

面向数据不均衡下机械智能故障诊断的 改进循环一致生成对抗网络^{*}

王报祥¹, 丁传仓², 居淼², 皇甫一樊², 黄伟国²

(1. 苏州科技大学机械工程学院 苏州 215009; 2. 苏州大学轨道交通学院 苏州 215131)

摘要:机械设备在复杂工况下长期运行时极易发生故障,如果不能及时准确诊断,不仅会造成性能下降和经济损失,还可能引发严重的安全事故,因此研究高效可靠的智能故障诊断方法具有重要工程价值。然而,在实际工业场景中,监测数据中故障样本数量有限,导致存在数据不均衡问题,严重制约了传统诊断模型的准确性与鲁棒性。为有效缓解上述问题,引入谱图卷积和混合注意力模块,提出了改进循环一致生成对抗网络,用于生成高质量的故障数据样本,从而提高数据不平衡下的机械故障智能诊断精度。具体地,谱图卷积通过稀疏邻接矩阵建模全局像素依赖关系,提升远程特征交互能力并降低计算复杂度;同时,混合注意力模块在通道和空间两个层面动态设置权重,突出关键区域并强化特征表达。利用提出的改进循环一致生成对抗网络,可以生成更加真实和多样的故障样本,有效扩充少数类样本,缓解数据不均衡对机械智能故障诊断性能的限制。在北京交通大学地铁列车转向架数据集和苏州大学轴承数据集上的实验结果表明,所提方法在3个图像质量评估指标和故障分类准确率方面均显著优于对比方法,验证了其在数据不均衡下的智能故障诊断性能,为工业应用中解决数据不均衡难题提供了一种切实可行的解决方案。

关键词:故障诊断;生成对抗网络;谱图卷积;混合注意力;数据不均衡

中图分类号: TH165+.3 TH133.33 **文献标识码:** A **国家标准学科分类代码:** 460.99

Improved cycle-consistent generative adversarial network for mechanical intelligent fault diagnosis under data imbalance condition

Wang Baoxiang¹, Ding Chuancang², Ju Miao², Huangfu Yifan², Huang Weiguo²

(1. School of Mechanical Engineering, Suzhou University of Science and Technology, Suzhou 215009, China;
2. School of Rail Transportation, Soochow University, Suzhou 215131, China)

Abstract: Mechanical equipment operating under complex working conditions is highly prone to failure. If such failures are not diagnosed in a timely and accurate manner, they may lead not only to performance degradation and economic losses but also to serious safety accidents. Therefore, developing efficient and reliable intelligent fault diagnosis methods is of significant engineering importance. However, in real industrial scenarios, the number of fault samples in monitoring data is usually limited, resulting in data imbalance problems that severely constrain the accuracy and robustness of traditional diagnostic models. To effectively mitigate this issue, this paper introduces spectral graph convolution and a hybrid attention module, and proposes an improved cycle-consistent generative adversarial network for generating high-quality fault samples, thereby enhancing intelligent mechanical fault diagnosis under imbalanced data conditions. Specifically, spectral graph convolution models global pixel dependencies through sparse adjacency matrices, improving long-range feature interactions while reducing computational complexity. Meanwhile, the hybrid attention module dynamically assigns weights at both channel and spatial levels to highlight critical regions and strengthen feature representation. With the proposed improved cycle-consistent generative adversarial network, more realistic and diverse fault samples can be generated, effectively augmenting minority-class data and alleviating the limitations imposed by data imbalance on intelligent fault diagnosis performance. Experimental results on the Beijing Jiaotong University metro bogie dataset and the Soochow University bearing dataset show that the proposed method

significantly outperforms comparison approaches in three image quality evaluation metrics and fault classification accuracy. These results validate its diagnostic effectiveness under imbalanced data conditions and demonstrate that it provides a practical and feasible solution for addressing data imbalance challenges in industrial applications.

Keywords: fault diagnosis; generative adversarial network; spectral graph convolution; hybrid attention; imbalanced data

0 引言

作为机械装备的关键部件,轴承、齿轮等在复杂高工况下长期运行时极易出现腐蚀、裂纹、剥落、磨损等多种类型故障。这些故障不仅会导致设备性能下降和生产效率降低,还可能引发严重的安全事故。因此,如何对机械装备核心部件进行高效、可靠的故障诊断,主动识别潜在损伤并保障系统运行安全,已成为工业界和学术界广泛关注的核心问题^[1]。

随着数据存储技术的进步和计算机处理速度的不断提升,大数据分析在工业领域得到了广泛应用。尤其是基于大数据分析的深度学习智能故障诊断方法,凭借其强大的特征识别与模式分类能力,在机械装备状态监测和健康管理中展现出巨大潜力和广阔前景^[2]。然而,工业故障诊断任务普遍面临数据类别分布不均衡的挑战,表现为在实际工况中,设备一旦出现异常通常需要立即停机检修,导致健康状态数据远多于故障状态数据。样本数量的显著失衡使得算法难以充分学习少数类特征,从而削弱模型的故障识别能力并显著降低整体预测精度^[3]。

为缓解这一问题,研究者提出了多种改进思路,主要包括数据层面与算法层面的优化。在数据层面,重采样技术(如过采样与欠采样)通过调整不同类别样本数量来缓解分布失衡,但可能引入冗余样本或丢失关键特征^[4]。在算法层面,损失函数加权方法通过对少数类样本赋予更高权重,使模型在训练过程中更加关注不均衡类别,从而改善分类性能^[5]。例如,Han 等^[6]提出自适应加权迁移网络,能够根据样本重要性动态调整权重,为无关源样本分配较小权重以避免负迁移,从而提升跨域诊断的有效性;Jia 等^[7]在卷积神经网络中引入加权 Softmax 损失函数,根据类别不平衡率重新加权小类别的损失,有效缓解了不均衡带来的精度下降问题。尽管这些方法在一定程度上改善了学习效果,但其局限性也较为突出,表现为重采样方法容易导致样本冗余或噪声引入,增加过拟合风险;而基于损失加权的方法则对权重系数高度敏感,不同任务下难以统一设定。

在此背景下,数据生成与增强逐渐成为解决不均衡问题的重要途径。其中,基于深度学习的生成对抗网络^[8]在扩展样本多样性方面展现出独特优势,能够在无监督或半监督模式下实现数据增强。生成对抗网络

(generative adversarial network, GAN)作为典型的生成模型,通过生成器与判别器的对抗训练逐步逼近真实数据分布,从而生成高质量样本,既提升了数据集的多样性和代表性,也为少数类扩增提供了新思路。然而,基础 GAN 在实践中仍面临模式崩溃、训练不稳定和收敛困难等问题。为此,学界提出了多种改进方法以增强其稳定性和生成质量。例如,Wasserstein GAN^[9]通过引入基于 Wasserstein 距离的损失度量替代传统 Jensen-Shannon 散度,并结合梯度惩罚技术改善了收敛特性,从而使训练过程更稳定且生成样本更接近真实分布,但其计算复杂度较高。辅助分类器 GAN^[10]在判别器中增加类别分类器,使生成器能够在多类别场景下生成更高质量和多样化的样本,显著提升了模型对复杂任务的适应性。变分自编码 GAN^[11]则结合了变分自编码器的潜在空间建模优势与 GAN 的对抗生成能力,在特征建模方面有所增强,但在捕捉复杂结构和多层次特征时仍存在不足。与此同时,研究者还探索了 GAN 与其他深度学习模型的结合。例如,GAN 与堆叠去噪自编码器的融合能够在生成过程中学习真实数据的深层特征,从而提升合成样本的质量与鲁棒性。Gu 等^[12]提出的局部融合 GAN (local fusion GAN, LoFGAN) 通过局部融合模块强化局部特征表达,能够生成更真实和多样化的图像,并实现语义对齐,在图像生成任务中展现出良好的应用潜力。条件 GAN^[13]则通过在输入噪声向量中引入类别或标签信息,使生成器能够产生类别特定的数据,极大提高了生成结果的可控性和实用性。为进一步缓解传统 GAN 在训练中存在的不稳定性与模式崩溃问题,深度卷积 GAN^[14]利用卷积神经网络结构构建生成器与判别器,不仅增强了特征提取能力,还能生成更高分辨率和更高质量的图像,为后续众多基于卷积的 GAN 变体奠定了基础。总体而言,GAN 及其变体在生成质量、训练稳定性、样本多样性和特征建模方面不断取得进展,为解决工业故障诊断中的数据不足和不均衡问题提供了丰富工具和新思路。

然而,上述方法属于监督学习算法,通常依赖大量成对样本,但是工业数据往往存在难以配对的问题。因此,作为一种无监督学习方法,循环一致生成对抗网络 (cycle-consistent GAN, CycleGAN)^[15]能够在无需成对数据的情况下实现跨域映射,并通过引入循环一致性损失,在保持关键信息不变的同时完成特征转换,被广泛应用于图像风格迁移和无监督训练任务。此外,特征保留 CycleGAN (feature preserving CycleGAN, FP-CycleGAN)^[16]

针对传统上采样过程中易出现的棋盘伪影问题,采用基于 U-Net 的生成器结构和 ConvNeXt 模块,并以双三次插值替代反卷积操作,从而有效提高图像重构质量,在旋转机械故障诊断中取得了积极进展。然而,CycleGAN 及其变体在全局依赖建模、上采样特征表达和计算效率方面仍存在不足。具体而言,卷积操作的局部性使其难以捕捉远距离像素之间的依赖关系,从而导致生成图像缺乏整体结构建模;虽然插值算法在一定程度上缓解了伪影问题,但其在特征提取与细节表达上仍显不足;同时,随着输入分辨率的提升,模型计算复杂度急剧增加,难以在故障诊断任务中保持效率。

针对上述问题,本文提出改进循环一致生成对抗网络 (improved cycle-consistent generative adversarial network, I-CycleGAN)。该方法引入谱图卷积,以稀疏邻接矩阵建模像素间的全局依赖关系,从而弥补传统卷积在远程特征捕捉方面的不足,同时谱图卷积中的稀疏图结构能够有效降低计算与存储开销,从而提升整体效率;此外,结合混合注意力模块,在通道和空间层面动态分配权重,以强化特征提取并突出显著区域。因此,I-CycleGAN 可以生成更加真实和多样的故障样本,并有效缓解数据不均衡对故障诊断性能的限制。基于北京交通大学地铁列车转向架数据集和苏州大学轴承数据集的实验结果表明,I-CycleGAN 在数据不均衡条件下能够显著提升生成图像质量和故障分类准确率,为机械装备智能故障诊断提供了一种切实可行的解决方案。

1 理论基础

CycleGAN 最初主要应用于图像处理领域,其核心功能是在两个不同域的图像之间实现特征迁移,在无监督的图像风格转换以及图像生成等领域有着广泛的应用。

CycleGAN 的结构由两个生成器 (G_{AB} 与 G_{BA}) 和两个判别器 (D_A 与 D_B) 组成,如图 1 所示。

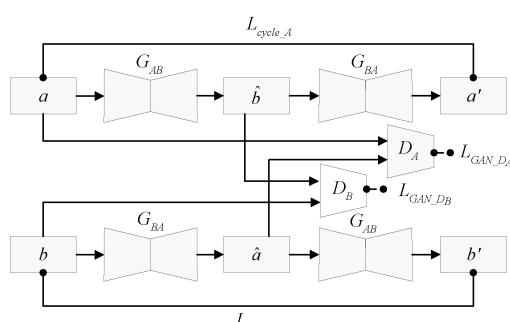


图 1 循环一致生成对抗网络结构

Fig. 1 Structure of CycleGAN

其中, G_{AB} 将 A 域的图像转换到 B 域, G_{BA} 将 B 域的图像转换到 A 域。具体地,在 CycleGAN 的前向循环中,A 域真实图像 a 经由生成器 G_{AB} 生成虚假图像 \hat{b} , 将 \hat{b} 经由生成器 G_{BA} 生成重构图像 a' ; 在后向循环中,B 域真实图像 b 经由生成器 G_{BA} 生成虚假图像 \hat{a} , 将 \hat{a} 经由生成器 G_{AB} 生成重构图像 b' 。对于虚假图像 \hat{a} , 不仅应当具备 A 域图像的风格分布,而且还需要确保 B 域图像的内容特性得以保留;对于虚假图像 \hat{b} , 不仅应当具备 B 域图像的风格分布,而且还需要确保 A 域图像的内容特性得以保留。此外,判别器 D_A 用于判断符合 A 域概率分布的图像是真实图像还是虚假图像,而判别器 D_B 则用于判断符合 B 域概率分布的图像是真实图像还是虚假图像。

CycleGAN 的损失函数由生成对抗损失 $L_{GAN_{DA}}$ 、 $L_{GAN_{DB}}$ 与循环一致损失 L_{cycle_A} 、 L_{cycle_B} 构成。在训练生成器时,判别器 D_A 与 D_B 的参数固定,只有生成器 G_{AB} 与 G_{BA} 的参数可调,生成器试图最小化损失来欺骗判别器;而训练判别器时,生成器 G_{AB} 与 G_{BA} 的参数固定,只有判别器 D_A 与 D_B 的参数可调,且此时优化目标由最小化损失转变为最大化损失。生成器与判别器的交替迭代构成了 CycleGAN 的对抗过程,使得生成器与判别器的性能在迭代更新过程中不断得到提升。

考虑到 CycleGAN 在数据生成方面的优势,将其引入数据不均衡场景下的故障诊断任务具有显著意义。具体地,CycleGAN 通过学习不同域图像之间的特征映射,能够生成丰富多样的故障样本,扩充少数类样本,有助于改善训练数据的分布平衡,提升故障分类模型的精度与鲁棒性。

2 改进循环一致生成对抗网络

针对 CycleGAN 及其变体在全局依赖建模、特征表达及计算效率方面仍存在的不足,提出改进循环一致生成对抗网络。该方法能够更有效地生成高质量图像,缓解数据不均衡问题,提升故障分类精度。

2.1 总体构架

I-CycleGAN 的框架如图 2 所示。其主要步骤为:

1) 真实图像 a 和 b 分别输入生成器 G_{AB} 和 G_{BA} ,生成虚假图像 \hat{b} 和 \hat{a} 。随后,生成的虚假图像再次输入生成器 G_{BA} 和 G_{AB} ,生成重构图像 a' 和 b' 。

2) 使用判别器 D_A 将 a 和 \hat{a} 进行比较,计算对抗损失值,同时计算真实图像 a 与重构图像 a' 的循环一致性损失;同样地,使用判别器 D_B 将 b 和 \hat{b} 进行比较,计算对抗损失值,同时计算真实图像 b 与重构图像 b' 的循环一致性损失。

3) 每一对生成的虚假图像与对应的真实图像按一定的查询概率(总和为 1)存入图像缓冲区。 a 和 \hat{a} 组成图像缓冲区,从中随机提取一张图像,命名为 \tilde{a} 。 \tilde{b} 通过相同过程生成。随后,将 \tilde{a} 和 \tilde{b} 输入判别器 D_{AB} 进行二分类,并使用交叉熵函数计算二元分类损失。

4) 将所有损失值相加,并通过梯度反馈进行网络参数更新,最终利用训练好的网络进行数据扩增。

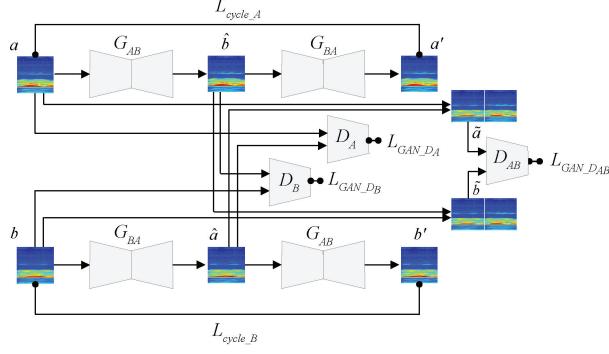


图 2 I-CycleGAN 结构

Fig. 2 Structure of I-CycleGAN

2.2 生成器架构

为了增强图像的细节表现,生成高质量图像并保持计算高效性,对于 I-CycleGAN 中的生成器,设计了一种结合谱图卷积与混合注意力机制的生成器架构,其结构如图 3 所示。该生成器在图像生成任务中能够同时捕捉图像的空间结构与关键特征,提升生成图像的真实感与细节保真度。

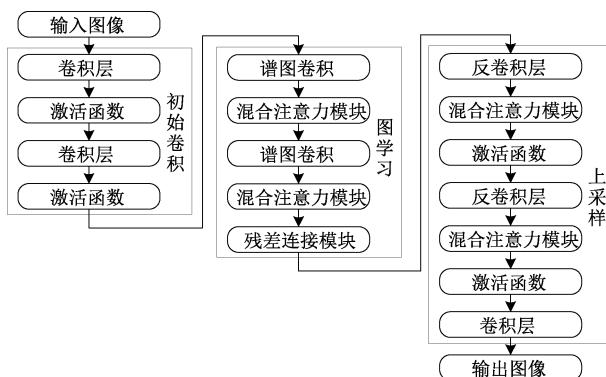


图 3 生成器架构

Fig. 3 Architecture of generator

在生成器中,首先通过卷积层对输入图像进行初步特征提取,并配合 ReLU 激活函数引入非线性增强表达能力;随后额外的卷积层进一步增加特征复杂度并加深特征表征。

在图学习阶段,谱图卷积(spectral graph convolution, SGC)与混合注意力模块(hybrid attention module, HAM)

协同作用。谱图卷积基于邻接矩阵运算,有效建模不同尺度下的全局依赖;混合注意力模块通过通道与空间加权机制突出关键信息区域,使生成器能够自适应地关注最具判别力的图像区域,从而提高细节建模及特征表示能力。经过图学习部分后,特征图进入残差连接模块,以缓解梯度消失并保持跨层信息流动。每次卷积后通过 1×1 卷积对齐输入与输出维度,确保残差连接的有效性与稳定性。

在上采样阶段,生成器采用逐级反卷积层恢复图像分辨率。每一阶段结合混合注意力模块强化关键区域特征,从而在上采样过程中兼顾全局结构与细节表现。最终,生成图像通过激活函数输出,得到高分辨率且细节丰富的重建结果。此外,在生成器的每一层中,引入层归一化以提高训练稳定性与泛化能力;同时,采用 Dropout 防止过拟合并提升鲁棒性。

凭借这一架构设计,构建的生成器能够在多尺度特征提取与细节重建之间取得良好平衡,最终实现高质量图像生成。

1) 谱图卷积

谱图卷积作为图信号处理的重要方法,能够利用图的拓扑结构有效增强模型的特征表达能力。图通常蕴含关键的拓扑信息,因此在 I-CycleGAN 的生成器中引入谱图卷积以充分聚合图中的内在特征。

图 4 展示了谱图卷积的结构细节,主要流程为:输入特征首先经过 K 近邻构建邻接矩阵,并通过权重计算与稀疏化存储得到高效表示;随后进行图卷积运算,结合残差连接、层归一化与 Dropout 等机制,在保持数值稳定性的同时提升特征建模及表示能力;最后通过 ReLU 激活输出增强后的特征表示。接下来,详细描述谱图卷积中的关键环节。

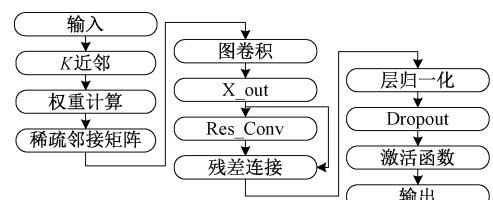


图 4 谱图卷积

Fig. 4 Spectral graph convolution

在图神经网络中,邻接矩阵是描述节点间关系的核心要素。采用 K 近邻算法构造邻接矩阵,其中对图像中每个像素节点 v_i ,选取距离最近的 K 个节点作为其邻居,从而建立连接边。邻接矩阵 A 的元素 A_{ij} 表示节点 v_i 与节点 v_j 之间是否存在连接及其强度,连接强度则依据节点之间的相似性来确定,本研究通过欧几里得距离度量节点间的连接强度。元素 A_{ij} 随距离增大而衰减,以突出局部相似性。

此外,为节省存储与计算开销,邻接矩阵采用稀疏表示,仅保存相邻节点的索引及其权重。该方式既保留了节点间的拓扑关系与相似性,又避免了稠密矩阵中大量零值的冗余存储。

在邻接矩阵构建完成后,对其进行归一化操作,主要通过计算图拉普拉斯矩阵 \mathbf{L} 实现,计算公式为:

$$\mathbf{L} = \mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \quad (1)$$

式中: \mathbf{D} 为度矩阵; \mathbf{A} 为邻接矩阵; $\mathbf{D}^{-\frac{1}{2}}$ 表示度矩阵的逆平方根。该归一化过程确保了图卷积操作的数值稳定性,并使得图信号在不同拓扑结构下保持一致性,从而提高了卷积计算的效率。

在得到归一化后的图拉普拉斯矩阵 \mathbf{L} 后,进一步进行图卷积操作。图卷积的基本思想是通过矩阵乘法,将每个节点的特征与其邻居节点的特征加权结合,从而更新节点特征。图卷积计算公式为:

$$\mathbf{X}_{\text{out}} = \mathbf{L} \mathbf{X}_{\text{in}} \quad (2)$$

式中: \mathbf{X}_{in} 是输入特征; \mathbf{X}_{out} 是卷积后的输出特征,表示每个节点的新特征。这样每个节点的表示不仅由自身决定,还能综合邻居节点的特征进行更新。

为避免信息丢失并保持梯度流动,谱图卷积中引入残差连接,即:

$$\mathbf{X}'_{\text{out}} = \mathbf{X}_{\text{out}} + \text{Res_Conv}(\mathbf{X}_{\text{in}}) \quad (3)$$

式中: $\text{Res_Conv}(\mathbf{X}_{\text{in}})$ 表示通过 1×1 卷积处理后的输入特征,确保输入与输出在维度上匹配。

在卷积之后,依次采用层归一化与 Dropout 操作,以提高训练稳定性并抑制过拟合,即:

$$\hat{\mathbf{X}} = \frac{\mathbf{X}'_{\text{out}} - \mu}{\sigma + \varepsilon} \quad (4)$$

$$\mathbf{X}_{\text{drop}} = \hat{\mathbf{X}} \cdot \text{Bernoulli}(1 - p) \quad (5)$$

式中: μ 和 σ 分别为均值与标准差; ε 为防止除 0 的常数; p 表示丢弃率。

最后,通过 ReLU 激活函数引入非线性,提升捕捉非线性复杂特征的建模能力。

$$\mathbf{X}_{\text{ReLU}} = \max(0, \mathbf{X}_{\text{drop}}) \quad (6)$$

综合上述设计,谱图卷积能够通过图卷积、残差连接、归一化、Dropout 与 ReLU 激活高效聚合图的拓扑与特征信息。同时,谱图卷积采用动态邻接构建避免了谱分解带来的高计算开销,稀疏矩阵存储进一步提升了效率与可扩展性,从而在保证稳定性与效率的同时,显著增强了模型的特征表达能力。具体来讲,相较于传统图卷积方法,谱图卷积的计算复杂度从 $O(n^2)$ 降低到 $O(|E|)$,其中 $|E|$ 是图中边的数量。对于稀疏图而言,存在 $|E| \ll n^2$,从而大幅减轻计算负担;同时,谱图卷积避免了对拉普拉斯算子进行特征分解,有效规避了特征分解

在大型图结构中存在的高时间与空间开销,使得模型能够更好地适应大规模图数据。

2) 混合注意力模块

为进一步增强特征表示能力,在 I-CycleGAN 的生成器中引入混合注意力模块,其核心思想是在通道维度和空间维度同时建模注意力分布,以更充分地捕捉输入特征图中的判别性信息。该模块能够在不同层面突出关键特征,既强化通道间的全局相关性,又提升空间维度的区域感知能力,从而为后续故障特征建模提供更强的支撑。

混合注意力模块的整体结构如图 5 所示。具体而言,输入特征图 $\mathbf{X} \in \mathbb{R}^{H \times W \times C}$ 首先通过通道注意力模块,生成能够反映不同通道对任务贡献度的通道注意力权重图 $\mathbf{C}_f \in \mathbb{R}^{1 \times 1 \times C}$;随后,再经过空间注意力模块,提取与目标区域高度相关的信息,生成空间注意力权重图 $\mathbf{S}_f \in \mathbb{R}^{H \times W \times 1}$ 。最终,二者结合得到增强后的特征表示 $\mathbf{X}' \in \mathbb{R}^{H \times W \times C}$ 。接下来,详细描述混合注意力模块中的关键环节。

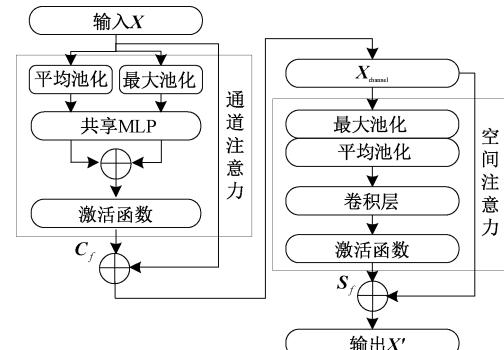


图 5 混合注意力模块

Fig. 5 Hybrid attention module

通道注意力的目标在于衡量不同通道对整体任务的重要性。具体而言,输入特征图 $\mathbf{X} \in \mathbb{R}^{H \times W \times C}$ 分别经过全局平均池化与全局最大池化,得到两个通道描述特征 $\mathbf{M}_{c_{\text{ave}}} \in \mathbb{R}^{1 \times 1 \times C}$ 与 $\mathbf{M}_{c_{\text{max}}} \in \mathbb{R}^{1 \times 1 \times C}$ 。二者输入共享的多层感知器(multilayer perceptron, MLP),经加和后通过 Sigmoid 激活函数生成通道注意力权重图 \mathbf{C}_f ,即:

$$\mathbf{C}_f = \sigma(\mathbf{W}_1 \mathbf{W}_0(\mathbf{M}_{c_{\text{ave}}}(\mathbf{X})) + \mathbf{W}_1 \mathbf{W}_0(\mathbf{M}_{c_{\text{max}}}(\mathbf{X}))) \quad (7)$$

式中: $\sigma(\cdot)$ 为 Sigmoid 激活函数; $\mathbf{W}_0 \in \mathbb{R}^{C \times C/r}$ 和 $\mathbf{W}_1 \in \mathbb{R}^{C/r \times C}$ 是 MLP 中的权重矩阵; r 是压缩比。通道注意力机制能够自适应地突出对任务贡献更显著的通道特征。

空间注意力旨在捕捉输入特征中与目标相关的关键区域,抑制冗余或噪声特征。首先,对通道加权后的特征图 $\mathbf{X}_{\text{channel}} = \mathbf{X} \times \mathbf{C}_f$ 进行全局平均池化和全局最大池化,得到两个空间描述特征: $\mathbf{M}_{s_{\text{ave}}} \in \mathbb{R}^{H \times W \times 1}$ 和 $\mathbf{M}_{s_{\text{max}}} \in \mathbb{R}^{H \times W \times 1}$,随后将二者拼接形成综合特征 $\mathbf{M}_{s_{\text{merge}}}(\mathbf{X}) = [\mathbf{M}_{s_{\text{ave}}}(\mathbf{X}), \mathbf{M}_{s_{\text{max}}}(\mathbf{X})]$,再经卷积操作及 Sigmoid 激活函数处理后获

得空间注意力权重图 S_f 。空间注意力的计算公式表示为:

$$S_f = \sigma(\text{Conv2d}([\mathbf{M}_{s_{\text{ave}}}(X), \mathbf{M}_{s_{\text{max}}}(X)])) \quad (8)$$

最终,输入特征图在通道与空间注意力的共同作用下完成加权融合,得到增强后的特征表示 X' ,即:

$$X' = X \times \mathbf{C}_f \times S_f \quad (9)$$

通过这种级联式融合,通道注意力能够识别不同特征维度的相对贡献,而空间注意力则引导网络聚焦于关键区域。二者协同作用,使特征表示兼具全局判别性与局部敏感性,从而显著提升模型在故障诊断中的特征建模及表示能力。

2.3 目标函数设计

为提升生成图像的真实性与多样性,在 I-CycleGAN 的目标函数设计中引入多重约束,包括对抗损失、循环一致性损失以及分类损失。综合上述损失,I-CycleGAN 的总体优化目标函数为:

$$L_{\text{total}} = L_{\text{GAN}} + L_{\text{cycle}} + L_{\text{class}} \quad (10)$$

式中: L_{GAN} 为对抗损失; L_{cycle} 为循环一致性损失; L_{class} 为分类损失。

接下来将分别对各个损失函数进行详细说明。

1) 对抗损失

对抗损失是对抗性学习的核心,旨在实现不同域之间的图像分布映射。由于 I-CycleGAN 包含两个生成器和两个判别器,其对抗损失可表示为:

$$\begin{aligned} L_{\text{GAN}} &= L_{\text{GAN}_{D_A}} + L_{\text{GAN}_{D_B}} = \\ &E_{a \sim P_{\text{data}}(a)} [\log D_A(a)] + E_{b \sim P_{\text{data}}(b)} [\log (1 - D_A(G_{BA}(b)))] + \\ &E_{b \sim P_{\text{data}}(b)} [\log D_B(b)] + E_{a \sim P_{\text{data}}(a)} [\log (1 - D_B(G_{AB}(a)))] \end{aligned} \quad (11)$$

式中: G_{AB} 表示从域 A 映射到域 B 的生成器, G_{BA} 与之对称。生成器的目标是最小化对抗损失,使生成的虚假图像尽可能接近真实图像分布;判别器的目标则是最大化对抗损失,以保持区分真实与虚假图像的能力。

2) 循环一致性损失

为保证跨域映射的稳定性与可逆性,引入循环一致性损失:

$$\begin{aligned} L_{\text{cycle}} &= L_{\text{cycle}_{-A}} + L_{\text{cycle}_{-B}} = \\ &E_{a \sim P_{\text{data}}(a)} [\| G_{BA}(G_{AB}(a)) - a \|_1] + \\ &E_{b \sim P_{\text{data}}(b)} [\| G_{AB}(G_{BA}(b)) - b \|_1] \end{aligned} \quad (12)$$

式中: $\| \cdot \|_1$ 表示 l_1 范数。通过该约束,模型能够在域间映射的同时保持真实图像与重构图像的一致性,从而提升生成结果的稳定性。

3) 分类损失

在判别器 D_{AB} 中,引入交叉熵损失对图像 \hat{a} 与图像 \tilde{b} 进行二元分类,分类损失 L_{class} 表达式为:

$$\begin{aligned} L_{\text{class}} &= E_{\hat{a} \sim P_{\text{data}}(\hat{a})} [\log D_{AB}(\hat{a})] + \\ &E_{b \sim P_{\text{data}}(b)} [\log (1 - D_{AB}(G_{BA}(b)))] + \\ &E_{\tilde{b} \sim P_{\text{data}}(\tilde{b})} [\log D_{AB}(\tilde{b})] + \\ &E_{\hat{a} \sim P_{\text{data}}(\hat{a})} [\log (1 - D_{AB}(G_{AB}(\hat{a})))] \end{aligned} \quad (13)$$

式中: $P_{\text{data}}(\hat{a})$ 是真实图像 a 和虚假图像 \hat{a} 之间的联合分布; $P_{\text{data}}(\tilde{b})$ 是真实图像 b 和虚假图像 \tilde{b} 之间的联合分布,定义为:

$$P_{\text{data}}(\hat{a}) = \mu P_{\text{data}}(a) + (1 - \mu) P_{\text{data}}[G_{BA}(b)] \quad (14)$$

$$P_{\text{data}}(\tilde{b}) = \mu P_{\text{data}}(b) + (1 - \mu) P_{\text{data}}[G_{AB}(a)] \quad (15)$$

式中: μ 是新联合分布中真实图像与虚假图像的比例。

3 实验验证

3.1 数据集描述

为全面验证所提出方法 I-CycleGAN 在数据不均衡条件下智能故障诊断中的有效性与鲁棒性,选取了两个典型实验数据集进行分析与对比。第 1 个为北京交通大学—轨道自主运行 (Beijing Jiaotong University-rail autonomous operations, BJTU-RAO) 转向架数据集,来源于北京交通大学地铁列车转向架传动系统实验平台^[17],能够真实反映轨道交通装备在不同工况下的典型故障特征;第 2 个为苏州大学滚动轴承数据集,基于标准化试验台获取^[18],涵盖多种故障模式与损伤程度,为模型验证提供实验支撑。

数据集 1: BJTU-RAO 转向架数据集。北京交通大学地铁列车转向架传动系统故障模拟实验台由电机、斜齿轮减速箱、加速度传感器、声音传感器、轴箱以及转速传感器等主要部件构成,其整体布局如图 6 所示。

输入轴的转速通过转速传感器进行实时测量,减速齿轮箱采用斜齿轮传动形式,其中驱动齿轮齿数为 16;从动齿轮齿数为 107;驱动齿轮的支撑轴承型号为 HRB 32305;轴箱轴承型号为 HRB 352213。数据集中包含健康状态和多类典型轴箱轴承故障状态,包括外圈加滚动体故障、单一滚动体故障和外圈故障,分别在 3 种不同转速下(1 500、2 000 和 3 000 rpm)进行采集。实验中,通过调整工况实现多种运行状态下的信号采集,保证数据的多样性和代表性。数据集 1 的详细信息如表 1 所示。

数据集 2: 苏州大学滚动轴承数据集。数据集从苏州大学滚动轴承试验台采集得到(如图 7 所示)。

该试验台由团队自主搭建,主要由驱动电机、联轴器、被测轴承、减速器和加速度传感器组成,其中被测轴承型号为 NJ204ETNSK。实验过程中,通过调节螺母来控制加载状态,并使用负载计对实际承载进行测量。在本文实验条件下,设置载荷为 2.4 kN,转速为 1 200 rpm。

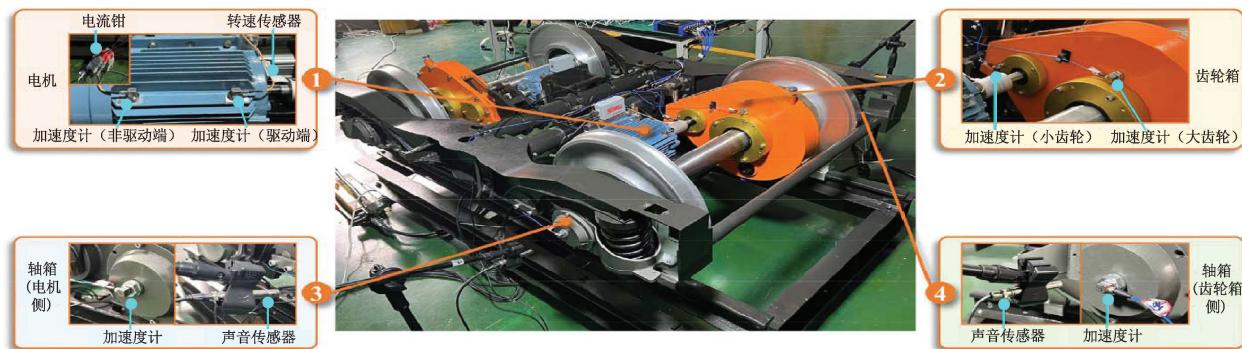


图 6 BJTU-RAO 转向架实验台

Fig. 6 BJTU-RAO bogie test bench

表 1 BJTU-RAO 数据集

Table 1 BJTU-RAO dataset (rpm)

健康状态类型	转速
外圈加滚动体故障	1 500
外圈故障	1 500
滚动体故障	1 500
外圈加滚动体故障	2 000
外圈故障	2 000
滚动体故障	2 000
外圈加滚动体故障	3 000
外圈故障	3 000
滚动体故障	3 000

表 2 苏州大学轴承数据集

Table 2 Soochow University bearing dataset (mm)

健康状态类型	故障尺寸
内圈加滚子故障	0.2
内圈加外圈故障	0.2
内圈故障	0.2
外圈故障	0.2
滚子故障	0.2
内圈故障	0.4
外圈故障	0.4

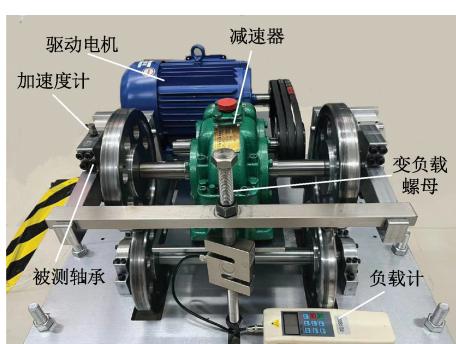


图 7 苏州大学滚动轴承实验台

Fig. 7 Rolling bearing test bench of Soochow University

为了全面覆盖不同的故障模式,实验中设计并采集了 7 类损伤状态:0.2 mm 内圈故障、0.2 mm 滚子故障、0.2 mm 外圈故障、0.2 mm 内圈与滚子复合故障、0.2 mm 内圈与外圈复合故障、0.4 mm 内圈故障、0.4 mm 外圈故障。数据集 2 的详细信息如表 2 所示。

由于 I-CycleGAN 模型需要以图像形式作为输入,因此采集的时域振动信号先经过连续小波变换转化为二

维时频图,再进一步转换为固定尺寸的三通道 RGB 图像。该转换过程在 MATLAB 环境下实现,RGB 图像被存储并用于后续的特征提取与故障分类实验。

特别需要强调的是,测试集仅包含真实采集的样本,且与训练集在原始时域数据上完全不重叠,不包含任何生成数据,避免潜在的信息泄漏问题。这一设计保证了实验结果的客观性和公平性,使得模型的评估更具科学性和可信度。

3.2 图像生成性能评估

为全面验证 I-CycleGAN 在数据不均衡条件下的图像生成能力,本节基于 3.1 节所述数据集开展实验,并与多种主流生成对抗网络进行对比,包括 FP-CycleGAN、CycleGAN、DualGAN^[19]、DiscoGAN^[20] 和 LoFGAN。通过对比分析,验证所提方法在不同实验场景下的优势与适用性。

为实现客观的量化评估,本文选取 3 项常用指标对生成结果进行评价:FID (Fréchet inception distance)、LPIPS (learned perceptual image patch similarity) 和 SSIM (structural similarity index measure)^[21],对生成图像的质量进行定量评估,从而全面验证提出方法的优越性。FID、SSIM、LPIPS 能够用于衡量生成图像与真实图像之

间的相似性。总体而言, FID 与 LPIPS 值越小、SSIM 值越大, 均表明生成图像与真实图像的相似性越高, 图像质量越优。

实验中, I-CycleGAN 的主要参数设置为: 训练轮数为 300, 学习率固定为 0.000 1, 优化器为 Adam, 其动量参数

设为 0.5, 判别器训练图像缓冲比例设定为 $\mu = 0.9$ 。实验硬件平台包括 E5-2690v3 CPU、96 GB 内存以及 NVIDIA GeForce 2080Ti GPU。

表 3 给出了提出方法与对比方法在数据集 1 和数据集 2 上的量化评估结果。

表 3 6 种方法的定量评估指标计算结果

Table 3 Quantitative evaluation metrics calculation of six methods

方法	FID		LPIPS		SSIM	
	数据集 1	数据集 2	数据集 1	数据集 2	数据集 1	数据集 2
I-CycleGAN	33.158(±1.430)	68.195(±0.520)	0.229(±0.013)	0.167(±0.019)	0.793(±0.012)	0.890(±0.014)
FP-CycleGAN ^[16]	115.403(±3.450)	108.295(±2.230)	0.283(±0.029)	0.188(±0.017)	0.792(±0.011)	0.884(±0.019)
CycleGAN ^[15]	156.543(±4.210)	141.380(±3.630)	0.331(±0.069)	0.286(±0.028)	0.764(±0.043)	0.781(±0.057)
DualGAN ^[19]	132.321(±2.510)	105.877(±2.230)	0.301(±0.054)	0.269(±0.036)	0.781(±0.063)	0.795(±0.093)
DiscoGAN ^[20]	141.380(±6.780)	120.343(±2.670)	0.286(±0.093)	0.299(±0.033)	0.781(±0.095)	0.771(±0.102)
LoFGAN ^[12]	150.982(±4.190)	115.686(±2.100)	0.321(±0.057)	0.285(±0.028)	0.772(±0.053)	0.779(±0.061)

从表 3 中可以清晰看出, 提出方法 I-CycleGAN 在 3 项指标(FID、SSIM、LPIPS)上均取得最优表现。具体而言, 在 FID 指标上, I-CycleGAN 在数据集 1 和 2 中分别为 33.158 和 68.195, 远低于其他方法, 表明 I-CycleGAN 生成图像的分布与真实数据更加接近, 具有更高的真实性。在 LPIPS 指标上, I-CycleGAN 分别达到 0.229 与 0.167, 相比其他方法优势显著, 说明其生成结果在感知相似性上更贴近真实样本, 质量更高。与此同时, 在 SSIM 指标上, I-CycleGAN 在数据集 1 和 2 中分别为 0.793 与 0.890, 均高于对比方法, 说明其能够更好地保持图像结构信息与细节特征。

总体来说, 对比方法 FP-CycleGAN 在 SSIM 指标上表现相对接近提出方法 I-CycleGAN, 但在 FID 和 LPIPS 上仍存在较大差距。对比方法 CycleGAN、DualGAN、DiscoGAN 和 LoFGAN 则在 3 项指标上均显著落后于 I-CycleGAN, 尤其是在 FID 与 LPIPS 指标上, 差距最为明

显, 进一步凸显了提出方法在生成真实性和多样性上的优势。

综上所述, I-CycleGAN 在两个数据集和 3 个评价指标下均展现出稳定的性能优势, 能够生成更接近真实分布且结构细节更清晰的图像, 为数据不平衡下的故障诊断任务提供了更高质量的数据支撑。

3.3 消融实验分析

为了进一步探究谱图卷积与混合注意力模块对模型性能的贡献, 本文进行了消融实验, 分别构建了两种变体模型: 一种为仅保留谱图卷积而移除混合注意力模块的 I-CycleGAN-w/o H; 另一种为仅使用混合注意力模块而移除谱图卷积层的 I-CycleGAN-w/o S。

表 4 展示了 I-CycleGAN 及其两种变体在数据集 1 和 2 下的量化评估结果, 可以明显看出完整的 I-CycleGAN 在所有指标上均优于两种变体, 验证了谱图卷积与混合注意力模块在模型中的重要性。

表 4 消融实验中的定量度量计算

Table 4 Quantitative metric calculation in ablation experiment

方法	FID		LPIPS		SSIM	
	数据集 1	数据集 2	数据集 1	数据集 2	数据集 1	数据集 2
I-CycleGAN	33.158(±1.430)	68.195(±0.520)	0.229(±0.013)	0.167(±0.019)	0.793(±0.012)	0.890(±0.014)
I-CycleGAN-w/o H	40.811(±2.310)	87.275(±5.210)	0.235(±0.017)	0.172(±0.015)	0.789(±0.011)	0.874(±0.012)
I-CycleGAN-w/o S	46.555(±3.190)	80.513(±4.690)	0.243(±0.023)	0.176(±0.018)	0.762(±0.009)	0.782(±0.023)

具体而言, 在 FID 指标上, I-CycleGAN 分别取得 33.158(数据集 1)与 68.195(数据集 2), 显著低于 I-CycleGAN-w/o H 和 I-CycleGAN-w/o S, 说明当去除任

一模块后, 生成的虚假图像与真实图像分布的接近程度均有所下降。在 LPIPS 指标上, I-CycleGAN 分别达到 0.229 与 0.167, 表现最佳; 而两种变体的 LPIPS 值均有

所上升,特别是 I-CycleGAN-w/o S 在数据集 1 中升至 0.243。在 SSIM 指标上,I-CycleGAN 同样取得最优结果,相比之下,去除混合注意力模块的 I-CycleGAN-w/o H 略有下降,而去除谱图卷积的 I-CycleGAN-w/o S 降幅更大。

这些结果充分表明,两种模块在生成图像质量和结构保持方面均发挥了关键作用。谱图卷积能够捕捉并聚合图像中潜在的全局拓扑关系,增强特征的全局捕捉能力;混合注意力模块通过通道与空间特征的联合建模,使模型能够更有效地关注不同通道和区域的关键信息。缺少任一模块都会削弱模型的整体表现,而二者协同作用时,I-CycleGAN 在生成图像的真实性上显著优于其变体。

3.4 数据不平衡下故障诊断性能验证

为进一步验证 I-CycleGAN 在数据不均衡条件下故障诊断中的有效性,本文设计了 6 个逐步递增生成样本数量的诊断任务,以评估生成样本在改善诊断性能方面的作用。表 5 给出了 6 个任务的具体设置。训练集由真实样本与生成样本共同构成,用于训练故障状态识别分类器。在每个任务中,均包含 42 个健康样本和 6 个真实故障样本,故障类别的生成样本在任务 1~6 中分别为 6、12、18、24、30 和 36 个。这种任务设置能够有效模拟不同程度的数据不均衡场景。

表 5 数据不平衡下的 6 个故障诊断任务

Table 5 Six fault diagnosis tasks under data imbalance

任务	训练集		测试集
	每种故障类型的生成/实际样本数	健康类型样本数量	
任务 1	6/6	42	30
任务 2	12/6	42	30
任务 3	18/6	42	30
任务 4	24/6	42	30
任务 5	30/6	42	30
任务 6	36/6	42	30

具体地,在任务 1 中,生成样本数量有限,数据分布仍然存在明显偏差;而随着生成样本数量逐步增加,数据集逐渐趋于平衡。通过对比 6 个任务的实验结果,可以系统性地分析生成样本数量对故障诊断性能的影响,进而验证提出方法 I-CycleGAN 在生成高质量样本和缓解类别不均衡方面的作用。特别是在任务 5 和 6 中,生成样本数量已与真实样本规模相当,能够全面检验 I-CycleGAN 在大规模样本扩充条件下对分类器训练的支撑能力与稳定性。测试集则由每种类别下 30 个真实样本组成,且与训练集无重叠,以保证评估的公平性与科学性。

为验证所提方法的性能优势,本文选取 FP-CycleGAN、CycleGAN、DualGAN、DiscoGAN 和 LoFGAN 这 5 种方法作为对比基准,并在数据集 1 和 2 的 6 个任务中分别进行诊断准确度的对比实验。图 8 和 9 展示了不同方法在 6 个任务下的诊断准确率。在所有任务中,I-CycleGAN 的诊断准确率始终高于对比方法。这表明 I-CycleGAN 在有限样本条件下更能生成与真实样本在特征层面高度一致的高质量样本,从而显著提升故障分类模型的判别能力。同时,在数据集 1 和数据集 2 中,I-CycleGAN 均表现出优于对比方法的稳定优势,说明所提方法不仅在单一数据集上有效,而且具有良好的跨数据集适应性。

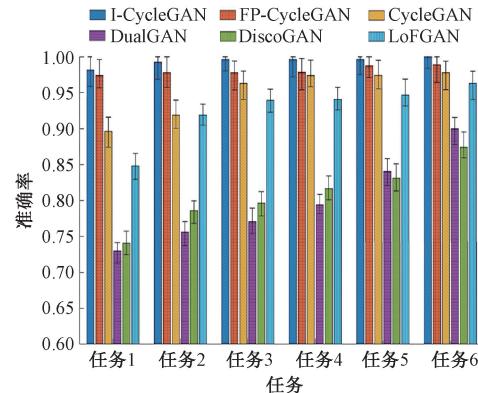


图 8 不同方法在数据集 1 中 6 个任务的诊断准确率

Fig. 8 Diagnosis accuracies of different methods for six tasks of case 1

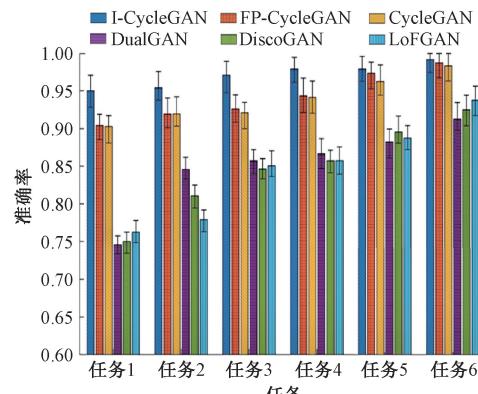


图 9 不同方法在数据集 2 中 6 个任务的诊断准确率

Fig. 9 Diagnosis accuracies of different methods for six tasks of case 2

此外,在任务 1 中,所有方法的诊断准确率均明显偏低,反映了数据不均衡对分类性能的负面影响。随着生成样本数量逐步增加,准确率整体呈上升趋势,验证了生成样本在改善数据不均衡和提升诊断精度方面的关键作用。

综上所述,实验结果充分证明了 I-CycleGAN 在故障诊断中的优势,其生成的高保真样本与真实样本在特征层面高度一致,为分类模型提供了更加平衡且具有代表性的训练数据,是应对工业应用中数据不均衡问题的切实可行的解决方案。

4 结 论

针对机械装备在复杂工况下普遍存在的数据不均衡问题,本研究提出了改进循环一致生成对抗网络(I-CycleGAN),通过引入谱图卷积层与混合注意力模块,显著提升了生成图像的整体质量。具体而言,谱图卷积基于稀疏邻接矩阵建模全局像素依赖,有效弥补了传统卷积在远程特征捕捉方面的不足,同时稀疏图结构降低了计算复杂度与存储需求;混合注意力模块在通道与空间层面动态设置权重,突出关键区域并增强特征表达。基于地铁列车转向架与苏州大学轴承数据集的实验结果表明,I-CycleGAN 在图像生成质量(FID、SSIM、LPIPS 等)和故障分类准确率方面均显著优于 5 种对比方法,有效缓解了数据不均衡对诊断性能的限制。综上所述,I-CycleGAN 在生成样本的真实性、多样性和诊断精度方面展现出突出优势,为工业领域应对数据不均衡问题提供了具有推广价值的技术路径。

参考文献

- [1] 楚晓艳, 刘星, 苗强. 多域对抗迁移的轨道列车转向架故障诊断方法[J]. 仪器仪表学报, 2025, 46(6): 263-275.
- CHU X Y, LIU X, MIAO Q. A multi-domain adversarial transfer method for fault diagnosis of railway bogies[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 263-275.
- [2] 石明宽, 丁传仓, 王锐, 等. 面向变工况下工业流数据故障诊断的持续迁移学习系统[J]. 仪器仪表学报, 2024, 45(4): 10-16.
- SHI M K, DING CH C, WANG R, et al. Continuous transfer learning system for fault diagnosis of industrial stream data under variable operating conditions [J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 10-16.
- [3] 王玉静, 叶柏宏, 康守强, 等. 多源不平衡数据下基于联邦学习的谐波减速器故障诊断方法[J]. 仪器仪表学报, 2025, 46(6): 317-329.
- WANG Y J, YE B H, KANG SH Q, et al. Fault diagnosis method for harmonic reducers based on federated learning with multi-source imbalanced data[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 317-329.
- [4] REN ZH J, LIN T J, FENG K, et al. A systematic review on imbalanced learning methods in intelligent fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3246470.
- [5] ZHANG W, LI X, MA H, et al. Universal domain adaptation in fault diagnostics with hybrid weighted deep adversarial learning[J]. IEEE Transactions on Industrial Informatics, 2021, 17(12): 7957-7967.
- [6] HAN T ZH, WANG J X, PENG CH, et al. Novel adaptive loss weighted transfer network for partial domain fault diagnosis[J]. ISA Transactions, 2024, 145: 362-372.
- [7] JIA F, LEI Y G, LU N, et al. Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization[J]. Mechanical Systems and Signal Processing, 2018, 110: 349-367.
- [8] WANG X, JIANG H K, MU M ZH, et al. A trackable multi-domain collaborative generative adversarial network for rotating machinery fault diagnosis [J]. Mechanical Systems and Signal Processing, 2025, 224: 111950.
- [9] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks[J]. JMLR, 2017: 214-223.
- [10] LI W, ZHONG X, SHAO H D, et al. Multi-mode data augmentation and fault diagnosis of rotating machinery using modified ACGAN designed with new framework[J]. Advanced Engineering Informatics, 2022, 52: 101552.
- [11] AKKEM Y, BISWAS S K, VARANASI A. A comprehensive review of synthetic data generation in smart farming by using variational autoencoder and generative adversarial network [J]. Engineering Applications of Artificial Intelligence, 2024, 131: 107881.
- [12] GU ZH, LI W B, HUO J, et al. LoFGAN: Fusing local representations for few-shot image generation[C]. 2021 IEEE/CVF International Conference on Computer Vision, 2021: 8443-8451.
- [13] ZHANG S Y, WIJESINGHE A, DING ZH. RME-GAN: A learning framework for radio map estimation based on

- conditional generative adversarial network [J]. IEEE Internet of Things Journal, 2023, 10 (20): 18016-18027.
- [14] ZHOU K, DIEHL E J, TANG J. Deep convolutional generative adversarial network with semi-supervised learning enabled physics elucidation for extended gear fault diagnosis under data limitations [J]. Mechanical Systems and Signal Processing, 2023, 185: 109772.
- [15] LIAO W J, WU L K, XU SH H, et al. A novel approach for intelligent fault diagnosis in bearing with imbalanced data based on cycle-consistent GAN [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 3427886.
- [16] GUO L, CHUAH J H, RAYMOND W J K, et al. Unsupervised feature-preserving CycleGAN for fault diagnosis of rolling bearings using unbalanced infrared thermal imaging sample [J]. IEEE Access, 2024, 12: 28449-28461.
- [17] QIN Y, WANG Y R, LI ZH J, et al. An in-depth tutorial on BJTU-RAO bogie datasets for fault diagnosis [J]. IEEE Access, 2025, 13: 60879-60888.
- [18] JU M, DING CH C, HUANG W G, et al. Local fusion generative adversarial network with dual-discriminator and parallel multipath and its application in machinery fault diagnosis with imbalanced data [J]. Measurement Science and Technology, 2024, 35(11): 1-16.
- [19] YI Z L, ZHANG H, TAN P, et al. DualGAN: Unsupervised dual learning for image-to-image translation [C]. 2017 IEEE International Conference on Computer Vision, 2017: 2868-2876.
- [20] KIM T, CHA M, KIA H, et al. Learning to discover cross-domain relations with generative adversarial networks [C]. 34th International Conference on Machine Learning, 2018: 2941-2949.
- [21] MENG Z, HE H H, CAO W, et al. A novel generation network using feature fusion and guided adversarial learning for fault diagnosis of rotating machinery [J]. Expert Systems with Applications, 2023, 234: 121058.

作者简介



王报祥,2016年于山东农业大学获得学士学位,2023年于西安交通大学获得博士学位,现为苏州科技大学讲师,主要研究方向为机械信号分析与设备故障诊断。
E-mail: wangbaoxiang@usts.edu.cn

Wang Baoxiang received her B. Sc. degree from Shandong Agricultural University in 2016, her Ph. D. degree from Xi'an Jiaotong University in 2023. She is currently a lecture at Suzhou University of Science and Technology. Her main research interests include mechanical signal analysis and machine fault diagnosis.



丁传仓(通信作者),2016年于山东大学获得学士学位,2021年于西安交通大学获得博士学位,现为苏州大学副教授,主要研究方向为机械信号分析与设备状态监测。
E-mail: ccding@suda.edu.cn

Ding Chuancang (Corresponding author) received his B. Sc. degree from Shandong University in 2016, his Ph. D. degree from Xi'an Jiaotong University in 2021. He is currently an associate professor at Soochow University. His main research interests include mechanical signal analysis and machine condition monitoring.