系统, 其采样频率为 2 min. 本研究选取的数据集包含 5 个退化等级, 即  $K = 5$ . 为了考虑变负荷对于压气机性能退化阈值的影响, 为各退化等级设计消除变负荷影响的先验知识来反映压气机性能状态. 其中: 先验知识包括 8 类属性向量, 每类属性向量包含 4 个属性, 即  $M = 4$ , 专家使用“优”“良”“中”“差”4 个评价标准度量各等级的属性. 压气机退化的同一等级可能包含不同情况, 对应不同的属性值组合, 但是, 它们均需要被工厂以同样的严重程度对待. 因此, 对于某个退化等级, 可能对应多个属性向量. 本文中使用的数据集包含玻纤脏污、粗滤脏污、精滤脏污、叶片脏污 4 个属性, 退化等级划分以及属性表示如表 1 所示.

为量化评价标准的值以便建模, 在实际建模过程中, 将“优”“良”“中”“差”4 个评价标准分别映射至“0.25”“0.5”“0.75”“1.00”四个值中. 同时, 压气机运行过程包含 5 个负荷工况, 即  $Q = 5$ ,  $W = \{1, 2, 3, 4, 5\}$ , 数据集中每个工况的每类属性向量均有 200 个样本与之对应. 其中: 50% 作为训练集, 50%

表1 电厂数据集压气机等级划分以及属性表示

	属性编号	玻纤脏污	粗滤脏污	精滤脏污	叶片脏污
等级1	#1	优	优	优	优
	#2	良	优	中	优
等级2	#3	中	差	良	优
等级3	#4	差	中	差	优
	#5	中	良	差	良
等级4	#6	优	良	良	差
	#7	良	差	中	中
等级5	#8	差	差	差	差

作为测试集. 每个样本包含与压气机性能衰退相关的 19 个测点, 如压气机进出口温度、压气机轴承振动等, 具体测点参数、对应的符号以及单位如表 2 所示.

### 2.2 结果与分析

在实际电厂运行环境中, 高退化等级数据存在缺失的情况, 因此, 本文仅使用低退化等级的数据作为训练集训练评估模型, 在遇到新的数据时能够正确判断所属退化等级. 对于本案例的 5 个退化等级, 选取低退化等级的数据作为训练集, 即退化等级 1 ~ 等级 3 作为已见退化等级, 剩余两种作为未见退化等级. 在本案例中, 本文同时测试零样本和广义零样本设定下模型的性能. 在零样本设定下, 训练数据集包含 3 种已见退化等级, 测试数据集包含 2 类未见退化等级; 在广义零样本设定下, 训练数据集包含 3 种已见退化等级, 测试数据集包含全部 5 类退化等级.

为检验域对抗训练特征提取器的效果, 图 6(a) 和图 6(b) 分别给出了属性编号#1 对应的原始数据分布及其经过域对抗特征提取后的特征分布的对比, 其中  $w_s \sim W$  为属性编号#1 对应已见退化等级域标签. 相较于图 6(a), 图 6(b) 中不同域标签的特征呈现

表2 测点名及其单位

序号	测点名	单位
1	压气机进口温度	°C
2	压气机出口压力	MPa
3	压气机进气道凝聚过滤器压差	kPa
4	压气机进气道粗滤压差	kPa
5	压气机进气道精滤压差	kPa
6	压气机出口温度	°C
7	压气机轴承温度	°C
8	压气机推力瓦轴承发电机端温度	°C
9	压气机推力瓦轴承燃机端温度	°C
10	压气机侧大轴振动	um
11	压气机轴承振动	mm/s
12	防冰冻装置进气电动调节阀阀位	%
13	燃烧室压差	hPa
14	燃机燃烧室加速度	g
15	IGV阀位	%
16	燃机IGV位置	%
17	燃机预混控制阀阀位	%
18	燃机值班控制阀阀位	%
19	燃机值班气流量	kg/s

聚集特性,表示域对抗结构中判别器 $D_d$ 辅助特征提取器习得了缓解原始数据域间分离的能力,提取出消除变负荷影响的特征.此外,图6(c)和图6(d)分别给出了所有属性原始测点数据及其经过域对抗训练的特征提取器所提取特征的对比.图6(d)展示了属性预测器 $D_a$ 的引入辅助特征提取器获得了缓解图6(c)相同属性对应原始数据分散情况的能力,使得相同属性的特征相接近.总体而言,所提取特征表现出类内聚集,类间分离的特性,降低了下游评估任务的难度.

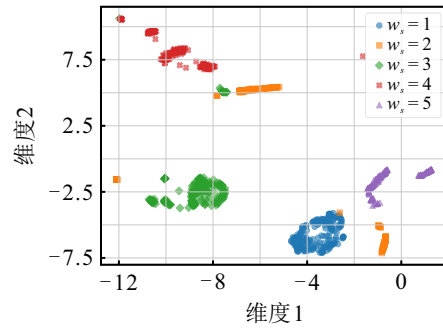
下面以案例测试集的等级评估结果来表明所提出方法的有效性,即以传统零样本、广义零样本性能退化评估准确率,广义零样本已见、未见评估准确率以及调和平均准确率来衡量其效果.令 $Acc_{zsl}$ 表示传统零样本性能退化评估的准确率,即

$$Acc_{zsl} = \frac{N^c}{N}. \quad (12)$$


其中: $N^c$ 为传统零样本设定下测试集样本正确分类数量, $N$ 为测试集退化等级样本总数.令 $Acc_s$ 、 $Acc_u$ 分别表示广义零样本已见、未见评估准确率,即

$$Acc_s = \frac{N_s^c}{N_s}, Acc_u = \frac{N_u^c}{N_u}. \quad (13)$$

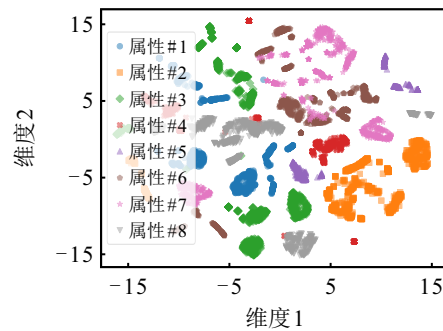
这里: $N_s^c$ 、 $N_u^c$ 分别为广义零样本设定下测试集已见、未见退化等级样本的正确分类数量, $N_s$ 、 $N_u$ 分别为测试集已见、未见退化等级样本总数.令 $Acc_h$ 表示广义零样本调和平均准确率,即



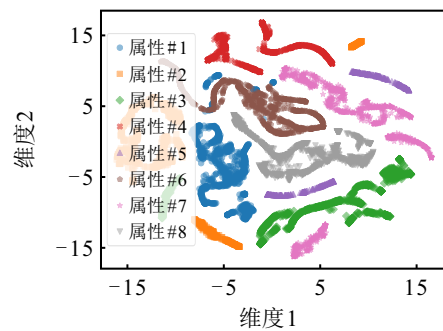
(a) 属性编号#1 原始数据分布



(b) 属性编号#1 域对抗特征提取特征分布



(c) 压气机原始数据分布



(d) 域对抗特征提取特征分布

图6 域对抗训练结果 t-SNE 降维可视化

$$Acc_h = 2 \times \frac{Acc_s \times Acc_u}{Acc_s + Acc_u}. \quad (14)$$

令 $Acc_{gzsl}$ 表示广义零样本性能退化评估准确率,即

$$Acc_{gzsl} = \frac{N_s \times Acc_s + N_u \times Acc_u}{N_s + N_u}. \quad (15)$$

本文选取嵌入式方法:直接属性预测 FDAT<sup>[10]</sup>、IAP<sup>[32]</sup>、ESZSL<sup>[33]</sup>、Devise<sup>[17]</sup>、ALE<sup>[34]</sup>、SJE<sup>[16]</sup>以及生成式方法: CVAE-ZSL<sup>[23]</sup>、f-CLSWGAN<sup>[24]</sup>用于实验对比.在 DAP 和 IAP 方法中,替换基学习器可获得不同的效果,由于属性为连续值,属性二分类判别器

和贝叶斯推断失效,这里分别以多层感知机(multilayer perceptron, MLP)、岭回归(ridge regression)和自适应提升(adaptive boosting, AdaBoost)作为基学习器.公平起见,对比方法采用

与本文一致的校准堆叠策略缓解域偏移问题.对比实验结果如表3所示.对于上述每个评价指标,表3所有对比方法中的最优值被标记为下划实线,次优值被标记为下划虚线.

表3 压气机传统/广义零样本性能退化评估实验结果以及方法对比

		ZSL		GZSL		
		Acc <sub>zsl</sub>	Acc <sub>s</sub>	Acc <sub>u</sub>	Acc <sub>h</sub>	Acc <sub>g<sub>zsl</sub></sub>
FDAT <sup>[10]</sup>	MLP	<u>0.9393</u>	0.5875	0.3553	0.4428	0.4880
	Ridge	0.8347	<u>0.8440</u>	0.3080	0.4513	<u>0.6142</u>
	AdaBoost	0.7713	0.5955	0.4840	0.5340	0.5477
IAP <sup>[32]</sup>	MLP	0.6667	0.4770	0.1493	0.2275	0.3366
	Ridge	0.7047	0.5000	0.2293	0.3144	0.3840
	AdaBoost	0.8667	0.7500	0.1333	0.2264	0.4857
ESZSL <sup>[33]</sup>		0.6630	0.6470	0.3907	0.4872	0.5371
DeVise <sup>[17]</sup>		0.6597	0.6660	0.4880	<u>0.5633</u>	0.5897
ALE <sup>[34]</sup>		0.6656	0.5765	<u>0.5193</u>	0.5464	0.5520
SJE <sup>[16]</sup>		0.5880	0.5625	0.4240	0.4835	0.5031
CVAE-ZSL <sup>[23]</sup>		0.9320	0.5927	0.3533	0.4427	0.4901
f-CLSWGAN <sup>[24]</sup>		0.7587	0.7160	0.3467	0.4671	0.5577
DFGAN (ours)		<u>0.9913</u>	<u>0.7870</u>	<u>0.5053</u>	<u>0.6155</u>	<u>0.6663</u>

由表3实验结果可见,所提出方法的零样本/广义零样本评估准确率分别为0.9913和0.6663,广义零样本已见、未见评估准确率及其调和平均数分别为0.7870、0.5053和0.6155,所有指标均为对比方法中的最优值或次优值.可以发现,所提出方法在这5个精度指标上整体比其他零样本学习方法有较大提升,其中退化等级评估调和平均准确率相较于对比方法提升了5.22%以上.尽管所提出方法在已见、未见评估准确率上相较于个别对比方法表现次优,

但是二者表现更为均衡,因此,包括其调和平均值在内的其他指标均超越对比方法,即表明了所提出方法在压气机严重退化状态数据缺失下能够有效实现变负荷压气机水洗智能决策的零样本性能退化评估.

图7为部分效果较优对比方法与所提出方法的退化等级评估结果混淆矩阵.由图7可见,相较于对比方法,所提出方法在取得较高准确率的同时,对错分样本也尽可能归类到相近的退化等级中,提高了压气机退化等级评估的可靠性.

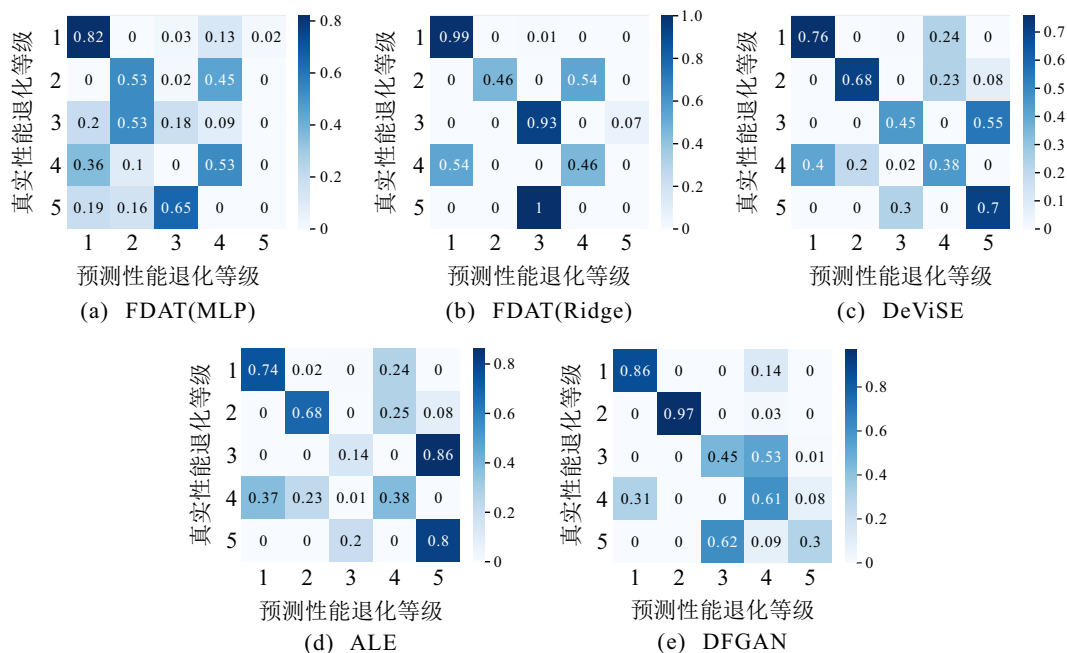


图7 部分对比方法与本文方法退化等级评估结果混淆矩阵

为验证所提出模块的有效性,设计针对可拆卸模块,包括转换器 $T(\cdot)$ 、生成对抗属性判别损失 $L'_A$ 和属性预测器 $D_a(\cdot)$ 的消融实验,其中属性预测器 $D_a(\cdot)$ 的消融同时涉及域对抗和生成对抗阶段。消融实验结果如图8所示,其中“w/o”表示消融某模块。图8反映出任一模块的消融均会损害性能评估结果。这里:由于转换器 $T(\cdot)$ 可被生成器 $G(\cdot)$ 部分代偿,其消融对于结果影响相对较小;相较而言,由于生成对抗属性判别损失 $L'_A$ 能够为DFGAN保留不同属性间特征的差异,增加了退化等级的可分性,从而更能影响评估结果;属性预测器 $D_a(\cdot)$ 在前者的基础上为域对抗引入了属性判别损失 $L_A$ ,帮助特征提取器 $f(\cdot)$ 提取包含属性间差异的特征,因此,其消融进一步降低了评估结果的准确性。

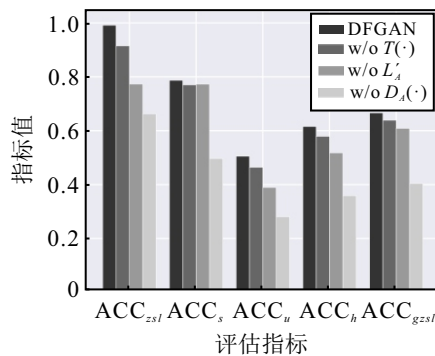


图8 DFGAN 评估结果以及针对转换器 $T(\cdot)$ 、生成对抗属性判别损失 $L'_A$ 和属性预测器 $D_a(\cdot)$ 的消融实验

### 3 结论

本文针对压气机水洗智能决策过程中的性能退化评估任务,突破了传统数据驱动方法依赖全退化过程的数据建模且评估结果易受到负荷干扰的局限。通过引入专家标注的先验知识来生成样本,有效降低了对严重退化数据收集的依赖,并提出了一种变负荷条件下零样本性能退化评估研究范式。首先,将不同负荷工况视为多个域,引入了域对抗训练策略,从运行数据中提取出消除变负荷影响的特征,缓解了负荷变化造成的干扰,同时设计了属性预测器,在特征中保留了各类知识信息,提高了性能退化等级的可区分性;然后,提出了压气机性能退化知识引导的退化差值生成网络,引入了性能退化的渐近特性,在知识的辅助下利用较轻微退化程度的特征生成较严重退化程度的特征,实现了零样本性能退化评估;最后,使用真实压气机运行数据对方法有效性进行了验证,在压气机严重退化状态数据缺失的情况下建立了退化评估模型,并使得退化等级评估调和平均准确率相较于对比方法提升了5.22%。

### 参考文献 (References)

- [1] Meher-Homji C, Bromley A F, Stalder J P. Gas turbine performance deterioration and compressor washing[C]. Proceedings of the 2nd Middle East Turbomachinery Symposia. Doha, 2013.
- [2] Musa G, Igie U, Pilidis P, et al. Economic viability of on-line compressor washing for different rated capacity[C]. Turbo Expo: Power for Land, Sea, and Air. Charlotte, 2017: 50831: V003T06A032.
- [3] Diwa E J, Igbong D I, Archibong A E, et al. Benefit of compressor washing on power output in oil and gas applications[J]. International Journal of Mechanical Engineering and Applications, 2017, 5(5): 239-246.
- [4] Jombo G, Pecinka J, Sampath S, et al. Influence of fouling on compressor dynamics: Experimental and modeling approach[J]. Journal of Engineering for Gas Turbines and Power, 2018, 140(3): 032603.
- [5] Byington C S, Watson M, Roemer M J, et al. Prognostic enhancements to gas turbine diagnostic systems[C]. IEEE Aerospace Conference. Big Sky, 2003: 3247-3255.
- [6] Kurz R, Musgrove G, Brun K. Experimental evaluation of compressor blade fouling[J]. Journal of Engineering for Gas Turbines and Power, 2017, 139(3): 032601.
- [7] Mund F C, Pilidis P. Gas turbine compressor washing: Historical developments, trends and main design parameters for online systems[J]. Journal of Engineering for Gas Turbines and Power, 2006, 128(2): 344-353.
- [8] Zagorowska M, Spüntrup F S, Ditlefsen A M, et al. Adaptive detection and prediction of performance degradation in off-shore turbomachinery[J]. Applied Energy, 2020, 268: 114934.
- [9] Jin Y F, Liu C, Tian X, et al. A hybrid model of LSTM neural networks with a thermodynamic model for condition-based maintenance of compressor fouling[J]. Measurement Science and Technology, 2021, 32(12): 124007.
- [10] Feng L J, Zhao C H. Fault description based attribute transfer for zero-sample industrial fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2021, 17(3): 1852-1862.
- [11] Xian Y Q, Schiele B, Akata Z. Zero-shot learning — The good, the bad and the ugly[C]. IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, 2017: 3077-3086.
- [12] Zhao J C, Yue J Q, Zhao C 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.
- [13] Wang W, Zheng V W, Yu H, et al. A survey of zero-shot learning: Settings, methods, and applications[J]. ACM Transactions on Intelligent Systems and Technology, 2019, 10(2): 1-37.
- [14] Feng L J, Zhao C H. Transfer increment for generalized zero-shot learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(6): 2506-

- 2520.
- [15] Lampert C H, Nickisch H, Harmeling S. Learning to detect unseen object classes by between-class attribute transfer[C]. IEEE Conference on Computer Vision and Pattern Recognition. Miami, 2009: 951-958.
- [16] Akata Z, Reed S, Walter D, et al. Evaluation of output embeddings for fine-grained image classification[C]. IEEE Conference on Computer Vision and Pattern Recognition. Boston, 2015: 2927-2936.
- [17] Frome A, Corrado G S, Shlens J, et al. DeViSE: A deep visual-semantic embedding model[C]. Advances in Neural Information Processing Systems. Lake Tahoe, 2013: 2121-2129.
- [18] 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 C, 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.)
- [19] Sun X H, Gu J N, Sun H Y. Research progress of zero-shot learning[J]. Applied Intelligence, 2021, 51: 3600-3614.
- [20] Yue J Q, Zhao J C, Zhao C 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.
- [21] 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.
- [22] Yue J Q, Zhao J C, Feng L J, et al. A survey and experimental study for embedding-aware generative models: Features, models, and any-shot scenarios[J]. Journal of Process Control, 2024, 143: 103297.
- [23] Mishra A, Reddy S K, Mittal A, et al. A generative model for zero shot learning using conditional variational autoencoders[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Salt Lake City, 2018: 2269-22698.
- [24] Xian Y Q, Lorenz T, Schiele B, et al. Feature generating networks for zero-shot learning[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 5542-5551.
- [25] Rathakrishnan E. Fundamentals of engineering thermodynamics[M]. New Delhi: PHI Learning Pvt. Ltd., 2005.
- [26] Pichler K, Lughofer E, Pichler M, et al. Fault detection in reciprocating compressor valves under varying load conditions[J]. Mechanical Systems and Signal Processing, 2016, 70: 104-119.
- [27] Chai Z, Zhao C 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.
- [28] Ganin Y, Ustinova E, Ajakan H, et al. Domain-adversarial training of neural networks[J]. Journal of Machine Learning Research, 2016, 17(59): 1-35.
- [29] Zonoozi M H P, Seydi V. A survey on adversarial domain adaptation[J]. Neural Processing Letters, 2023, 55(3): 2429-2469.
- [30] Arjovsky M, Chintala S, Bottou L. Wasserstein generative adversarial networks[C]. Proceedings of the 34th International Conference on Machine Learning. Sydney, 2017: 214-223.
- [31] Chao W L, Changpinyo S, Gong B Q, et al. An empirical study and analysis of generalized zero-shot learning for object recognition in the wild[C]. Computer Vision — ECCV 2016. Amsterdam, 2016: 52-68.
- [32] Lampert C H, Nickisch H, Harmeling S. Attribute-based classification for zero-shot visual object categorization[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(3): 453-465.
- [33] Romera-Paredes B, Torr P. An embarrassingly simple approach to zero-shot learning[C]. International Conference on Machine Learning. Lille, 2015: 2152-2161.
- [34] Akata Z, Perronnin F, Harchaoui Z, et al. Label-embedding for image classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(7): 1425-1438.

## 作者简介

张堡霖 (2000–), 男, 硕士生, 主要研究方向为工业故障诊断、零样本学习, E-mail: [22232061@zju.edu.cn](mailto:22232061@zju.edu.cn);

赵健程 (1999–), 男, 博士生, 主要研究方向为工业故障诊断、零样本学习, E-mail: [zhaojiancheng@zju.edu.cn](mailto:zhaojiancheng@zju.edu.cn);

岳嘉祺 (2000–), 男, 博士生, 主要研究方向为工业故障诊断、零样本学习, E-mail: [12232051@zju.edu.cn](mailto:12232051@zju.edu.cn);

赵春晖 (1979–), 女, 教授, 博士, 博士生导师, 主要研究方向为工业大数据分析与应用、状态监测、故障诊断、软测量, E-mail: [chzhao@zju.edu.cn](mailto:chzhao@zju.edu.cn);

闫月君 (1989–), 女, 高级工程师, 博士, 主要研究方向为算力-能源协同优化, E-mail: [hiyuejun@163.com](mailto:hiyuejun@163.com);

陈辰 (1994–), 男, 博士生, 主要研究方向为工业故障诊断、增量学习、零样本学习, E-mail: [chenchen\\_9407@163.com](mailto:chenchen_9407@163.com).