doi:10.3969/j.issn.1001-4837.2025.04.011

检验与维护

基于W-GAN的储罐底板超声导波缺陷数据增强技术

桑　瀚[1],朱　健[2],胡庆龙[3],包瑞新[1],关凯及[2],张　军[2],杨昊晔[2]
(1.辽宁石油化工大学 机械工程学院,辽宁抚顺 113001;2.抚顺市特种设备监督检验所,辽宁抚顺 113001;
3.中国人民解放军第六四零九工厂,辽宁抚顺 113105)

摘　要:针对储罐底板超声导波检测数据集获取困难,数据质量难以保障等问题,提出一种基于W-GAN的超声导波数据增强方法,并使用ResNet验证其数据增强的性能。以损伤板材的导波检测数据为样本,包含无缺陷、针孔缺陷、裂纹缺陷和腐蚀缺陷4种类别。通过W-GAN对数据集进行增强,最终得到2 048条扩展数据,并对增强数据进行PSNR和Wilcoxon秩和检验。结果表明,由W-GAN生成的增强数据与原始数据具有较高的特征相似性和较强同分布性,原始数据和增强数据的分类准确率分别为96%,93%。测试结果表明,增强数据能够有效保留原始数据的损伤特征,在分类器中展现与原始数据相当的可识别性能。本研究可为储罐底板超声导波检测提供一种高效的数据增强手段。

关键词:储罐底板;超声导波;数据增强;W-GAN;ResNet
中图分类号:TH49;TE972;TG115.285　　**文献标志码:**B

A data enhancement technique based on W-GAN for tank bottom plate ultrasonic guided wave defect

SANG Han[1],ZHU Jian[2],HU Qinglong[3],BAO Ruixin[1],GUAN Kaiji[2],ZHANG Jun[2],YANG Haoye[2]
(1.School of Mechanical Engineering,Liaoning Petrochemical University,Fushun 113001,China;
2.Fushun Special Equipment Supervision and Inspection Institute,Fushun 113001,China;
3.Chinese People's Liberation Army 6409 Factory,Fushun 113105,China)

Abstract: In light of the challenges in acquiring ultrasonic guided wave detection datasets for tank bottom plates and ensuring data quality,this study proposes a data enhancement method based on W-GAN(wasserstein generative adversarial network).The performance of the enhanced data is validated using ResNet.Taking the guided wave detection data of damaged plates as samples,the dataset includes four categories:non-defective,pinhole defects,crack defects,and corrosion defects.W-GAN is employed to augment the dataset,ultimately generating 2 048 extended samples,which are evaluated using PSNR and the Wilcoxon rank-sum test. The results show that the enhanced data generated by W-GAN exhibits high feature similarity and strong distribution consistency with the original data. The classification accuracies for the original and enhanced datasets are 96% and 93%,respectively.Testing demonstrates that the enhanced data effectively preserves the damage characteristics of the original data,achieving comparable recognizability in the classifier. This research provides an efficient data augmentation approach for ultrasonic guided wave detection of tank bottom plates.

Key words:tank bottom plate;ultrasonic guided wave;data enhancement;W-GAN;ResNet

0　引言

超声导波作为一种检测距离长、灵敏度高且能量衰减小的无损检测方法,被广泛地应用于大型储罐和石油管道的检测[1-3]。压电式换能器主要通过耦合剂将超声导波激励传递至检测对

收稿日期:2025-01-12　**修回日期:**2025-03-22
基金项目:辽宁省自然科学基金计划项目(2024-BS-223)

象[4]，高温环境会削弱其检测精度和稳定性。电磁式换能器通过调整永磁体和线圈的结构，激发超声导波信号，具有无接触、全模式控制和可用于高温环境的优点[5]，但其能量转换效率低，无法大量获取准确的超声导波信号。

现阶段，深度学习技术广泛应用于缺陷定位、缺陷形貌分析等后处理工作[6-7]。该技术对数据品质和数量有较高要求，数据质量不佳使结果精度较差，数据过少将无法支撑网络训练[8]。因此，需要一种有效的数据增强技术来实现超声导波数据样本的有效增量，以支持基于深度学习的无损检测研究。生成对抗网络（generative adversarial network，GAN）[9]逐渐应用于数据增强，黄星烨[10]为了保障管道结构完整性和能源运输安全，基于条件生成对抗网络进行数据增强，开展了管道点蚀深度预测相关算法的研究。杜锋[11]为解决卷积神经网络在红外小目标检测方面训练数据稀缺的问题，提出了一种生成红外小目标检测合成训练数据的方法。通过数据变换和处理生成新的数据集，增加数据集的多样性和数量[12]。GAN对超参数非常敏感，微小的扰动会对训练结果产生很大的影响。通过引入Wasserstein距离作为损失函数，W-GAN[13]显著提高了训练的稳定性和收敛性。自W-GAN提出以来，出现了多个变体。W-GAN-GP[14]在W-GAN的基础上引入了梯度惩罚项，通过对判别器的梯度进行约束，避免了对判别器权重进行剪裁，提高训练过程的稳定性。LS-GAN[15]采用最小二乘损失函数，减少训练过程中产生的梯度消失问题，提高图像的质量和训练的稳定性。RS-GAN[16]通过增强W-GAN的鲁棒性，改进其在高噪声环境下的表现，该变体通过引入一种新的正则化技术，增强处理复杂数据集时的稳定性。W-GAN通过不断的创新和改进，在图像生成和数据增强中得到广泛应用。

针对储罐底板检测数据不足、难以开展基于深度学习的问题，提出一种基于W-GAN的超声导波信号增强技术。以无缺陷、针孔缺陷、裂纹缺陷和腐蚀缺陷的超声导波信号为初始样本，包括3 600条数据。通过W-GAN数据增强技术扩展得到2 048条数据，对比生成的数据与原数据的特征还原度和同分布性能，并进行可分类性能验证。

1 基于W-GAN的储罐底板超声导波数据增强技术

1.1 储罐底板超声导波检测

储罐底板超声导波检测的原理如图1所示。底板厚为d，由传感器激发纵波激励信号，通过斜探头入射的方式在分界面处产生波形转换，使纵波与横波相互叠加形成波包，从而产生Lamb波。根据Lamb波在平板上下表面质点振动方向不同，可以把Lamb波分为对称型S和反对称型A两种模态。传感器按照特定的角度紧贴于固体楔块上，构成特定结构的表面声波激励源。通过设置不同角度的楔块，能够激励出不同模态的Lamb波信号，从而使该方法对于复杂的检测结构和场景具有广泛的适用性。

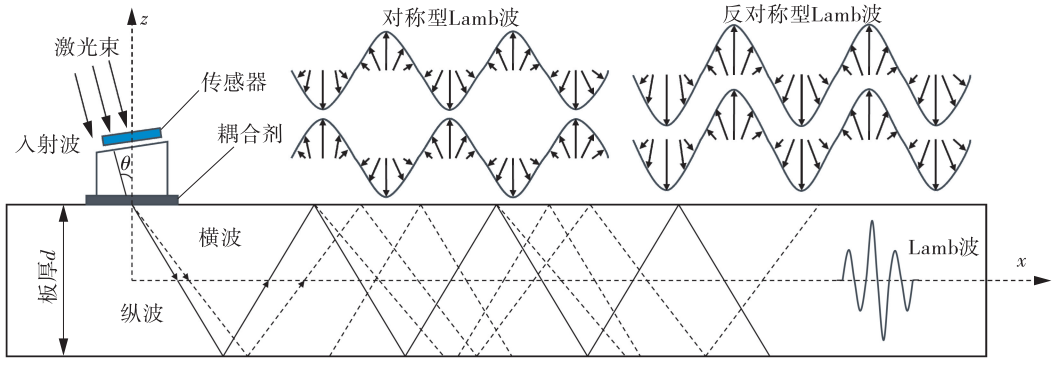


图1 超声导波检测原理

Fig.1 The detection principle of the ultrasonic guided wave

图2示出储罐底板结构。典型储罐底板主要由中幅板、边缘板、焊缝等结构组成。储罐底板作为储罐的重要组成部分，直接承载储存介质的重量与压力，其结构和材料质量对储罐的安全运行具有重要影响。在石油、化工等行业中，储罐底板常暴露于高温、高压及腐蚀介质中，长期服役后极易出现多种损伤形式，如针孔、裂纹及局部腐蚀等。图3示出储罐底板的几种常见腐蚀形貌。

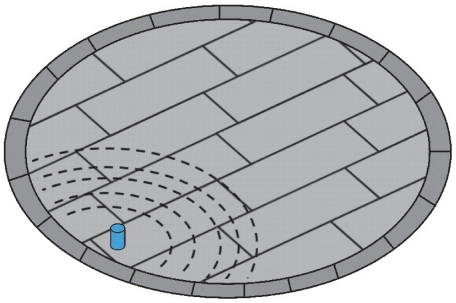
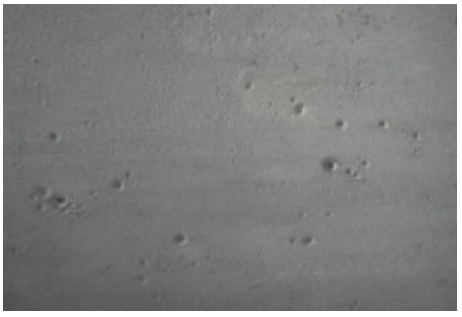
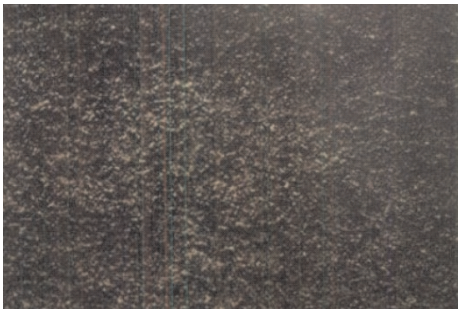


图2 储罐底板结构示意

Fig.2 Schematic of the storage tank bottom plate structure



(a)针孔缺陷



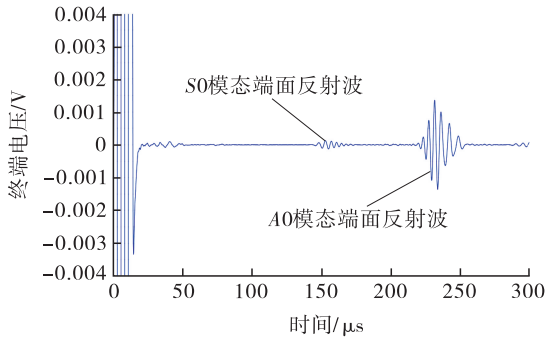
(b)腐蚀缺陷

图3 储罐底板缺陷

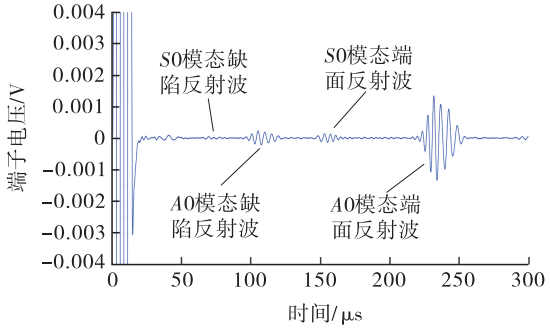
Fig.3 The defects on tank bottom plate

不同缺陷类别的波形信号特征表现出的差异性为基于深度学习的缺陷识别技术提供基础。从图4中可清晰地看出不同缺陷类型的波形特征。

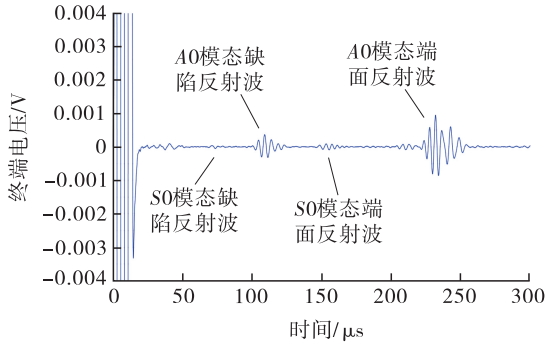
虽然深度学习在超声检测中具有明显的优势，但很难获得足够数量的适合深度学习的数据集：一方面，由于传感器自身特性缺陷，以及通过试验测量的方法处理人工缺陷耗时高且低效，进而导致大量可用数据无法被捕获；另一方面，现有GAN数据增强技术存在超参数敏感，小干扰影响训练结果等问题，导致其无法满足深度学习在超声导波缺陷检测中的要求。文中使用W-GAN技术实现数据集的数据增强，以满足深度学习对数据量和品质的需求。



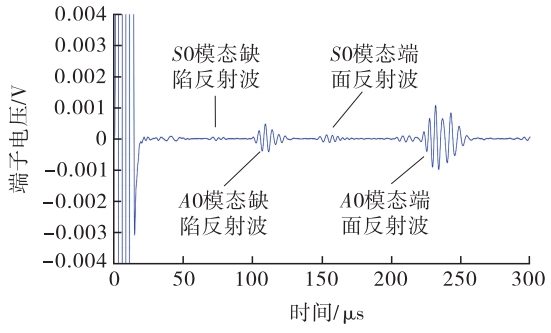
(a)无缺陷储罐底板的波形信号



(b)针孔缺陷储罐底板的波形信号



(c)裂纹缺陷储罐底板的波形信号



(d)腐蚀缺陷储罐底板的波形信号

图4 仿真缺陷信号

Fig.4 The simulated defect signals

1.2 W-GAN网络的提出与改进

W-GAN由ARJOVSKY等[13]于2017年提出，是对传统GAN的一种改进。W-GAN通过引入

Wasserstein距离替换GAN中的JS散度，使生成器和判别器之间的训练变得更加平滑，比较生成数据分布与真实数据分布之间的差异，并且克服了传统GAN训练不稳定的问题，使其在没有大量的超参数调整下，能够避免模式崩溃。

W-GAN结构如图5所示，该结构具有两个模块：生成器（Generator）和判别器（Discriminator）。算法开始时，生成器首先生成100维高斯分布的随机噪声数据，经过两个全连接层后拓展到8 000维，随后，将其与6 000条真实数据输入判别器。判别器也嵌入了两个全连接层，并使用LReLU激活层来实现降维。生成器的最后一层使用了Sigmoid激活函数，确保生成的信号与输入信号的幅度和范围一致，保证生成的信号具有更好的真实性和质量。然后，利用Sigmoid交叉熵函数得到每组数据的训练损失，并依据损失分别对生成器和判别器参数进行调整，最终输出增强数据集总计2 048条，每组512条。W-GAN的基本框架通过优化Wasserstein损失函数进行对抗训练，其公式如下：

$$\min_{G}\max_{D\in G}V(D,G)=E_{x\sim p_{\text{data}}}(x)\left[D(x)\right]+E_{z\sim p_z}(z)\left\{D[G(z)]\right\} \tag{1}$$

式中，D为判别器；G为生成器；p_{data}为真实数据分布；p_z为噪声分布；$D(x)$为判别器对真实数据样本x的评估；$D\left[G(z)\right]$为判别器对生成样本的评估；$G(z)$为生成器生成的假样本。

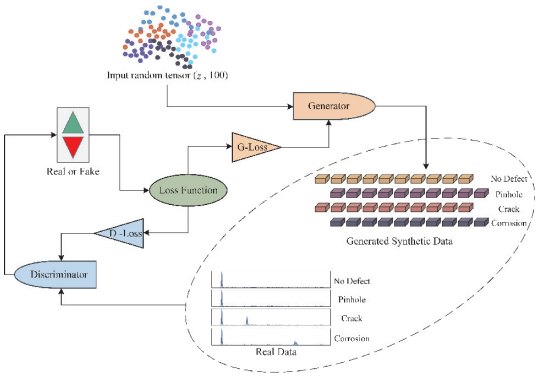


图5 W-GAN结构

Fig.5 The framework of W-GAN

1.3 PSNR和Wilcoxon秩和检验

原始数据经W-GAN训练完成后，得到4组生成数据，分别为无缺陷、针孔缺陷、裂纹缺陷和腐蚀缺陷数据，每组包含512条超声导波信号数据，分别对这4组数据进行PSNR和Wilcoxon秩和检验。PSNR通过比较两幅图像的差异来评估压缩质量[17]，常用于检验重构数据与原始数据之间的差异，文中PSNR用于衡量W-GAN生成数据对原始数据的特征还原度。*PSNR*的计算公式如下：

$$PSNR=10\times\log_{10}\left(I_{\max}^2/MSE\right) \tag{2}$$

式中，$I_{\max}$为时域信号中的最大值，对于归一化到[0，1]的信号数据，通常$I_{\max}=1$；*MSE*为数据的均方误差。

*PSNR*值越高，表示重构数据与原始数据的差异越小。一般来说，*PSNR*值大于30 dB，表示生成数据与原始数据具有较高的特征重合度。

Wilcoxon秩和检验[18]用于比较两个独立样本的分布差异性。通过对两组数据合并后进行秩次排序，计算秩和的差异来检验两组数据是否有显著差异。其主要计算公式如下：

$$R_x=\sum_{x_i\in x}\text{rank}(x_i) \tag{3}$$

$$R_y=\sum_{y_i\in y}\text{rank}\,(y_i) \tag{4}$$

式中，$\text{rank}\left(x_i\right)$和$\text{rank}\left(y_i\right)$是$x_i$和$y_i$在合并数据中的秩。

$$W=R_x-\frac{m(m+n+1)}{2} \tag{5}$$

式中，m和n分别是样本x和y的大小。

通过查找检验统计量W对应的P值，可以判断两数据的同分布性能。一般来说，若P值小于显著性水平（如0.05），则拒绝原假设，认为两个样本有显著差异。

1.4 ResNet分类器

ResNet分类器[19]用于检验真实数据和增强数据在同一网络中的可分类性，其结构如图6所示。ResNet分类器由输入层、特征提取模块、全局池化层、残差块堆叠模块和分类层组成。输入层接收4组生成数据和真实数据，并将其传递到数据预处理模块，通过初始卷积操作提取低级特征并抑制噪声。ResNet分类器的核心模块为4个BasicBlock〔（32，3）×2和（64，3）×2〕的ResBlock-2和6个BasicBlock〔（128，3）×3和（256，3）×3〕的ResBlock-3，这两模块用于从导波数据中提取缺陷特征。在残差块堆叠模块中，每个残差块在原有ResNet结构的基础上，加入了特征增强模块，用于生成更高维度、更丰富的特征，从而提升对复杂信号的特征提取能力。这些残差模块逐层堆叠，逐步提取信号的深层次特征，最终通过全连接层和Softmax激活函数完成分类任务，并通过Argmax函数来预测缺陷类型。

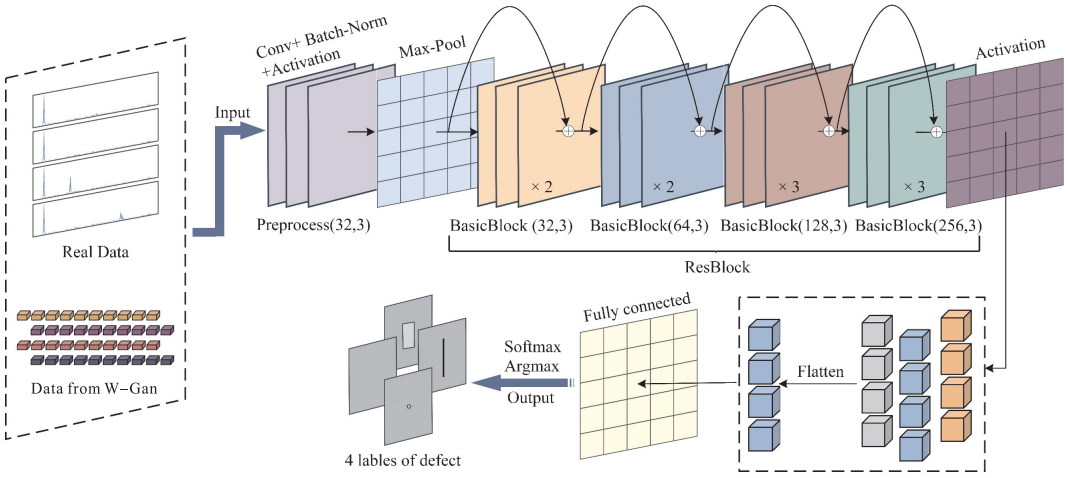


图6 ResNet结构

Fig.6 The framework of the ResNet

2 试验设计与讨论

2.1 数据组织

试验采用的数据集为6 000条铝板表面超声导波检测的人工缺陷数据，包括无缺陷、针孔缺陷、裂纹缺陷和腐蚀缺陷，每条数据包含1列缺陷特征标签和8 000个时序点。选取文献[20]中的3 600条用于W-GAN的试验数据。整个数据集的训练集、测试集和验证集划分比例为6∶2∶2。

使用Pycharm框架来构建和训练神经网络，版本为Pycharm2024.1.6，CUDA11.8和Python3.9。硬件参数为AMD Ryzen 9 7945HX，RTX-4070 GPU，16 GB内存。

2.2 试验验证与讨论

为了验证W-GAN网络生成的增强数据与原始数据的特征相似性和同分布性能，采用PSNR和Wilcoxon秩和2个指标分别对生成的4组增强数据进行计算，结果如表1所示。

表1 4组增强数据的平均*PSNR*和Wilcoxon秩和

Tab.1 The average *PSNR* and Wilcoxon rank-sum of 4 enhanced datasets

缺陷类型	无缺陷	针孔缺陷	裂纹缺陷	腐蚀缺陷
PSNR/dB	39.67	39.90	37.75	37.22
*P*值	0.078 63	0.097 62	0.098 76	0.098 15

由*PSNR*的计算结果可以看出，4组增强数据的*PSNR*值均大于30 dB，表明对于不同缺陷类型，W-GAN生成的增强数据与真实数据具有高相似度的视觉特征。因此，由W-GAN得到的增强数据是能够满足初级的特征提取。

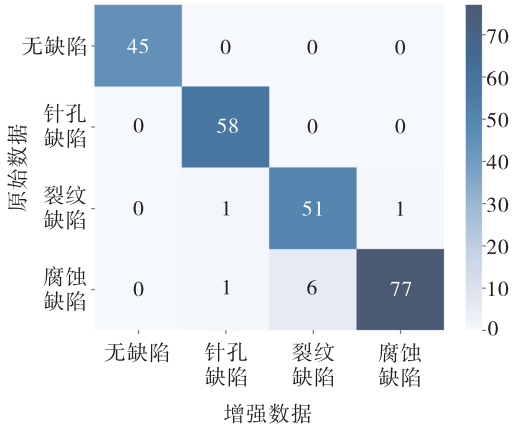
4组增强数据的*P*值均大于0.05，其中，针孔缺陷、裂纹缺陷和腐蚀缺陷均高于0.097，说明增强数据与原始数据具有极强的分布一致性，进一步验证W-GAN的优越性能。

为评判由W-GAN生成的增强数据能够高质量地还原原始数据的固有特征，增强数据与原始数据在深度学习中具有相当的可适用性。设计ResNet分类器，分两步展开，具体过程如下。

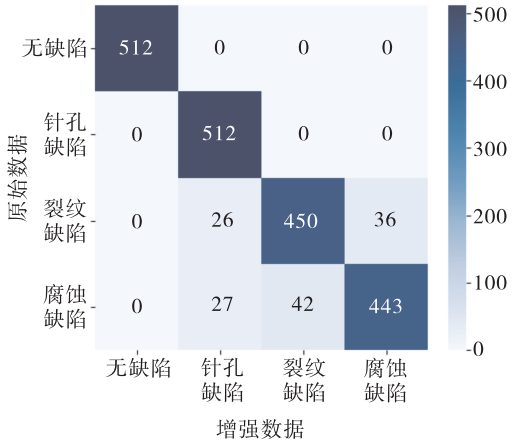
（1）验证ResNet分类器的性能。使用3 600条原始训练集数据用于训练分类器，然后用1 200条原始测试集数据测试该网络的训练效果，最后，用1 200条原始验证集数据检验该网络的分类性能。检验结果的混淆矩阵如图7(a)所示。

由验证集的混淆矩阵的结果可知，ResNet对于无缺陷、针孔缺陷、裂纹缺陷和腐蚀缺陷分类准确率分别为100%，100%，96%，92%，整体分类准确率96%。说明原始数据具备缺陷固有特征和良好的可分类性，适用于基于深度学习的储罐底板的导波检测；经原始数据训练的ResNet具备良好的分类能力。

（2）将W-GAN生成的增强数据分为4组，作为测试集输入到分类器中，检验增强数据的可分类性，结果如图7(b)所示。可以看出，无缺陷和针孔缺陷分类准确率达到了100%，裂纹缺陷准确率为88%，腐蚀缺陷为87%，整体分类准确率为94%，进一步证明W-GAN生成的增强数据和原始数据具有相当的可分类性能，能够代替运用至基于深度学习或数据驱动的超声导波研究。



（a）原始数据混淆矩阵



（b）W-GAN增强数据混淆矩阵

图7 混淆矩阵结果

Fig.7 The result of confusion matrix

3 结论

（1）以板材导波检测数据为试验样本，包含无缺陷、针孔缺陷、裂纹缺陷和腐蚀缺陷4种类别。利用W-GAN将每种缺陷类别增强512条数据，总计2 048条增强数据。对W-GAN生成的增强数据进行PSNR和Wilcoxon秩和检验，每类信号的*PSNR*值均大于30 dB，表明生成的增强数据与原始数据具有很高的特征相似度。

（2）Wilcoxon秩和的计算中，4组增强数据的*P*值均大于0.05，说明增强数据与原始数据具有极强的分布一致性。使用ResNet对增强数据进行分类器适用性验证，原始数据被用作训练集和验证集，增强数据被用作测试集。验证集和测试集的平均分类准确率分别为96%和93%，表明由W-GAN生成的增强数据能够大量保留原始数据的特征，在基于深度学习的分类器中具有相当的表现能力。

参考文献：

[1] 王慧力，蔡亮，孟虎林，等.大型在役储罐检测技术现状分析[J].全面腐蚀控制，2023，37(12)：94-97.
WANG H L，CAI L，MENG H L，et al.Analysis of the current situation of inspection technology for large in-service storage tanks[J].Total Corrosion Control，2023，37(12)：94-97.

[2] 刘文才.基于超声导波的大型油品储罐罐顶腐蚀检测技术研究[D].北京：中国石油大学(北京)，2022.
LIU W C. Research on large oil storage tank top corrosion detection technology based on ultrasonic guided wave [D]. Beijing：China University of Petroleum(Beijing)，2022.

[3] 袁奕雯.基于超声导波的车用氢瓶在线检验技术研究[J].压力容器，2024，41(4)：9-15.
YUAN Y W.Research on online inspection of vehicle hydrogen cylinders based on ultrasonic guided wave technology [J]. Pressure Vessel Technology，2024，41(4)：9-15.

[4] 张斯琪.油气管道结构完整性的压电传感检测机理研究[D].青岛：中国石油大学(华东)，2020.
ZHANG S Q.Study on the mechanism of piezoelectric sensing for structural integrity of oil and gas pipelines [D]. Qingdao：China University of Petroleum (East China)，2020.

[5] HILL S，DIXON S.Frequency dependent directivity of periodic permanent magnet electromagnetic acoustic transducers [J]. NDT & E International，2014，62：137-143.

[6] 屈言森.基于深度学习的管材表面缺陷检测技术研究[D].太原：太原科技大学，2024.
QU Y S. Research on pipe surface defect detection technology based on deep learning [D]. Taiyuan：Taiyuan University of Science and Technology，2024.

[7] 崔俊佳，张军，菁茹茹，等.基于深度学习的自冲铆接偏铆缺陷检测算法研究[J].航空制造技术，2023，66(6)：22-30.
CUI J J，ZHANG J，XIAO R R，et al. Research on detection algorithm of partial riveting defects in self-piercing riveting based on deep learning [J]. Aeronautical Manufacturing Technology，2023，66(6)：22-30.

[8] 周明康，张静，朱晨晨.WGAN-GP数据增强及预训练模型的SAR目标识别方法[J].信息工程大学学报，2025，26(1)：21-28.
ZHOU M K，ZHANG J，ZHU C C. SAR target recognition method based on WGAN-GP data enhancement and pre-trained model [J]. Journal of

Information Engineering University, 2025, 26(1): 21-28.

[9] 杨鹏坤,李金龙,郝润来.基于生成对抗网络的小样本图像数据增强技术[J].网络安全与数据治理,2023,42(6):79-84.
YANG P K, LI J L, HAO R L. Few-shot image data augmentation based on generative adversarial networks [J]. Cyber Security and Data Governance, 2023, 42(6):79-84.

[10] 黄星烨.基于条件生成对抗网络的数据增强:神经网络在点蚀深度预测与检测中的应用[J].油气储运,2024,43(11):1320.
HUANG X Y. Data augmentation using conditional generative adversarial network (cGAN): Application for prediction of corrosion pit depth and testing using neural network [J]. Oil & Gas Storage and Transportation, 2024, 43(11):1320.

[11] 杜锋.基于GAN的红外小目标检测合成数据增强技术研究[J].计算机测量与控制,2024,32(11):118-124.
DU F. Research on GAN-based synthetic data augmentation technology for infrared small target detection [J]. Computer Measurement & Control, 2024, 32(11):118-124.

[12] 李晋芳,肖立宝,何明桐,等.基于生成式样本合成的工件缺陷样本数据增强[J].广东工业大学学报,2025,42(3):27-35.
LI J F, XIAO L B, HE M T, et al. Method for data augmentation of workpiece defect samples based on generative sample synthesis [J]. Journal of Guangdong University of Technology, 2025, 42(3):27-35.

[13] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks [C]// Proceedings of the 34th International Conference on Machine Learning. Cape Town, South Africa, 2017: 214-223.

[14] MILNE T, NACHMAN A I. Wasserstein gans with gradient penalty compute congested transport [C]// Proceedings of Thirty Fifth Conference on Learning Theory. PMLR, 2022: 103-129.

[15] MAO X D, LI Q, XIE H R, et al. Least squares generative adversarial networks [C]//Proceedings of the 2017 IEEE International Conference on Computer Vision, Venice, Italy, 2017: 304.

[16] LIU Z, LOH P L. Robust W-GAN-based estimation under Wasserstein contamination [J]. Information and Inference: A Journal of the IMA, 2022, 12(1): 312-362.

[17] 李婉婷,林志成,姜东,等.一种基于峰值信噪比的某试验现场监控采集图像对比算法设计[J].中国科技信息,2023(1):115-118.
LI W T, LIN Z C, JIANG D, et al. Design of a peak signal-to-noise ratio-based contrast algorithm for acquired monitoring images at a test site [J]. China Science and Technology Information, 2023 (1): 115-118.

[18] 董晓芳,张良勇,王志军.基于非均等排序集抽样的Wilcoxon符号秩检验[J].河北大学学报(自然科学版),2020,40(3):225-231.
DONG X F, ZHANG L Y, WANG Z J. Wilcoxon signed-rank test based on ranked set sampling with unequal samples [J]. Journal of Hebei University (Natural Science Edition), 2020, 40(3):225-231.

[19] 马建宝,李小飞,毕江,等.一种改进SSD和ResNet的光伏组件缺陷识别算法[J].粘接,2025,52(2):141-145.
MA J B, LI X F, BI J, et al. An improved defect identification algorithm for photovoltaic modules based on SSD and ResNet[J]. Adhesion, 2025, 52(2): 141-145.

[20] SUN H, PENG L, WANG S, et al. Development of frequency-mixed point-focusing shear horizontal guided-wave EMAT for defect inspection using deep neural network [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-14.

作者简介:桑瀚(1999),男,主要从事储罐底板导波检测相关研究,通信地址:113001辽宁省抚顺市望花区建设街道辽宁石油化工大学,E-mail:1959922567@qq.com。

通信作者:包瑞新(1981),男,教授,主要研究领域为能源与动力装备故障诊断与健康管理,通信地址:113001辽宁省抚顺市望花区建设街道辽宁石油化工大学,E-mail:ruixinbao@126.com。

本文引用格式:
桑瀚,朱健,胡庆龙,等.基于W-GAN的储罐底板超声导波缺陷数据增强技术[J].压力容器,2025,42(4):82-88.
SANG Han, ZHU Jian, HU Qinglong, et al. A data enhancement technique based on W-GAN for tank bottom plate ultrasonic guided wave defect [J]. Pressure Vessel Technology, 2025, 42(4):82-88.