

改进GAN数据增强的小样本管道漏磁缺陷识别 *

温江涛^{1,2} 闫 鹏¹ 周家鑫¹ 孙洁娣³

(1. 燕山大学电气工程学院 秦皇岛 066004; 2. 燕山大学河北省测试计量技术及仪器重点实验室 秦皇岛 066004;
3. 燕山大学信息科学与工程学院 秦皇岛 066004)

摘要:针对复杂管道漏磁缺陷识别研究中,因实际漏磁缺陷样本数量少、差异大导致的智能识别模型在实际应用中性能不佳的问题,提出了一种基于改进生成对抗网络的数据增强方法。首先,该方法研究了多类别混合估计的方法为生成器提供原始信号的先验信息,改进生成器的随机噪声输入,同时在生成器网络中引入多头注意力机制以捕获全局关键特征,提高生成样本质量;然后,研究了基于变分自编码重构误差的样本筛选方法,从生成样本中选取质量更高的样本,用来改善识别模型的训练效率;最后,将筛选出的生成样本及原始样本组合构成缺陷样本数据集,实现了数据增强。为验证数据增强效果,实验中采用常用的分类方法对扩充后的漏磁缺陷信号进行分类识别,实验结果表明,改进的方法在样本量较小的情况下平均识别准确率可达93%,相比其他类似方法具有更好的性能。

关键词:管道漏磁检测;小样本;生成对抗网络;多头注意力;多类别混合估计;样本筛选

中图分类号: TN06; TE88 **文献标识码:** A **国家标准学科分类代码:** 440.55

Small samples defect recognition for pipeline magnetic flux leakage based on improved GAN data augmentation

Wen Jiangtao^{1,2} Yan Peng¹ Zhou Jiaxin¹ Sun Jiedi³

(1. School of Electrical Engineering, Yanshan University, Qinhuangdao 066004, China; 2. Key Laboratory of Measurement Technology and Instrumentation of Hebei Province, Yanshan University, Qinhuangdao 066004, China; 3. School of Information Science and Engineering, Yanshan University, Qinhuangdao 066004, China)

Abstract: In the study of pipeline magnetic leakage detection, intelligent recognition models often struggle due to the limited number and significant variability of defect samples. To address this, a data augmentation method based on an improved Generative Adversarial Network is proposed. A multi-class mixed estimation approach provides prior information to the generator, enhancing its random noise input. A multi-head attention mechanism is integrated into the generator to capture global features, improving the quality of generated samples. Additionally, a sample selection method based on variational autoencoder reconstruction error filters higher-quality generated samples, improving the training efficiency of the recognition model. Finally, selected generated and original samples are combined to form an augmented defect sample dataset. Classification methods are applied to classify the augmented leakage magnetic defect signals. Results show that under small sample conditions, the proposed method achieves an average recognition accuracy of 93%, outperforming similar methods.

Keywords: pipeline magnetic leakage detection; small samples; generated adversarial network; multi-head attention; multi-class mixed estimation; sample selection

0 引言

管道是石油天然气等能源介质相对安全、可靠的运输方式,但由于制造及焊接缺陷、局部损伤、腐蚀等导致的管道事故极大的威胁到管道安全运行,因此进行管道缺陷检测研究具有重要意义^[1]。基于不同的原理,油气金属管道缺陷检测方式有涡流法^[2]、超声波法^[3]、管道内漏磁法^[4]、金属磁记忆法^[5]等,涡流法和超声波法依赖于外部激励源,管道内漏磁法需要在管道内放入漏磁检测器,若出现停机故障则影响管道的运行,金属磁记忆法与其他缺陷检测方式相比,无需开挖和外加激励,且不影响管道正常运行,是实现管道缺陷检测的有效方式。

管道不同缺陷导致的漏磁信号受管道材料、缺陷类型、环境等多方面因素的影响,会呈现不同的特点,传统的管道缺陷数据分析方法通常先提取时域、频域或者其他变换域的特征作为漏磁信号特征,然后利用机器学习算法实现漏磁缺陷的分类^[6]。王贵生等^[7]通过提取时域、形态、频域3种不同特征量,建立了支持向量机(support vector machine, SVM)模型对实验管道的腐蚀程度进行识别;赵翰学等^[8]提取了漏磁检测信号的4种特征值,采用支持向量机、随机森林(random forest, RF)以及梯度提升决策树3种机器学习算法对缺陷信号特征量进行分类识别;张勇等^[9]提出一种基于散布熵和峭度的特征提取法,将提取的特征参数作为支持向量机的输入,可以有效识别和分类输油管道的工况;Liu等^[10]提取了漏磁缺陷的对比度、中心点等4种特征,利用支持向量机、随机森林和K近邻(K-nearest neighbor, KNN)方法对漏磁图像正常区域和缺陷区域进行检测分类。传统方法将特征提取及分类分别进行,并且严重依赖专业的信号处理知识及诊断经验。

近年来,基于深度学习的特征学习及模式分类方法在很多工程领域得到了广泛研究,相较于传统的机器学习,深度学习通过多层神经网络直接从原始数据自动提取高层次特征而无需人工干预,可以取得较好的诊断性能。Luo等^[11]利用一维卷积神经网络,实现了对金属管道制造工艺中产生的溅射、裂纹和气孔等缺陷的识别。施佳椰等^[12]提出一种基于卷积胶囊网络的油套管变形程度评估方法,通过设计多个卷积层对涡流信号进行特征提取,取得了较好的变形量化精度。梁海波等^[13]提出变分自编码结合一维卷积神经网络与随机森林的缺陷识别方法,对腐蚀缺陷进行特征提取和分类,可以有效识别天然气钢制管道的健康状况。深度学习模型的分类效果依赖于训练样本的数量,如果训练样本有限,则提取的特征信息有限,训练模型可能出现难以达到拟合状态等问题,从而影响缺陷识别精度。油气管道实际运行的大部

分时间都处于健康状态,获取大量的缺陷信号较为困难,因此研究数据增强方法,对有限的漏磁缺陷样本进行高质量的扩充,能够改善因训练过程中真实样本不足导致的模型准确度不高、泛化能力差的状况。

管道缺陷本质上可视为管道的故障状态,因此可以借鉴故障诊断领域的一些分析方法。生成对抗网络(generative adversarial network, GAN)^[14]是近年来基于深度神经网络发展起来的一类较为有效的数据增强方法,并广泛应用于故障诊断领域。Wang等^[15]利用WGAN(Wasserstein GAN)对获取困难的机械故障信号进行扩展,结合真实信号和生成信号训练堆叠自编码器来检测机械设备的健康状态。张永宏等^[16]提出了一种变分自编码生成式对抗网络对故障样本进行数据增强,训练卷积故障分类器来实现小样本滚动轴承故障分类。Dixit等^[17]提出了一种结合元学习的新型条件辅助分类器(auxiliary classifier GAN, ACGAN)框架,并通过轴承数据集和空压机数据集对方法进行验证。Fu等^[18]提出Transformer和辅助分类器结合的生成网络用于轴承故障诊断。GAN能够在随机噪声的基础上,通过深度模型对真实样本的学习,尽可能的捕获给定真实样本的特征分布,生成具有和真实数据相似分布的新样本,在一定程度上缓解数据不足问题。

以上方法均取得了良好的分类效果,但是一方面漏磁缺陷信号的样本较少,不同类型的缺陷信号差别较大,GAN网络难以学习到真实样本的分布,特征网络学习能力不足进而影响生成样本的质量;另一方面质量不佳的生成样本用来训练分类模型,会对模型性能产生较大影响。如何让GAN网络更好的学习到真实缺陷样本的分布,并挖掘关键的特征信息,在增加生成样本数量的同时减少低质量数据的产生,具有重要的理论研究和实际意义。

针对复杂的管道缺陷识别研究中,因漏磁样本量少导致缺陷识别模型性能不佳的问题,本文提出了优化随机噪声输入和改进生成器网络结构的方法。该方法首先基于多类别高斯混合估计的方法优化生成器的随机输入噪声,为生成器提供原始信号的先验知识,使生成器输入更接近原始样本;同时引入多头注意力机制来捕捉全局关键的特征信息,进一步改善网络学习能力。另一方面,为改善生成样本的质量,本文研究了基于重构误差的生成样本选择方法,通过变分自编码器(variational auto-encoder, VAE)网络学习真实样本和生成样本的潜在分布并重构输入,获得重构误差,将重构误差作为选择指标,筛选出高质量的漏磁生成样本。

实验结果及分析表明,相比传统方法,本文所提出的方法通过学习有限缺陷样本,即可产生高质量的生成样本,并显著提高管道缺陷的分类识别准确率。

1 基于改进生成对抗网络的漏磁样本增强

传统的生成对抗网络 GAN 输入为随机噪声, 对复杂信号特征的学习能力不足, 且存在训练不稳定等问题, 为此本文以特征学习能力和训练稳定性更具优势的 CWGAN-GP (conditional Wasserstein GAN-gradient penalty) 网络为基础, 并进一步从输入和网络结构角度来改善学习能力, 提出了基于多分布混合噪声输入及引入多头注意力机制的改进措施, 优化生成网络的性能。

1.1 CWGAN-GP 概述

CWGan-GP^[19] 是一种改进的 WGAN-GP 模型, WGAN-GP 将传统 GAN 中的 JS 散度 (Jensen-Shannon divergence) 转换为 Wasserstein 距离, 并引入梯度惩罚项, 显著缓解了传统 GAN 训练中的模式崩溃、梯度消失和爆炸问题, 使模型训练更为稳定, CWGAN-GP 则是在此基础上引入条件信息, 将类别标签和信号样本一起输入生成器, 使生成器在标签引导下生成符合特定条件的信号, 提升生成信号的准确性和多样性, 在图像、文本生成等多个领域展示了其优越的性能^[20-21]。

CWGan-GP 网络由生成器和判别器组成, 其中生成器利用随机噪声生成与真实数据分布相同的数据样本, 判别器来评估输入数据是生成数据或真实数据, 当判别器无法识别输入样本是真实的样本还是生成样本时即达到训练目的。CWGAN-GP 网络的损失函数如下:

$$L(G) = -E_{x \sim P_x} [D(x | y)] \quad (1)$$

$$L(G) = -E_{x \sim P_x} [D(x | y)] + E_{x \sim P_x} [D(x | y)] + \lambda E_{x \sim P_x} [(\|\nabla_x D(x | y)\|_p - 1)^2] \quad (2)$$

式中: x 表示真实的数据; 条件变量 y 即为数据的标签; $\nabla_x D(x | y)$ 表示判别器梯度。将标签数据和漏磁缺陷数据一起输入生成器, 生成器在标签引导下生成新的漏磁样本。

CWGan-GP 性能较传统 GAN 有了较大改善, 但是其输入仍然是先验分布较为单一的噪声, 因此在生成信号的多样性方面存在不足; 此外对不同类型复杂漏磁信号的特征学习能力也需要提高, 因此, 为提高生成样本的多样性, 增强网络模型捕捉复杂信号特征的能力, 本文考虑从网络输入和网络结构两个角度改进 CWGAN-GP 生成器。

1.2 基于多类别混合分布估计的噪声输入

生成器网络的输入通常是满足正态分布或均匀分布的随机噪声, 不考虑任何原始数据的先验知识、通过生成器和鉴别器的相互作用以及对大量样本的学习, 产生尽可能接近真实分布的新数据, 但是在不同类型的缺陷样本量较小、且有一定差异性的情况下, 生成样本的质量会

受到较大影响, 因此如能在输入阶段获取一定的分布信息, 就能够使生成器即使在小样本情况下也能够产生更接近真实样本的数据。

高斯混合模型 (Gaussian mixture model, GMM) 由多个高斯分布函数的线性组合构成, 理论上能够拟合任意类型的分布。每一种漏磁缺陷类别 (凹坑、凹坑+裂纹、裂纹) 均表现出多特征融合特性, 其幅值、波形和空间分布等信息相互关联并共同反映缺陷特性, GMM 通过调整多个高斯分布的均值和方差, 可以拟合复杂的分布特性。

本文引入多类别高斯混合模型拟合漏磁信号的分布, 随后将拟合结果作为生成模型的噪声输入。改进后的输入噪声不仅具有随机性, 还嵌入了漏磁信号的粗略特征, 将其作为生成器的噪声输入, 能够为生成器提供一定的先验知识, 有助于训练时生成样本逼近原始分布, 并改善生成样本的多样性。假设采集到某类缺陷信号数据集, 该类型漏磁信号分布可用 K 个高斯分布来拟合, 各分布用 P_1, P_2, \dots, P_k 表示, 则输入信号分布的拟合过程如图 1 所示。

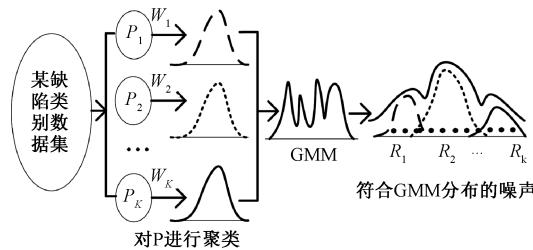


图 1 缺陷集 P 中由 k 类分布拟合噪声输入

Fig. 1 Improved noise input fitted by k -class in defect set P

类别数量 K 对拟合结果有重要影响, 其本质上表明同类型样本中存在 K 类分布有一定差异的数据, 具体表现为样本中会呈现不同的聚类。本文采用了 K 均值^[22] 算法进行缺陷故障信号的内部聚类分析, 并进一步基于戴维森堡丁指数 (Davies-Bouldin index, DBI)^[23] 指数确定 K 的取值。DBI 是一种评估聚类算法效果的指标, 它通过衡量簇内紧密度和簇间分离度综合评估聚类结果的质量。DBI 值越小, 表示聚类效果越好, 簇内紧密且簇间分离明显。通过 DBI 评估不同聚类数 K 的效果, 并选择 DBI 最小的 K 值作为某类缺陷集的聚类数。

DBI 先计算每个簇内散度 S_K 和簇间分离度 D_{K_1, K_2} , 然后通过相似性度量获得每对簇之间的相似性。对于每个簇, 找到与其最相似的簇并记录相似性, 最后将所有簇最大相似性的平均值作为 DBI 的值。公式如下:

$$P_k = \{x_{K,i} | x_{K,i} \in R^n, i = 1, 2, \dots, |P_K|\} \quad (3)$$

$$S_K = \frac{1}{|P_K|} \sum_{x \in P_K} \|x_{K,i} - a_K\| \quad (4)$$

$$D_{K_1, K_2} = \|a_{K_1} - a_{K_2}\| \quad (5)$$

$$R_{K_1, K_2} = \frac{S_{K_1} + S_{K_2}}{D_{K_1, K_2}} \quad (6)$$

$$DBI = \frac{1}{K} \sum_{i=1}^K \max_{i \neq K_1, K_2} (R_{K_1, K_2}) \quad (7)$$

式中: K 是聚类总数; P_K 是第 K 个簇的样本集合; $x_{K,i}$ 是簇 P_K 的样本; $|P_K|$ 是簇 P_K 中样本的数量; S_K 表示簇内散度; a_K 表示聚类中心; D_{K_1, K_2} 表示簇间分离度; R_{K_1, K_2} 表示簇的相似性。

通过对缺陷集进行聚类, 缺陷集的样本被划分到了 K 个簇 P_1, P_2, \dots, P_K 中。在特征空间中每一个簇都符合高斯分布, 用高斯概率密度函数来拟合每个簇 P_K , 其中高斯分布的均值向量 μ_K 为簇中所有样本的均值, 协方差矩阵 Σ_K 用于描述簇内数据的相关性, μ_K 和 Σ_K 的计算公式如式(8)和(9)所示, 簇 P_K 的高斯分布概率密度函数如式(10)所示。最后利用 K 个高斯概率密度函数, 构建多分布混合 GMM, 如式(11)所示。

$$\mu_K = \frac{1}{|P_K|} \sum_{i=1}^{|P_K|} x_{K,i} \quad (8)$$

$$\Sigma_K = \frac{1}{|P_K|} \sum_{i=1}^{|P_K|} (x_{K,i} - \mu_K)(x_{K,i} - \mu_K)^T \quad (9)$$

$$N(x | \mu_K, \Sigma_K) = \frac{1}{(2\pi)^{n/2} |\Sigma_K|^{1/2}} e^{-\frac{1}{2}(x - \mu_K)^T \Sigma_K^{-1} (x - \mu_K)} \quad (10)$$

$$N(x | \mu, \Sigma) = \sum_{k=1}^K \frac{|P_k|}{|P|} N(x | \mu_k, \Sigma_k) \quad (11)$$

式中: Σ_K 是 P_K 的协方差矩阵; n 表示数据的维度; $\mu = (\mu_1, \mu_2, \dots, \mu_K)$; $|P|$ 表示所有簇中总样本的个数; $\Sigma = (\Sigma_1, \Sigma_2, \dots, \Sigma_K)$ 。

通过将原始漏磁信号的先验知识融入到输入噪声 z 中, 为数据生成提供先验分布, 使得新样本能在产生之初就更加贴近真实样本, 后续仅通过少量真实样本的校正即可产生质量较好的生成样本。

1.3 多头注意力机制改进的生成网络

为了更好的增强生成网络模型对复杂漏磁信号特征的捕捉能力, 聚焦重要的特征信息, 本文在生成器中引入多头注意力机制^[24-25], 通过并行执行多个独立的注意力机制, 从不同的子空间提取信息, 提高生成模型捕捉全局关键漏磁特征的能力, 从而增强模型对复杂信号的理解和生成能力, 改善样本生成质量。

假设输入的漏磁信号数据为 X , 经过线性变换生成查询集 Q , 键 K 和值 V , 将漏磁信号的输入映射到不同的特征子空间, 以捕捉多尺度的信号特征。公式如式(12)所示。

$$Q = XW^Q, K = XW^K, V = XW^V \quad (12)$$

式中: W^Q, W^K, W^V 表示不同的权重矩阵。

对于单个注意力头, 利用缩放点积注意力机制计算漏磁特征之间的相关性, 并通过权重调整特征的重要性, 使模型聚焦于信号中有代表性的特征区域, 忽略不必要的背景噪声, 如式(13)所示。

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_K}}\right)V \quad (13)$$

式中: QK^T 为查询和键的点积, 用来衡量不同漏磁信号特征之间的相似度; $\sqrt{d_K}$ 为缩放因子。

为更全面提取漏磁信号的复杂特征, 引入 h 个独立的注意力头, 每个头关注不同的特征子空间, 如式(14)所示。

$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (14)$$

式中: 其中 $W_i^Q, W_i^K, W_i^V, i = 1, 2, \dots, h$, 表示第 i 个头的独立权重矩阵。通过并行的多个注意力头, 模型能够从不同视角提取漏磁信号的局部与全局特征, 提升对复杂信号的理解能力。

最后将 h 个注意力头的输出拼接, 通过线性变换 W_o 还原维度, 使其与原始输入保持一致, 公式如式(15)所示。

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h)W_o \quad (15)$$

将多个注意力头提取的信息进行融合, 实现对漏磁信号特征的全局捕捉能力, 使生成网络可以整合多角度的特征信息, 改善样本的生成质量。

2 基于 VAE 重构误差的生成样本筛选

改进的生成模型可以生成大量的漏磁缺陷样本, 但生成的样本质量有差异, 质量不高的生成样本会给分类识别过程带来负面影响, 因此筛选质量更高的样本有助于改善分类识别性能, 为此, 本文研究了基于 VAE 重构误差的方法^[26-27], 对生成的新样本进行质量评估。经过训练的 VAE 模型对数据进行解码和编码, 得到重构误差, 若重构误差大于阈值, 则可认为生成数据与原样本差异较大, 生成质量不佳, 通过此方法可以选择生成数据的高质量子集, 采用筛选得到的样本训练缺陷分类模型, 可以进一步提高分类识别准确率。

2.1 样本筛选网络

图 2 所示为生成样本的筛选网络。筛选网络由编码器和解码器组成, 编码器和解码器的网络结构都是由两个全连接层组成, 使用 Leaky Relu 作为激活函数。编码器将输入数据转换到潜在空间, 并输出潜在变量的均值向量 μ 和标准差向量 σ , 基于 μ 和 σ , 编码器使用重参数化方法生成潜在变量 Z , 如式(16)所示。解码器将潜

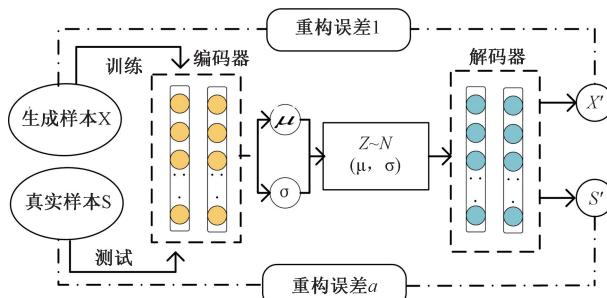


图 2 生成样本筛选网络

Fig. 2 Selecting network for generated sample

在变量 Z 重新映射回原始数据空间，并重构出与原始输入数据形状近似的输出数据。

$$Z = \mu + \sigma * \varepsilon \quad (16)$$

式中： ε 表示标准正态分布的随机噪音； $\sigma * \varepsilon$ 表示对标准正态噪音按标准差进行调整。

在训练阶段，VAE 筛选网络通过 Adam 优化器对总损失函数进行优化来更新模型参数，总损失函数为 KL(Kullback-Leibler) 散度和均方根误差 (mean squared error, MSE) 之和。其中 KL 散度表示先验分布和编码器输出分布之间的差异，约束了潜在空间的分布，但单独使用 KL 散度，模型不会关注数据的重构相似度。MSE 直接衡量输入数据和重构数据的相似度，确保解码器能够重建出尽可能接近于真实数据的输出，但单独使用 MSE，潜在空间 Z 的分布可能是无序的，影响重构效果。将 KL 和 MSE 相结合，可以平衡数据重构和潜在空间的分布约束，共同优化 VAE 对输入数据的重构过程。重构误差的损失函数如下：

$$L_{VAE} = L_{MSE} + L_{KL} \quad (17)$$

$$L_{MSE} = \frac{1}{d} \| X_i - \hat{X}_i \|^2 = \frac{1}{d} \sum_{j=1}^d (x_{ij} - \hat{x}_{ij})^2 \quad (18)$$

$$L_{KL} = -\frac{1}{2} \sum_{j=1}^d (1 + \log(\sigma_j^2) - \mu_j^2 - \sigma_j^2) \quad (19)$$

式中： X_i 是输入数据样本； \hat{X}_i 是解码器重构数据样本； x_{ij} 和 \hat{x}_{ij} 分别是样本第 j 个特征的输入值和重构值； μ 和 σ 是编码器输出的均值向量和方差向量； d 表示样本维度。

在训练完成且模型稳定后，编码器和解码器已经学习到了输入数据的潜在表示和重构能力。将训练样本重新输入到训练后的 VAE 网络中，可以得到输入样本的重构误差。

2.2 基于重构误差的样本筛选过程

图 3 所示为生成样本的筛选方法。

1) 从某类别的生成样本数据集中随机选择 m 个样本作为训练集来训练 VAE 网络，网络经过不断地迭代优

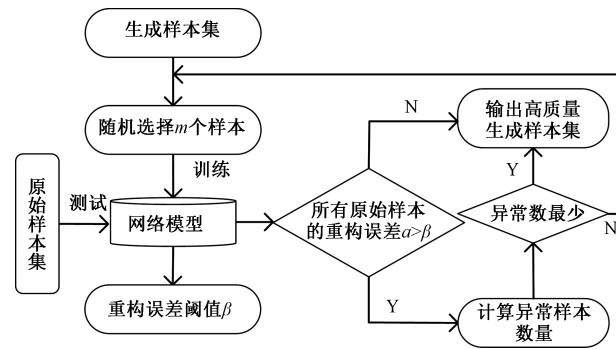


图 3 生成样本筛选过程

Fig. 3 Selection process of the generated samples

化趋于稳定；然后将训练集重新输入，得到训练集中所有样本的重构误差集合，如式(20)所示。

$$L = \{l_1, l_2, \dots, l_m\} \quad (20)$$

使用 MSE 作为指标评估生成样本的重建质量，计算公式如式(21)所示。

$$l_i = \frac{1}{d} \| X_i - \hat{X}_i \| = \frac{1}{d} \sum_{j=1}^d (x_{ij} - \hat{x}_{ij})^2 \quad (21)$$

式中： l_i 为生成样本 X_i 的重构误差； d 是样本维度； L 为输入样本的重构误差集合。

本文采用重构误差排序的方法来动态确定重构误差阈值 β ，使该阈值可以根据数据特性自适应的调整。将误差集合按照从小到大的顺序排列，设定异常比例 r 表示生成样本中低质量样本的占比，所有样本中的后 r 占比的数据对应的重构误差值作为阈值 β ，通过此方式，阈值 β 会根据数据的重构误差分布和异常比例自动调整。本文选择 r 为 0.1。

2) 使用上述经过生成样本训练的 VAE 网络对原始样本测试集进行编码和解码，得到原始样本重构误差集合 A 。

$$A = \{a_1, a_2, \dots, a_m\} \quad (22)$$

式中： a_i , $i = 1, 2, \dots, m$, 表示原始样本的重构误差。

每个原始样本通过训练后的 VAE 网络得到的 a_i 应小于重构误差阈值 β ，但由于训练集中存在部分低质量的数据，影响了 VAE 网络的重构能力，进而导致部分原始样本的重构误差大于阈值 β ，故当 $a_i > \beta$ 时表示该原始样本被误判为异常。因此可以通过计算测试集中原始样本被误判的异常数量，来量化训练集中生成样本的质量。被误判的异常数量越大，说明训练数据中低质量的生成样本比例越高，对 VAE 网络的重构能力产生了较大的负面影响，反之则表明训练集的质量越高。

3) 重复上述 1) 和 2) 过程 n 次，可以得到 n 个异常数量。选择 n 个异常数量中的最小值所对应的训练集作为高质量生成样本集。

3 本文方法的处理过程

针对由于管道漏磁信号复杂、真实样本较少导致的深度神经网络类管道缺陷识别方法效果差的问题,本文提出了基于改进生成网络的数据生成及误差重构筛选的小样本管道漏磁分类识别方法。首先引入高斯混合模型

从不同缺陷类别的分布中得到包含不同类别原始信号的先验知识,实现生成器有针对性的学习特征;生成网络中引入多头注意力机制,增强对关键特征的捕捉能力;生成样本进一步通过筛选网络,改善样本的质量,最后用4种机器学习算法对缺陷进行分类识别,比较增强效果。本文方法的整体流程如图4所示。

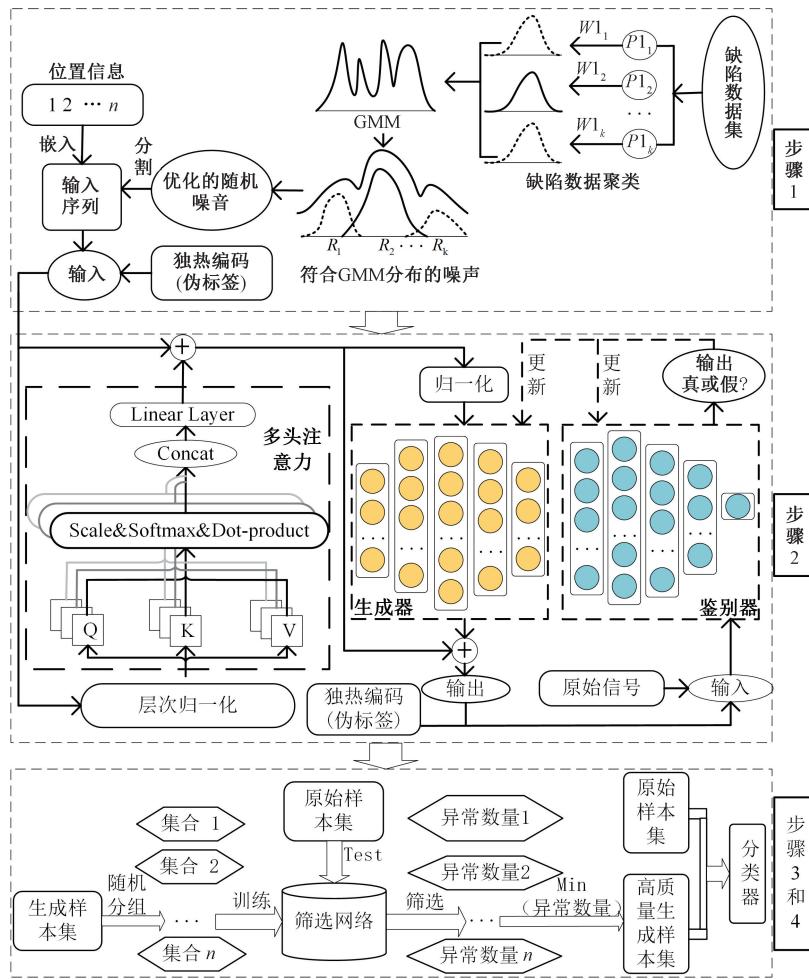


图4 本文方法处理过程

Fig. 4 Procedure of the proposed method

步骤1) 噪声优化,将漏磁缺陷数据集按不同缺陷类别分别进行聚类,来获得各类别的高斯混合分布。然后根据类别标签,可以得到服从对应高斯混合分布的噪声。

步骤2) 漏磁新样本生成,训练生成对抗网络模型直至生成器和判别器达到平衡且网络收敛。最终生成每个类别的新漏磁样本集。

步骤3) 生成样本的筛选,从每种缺陷类型的生成样本集中随机选择m个生成样本训练筛选网络。重复随机选择过程,选择最小的异常数量所对应的生成样本集

作为高质量生成样本集。

步骤4) 分类模型训练与缺陷识别,将生成样本与真实样本合并,作为训练集来训练识别模型,实现管道缺陷的识别。

本文研究了基于改进生成对抗网络及样本筛选的数据增强类缺陷识别方法,为验证本文方法的样本生成质量,选用RF、SVM、多层感知机(multilayer perceptron, MLP)、KNN 4种常用分类方法,实现小样本漏磁缺陷信号的分类识别,并分析识别效果。

4 实验及结果分析

4.1 实验数据来源

为验证所提方法的有效性,进行实验数据处理及结果分析。缺陷数据来自直径 8 mm、壁厚 2 mm、总长 2 m 的小口径无缝钢管,通过机械加工,在管道上模拟产生凹坑、凹坑+裂纹、裂纹 3 种缺陷,检测设备分别采集此 3 类缺陷及正常管道漏磁共 4 种类型信号。以连续 5 个信号为窗口提取原始数据和梯度数据的最小值、最大值、平均值等特征向量,漏磁缺陷特征样本数据集共 440 个样本,其中各类训练样本 60 个,测试样本 50 个,如表 1 所示。

表 1 缺陷状态标签及数量

Table 1 Tags and quantity of defects

缺陷状态	标签	训练集	测试集
正常	0	60	50
凹坑	1	60	50
裂纹	2	60	50
裂纹+凹坑	3	60	50

4.2 本文方法在不同小样本下的缺陷识别结果

按照本文方法构建小样本漏磁缺陷分类识别网络,每种缺陷类型的样本量分别为 5、10、20、30,并进行 10 次重复实验,统计实验结果如表 2 所示。

表 2 不同样本量下的缺陷识别结果

Table 2 Identification results under different sample sizes

样本量	分类方法	准确率/%	标准差/%
5	RF	60.72	2.20
	SVM	58.29	1.34
	MLP	58.18	2.78
	KNN	60.46	0.95
10	RF	75.99	0.86
	SVM	74.74	0.78
	MLP	76.02	1.08
	KNN	74.84	1.21
20	RF	86.38	0.74
	SVM	87.63	1.34
	MLP	86.50	0.88
	KNN	87.50	1.47
30	RF	93.03	0.94
	SVM	92.78	1.01
	MLP	92.68	0.73
	KNN	93.33	0.65

由表 2 可以看出,本文方法在样本相对较多的情况下实现的缺陷分类识别准确率保持在 92% 以上,样本极少的情况下准确率仍可达到 60%,且具有较低的标准偏差,表明了本文所提的方法在处理不同数量小样本下的缺陷识别问题时总体效果较好,而且可以适用不同的分

类器。

4.3 改进 CWGAN-GP 的消融实验

为探究对生成模型改进噪声和引入多头注意力时,生成的漏磁信号对缺陷分类识别效果的影响,重复 10 次实验比较原始 CWGAN-GP、改进噪声、引入多头注意力、同时改进噪声和引入多头注意力这 4 种生成模型在同一小样本数量下的缺陷识别结果,并分析结果。如图 5 和 6 均是在小样本量 30 的情况下引入不同方法的生成模型准确率和 F1 得分的识别结果,其中 F1 指标可以衡量模型整体的分类性能,是精确率和召回率的调和平均数。图 5 中的分类器选用了 SVM。

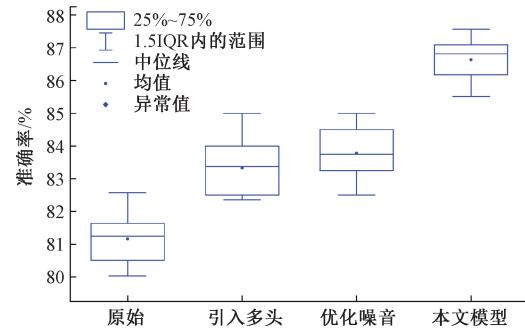


图 5 样本数量 30 情况下的消融实验准确率

Fig. 5 Accuracy of ablation experiments with sample size 30

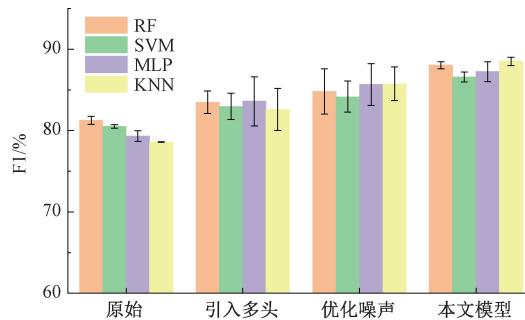


图 6 样本数量 30 情况下的消融实验 F1 得分

Fig. 6 F1 score of ablation experiments with sample size 30

从图 5 和 6 可以看出,分别引入两种方法对于 CWGAN-GP 生成模型的准确率和 F1 均有不同程度的提升,其中引入多头注意力机制相比于改进噪声方法效果稍好,两种方法叠加对于原始模型的准确率提升了 5% 左右。

图 7 所示为原始生成模型和本文生成模型的损失函数在不同迭代训练的变化对比。

由图 7(b)可以看到,本文模型在训练 500 次时,生成器和判别器已经达到了平衡,且生成器学习速度较快,在后续的训练中持续保持平稳;而原始模型在迭代 2 700 次时,生成器和判别器才达到平衡,训练过程中生成器

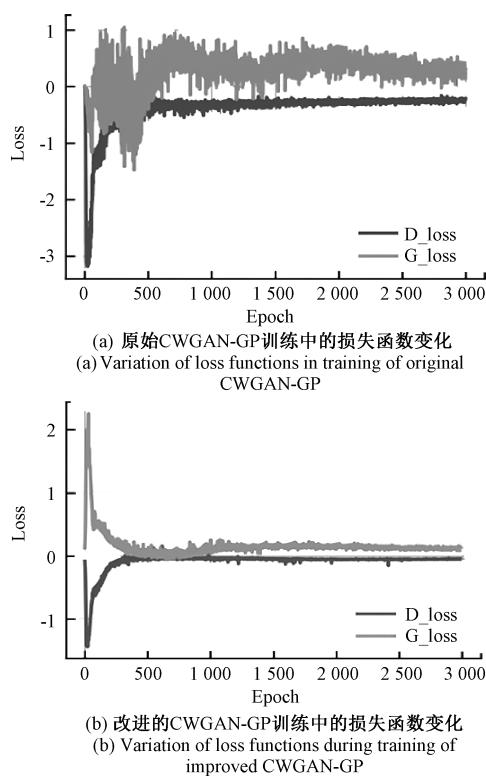


图7 CWGAN-GP 改进前后的损失函数变化对比

Fig. 7 Comparison of loss variations before and after CWGAN-GP improvement

的波动较为剧烈。

以上结果表明改进的生成模型可以更好的捕捉漏磁信号样本的特征,从而提升生成器学习漏磁缺陷信号特征的能力,提高有限样本下管道缺陷分类识别的准确度。

4.4 生成样本筛选的有效性验证

本文通过改进生成模型扩充缺陷信号样本数量,从而提升管道分类识别的准确率,但生成质量不佳的样本也会影响最终的缺陷分类准确度,为此对比了3种筛选机制的处理结果,来验证本文所提筛选方法的有效性。统计了在不同小样本训练下,生成样本数量同为1000时,本文生成的漏磁信号经过无筛选、采用集成筛选方法^[28]以及本文筛选方法3种筛选处理后的分类准确率对比,识别部分选用了RF、SVM、MLP、KNN 4种分类器,统计准确率结果如表3所示。

从统计结果可以看出,本文的筛选机制在不同数量的小样本下,准确率均高于无筛选机制和集成筛选机制。在真实样本为5的情况下,本文筛选机制准确率接近于60%,明显高于无筛选方法。在真实样本为30的情况下,3种方式的准确率较为接近,均可以达到85%以上。实验结果表明本文生成模型的性能较好,在样本数量较多的情况下,筛选方法可以在一定程度上提升模型性能。但在样本数量较少的情况下,生成的漏磁信号容易出现质量不稳定的情况,采用本文的筛选方法可以选出生成

表3 不同筛选方法在不同分类器下及样本量的准确率

Table 3 Classification accuracy of different screening methods across various classifiers and sample sizes

方法	分类器	不同样本数量的准确率/%			
		5	10	20	30
无筛选	RF	45.66±0.18	65.11±0.87	80.75±1.09	88.29±0.97
	SVM	43.28±1.23	64.63±0.27	81.47±1.38	86.63±0.59
	MLP	43.95±0.72	64.28±1.68	78.52±0.83	87.34±0.96
	KNN	44.71±0.33	63.18±0.12	81.93±0.59	88.61±1.06
集成筛选	RF	56.57±1.81	71.90±0.44	84.25±0.88	89.55±1.34
	SVM	53.24±1.14	71.66±0.35	86.16±1.51	90.02±2.64
	MLP	53.91±0.63	72.13±1.41	83.40±2.46	88.74±0.93
	KNN	54.71±0.33	72.39±2.42	84.52±1.66	90.92±2.27
本文	RF	59.66±1.26	75.99±0.13	86.37±2.72	93.00±2.75
	SVM	57.28±1.50	74.74±0.72	88.75±1.31	92.78±0.77
	MLP	56.44±1.42	76.02±2.81	86.50±2.74	92.68±1.31
	KNN	59.24±1.24	74.84±0.43	87.50±2.25	93.33±0.20

质量更好的漏磁信号,从而较大程度上提升管道缺陷的分类识别性能。

4.5 不同生成数量和筛选比例的比较

缺陷漏磁信号经生成模型生成的数量及筛选比例会对缺陷识别模型的分类效果产生重要影响。为探究不同的样本生成数量以及筛选比例对识别结果的影响,实验设置500、1000、1500三种不同的生成样本数量,以及

25%、50%、75% 3种不同的筛选比例,用不同的分类器进行10次重复实验,对缺陷分类识别效果进行分析,统计结果如表4所示。

从表4可以看出,多组实验中,在相同的筛选比例下,样本生成数量为1000时准确率最高,且具有较好的鲁棒性。在相同样本生成数量下,随着筛选比例的增加,分类识别准确率有一定程度的提高,但达到75%时,准确

率没有提升反而有所下降。以上结果表明,选取合适的生成数量和筛选比例对于提升样本生成的多样性、使生成样本与真实样本有更接近的分布,从而提升缺陷识别的准确率有重要作用。

表 4 不同生成样本数量及筛选比例下的缺陷分类效果

Table 4 Defect classification performance under varying generated sample quantities and screening ratios

不同筛选比例	25%		50%		75%	
	准确率/%	标准差	准确率/%	标准差	准确率/%	标准差
RF(500)	85.83	1.15	88.35	0.60	87.5	0.18
SVM(500)	85.27	0.32	89.44	0.85	88.65	0.65
MLP(500)	87.84	0.54	89.46	0.45	89.52	1.2
KNN(500)	86.33	0.12	90.23	0.58	88.47	0.11
RF(1 000)	88.33	0.12	93.03	0.4	91.66	0.13
SVM(1 000)	89.16	0.15	92.78	0.18	91.40	0.18
MLP(1 000)	89.45	0.10	92.68	0.21	90.30	0.27
KNN(1 000)	88.50	0.25	93.33	0.34	89.56	0.23
RF(1 500)	86.52	0.57	87.47	0.53	87.5	0.69
SVM(1 500)	85	0.23	88.64	0.31	86.96	0.48
MLP(1 500)	84.19	0.59	87.9	0.39	85.23	0.57
KNN(1 500)	86.54	0.34	89.23	0.55	87.19	1.09

4.6 不同数据增强方法生成信号的比较

近年来,许多学者采用不同的 GAN 网络研究小样本情况下的机械故障诊断,用于解决标注样本不足等问题,其中 VAE-GAN^[29]、DCGAN^[30]、ACGAN-DC^[31]等是常见的数据增强方法。管道缺陷本质上是通过分析振动信号而识别的故障,因此本节选用机械故障诊断领域常见的 3 种小样本数据增强方法与本文方法进行对比。为对比

生成样本有利于分类判别,将不同增强算法生成的样本进行特征提取结果用 t 分布随机近邻方法(t-distributed stochastic neighbor, t-SNE)进行可视化如图 8 所示。

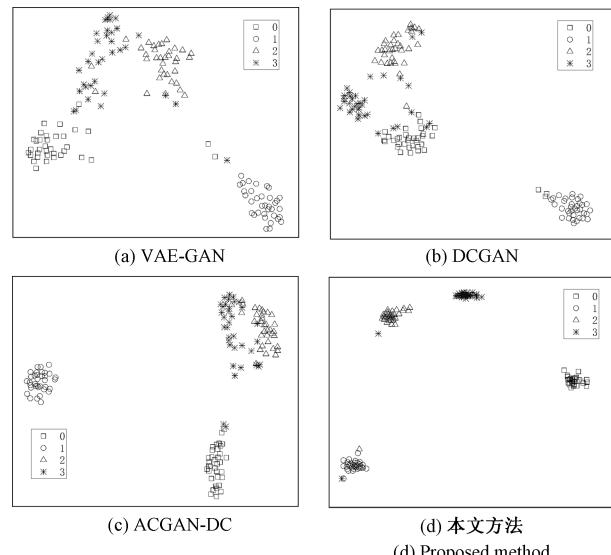


图 8 不同增强方法的生成样本的 t-SNE 特征图

Fig. 8 T-SNE visualization of generated samples from different augmentation methods

4.7 不同数据增强方法识别效果比较

由 4.6 节可以看到,与常用信号生成方法相比,本文方法生成信号的特征区分度更为明显。为了比较不同方法生成样本的故障诊断效果,将 4.6 节的增强算法与本文方法进行诊断性能对比。每种缺陷类型小样本数分别为 5、10、20、30,进行 10 次实验,4 种模型的分类识别结果如表 5 所示。

表 5 各数据增强方法在不同样本数量的准确率和 F1 得分

Table 5 Performance (accuracy/F1) of different data augmentation methods versus sample sizes

数据增强方法	分类器	5		10		20		30	
		Acc	F1-score	Acc	F1-score	Acc	F1-score	Acc	F1-score
VAE-GAN	RF	0.275 7	0.233 6	0.490 5	0.486 6	0.729 8	0.729 6	0.795 7	0.795 1
	SVM	0.288 6	0.226 8	0.442 2	0.397 1	0.736 6	0.734 4	0.825 2	0.826 1
	MLP	0.261 1	0.171 1	0.409 6	0.390 8	0.748 9	0.747 0	0.782 6	0.783 7
	KNN	0.294	0.226 8	0.394 3	0.337 4	0.736 6	0.734 7	0.823 5	0.824 3
DCGAN	RF	0.255	0.194 6	0.422 8	0.420 6	0.719 0	0.709 2	0.816 1	0.815 3
	SVM	0.278 7	0.199 8	0.410 6	0.351 9	0.730 7	0.723 2	0.810 2	0.805 7
	MLP	0.247 7	0.154 3	0.396 9	0.350 0	0.741 7	0.730 8	0.794 9	0.817 6
	KNN	0.280 1	0.196 2	0.405 6	0.387 5	0.723 9	0.712 0	0.814 2	0.808 9
ACGAN-DC	RF	0.310 1	0.2921	0.609 0	0.598 1	0.813 7	0.812 9	0.869 5	0.866 2
	SVM	0.287 4	0.254	0.584 9	0.573 1	0.791 5	0.790 5	0.857 0	0.852 7
	MLP	0.283 4	0.2436	0.557 0	0.572 0	0.815 5	0.808 4	0.841 0	0.832 3
	KNN	0.310 6	0.275 1	0.604 7	0.591 0	0.822 0	0.820 0	0.859 0	0.855 1
本文	RF	0.607 2	0.596 6	0.759 9	0.749 1	0.863 8	0.860 6	0.930 3	0.929 6
	SVM	0.582 9	0.572 8	0.747 4	0.736 1	0.876 3	0.872 1	0.927 8	0.923 3
	MLP	0.581 8	0.564 4	0.760 2	0.753 8	0.865 0	0.859 9	0.926 8	0.923 7
	KNN	0.604 6	0.592 4	0.748 4	0.748 5	0.875 0	0.870 9	0.933 3	0.930 2

为更直观的展示实验结果,将各类方法在不同样本下取得的分类器平均准确率和 F1 得分对比如图 9 和 10 所示。

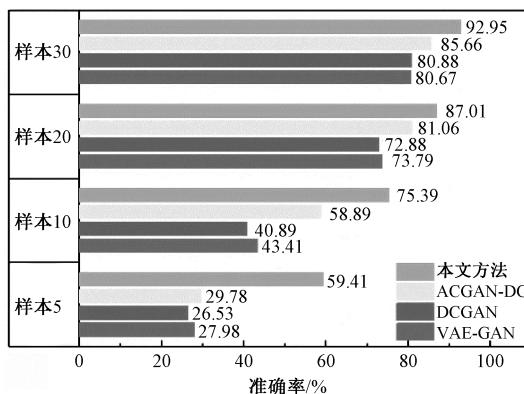


图 9 不同样本数量下各模型的准确率

Fig. 9 Accuracy of individual models with different sample sizes

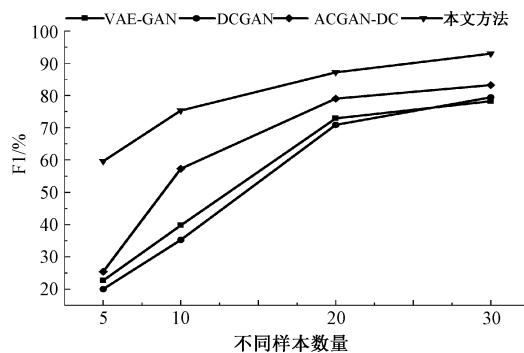


图 10 不同样本数量下各模型的 F1 得分

Fig. 10 F1 score of individual models with different sample sizes

从表 5、图 9 和 10 可以看出,在样本量为 5 时本文方法的识别效果显著优于其他 3 种方法,准确率可以接近 60%,而其他方法的准确率均低于 32%,同时本文方法的 F1 分数也显著高于其他方法。表明了本方法在漏磁缺陷信号数量极少的情况下也可以学习到重要的特征,相较于其他方法生成的样本,具有和原始信号更为接近的分布,而后续的生成样本筛选处理能够选出质量更好的生成样本,进一步提高了模型的分类性能。

由表 5 和图 9 可知,随样本量不断增加,各类方法的准确率均有所提升,当样本量为 30 时,本文方法和其余 3 种生成模型的准确率都能达到 80% 以上,特别是本文方法,平均识别准确率可以达到 93%。实验结果表明,在样本量增加的情况下,3 种对比方法均能够在不同程度上提升漏磁信号关键特征的学习能力,但生成的样本没有经过评估筛选机制,会导致生成质量不佳的漏磁信号影响模型训练,从而导致最终的分类识别性能降低。本文

方法则不仅优化了生成器的结构和噪声,而且建立了生成信号的质量评估机制,从而提高了分类模型整体的性能,因此本文方法在不同的有限样本数量下均可达到较好的分类效果。

5 结 论

针对油气管道缺陷检测面临的原始漏磁信号数据量有限、生成模型的学习能力和生成样本的质量影响分类识别性能等问题,本文提出了基于多类别混合分布估计和多头注意力机制的 CWGAN-GP 生成网络,并结合了基于 VAE 重构误差的生成样本筛选的方法来扩充有限的漏磁信号。生成网络引入多头注意力机制,可以使生成模型在多个角度关注漏磁缺陷信号的有效信息,从多类别高斯混合分布中获取随机噪声来获得原始信号的先验知识,提高了生成模型学习原始信号特征分布的能力;另外本文对生成的信号建立了筛选方法,进一步改善了生成信号的质量。在有限的漏磁样本下,本文方法对管道缺陷的分类识别准确率达到了 93%,且在数据量极少的情况下对管道缺陷识别依旧可以取得较好的分类识别效果。综上所述,本文所提出的小样本分类识别模型,在漏磁缺陷样本较少的情况下即可实现较好的缺陷分类识别效果,为解决管道漏磁缺陷样本量不足提供了一种新思路。

参 考 文 献

- [1] 万勇,王永智,杨勇,等. 基于磁通门磁力计的油气管道多缺陷智能识别分类方法研究[J]. 哈尔滨工程大学学报, 2021, 42(9): 1321-1329.
WAN Y, WANG Y ZH, YANG Y, et al. Intelligent identification and classification methods of oil and gas pipeline defects by fluxgate magnetometry[J]. Journal of Harbin Engineering University, 2021, 42(9):1321-1329.
- [2] 李佳东,张彦杰,邱俊杰,等. 带包覆层管道缺陷的脉冲涡流检测方法研究[J]. 电子测量与仪器学报, 2024, 38 (10): 137-146.
LI J D, ZHANG Y J, QIU J J, et al. Research on pulse eddy current testing method for pipeline defects with coating layer[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (10): 137-146.
- [3] 金士杰,张波,孙旭,等. 基于 TOFD 周向扫查图像特征的管道缺陷超声检测[J]. 机械工程学报, 2023, 59(4): 18-24.
JIN SH J, ZHANG B, SUN X, et al. Ultrasonic testing of defects in pipeline based on image characteristics of TOFD circumferential scan [J]. Journal of Mechanical Engineering, 2023, 59(4):18-24.
- [4] 刘金海,赵真,付明芮,等. 基于主动小样本学习的

- 管道焊缝缺陷检测方法 [J]. 仪器仪表学报, 2022, 43(11): 252-261.
- LIU J H, ZHAO ZH, FU M R, et al. Active small sample learning based the pipe weld defect detection method [J]. Chinese Journal of Scientific Instrument, 2022, 43(11): 252-261.
- [5] 石明江, 陈瑞, 冯林. 基于磁记忆的金属管道缺陷检测方法 [J]. 电子测量与仪器学报, 2022, 36(1): 44-53.
- SHI M J, CHEN R, FENG L. Metal pipeline defect detection method based on magnetic memory [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 44-53.
- [6] 李苗, 李凌波, 左志恒, 等. 基于机器学习的成品油管道运行工况识别 [J]. 中国安全科学学报, 2024, 34(6): 127-135.
- LI M, LI L B, ZUO ZH H, et al. Machine learning-based recognition for recognizing operating conditions of multi-product pipelines [J]. China Safety Science Journal, 2024, 34(6): 127-135.
- [7] 王贵生, 李炜, 杨勇, 等. 基于磁记忆信号特征的管道缺陷分类识别和分级识别方法 [J]. 腐蚀与防护, 2022, 43(11): 68-73, 94.
- WANG G SH, LI W, YANG Y, et al. Identification methods for pipeline defect classification and grading based on magnetic memory signal characteristics [J]. Corrosion and Protection, 2022, 43(11): 68-73, 94.
- [8] 赵翰学, 张咪, 郭岩宝, 等. 基于机器学习的管道金属损失缺陷识别方法 [J]. 石油机械, 2020, 48(12): 138-145.
- ZHAO H X, ZHANG M, GUO Y B, et al. Recognition method of pipeline metal loss defects based on machine learning [J]. China Petroleum Machinery, 2020, 48(12): 138-145.
- [9] 张勇, 周兴达, 王明吉, 等. 基于 MEEMD-KF-散布熵的油气管道工况识别 [J]. 电子测量技术, 2022, 45(11): 64-71.
- ZHANG Y, ZHOU X D, WANG M J, et al. Identification of oil and gas pipeline working condition based on MEEMD-KF-dispersion entropy [J]. Electronic Measurement Technology, 2022, 45(11): 64-71.
- [10] LIU J, FU M, LIU F, et al. Window feature-based two-stage defect identification using magnetic flux leakage measurements [J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(1): 12-23.
- [11] LUO S Y, MA X Q, XU J, et al. Deep learning based monitoring of spatter behavior by the acoustic signal in selective laser melting [J]. Sensors, 2021, 21(21): 71-79.
- [12] 施佳榔, 王章权, 徐菲, 等. 基于卷积胶囊网络的油套管变形程度评估方法 [J]. 腐蚀与防护, 2022, 43(7): 102-108.
- SHI J Y, WANG ZH Q, XU F, et al. Estimation method of oil pipeline casing deformation degree based on convolution capsule network [J]. Corrosion and Protection, 2022, 43(7): 102-108.
- [13] 梁海波, 王怡. 基于深度学习的天然气钢制管道缺陷检测方法研究 [J]. 电子测量与仪器学报, 2022, 36(9): 148-158.
- LIANG H B, WANG Y. Research on defect detection method of natural gas steel pipeline based on deep learning [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(9): 148-158.
- [14] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C]. Proceedings of the 28th Neural Information Processing Systems (NIPS). Montreal, Canada, 2014: 2672-2680.
- [15] WANG J, LI S, HAN B, et al. Generalization of deep neural networks for imbalanced fault classification of machinery using generative adversarial networks [J]. IEEE Access, 2019, 7: 111168-111180.
- [16] 张永宏, 张中洋, 赵晓平, 等. 基于 VAE-GAN 和 FLCNN 的不均衡样本轴承故障诊断方法 [J]. 振动与冲击, 2022, 41(9): 199-209.
- ZHANG Y H, ZHANG ZH Y, ZHAO X P, et al. Bearing fault diagnosis method based on VAE-GAN and FLCNN unbalanced samples [J]. Journal of Vibration and Shock, 2022, 41(9): 199-209.
- [17] DIXIT S, VERMA N K, GHOSH A K. Intelligent fault diagnosis of rotary machines: conditional auxiliary classifier GAN coupled with meta learning using limited data [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [18] FU Z, LIU Z, PING S, et al. TRA-ACGAN: A motor bearing fault diagnosis model based on an auxiliary classifier generative adversarial network and transformer network [J]. ISA Transactions, 2024, 149: 381-393.
- [19] MING Z A, TONG L, RUI Z, et al. Conditional Wasserstein generative adversarial network-gradient penalty-based approach to alleviating imbalanced data classification [J]. Information Sciences, 2020, 512: 1009-1023.
- [20] SHAHD H, MICHAEL P, LIU Y. A novel approach using WGAN-GP and conditional WGAN-GP for generating artificial thermal images of induction motor faults [J]. Procedia Computer Science, 2023, 225:

3681-3691.

- [21] CUI D, ZHOU R Z, LI H G, et al. Rotor fault diagnosis of centrifugal pumps in nuclear power plants based on CWGAN-GP-CNN for imbalanced dataset [J]. Progress in Nuclear Energy, 2025, 178: 105500.

- [22] 杨俊闯, 赵超. K-means聚类算法研究综述[J]. 计算机工程与应用, 2019, 55(23): 7-14,63.

YANG J CH, ZHAO CH. Survey on K-means clustering algorithm [J]. Computer Engineering and Applications, 2019, 55(23): 7-14,63.

- [23] ROS F, RIAD R, GUILLAUME S. PDBI: A partitioning Davies-Bouldin index for clustering evaluation [J]. Neurocomputing, 2023, 528: 178-199.

- [24] 王柯, 黄成橙, 王鹏. 深度学习在油气管道漏磁检测领域的应用[J]. 无损检测, 2024, 46(12): 93-99.

WANG K, HUANG CH P, WANG P. Application of deep learning in magnetic leakage detection of oil and gas pipelines [J]. Nondestructive Testing. 2024, 46 (12): 93-99.

- [25] LI X, YE F, TIAN Y, et al. Multi-head self-attention mechanism combined with feedforward network for time-varying nonlinear digital self-interference cancellation [J]. Digital Signal Processing, 2024, 155: 104699.

- [26] EDUN A S, LAFLAMME C, KINGSTON S R, et al. Detection of disconnects using SSTDR and variational autoencoders [J]. IEEE Sensors Journal, 2022, 22(4): 3484-3492.

- [27] MOU M, ZHAO X Q, LIU K, et al. Variational autoencoder based on distributional semantic embedding and cross-modal reconstruction for generalized zero-shot fault diagnosis of industrial processes [J]. Process Safety and Environmental Protection, 2023, 177: 1154-1167.

- [28] ZHONG C, YAN K, DAI Y, et al. Energy efficiency solutions for buildings: Automated fault diagnosis of air handling units using generative adversarial networks [J]. Energies, 2019, 12(3): 527.

- [29] YAN J, HUANG H, YANG K, et al. Synthetic data forenhanced privacy: A VAE-GAN approach against membership inference attacks [J]. Knowledge-Based Systems, 2025, 309: 112899.

- [30] ZHOU K, DIEHL E, 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.

- [31] LI W, ZHONG X, SHAO H, 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.

作者简介



温江涛(通信作者),分别在1998年和2003年于燕山大学获得学士及硕士学位,2009年于清华大学获得博士学位,现为燕山大学副教授,主要研究方向为智能故障诊断、深度学习理论及应用。

E-mail: wens2002@163.com

Wen Jiangtao (Corresponding author), received his B. Sc. and M. Sc. degrees from Yanshan University in 1998 and 2003, respectively, and Ph. D. degree from Tsinghua University in 2009. He is now an associate professor at Yanshan University. His main research interests include intelligent diagnosis, deep learning, and various applications.