

DOI: 10.19650/j.cnki.cjsi.J2413301

基于一致损失生成对抗网络的冷水机组故障诊断*

高学金¹, 吴浩宁¹, 高慧慧¹, 齐咏生²

(1. 北京工业大学信息科学技术学院 北京 100124; 2. 内蒙古工业大学电力学院 呼和浩特 010051)

摘要:冷水机组是供暖通风与空气调节系统的重要组成部分,当冷水机组发生故障时将造成能源浪费甚至安全事故。因此,针对冷水机组的故障诊断对于暖通与空气调节等系统至关重要。基于数据驱动的故障诊断方法依赖大量历史数据,但带标签的故障数据往往难以收集,导致模型的诊断准确率下降。为此,提出了一种基于一致损失生成对抗网络(CLGAN)的故障诊断方法。首先,利用少量带标签样本和大量无标签样本训练 CLGAN,并生成故障数据;然后,利用生成数据与历史数据构建一个包含各类故障的平衡数据集;最后,利用该数据集训练故障分类器并对冷水机组进行实时诊断。CLGAN 通过在判别器中引入一致性损失函数,能够有效利用无标签数据辅助模型训练,提升了数据利用率。同时,CLGAN 迫使生成器在多个尺度上满足判别器的要求,这种多维度的反馈机制使得模型在面对扰动时,依然能生成高质量的样本,进而提高故障诊断的准确性和鲁棒性。基于 ASHRAE 和 HY-31C 数据集的实验结果表明,在各类别仅有 5 个带标签样本的情况下,CLGAN 分别获得了 92.8% 和 95.9% 的故障诊断准确率,展现了良好的故障诊断性能。此外,在噪声和跨工况实验中,CLGAN 相比于其他对比方法也展现出了良好的鲁棒性和泛化性。

关键词: 故障诊断;生成对抗网络;冷水机组;一致损失函数;无标签数据

中图分类号: TH17 **文献标识码:** A **国家标准学科分类代码:** 510.80

Fault diagnosis of chillers based on consistency loss generative adversarial network

Gao Xuejin¹, Wu Haoning¹, Gao Huihui¹, Qi Yongsheng²

(1. School of Information Science and Technology, Beijing University of Technology, Beijing 100124, China;

2. School of Electric Power, Inner Mongolia University of Technology, Hohhot 010051, China)

Abstract: A chiller is a critical component of heating, ventilation, and air conditioning (HVAC) systems. Faults in chillers can lead to energy waste and even safety incidents. Therefore, fault diagnosis for chillers is essential for HVAC systems. Data-driven fault diagnosis methods rely on large amounts of historical data, but labeled fault data is often difficult to collect, resulting in reduced diagnostic accuracy of models. To address this issue, this paper proposes a fault diagnosis method based on a consistency loss generative adversarial network (CLGAN). First, CLGAN is trained with a small number of labeled samples and a large amount of unlabeled data to generate realistic fault samples. Next, a balanced dataset containing multiple fault categories is constructed by combining both generated and historical data. Finally, a fault classifier is trained on this balanced dataset to perform real-time fault diagnosis. By introducing a consistency loss function into the discriminator, CLGAN effectively leverages unlabeled data, increasing data utilization. Meanwhile, the generator is guided at multiple scales to meet the discriminator's requirements, enabling the model to produce high-quality samples even under various disturbances and thus enhancing diagnostic accuracy and robustness. Experimental results on the ASHRAE and HY-31C datasets demonstrate that, with only five labeled samples per class, CLGAN achieves fault diagnosis accuracies of 92.8% and 95.9%, respectively, illustrating its excellent performance. Moreover, in noise and cross-condition experiments, CLGAN shows superior robustness and generalization compared with other methods.

Keywords: fault diagnosis; generative adversarial network; chiller; consistency loss function; unlabeled data

0 引言

冷水机组是供暖通风与空气调节系统的关键部分,其能源消耗占建筑总能耗的40%以上^[1]。然而,当冷水机组长期运行、使用不当和缺少维护时,容易发生故障,造成额外的能源消耗,并降低室内环境的舒适度,当发生严重故障时甚至会引发设备损坏等安全性问题^[2]。因此,对冷水机组进行有效的故障诊断具有重要研究意义。

根据不同的原理,冷水机组的故障诊断方法可以分为3类^[3],基于规则的故障诊断^[4]、基于模型的故障诊断^[5]和基于数据驱动的故障诊断^[6-7]。其中,基于规则和基于模型的方法依赖于大量的专业知识和专家经验。然而,由于冷水机组结构复杂且运行环境多变,基于规则和基于模型的方法泛化性能较差^[8]。而基于数据驱动的方法不仅能够从大量复杂数据中提取特定类别的特征,而且具有较高的泛化性能^[9-11]。近年来,随着计算机技术的不断发展,基于数据驱动的故障诊断方法受到越来越多研究者的关注。在这些方法中,卷积神经网络(convolutional neural network, CNN)^[12]、时序卷积网络(temporal convolutional network, TCN)^[13]和长短期记忆网络(long short-term memory, LSTM)^[14]等方法已成功应用于冷水机组的故障诊断,并取得了较高的诊断准确率。然而,上述方法通常需要利用大量的历史故障数据来训练分类模型。在冷水机组实际运行过程中,大部分时间都处于正常运行状态,因此可收集的故障数据非常有限。实验结果表明,在历史数据有限的情况下,传统分类器的性能会显著下降^[15-16]。因此,在有限数据条件下执行故障诊断任务对于冷水机组的健康管理具有重要意义,这通常被称为小样本故障诊断。

为解决历史数据不足的问题,研究者们提出了多种数据增强方法^[17-18],其中合成少数类过采样技术(synthetic minority over-sampling technique, SMOTE)是一种常用的方法^[19]。SMOTE通过插值的方式生成样本并平衡数据集,降低过拟合的可能性,从而提高分类器的性能。Zhou等^[20]通过使用一种主成分分析与SMOTE相结合的数据增强技术,成功解决了变频流量系统数据驱动故障检测和诊断中的数据不平衡问题。Shen等^[21]提出了一种稳定的合成少数类过采样技术,通过k近邻以及设定阈值的方式划分远离分布边界特征空间,然后在该特征空间中生成具有较低重叠的故障样本,以实现故障数据的增强。然而,上述过采样方法生成的数据缺乏多样性,可能会导致模型过拟合。此外,还有研究者从知识迁移的角度来解决故障数据不足的问题^[22]。迁移学习通过将源域学到的特定类别知识转移到目标域来实现小样本故障诊断,然而,这些基于迁移学习的方法仍然需要源域中大量的训练样本。

近年来的研究表明,使用生成对抗网络(generative adversarial network, GAN)来丰富有限的训练样本是解决故障诊断中历史数据不足的有效途径。GAN最早由GoodFellow等^[23]提出,其原理是通过对抗训练充分拟合真实样本的分布,从而生成高质量的数据样本。与过采样方法相比,基于GAN的数据增强方法能够有效增加生成样本的多样性,从而能够很好的满足复杂工业场景下的需求。因此,GAN也已逐步应用在故障诊断领域。Yan等^[24]首次将GAN应用在冷水机组故障诊断中,并研究了初始故障训练数据样本的最小需求量。随后,Yan等^[25]设计了一种异常检测GAN(anomaly detective GAN, ADGAN),它将生成器模型和评估模型集成在一起,以提高生成样本的质量。具体来说,ADGAN通过异常检测评估和筛选生成的样本,并将结果返回给生成器,直到生成令人满意的样本。Du等^[26]提出了一种GAN与增量学习支持向量机模型相结合的冷水机组故障诊断方法,使用了一种增量学习策略定期更新故障检测与诊断模型。实验结果表明,结合GAN的增量学习支持向量机(support vector machine, SVM)达到了较高的诊断准确性。此外,Jiang等^[27]提出了一种视觉变换器生成对抗域泛化(vision transformer generative adversarial domain generalization, VIT-GADG)的冷水机组故障诊断框架。通过视觉变换器(vision transformer, VIT)域生成网络和VIT条件对抗域泛化网络,从源域和潜在域提取域不变知识,减少对多源域数据的依赖,并能泛化到未见目标域,有效提升了在未见目标域的诊断准确性。现有GAN及其改进方法在一定程度上解决了历史数据不足的问题,但仍无法充分利用无标签数据。在实际运行中,由于设备系统老旧等原因,无标签数据通常比带标签数据更加丰富,且同样包含可学习的类别特征。然而,由于无标签数据缺乏明确的分类信息,无法直接参与模型训练,这导致了现有方法中无标签数据利用率低的问题。在少量带标签数据且大量无标签数据的半监督学习场景中,一致性正则化(consistency regularization, CR)是一种有效的思路。它通过对同一无标签样本施加不同扰动,要求模型在不同扰动下保持相似的预测,从而平滑决策边界、挖掘无标签数据的潜在信息。在图像识别、语音识别等领域,一致性正则化已被广泛验证具有提升模型性能的效果,如 π 模型(π model, π -model)^[28]、Mean Teacher^[29]、虚拟对抗训练(virtual adversarial training, VAT)^[30]等,但在工业故障诊断领域,尤其是冷水机组故障诊断的半监督情形下尚缺少研究。

为解决上述问题,进一步提高故障诊断准确率,提出了基于一致损失生成对抗网络的冷水机组故障诊断方法。首先,利用一致损失生成对抗网络(consistency loss generative adversarial network, CLGAN)生成故障数据,构

建一个包含各类故障的平衡数据集。然后,利用生成的平衡数据集训练 CNN 分类模型,以提高模型的诊断准确率。最后,使用 CNN 模型对冷水机组进行在线故障诊断。与已有方法不同的是,CLGAN 利用一致性正则化的思想,通过在判别器中引入一致性损失函数,能够充分利用无标签数据辅助模型的训练,提高数据利用率。同时,在对抗训练过程中,CLGAN 通过提高判别器的判别能力,使得生成器可以生成更高质量的故障数据,从而提高故障诊断的准确性和鲁棒性。

1 基本理论

1.1 条件生成对抗网络

GAN 是一种通过对抗过程训练生成模型的方法。GAN 由两个神经网络组成:生成器和判别器。生成器将输入的随机噪声转换为逼真的数据样本,而判别器用于区分真实样本和生成样本。在训练过程中生成器和判别器相互博弈,生成器不断优化以生成更加逼真的样本,而判别器不断提高其识别生成样本的能力。

条件生成对抗网络(conditional generative adversarial network, CGAN)是 GAN 的一个扩展^[31]。CGAN 在原始 GAN 的基础上引入了条件变量,通过在训练过程中添加额外的标签信息,指导生成器和判别器的收敛过程。这些条件变量可以是任何形式的标签信息,例如数据的类别、属性等。在实验中使用冷水机组故障数据的类别作为标签信息,指导模型生成不同类别的故障数据。条件生成对抗网络的目标函数如式(1)所示。

$$\min_G \max_D V(G, D) = E_{x \sim P_{data}} [\log D(x|y)] + E_{z \sim P_z} [\log(1 - D(G(z|y)))] \quad (1)$$

式中: G 表示生成器; D 表示判别器; $V(G, D)$ 表示目标函数; E 表示分布的期望值; x 表示来自真实数据分布 P_{data} 的样本; z 表示从噪声分布 P_z 中采样的随机噪声; y 表示条件标签信息。

1.2 WGAN-GP

Goodfellow 等^[23]提出的 GAN 在实际训练中往往会遇到模式崩溃和梯度消失等问题,为克服这些缺陷,Arjovsky 等^[32]提出了 Wasserstein 生成对抗网络(wasserstein generative adversarial network, WGAN),WGAN 采用 wasserstein 距离替代原始 GAN 中的 Jensen-Shannon 散度,从而在生成器和判别器的博弈过程中得到更加平滑和稳定的梯度,提高生成模型的稳定性和生成样本的质量。WGAN 的损失函数为:

$$\min_G L_G = -E_{z \sim P_z} [D(G(z))] \quad (2)$$

$$\max_D L_D = E_{x \sim P_{data}} [D(x)] - E_{z \sim P_z} [D(G(z))] \quad (3)$$

然而, WGAN 通过权重裁剪的方式来实现 Lipschitz

连续的约束,这容易导致训练不稳定。为此, Gulrajani 等^[33]于 2017 年提出了带梯度惩罚的 Wasserstein 生成对抗网络(wasserstein generative adversarial network with gradient penalty, WGAN-GP),用一种梯度惩罚的策略替代权重剪裁,提高了模型训练的稳定性。WGAN-GP 的判别器损失函数如式(4)所示。

$$L_D = -E_{x \sim P_{data}} [D(x)] + E_{z \sim P_z} [D(G(z))] + \lambda E_{\hat{x} \sim p(\hat{x})} [(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1)^2] \quad (4)$$

式中: $\hat{x}$ 表示在真实数据 x 和生成数据 $G(z)$ 之间插值得到的样本: $\hat{x} = \epsilon x + (1 - \epsilon) G(z)$, ϵ 是一个介于 0 和 1 之间的常数; λ 是惩罚系数。通过引入梯度惩罚, WGAN-GP 不仅能保持 wasserstein 距离的合理性,还能有效避免梯度消失问题,从而在生成质量和训练稳定性方面取得了显著的提升。

1.3 基于自编码器的残差特征提取

为了提高 GAN 的训练效果,可以在数据预处理阶段引入自编码器进行残差特征提取,图 1 展示了该方法的训练流程。首先对正常样本进行重构训练,最小化重构误差。接着,使用训练好的自编码器模型对故障样本进行重构。最后,计算重构误差,提取故障样本的残差特征。训练流程的损失函数为:

$$L_{AE} = \frac{1}{N} \sum_{i=1}^N [f(x_{normal}^i) - x_{normal}^i]^2 \quad (5)$$

式中: x_{normal}^i 表示第 i 个正常样本; N 表示正常样本的总数; $f(\cdot)$ 表示自编码器模型的输出。残差特征的计算公式为:

$$R = x_{fault} - f(x_{fault}) \quad (6)$$

式中: R 表示残差特征; x_{fault} 表示故障样本; $f(x_{fault})$ 表示自编码器模型对故障样本的重构数据。




图1 基于自编码器的残差特征提取方法

Fig.1 Autoencoder-based residual feature extraction method

通过自编码器提取的残差特征可以更好地反映故障样本与正常样本之间的差异,有效捕捉故障模式的关键特征,减少数据中的噪声和冗余信息,从而提高了 GAN 的生成质量和训练稳定性。因此,在该研究方法中,采用自编码器提取的数据残差特征作为 GAN 的训练数据,而不直接使用原始数据。

2 基于一致损失生成对抗网络的故障诊断方法

2.1 一致损失生成对抗网络

GAN 及其改进在一定程度上解决了数据不平衡问题,但它们仍然无法充分利用无标签数据。原因在于传统 GAN 方法主要依赖于带标签数据进行监督训练,而无标签数据缺乏明确的分类信息,无法直接参与模型训练,导致这些数据在传统方法中利用率低下。在少量带标签数据及大量无标签数据的实际应用场景中,一致性正则化是一种有效的方法。它通过对同一无标签样本施加不同扰动,使模型在处理这些扰动后的输入时保持相似的输出,从而在无标签数据上平滑判别边界,增强模型的泛化能力。受此启发,在对抗训练框架中加入多尺度一致性损失,以充分利用无标签数据,提升冷水机组故障诊断的准确性和鲁棒性。

CLGAN 的结构包括判别器和生成器两部分,判别器包括初步特征提取层、共享特征提取层和输出层。在初步特征提取层,带标签数据和无标签数据分别通过对应的网络层进行处理,生成初步特征。共享特征提取层则对所有数据进行统一处理,提取高层次特征。为了进一步指导模型学习不同故障数据的特征,CLGAN 在判别器的最后引入了一个辅助分类器,用于对真实样本和生成样本进行有监督的分类。辅助分类器的输出为样本的类别预测,用于计算分类损失。

对于带标签数据,其判别损失包含两部分:分类损失和 Wasserstein 距离损失。分类判别损失通过交叉熵损失函数计算,定义为:

$$L_C = E_{x \sim p(x)} [\log P(y|x)] + E_{x^f \sim p(x^f)} [\log P(y|x^f)] \quad (7)$$

式中: x 表示来自真实数据分布 $P(x)$ 的样本; x^f 表示来自生成数据分布 $P(x^f)$ 的样本; y 表示样本对应的标签。

Wasserstein 距离的判别损失定义为:

$$L_{dis} = -E_{x \sim P(x)} [D(x)] + E_{z \sim P_z} [D(G(z))] + \lambda E_{\hat{x} \sim P(\hat{x})} [(|\nabla_{\hat{x}} D(\hat{x})|_2 - 1)^2] \quad (8)$$

式中: $D(x)$ 表示判别器对真实样本 x 的输出; z 表示来自随机分布 P_z 的噪声。

对于无标签数据,CLGAN 在训练的过程中判别器不仅需要学习区分真实数据和生成数据,还需要在不同层次上保持无标签数据的一致性。具体来说,CLGAN 是通过引入多尺度一致性损失函数实现这一目标的,如图 2 所示。在冷水机组故障诊断场景中,低层特征往往受到传感器噪声或环境扰动影响,而更高层特征则逐渐表现

出故障类型的核心差异。为保证在不同层面都能抑制噪声干扰、捕捉故障模式,CLGAN 在判别器的多个特征层 ($D_1, D_2, \dots, D_K$) 以及输出层上施加一致性约束。在每轮训练中,首先将无标签数据输入判别器,对于同一个无标签样本 x 及其扰动版本 $x + \eta$,分别经过判别器得到多尺度特征 $D_k(x)$ 和 $D_k(x + \eta)$,并计算对应层的均方误差,得到多尺度一致性损失 $L_{consistency}$, 定义为:

$$L_{consistency} = \sum_{k=1}^K E_{x \sim P_{unlabeled}} [(D_k(x) - D_k(x + \eta))^2] \quad (9)$$

式中: x 表示来自无标签数据分布 $P_{unlabeled}$ 的样本; $D_k(x)$ 是判别器在第 k 层的输出; η 表示对 x 的随机扰动。在此过程中,判别器能够在多种扰动条件下保持特征表征的一致性,从而提升对复杂工况和噪声的鲁棒性。




图2 多尺度一致性损失

Fig. 2 Diagram of multi-scale consistency loss

综合以上部分,判别器的总损失函数为:

$$L_D = L_C + L_{dis} + L_{consistency} \quad (10)$$

生成器的训练目的是生成与真实数据分布相似的样本,以欺骗判别器。生成器的损失函数为:

$$L_G = -E_{z \sim P_z} [D(G(z))] \quad (11)$$

在对无标签数据施加一致性损失后,判别器对输入扰动的判别能力得到有效增强。相应地,生成器在对抗训练过程中需生成更逼真且更具多样性的故障数据,才能达到对抗训练的平衡状态。无标签一致性约束与真假判别对抗,能够进一步提升生成器所生成故障样本的质量和丰富度,从而为故障诊断模型提供更具代表性的训练数据。多尺度一致性损失能够有效提高特征表示的鲁棒性。

总的来说,CLGAN 将该正则化思想与多尺度特征提取和生成对抗训练相结合,不仅能充分利用无标签数据,还能在冷水机组故障诊断这样噪声较多、数据分布复杂的场景中取得更好的鲁棒性。

2.2 故障分类器

CNN 网络结构具有强大的特征提取能力,通过堆叠多个卷积层和池化层,CNN 可以逐层提取数据的深层次特征,在处理高维数据时,能够有效地捕捉数据中的空间关系和局部特征,因此使用 CNN 作为故障分类器。

在 CLGAN 训练完成后,使用生成器生成故障数据,构建一个包含各类故障的平衡数据集。然后,构建基于 CNN 的故障分类器,使用平衡数据集训练其完成故障诊断任务。CNN 故障分类器包含 5 个卷积层,每个卷积层后接一个 LeakyReLU 激活函数,用于增加网络的非线性表示能力。在卷积层后,加入平均池化层,用于减少特征图的维度,减轻计算负担,同时保留重要特征。最后,通过全连接层,将提取到的特征映射到最终的故障分类结果。使用交叉熵作为 CNN 的损失函数,其表达式为:

$$L_{CNN} = E_{x \sim p(x)} [\log P(y|x)]$$

(12)

式中: x 表示来自混合了生成样本和真实样本的训练数据集。

2.3 CLGAN 的故障诊断方法

为了解决故障诊断中数据不平衡带来的精度下降问题,提出了一种基于 CLGAN 的故障诊断方法。图 3 展示了所提方法的流程,可分为两个阶段:离线建模和在线监测。




图 3 实验流程
Fig. 3 Flow diagram of experiment

离线建模阶段包含 3 个步骤。1) 提取残差特征,用于后续模型的训练。在此步骤中,首先对历史数据进行最大最小归一化,以保证数据尺度的一致性。再使用训练好的自编码器模型计算数据的残差,提取能够反映故障样本与正常样本之间差异的残差特征。历史数据按照

是否带有标签分为两部分:带标签数据占少数,用于监督学习,无标签数据占多数,用于无监督学习。2) 训练 CLGAN 模型。在此步骤中,使用带标签的和无标签数据同时训练 CLGAN,通过一致性损失确保无标签数据在生成过程中能提供有效信息,增强模型的泛化能力。CLGAN 训练完成后,使用生成器生成带标签的故障数据,与原数据集一起构建类别平衡的新数据集。3) 构建基于 CNN 的分类网络,并用新数据集训练,最终获得故障分类模型。

在线监测阶段首先收集冷水机组的在线运行数据,为了确保与训练数据的一致性,实时数据也经过相同的最大最小归一化处理。其次,利用离线阶段训练好的自编码器模型计算实时数据的残差。最后,将已计算的残差特征输入到故障分类模型中,获得最终的诊断结果。

3 实验结果及讨论

3.1 ASHRAE 实验数据集

1) 数据集介绍

本实验数据集源于美国暖通空调工程师协会 (American Society of Heating Refrigerating and Air-Conditioning Engineers, ASHRAE) RP-1043 研究项目,使用了一台 90 t, 316 kW 的冷水机组,采用 R134a 制冷剂^[34]。项目模拟了冷水机组的正常运行状态及 7 种典型故障状态,分别为冷凝器水流量下降、蒸发器水流量下降、制冷剂泄漏、制冷剂过量、润滑油过多、冷凝器结垢、冷凝剂中有非冷凝物,并利用传感器记录了冷凝水进出水温度、冷凝器水流量等 64 个过程变量。上述故障根据影响范围可分为部件级故障和系统级故障,其中蒸发器水流量下降、冷凝器水流量下降、冷凝剂中有非冷凝物和冷凝器结垢属于部件级故障,发生后会引起局部范围内运行参数的变化。而冷凝剂填充过量、润滑油过量和冷凝剂泄漏属于系统级故障,发生后会引起全局参数的变化。

2) 实验设置

首先,从数据集中随机选取 200 个正常状态的样本作为自编码器的训练数据集。为了验证所提方法在带标签故障数据不足情况下的有效性,依据不同的实验条件对 CLGAN 训练数据集进行划分,具体划分方式如表 1 所示。

根据有标签样本数和无标签样本数的不同,共有 12 种实验设置。模型训练完毕后,每类故障各生成 200 个样本,并与有标签样本一起构成 CNN 分类器的训练数据集。从每个故障类型和正常状态中随机选取 200 个样本作为测试数据集。最后,使用训练好的自编码器提取上述数据集的残差特征,以进行最终的模型训练和测试。

表 1 ASHRAE 数据集实验设置

Table 1 Experiment setting on ASHRAE dataset

实验编号	少数类样本个数(每类)	
	有标签	无标签
1	5	100
2	5	200
3	5	400
4	5	800
5	5	1 200
6	5	1 600
7	10	100
8	10	200
9	10	400
10	10	800
11	10	1 200
12	10	1 600

本实验使用的故障诊断模型参数如表 2 所示,包括 CLGAN 的生成器模型参数、判别器模型参数以及 CNN 故障分类器模型参数 3 个部分。其中,FC(full connected layer)代表全连接层,LR 表示带泄漏线性整流激活函数(leaky rectified linear unit, LeakyReLU),Tanh 表示双曲正切激活函数,Concat 表示特征拼接操作,用于增加特征的维度,C(convolutional layer)表示卷积层,AvgP(average pooling layer)表示平均池化层,|| 表示存在两个并行的全连接层,它们共享相同的输入特征,各自输出不同的特征向量,用于描述不同的语义信息。


表 2 冷水机组故障诊断模型参数设置

Table 2 Parameter setting for fault diagnosis on chiller


生成器	判别器	
FC1(256,512) LR	初步特征提取层	
FC2(512,512) LR	无标签数据	带标签数据
FC3(512,256) LR	FC1(1,64) LR	FC1(128,256) LR
FC4(256,128) LR	Concat(64,64)	
FC5(128,64) Tanh	FC2(128,256) LR	
CNN 网络	共享特征提取层	
C1(1,16,4,2,1) LR	FC1(256,128) LR	
C2(16,16,4,2,1) LR	FC2(128,64) LR	
C3(16,16,4,2,1) LR	FC3(64,32) LR	
C4(32,32,4,2,1) LR	输出层	
C5(32,32,4,2,1) LR	FC1(32,1) FC1(32,7)	
AvgP(1) FC(32,8)		

3) 实验结果分析

为了验证 CLGAN 的有效性,首先在无标签样本数 1 200 的条件下进行故障诊断实验。图 4 分别展示了在有标签样本数为 5 和 10 的情况下的故障诊断准确率。可以看出,所提方法在有标签样本数很少的条件下都获得了较高的故障诊断准确率。具体来说,在有标签样本数为 5 的情况下,蒸发器水流量下降、制冷剂泄漏和冷凝剂结垢的故障诊断率都达到了 0.95 以上,分别为 0.96、0.975 和 0.955。当有标签样本数为 10 时,除了润滑油过多,其余故障状态的诊断准确率都达到了 0.95 以上。此外,随着有标签样本数的增加,能够观察到平均故障诊断率也有明显提升,由 0.928 增加到 0.958。这是因为增加有标签样本数可以提供更多的监督信息,从而使得生成对抗网络的生成器和判别器在学习过程中能更有效地模拟故障数据的真实分布。有标签样本中包含的确切故障类型信息有助于判别器更准确地评估生成的样本,从而引导生成器产生更具代表性和多样性的故障样本。



(a) 有标签样本数等于5
(a) With 5 labeled samples



(b) 有标签样本数等于10
(b) With 10 labeled samples

图 4 各类故障的诊断准确率(ASHRAE 数据集)
Fig.4 Diagnosis accuracy of various fault pattern
(ASHRAE dataset)

为了进一步验证 CLGAN 模型在故障诊断中的性能,图 5 中的混淆矩阵展示了模型在有标签样本数等于 5 和 10 时的具体诊断结果。混淆矩阵的每一行代表了实际

类别,而每一列代表了预测类别,对角线上的值代表预测正确的数量,非对角线上的值代表预测错误的数量。

正常状态	198	1	0	1	0	0	0	0
冷凝器水流量下降	7	170	0	5	2	0	16	0
蒸发器水流量下降	2	0	192	0	0	6	0	0
制冷剂泄漏	0	2	0	195	0	0	1	2
制冷剂过量	0	0	0	2	179	17	1	1
润滑油过多	8	1	0	0	1	182	8	0
冷凝器结垢	0	2	0	7	0	0	191	0
冷凝剂中有非冷凝物	0	1	0	0	18	0	3	178

(a) 有标签样本数为5
(a) With 5 labeled samples

正常状态	198	1	0	1	0	0	0	0
冷凝器水流量下降	4	195	0	0	0	0	0	1
蒸发器水流量下降	3	0	194	0	0	3	0	0
制冷剂泄漏	0	7	0	190	0	0	1	2
制冷剂过量	0	0	0	2	191	5	0	2
润滑油过多	8	4	0	0	0	183	4	1
冷凝器结垢	0	6	0	3	0	0	191	0
冷凝剂中有非冷凝物	0	3	0	0	6	0	1	190

(b) 有标签样本数为10
(b) With 10 labeled samples

图 5 不同有标签样本数下的故障诊断混淆矩阵
(ASHRAE 数据集)

Fig. 5 Confusion matrices of fault diagnosis with different numbers of labeled samples (ASHRAE dataset)

总的来说,混淆矩阵显示了每个类别的预测结果与真实结果的对比,从而可以直观地观察模型在各个类别上的表现。可以看出,该方法对大多数故障类型的诊断准确性都非常高,这表明 CLGAN 模型能够有效地学习并识别故障数据的特征。例如,在有标签样本数为 5 的实验中,大部分故障类型的预测正确数目都接近或达到了最大值(如蒸发器水流量下降、制冷剂泄漏等),只有少数类别(如冷凝器水流量下降和润滑油过多)的预测存在一定误差。在有标签样本数为 10 的实验中,由于有监督信息的增加,模型在各类别的误诊断数量都有所减少。

此外,为了进一步研究无标签样本数量对故障诊断准确率的影响,通过逐步增加无标签样本的数量,观察其对模型性能的影响。实验结果如图 6 所示,横坐标为无标签样本数,纵坐标为故障诊断准确率,图中包括两组数据,正方形标签和圆形标签的折线分别对应有标签样本数为 5 和 10 的情况。

从图 6 可以看出,无标签样本数量的增加显著提升了故障诊断的准确率。具体来说,当无标签样本数从最初的 100 增至 400 时,两组实验的故障诊断准确率都有




图 6 不同无标签样本数下的故障诊断准确率
(ASHRAE 数据集)

Fig. 6 Fault diagnosis accuracy with different numbers of unlabeled samples (ASHRAE dataset)

明显提升,分别提升了 0.059 和 0.034。然而,当无标签样本数继续增加时,准确率的增幅逐渐减少,最终在 1 600 时到达最大值,分别为 0.928 和 0.958。其原因在于,由于数据集中带标签样本数较少,导致 CLGAN 对真实数据分布学习不足,而无标签样本在训练过程中作为辅助样本,增加其数量可以提供更多的数据信息,使模型迅速学习并改进其判别能力,从而迫使生成器生成更高质量的样本。然而,当无标签样本数量达到一定阈值后,模型已经学习了数据的主要特征,此时继续增加无标签样本,其对模型性能的贡献将呈现递减趋势。

为了直观地展示生成特征的不变性,图 7 显示了 CLGAN 对应类别的 t 分布-随机邻近嵌入 (t-distributed stochastic neighbor embedding, t-SNE) 可视化结果。




图 7 不同类别上真实特征与生成特征的可视化
(ASHRAE 数据集)

Fig. 7 Visualization of real and generated features across different categories (ASHRAE dataset)

t-SNE 是一种广泛使用的可视化技术,适用于高维数据的降维显示。该技术通过概率分布的方式将高维数据映射到二维或三维空间,使得原始数据点间的相对距离得以保留。在图 7 中,使用不同的形状来区分不同故障类别的数据,使用空心标记符号和实心标记符号分别代表生成特征和真实特征。例如,圆形标记表示冷凝器水流量下降,其中空心圆形代表生成的特征数据,而实心圆形代表真实特征数据。

通过对比可以看到,各故障类别的原始特征与生成特征在图中的分布具有高度相似性。CLGAN 生成的样本与原始样本在特征空间中紧密聚集,这说明生成器能够有效模拟真实的数据分布,保留了数据的关键特征,从而在未标签数据上实现了准确的故障诊断。

4) 对比实验

为了验证生成特征的有效性,本研究使用原始数据集训练 CNN 模型进行故障诊断对比实验。此外,为了验证 CLGAN 生成故障特征的优势,引入了以下 4 种数据生成方法及其变体进行相同的数据增强任务。

(1) SMOTE^[19]:一种广泛使用的数据增强技术,其核心思想是通过线性组合在少数类样本之间插入合成的数据点,从而模拟更多的少数类样本。

(2) WGAN-GP^[33]:GAN 基础上的一种改进模型,其引入的 Wasserstein 距离和梯度惩罚有效解决了 GAN 在训练过程中遇到模式坍塌和训练不稳定等问题,并改善了生成样本的多样性和质量。

(3) EDN-WGAN-GP^[35]:WGAN-GP 基础上的一种改进模型,首先使用编解码器(encoder decoder network, EDN)处理原始数据,以提取反映每个变量独立变化的高质量残差特征,然后再利用这些特征训练 WGAN-GP 网络。

(4) CLGAN-v0:与本研究提出的 CLGAN 具有相同的模型结构,但仅在判别器的输出层上施加一致性约束。

为确保对比实验的有效性,上述所有方法的卷积池化结构与 CLGAN 相同,且使用相同的数据集进行训练和测试,对每类故障均生成 200 个样本。在 CLGAN 的实验设置中,每类故障使用 1 600 个无标签样本辅助模型训练。

表 3 展示了各方法在不同条件下的故障诊断总体准确率。可以看到,CLGAN 在两种情况下的总体故障诊断率均远高于其他方法,这说明了 CLGAN 在有标签样本不足时的有效性。具体来说,CLGAN 在有标签样本数为 5 和 10 的条件下,故障诊断总体准确率分别为 0.928 和 0.958,相比于没有生成模型的 CNN,分别提升了 0.568 和 0.386,相比于仅使用有标签样本训练的 EDN-WGAN-GP,分别提升了 0.117 和 0.096。这表明了 CLGAN 能够有效利用无标签数据进行诊断。此外,EDN-WGAN-GP

的准确率比 WGAN-GP 有明显提升,这表明了 EDN 所提取的残差特征在 GAN 网络训练中的辅助作用。

表 3 故障诊断对比实验(ASHRAE 数据集)
Table 3 Fault diagnosis comparative experiments
(ASHRAE dataset)

方法	有标签样本数 = 5	有标签样本数 = 10
CNN	0.360	0.572
SMOTE	0.652	0.804
WGAN-GP	0.789	0.829
EDN-WGAN-GP	0.811	0.862
CLGAN-v0	0.914	0.939
CLGAN	0.928	0.958

为验证在判别器的多个尺度上施加一致性损失的必要性,本节使用 CLGAN-v0 模型进行对比实验。由表 3 可以看到,CLGAN-v0 的准确率相对 CLGAN 较低,这是因为若仅在判别器的输出层施加一致性损失,虽然对无标签数据具有一定的正则化效果,但无法降低中间层对随机扰动的敏感度,从而限制了生成器在故障数据生成过程中的多样性和真实性。从可解释性的角度来看,底层特征往往刻画传感器信号的细微变化,而高层特征则体现故障类型的整体模式,CLGAN 能够在不同的语义层面对同一无标签样本施加类似的判别要求,确保了生成器在对抗训练过程中能够学习到丰富且准确的故障特征分布。对比试验表明,CLGAN 能够有效提高数据利用率并生成高质量的故障样本,以解决实际应用中冷水机组历史故障数据不足导致的诊断精度下降的问题。

5) 鲁棒性和泛化性分析

实际运行场景中,传感器数据常因测量误差和环境因素产生噪声,设备的实际负载也会受环境因素的影响而发生改变,因此本节分别开展鲁棒性和泛化性实验,并将实验结果汇总于表 4,以对比不同方法在各类干扰下的诊断效果。

表 4 鲁棒性和泛化性实验
Table 4 Robustness and generalization experiments

实验条件	故障诊断总体准确率	
	EDN-WGAN-GP	CLGAN
低噪声	0.854	0.951
高噪声	0.801	0.933
工况 1	0.795	0.949
工况 2	0.787	0.940
对照组	0.862	0.958

为评估模型在实际复杂场景中的适应能力,通过向原始数据注入高斯噪声来模拟不同程度的扰动情况,并在此基础上测试故障诊断的准确率变化。高斯噪声通常

被视为最常见的一类随机噪声,其概率分布函数可用式(13)表示。

$$p(n)=\frac{1}{\sqrt{2\pi}\sigma}\exp\left(-\frac{(n-\mu)^2}{2\sigma^2}\right)$$

(13)

式中: n 表示噪声随机变量; μ 为噪声均值; σ 为噪声的标准差。在实验中,为模拟无偏移的纯随机扰动,均值设为 0。将高斯噪声叠加到原数据 x 上后,就得到:

$$x'=x+n$$

(14)

式中: x' 为加入噪声后的数据。为了更直观的验证模型在不同噪声强度下的表现,实验选取了两种标准差水平,分别为 $\sigma=0.01$,代表测量精度较高、环境干扰较小的情况,以及 $\sigma=0.05$,代表复杂的环境或外部干扰。在添加噪声时,对测试集的每条数据都按照 $n\sim N(0,\sigma^2)$ 的方式进行处理,对照组不做任何处理。

实验结果如表 4 所示,在低噪声条件下,对比方法均能保持较高的诊断准确率,但 CLGAN 的准确率下降程度更小,说明其对小幅度噪声更具适应性。在高噪声条件下,EDN-WGAN-GP 的准确率明显下降,而 CLGAN 仍能取得较高的诊断水平,这表明 CLGAN 面对强噪声干扰时具有更好的鲁棒性。

冷凝器水温的变化会直接影响机组内部的热交换效率和运行负载,因而不同水温条件下的系统特征分布往往出现较大差异。在本实验中,分别设置了 45℃、50℃ 和 55℃ 这 3 种冷凝器水温工况,记为工况 0、1 和 2。选用工况 0 的数据进行模型训练,作为对照组。由表 4 可以看出,当测试工况从 45℃ 变为 50℃ 时,EDN-WGAN-GP 的准确率出现下滑,CLGAN 尽管也有所下降,但依旧保持在较高水平,反映出其对温度变化导致的数据分布差异更具适应能力。当工况进一步变化至 55℃ 时,EDN-WGAN-GP 的性能下降更为明显,CLGAN 仍能取得可观的诊断结果,仅下降了 0.018,验证了在不同工况下良好的泛化性能。

3.2 HY-31C 数据集

1) 数据集介绍

HY-31C 数据集由本研究团队收集, HY-31C 型冷水机组的实验平台如图 8 所示。平台模拟了冷水机组 3 种不同的健康状态,即正常状态、蒸发器故障和冷凝器故障。每种故障根据发生的严重程度进一步分为两个类别,因此 HY-31C 数据集中共有 5 个类别。冷水机组的监控数据在系统运行稳定之后采集,利用传感器采集了冷却泵功率、冷冻水供水流量和压缩机功率等 39 个过程变量,数据采集间隔为 30 s。

2) 实验设置

为了验证基于 CLGAN 的故障诊断方法在 HY-31C 数据集上的有效性,相关实验的设计方式与 ASHRAE 数据集的实验相同,具体的实验设置如表 5 所示。其中,训




图 8 HY-31C 实验平台
Fig. 8 HY-31C experimental platform

练集中带标签样本且正常状态的样本数为 200,对于少数类故障数据,每类有标签样本的个数为 5~10 个,无标签样本个数为 100~600 个。此外,模型参数设置和训练超参数与 ASHRAE 数据集上的设置相同,在 CLGAN 训练完毕后,每类故障生成 200 条样本,使用生成样本与原始样本一起训练故障分类器。

表 5 HY-31C 数据集实验设置
Table 5 Experiment setting on HY-31C dataset

实验编号	少数类样本个数(每类)	
	有标签	无标签
1	5	100
2	5	200
3	5	300
4	5	600
5	10	100
6	10	200
7	10	300
8	10	600

3) 实验结果分析

首先使用 HY-31C 数据集对 CLGAN 进行了一系列故障诊断实验,在实验中每类故障的无标签样本数固定为 600。为直观展示数据分布,对不同故障类别进行了可视化,如图 9 所示。圆形和正方形标记分别表示蒸发器故障等级 1 和 2,三角形和菱形标记分别表示冷凝器故障等级 1 和 2,实心 and 空心标记分别表示真实数据和生成数据。

图 10(a) 和 (b) 分别展示了 CLGAN 在有标签样本数为 5 和 10 的条件下,各类故障的诊断准确率。可以看

出,当有标签样本数为 5 时,除了蒸发器故障等级 1,其余故障类型的诊断准确率都达到了 0.95。当有标签样本




图 9 不同类别上真实特征与生成特征的可视化 (HY-31C 数据集)

Fig. 9 Visualization of real and generated features across different categories (HY-31C dataset)




图 10 各类故障的诊断准确率 (HY-31C 数据集)

Fig. 10 Diagnosis accuracy of various fault pattern (HY-31C dataset)

数增加到 10 时,多数故障类型的诊断准确率都进一步提高。图 11 展示了实验中每类故障数据的具体诊断结果,尽管数据集中带标签的样本量很少,CLGAN 仍获得了较高的故障诊断准确率,分别为 0.959 和 0.975。当有标签样本数为 5 时,除了蒸发器故障等级 1 有 24 个样本误分类,其余故障类型的误诊断数量均<10。其原因可能在于,当故障发生程度较低时,故障之间的特征相似性较高,因此模型在生成相应的故障样本时标记上了错误的类别标签。这也反映在图 9 中,正下方三角形中出现了少量圆形标记,表示蒸发器故障等级 1 与冷凝器故障等级 1 的特征相似性较高。

正常状态	200	0	0	0	0
蒸发器故障等级1	1	176	0	22	1
蒸发器故障等级2	1	0	199	0	0
冷凝器故障等级1	2	3	3	190	2
冷凝器故障等级2	0	0	6	0	194

(a) 有标签样本数为5
(a) With 5 labeled samples

正常状态	200	0	0	0	0
蒸发器故障等级1	2	196	0	1	1
蒸发器故障等级2	6	0	194	0	0
冷凝器故障等级1	1	4	5	188	2
冷凝器故障等级2	3	0	0	0	197

(b) 有标签样本数为10
(b) With 10 labeled samples

图 11 不同有标签样本数下的故障诊断混淆矩阵 (HY-31C 数据集)

Fig. 11 Confusion matrices of fault diagnosis with different numbers of labeled samples (HY-31C dataset)

如图 12 所示,随着参与训练的无标签样本增多,CLGAN 从无标签样本中学习到的数据特征越多,生成的故障数据与真实的故障数据相似性越高,其故障诊断准确率也越高。具体来说,从当无标签样本数从 100 增至 200 时,两种实验条件下的故障诊断准确率提升明显,之后增幅逐渐减小,最终达到最高准确率,分别为 0.975 和 0.959。同样的,为了展示 CLGAN 在数据生成方面的优势,进行了与 ASHRAE 数据集中相同的对比实验,对比的实验模型包括 CNN、SMOTE、WGAN-GP、EDN-WGAN-GP 和 CLGAN-v0,具体的对比试验结果如表 6 所示。从表中可以看出,CLGAN 在两种无标签样本数的条件下,故障诊断总体准确率都超过了其他对比模型。相比于没有生成模型的 CNN,CLGAN 生成的数据特征显著的提升了分类器的分类准确率,分别提升了 0.3 和 0.256。在与其他数据生成模型的对比实验中,CLGAN 也展示了其能

够有效利用无标签数据进行辅助训练的优势。此外,相较于仅在判别器输出层施加一致性约束的 CLGAN-v0 模型,CLGAN 在有标签样本数为 5 和 10 的两种情况下,故障诊断总体准确率分别提高了 0.022 和 0.023,进一步验证了 CLGAN 多尺度约束的有效性。




图 12 不同无标签样本数下的故障诊断准确率 (HY-31C 数据集)

Fig. 12 Fault diagnosis accuracy with different numbers of unlabeled samples (HY-31C dataset)

表 6 故障诊断对比实验 (HY-31C 数据集)

Table 6 Fault diagnosis comparative experiments (HY-31C dataset)

方法	故障诊断总体准确率	
	有标签样本数=5	有标签样本数=10
CNN	0.659	0.719
SMOTE	0.830	0.869
WGAN-GP	0.871	0.924
EDN-WGAN-GP	0.896	0.932
CLGAN-v0	0.937	0.952
CLGAN	0.959	0.975

4 结 论

针对冷水机组历史数据中带标签样本不足而导致模型诊断精度下降的问题,提出了基于 CLGAN 的冷水机组故障诊断方法。CLGAN 通过在判别器中加入一致性损失函数,能够有效利用无标签数据辅助训练,提高了数据利用率。此外,CLGAN 通过在多个尺度上引入一致性损失,迫使生成器在多个层面上满足判别器的要求,这种多维度的反馈机制促使生成器在面对输入扰动时,依然能够生成高质量的样本。基于 ASHRAE 和 HY-31C 数据集的验证结果表明,在数据集中仅有少量带标签样本的情

况下,CLGAN 的故障诊断准确率均优于对比方法,表现出良好的故障诊断性能。

参考文献

[1] AFSHARI A, FRIEDRICH L. A proposal to introduce tradable energy savings certificates in the emirate of Abu Dhabi[J]. Renewable and Sustainable Energy Reviews, 2016, 55:1342-1351.

[2] KATIPAMULA S, BRAMBLEY M R. Methods for fault detection, diagnostics, and prognostics for building systems—a review, part I [J]. Hvac&R Research, 2005, 11(1):3-25.

[3] MIRNAGHI M S, HAGHIGHAT F. Fault detection and diagnosis of large-scale HVAC systems in buildings using data-driven methods: A comprehensive review [J]. Energy and Buildings, 2020, 229:110492.

[4] ROGERS A P, GUO F, RASMUSSEN B P. A review of fault detection and diagnosis methods for residential air conditioning systems [J]. Building and Environment, 2019, 161:106236.

[5] CHEN H T, LI L L, SHANG CH, et al. Fault detection for nonlinear dynamic systems with consideration of modeling errors: A data-driven approach [J]. IEEE Transactions on Cybernetics, 2023, 53(7):4259-4269.

[6] CHEN H T, LIU ZH G, ALIPPI C, et al. Explainable intelligent fault diagnosis for nonlinear dynamic systems: From unsupervised to supervised learning [J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(5):6166-6179.

[7] 高学金,张琳峰. 中央空调传感器双重降噪模糊故障检测方法[J]. 电子测量与仪器学报,2022,36(8):77-88.

GAO X J, ZHANG L F. Double noise reduction fuzzy fault detection method for sensors in central air conditioning[J]. Journal of Electronic Measurement and Instrumentation, 2022,36(8):77-88.

[8] ZHANG Y, JI J CH. Intelligent fault diagnosis of a reciprocating compressor using mode isolation convolutional deep belief networks [J]. IEEE/ASME Transactions on Mechatronics, 2021, 26(3):1668-1677.

[9] CHEN K, CHEN S L, ZHU X, et al. Interpretable mechanism mining enhanced deep learning for fault diagnosis of heating, ventilation and air conditioning systems [J]. Building and Environment, 2023, 237:110328.

- [10] 李巍华,何琛,陈祝云,等. 基于对称式对比学习的齿轮箱无监督故障诊断方法[J]. 仪器仪表学报,2022,43(3):121-131.
LI W H, HE CH, CHEN ZH Y, et al. Unsupervised fault diagnosis of gearbox based on symmetrical contrast learning[J]. Chinese Journal of Scientific Instrument, 2022, 43(3):121-131.
- [11] 徐卓飞,李旭东,张婵婵,等. 基于孪生网络的小样本滚动轴承故障诊断研究[J]. 仪器仪表学报,2022,43(10):241-251.
XU ZH F, LI X D, ZHANG CH CH, et al. Fault diagnosis of rolling bearings with limited samples based on siamese network[J]. Chinese Journal of Scientific Instrument, 2022, 43(10):241-251.
- [12] LI G N, WANG L H, SHEN L M, et al. Interpretation of convolutional neural network-based building HVAC fault diagnosis model using improved layer-wise relevance propagation[J]. Energy and Buildings, 2023, 286:112949.
- [13] HAN S Y, SHAO H D, HUO ZH Q, et al. End-to-end chiller fault diagnosis using fused attention mechanism and dynamic cross-entropy under imbalanced datasets[J]. Building and Environment, 2022, 212:108821.
- [14] JIANG ZH H, RISBECK M J, SAMY S C K, et al. A timeseries supervised learning framework for fault prediction in chiller systems[J]. Energy and Buildings, 2023, 285:112876.
- [15] CHEN ZH H, CHEN J L, FENG Y, et al. Imbalance fault diagnosis under long-tailed distribution: Challenges, solutions and prospects[J]. Knowledge-Based Systems, 2022, 258:110008.
- [16] 李川,伍依凡,杨帅. 不平衡分布的数据驱动故障诊断的研究进展[J]. 仪器仪表学报,2023,44(8):181-197.
LI CH, WU Y F, YANG SH. Research progress of fault diagnostics driven by imbalanced data distribution[J]. Chinese Journal of Scientific Instrument, 2023, 44(8):181-197.
- [17] 汤健,崔璨麟,夏恒,等. 面向复杂工业过程的虚拟样本生成综述[J]. 自动化学报,2024,50(4):688-718.
TANG J, CUI C L, XIA H, et al. A survey of virtual sample generation for complex industrial processes[J]. Acta Automatica Sinica, 2024, 50(4):688-718.
- [18] QIAN M, LI Y F. A weakly supervised learning-based oversampling framework for class-imbalanced fault diagnosis[J]. IEEE Transactions on Reliability, 2022, 71(1):429-442.
- [19] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: Synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16:321-357.
- [20] ZHOU ZH X, CHEN H X, LI G N, et al. Data-driven fault diagnosis for residential variable refrigerant flow system on imbalanced data environments[J]. International Journal of Refrigeration, 2021, 125:34-43.
- [21] SHEN C X, ZHANG H Y, MENG S P, et al. Augmented data driven self-attention deep learning method for imbalanced fault diagnosis of the HVAC chiller[J]. Engineering Applications of Artificial Intelligence, 2023, 117:105540.
- [22] WANG ZH J, HE X X, YANG B, et al. Subdomain adaptation transfer learning network for fault diagnosis of roller bearings[J]. IEEE Transactions on Industrial Electronics, 2022, 69(8):8430-8439.
- [23] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11):139-144.
- [24] YAN K, CHONG A, MO Y CH. Generative adversarial network for fault detection diagnosis of chillers[J]. Building and Environment, 2020, 172:106698.
- [25] YAN K. Chiller fault detection and diagnosis with anomaly detective generative adversarial network[J]. Building and Environment, 2021, 201:107982.
- [26] DU ZH M, CHEN K, CHEN S L, et al. Deep learning GAN-based data generation and fault diagnosis in the data center HVAC system[J]. Energy and Buildings, 2023, 289:113072.
- [27] JIANG K X, GAO X J, GAO H H, et al. VIT-GADG: A generative domain-generalized framework for chillers fault diagnosis under unseen working conditions[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72:3527413.
- [28] LAINE S, AILA T. Temporal ensembling for semi-supervised learning[J]. ArXiv preprint arXiv:1610.02242, 2016.
- [29] TARVAINEN A, VALPOLA H. Mean teachers are better role models: Weight-averaged consistency targets improve semi-supervised deep learning results[J]. ArXiv preprint arXiv:1703.01780, 2017.
- [30] MIYATO T, MAEDA S, KOYAMA M, et al. Virtual adversarial training: A regularization method for supervised and semi-supervised learning[J]. IEEE

Transactions on Pattern Analysis and Machine Intelligence, 2019, 41(8):1979-1993.

- [31] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J]. ArXiv preprint arXiv:1411.1784, 2014.
- [32] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks [C]. International Conference on Machine Learning. PMLR, 2017: 214-223.
- [33] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of wasserstein gans[J]. ArXiv preprint arXiv:1704.00028, 2017.
- [34] COMSTOCK M C, BRAUN J E, BERNHARD R. Development of analysis tools for the evaluation of fault detection and diagnostics in chillers [M]. Purdue University, 1999.
- [35] JIANG K X, GAO X J, HAN H Y, et al. ECMFGN: Extended conditional mapping feature generation network for severe few-shot fault diagnosis of chillers[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74:1-13.

作者简介



高学金, 2006 年在北京工业大学获得博士学位, 现为北京工业大学教授, 主要研究方向为间歇过程智能监测与故障诊断, 复杂系统故障诊断、寿命预测与性能评估。

E-mail: gaouxuejin@bjut.edu.cn

Gao Xuejin received his Ph. D. degree from Beijing University of Technology in 2006. He is currently a professor at Beijing University of Technology. His main research interests include intelligent monitoring and fault diagnosis of batch process, fault diagnosis, life prediction, and performance evaluation of complex systems.



吴浩宁, 2022 年在北京化工大学获得学士学位, 现为北京工业大学硕士研究生, 主要研究方向为智能故障诊断、深度学习理论研究及应用。

E-mail: kevinwuhaoning163.com

Wu Haoning received his B.Sc. degree from Beijing University of Chemical Technology in 2022. He is currently a M. Sc. candidate at Beijing University of Technology. His main research interests include intelligent fault diagnosis, deep learning theory and application.



高慧慧 (通信作者), 2017 年在北京化工大学获得博士学位, 现为北京工业大学副教授, 主要研究方向为智能数据解析, 工业过程安全监控, 关键设备健康管理。

E-mail: gaohh@bjut.edu.cn

Gao Huihui (Corresponding author) received her Ph. D. degree from Beijing University of Chemical Technology in 2017. She is currently an associate professor at Beijing University of Technology. Her main research interests include Intelligent data analysis, safety monitoring of industrial processes and Health management of critical equipment.



齐咏生, 2011 年在北京工业大学获得博士学位, 现为内蒙古工业大学教授, 主要研究方向为复杂工业过程的故障监测与诊断, 风力发电机组状态评估、故障监测与故障诊断, 移动机器人的协同控制技术。

E-mail: qys@imut.edu.cn

Qi Yongsheng received his Ph. D. degree from Beijing University of Technology in 2011. He is currently a professor at Inner Mongolia University of Technology. His research interests include fault detection and diagnosis of complex industrial processes, condition assessment, fault detection and fault diagnosis of wind turbines, cooperative control technology of mobile robots.