

基于 WGAN-GP 的轴承健康诊断方法

孙翔宇¹,盛一²,陈山鹏²,左敦稳¹

(1. 南京航空航天大学 机电学院,江苏 南京 210016;

2. 南京星合精密智能制造研究院有限公司,江苏 南京 211199)

摘要:针对生产现场设备的故障数据有限,影响其健康诊断准确性的问题,结合振动信号的特点,设计一种改进梯度惩罚 Wasserstein 距离生成对抗网络的数据扩充方法。对故障信号进行快速傅里叶变换获得其频谱信号,将频谱信号作为网络的输入,由生成器产生生成信号,扩充不平衡的数据集。在轴承健康诊断实验中,该方法可以解决数据不平衡下的健康诊断问题,并与其他常用的数据扩充方法相对比,验证该方法的有效性。

关键词:轴承;故障诊断;生成对抗网络;不平衡数据;一维神经网络

中图分类号:TH133.3;TP277.3 **文献标志码:**A **文章编号:**1671-5276(2023)02-0109-05

Health Diagnosis Method of Bearing Based on WGAN-GP

SUN Xiangyu¹, SHENG Yi², CHEN Shanpeng², ZUO Dunwen¹

(1. College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics,

Nanjing 210016, China; 2. Nanjing Xinghe Institute of Precision Intelligent Manufacturing, Nanjing 211199, China)

Abstract: To improve the accuracy of the health diagnosis affected by the limited fault data of the equipment on the production site, an improved Wasserstein generative adversarial network with Gradient penalty data expansion method is designed by combining the characteristics of vibration signals. Fast Fourier transform is performed on the fault signal to obtain its spectrum signal, with which as the input of the network, the fault signal is generated by the generator to expand the imbalanced dataset. In the bearing health diagnosis experiment, the proposed method can solve the health diagnosis problem under the imbalanced data, whose effectiveness is verified by comparing with other widely used data expansion methods.

Keywords: bearing; fault diagnosis; generative adversarial networks; Imbalanced data; one-dimensional neural networks

0 引言

近年来随着深度学习技术的不断成熟,越来越多的研究专注于使用深度学习技术来对设备进行健康诊断。YU J B 等^[1]提出了一种一维残差卷积自编码网络,用于以无监督学习方式直接从振动信号中提取特征。ZHU X X 等^[2]提出了预先连接深度卷积神经网络,并在此基础上建立了轴承振动状态识别模型。刘冰洁等提出一种基于卷积神经网络和控制图异常模式识别的电机装配故障诊断方法^[3]。

上述的研究虽然取得了很好的结果,但是这些研究都是基于平衡数据进行的。然而在实际加工现场,可以采集到的故障信号远少于正常信号。因此在需要大量数据支持的深度学习诊断方法中,数据分布不平衡会严重影响诊断模型的搭建,最终影响诊断精度^[4-6]。

为了解决不平衡数据下的健康诊断问题,许多学者提出了自己的见解。WEI J N 等^[7]提出了一种基于样本特征过采样技术和多类最小二乘支持向量机的多类不平衡故障诊断方法,通过此方法可以利用有限的平衡样本获

得更好的诊断结果。TRA V 等^[8]提出了一种新的过采样合成技术作为预处理方法,目的在于扩展数据集,该技术提高了深度学习模型的泛化能力,提高了诊断精度。

通过上述方法,可以看到解决数据不平衡的方法一般会使用过采样和下采样的方法解决。过采样的本质是随机复制少数样本以增加其规模,不可避免地会发生过拟合的问题。而下采样会丢弃大量的数据,使得本来信息就少的故障数据所包含的信息更少。

本文使用生成对抗网络(GAN)对故障样本进行扩充,解决数据不平衡的问题,使各种故障样本分布均匀。由于GAN在图像识别领域出色的表现,越来越多的学者正将其运用到健康诊断领域。HAN B K 等^[9]基于梯度惩罚 Wasserstein 距离生成对抗网络(WGAN-GP)和堆叠自编码器(SAE),提出一个不平衡故障分类框架 WGAN-GP-SAE,应用 WGAN-GP 算法对故障类型信号进行小样本的扩充,使所有故障类型样本达到数据均衡,最终通过实验验证该框架具有良好的诊断性能。LI Z X 等^[10]构建了一种辅助分类 WGAN-GP,该网络能够稳定利用不平衡训练集为少数类生成高质量样本,并随着不平衡的数据集逐渐扩展到平衡,诊断准确性不断增加。

基金项目:南京市科技计划项目资助项目(201911028)

第一作者简介:孙翔宇(1997—),男,山西大同人,硕士研究生,研究方向为机床健康诊断。

因此本文基于 WGAN-GP,将一维卷积网络运用在网络结构中,提出一种改进 WGAN-GP 用于生成少量的故障样本,对不平衡数据集进行扩充,并使用扩充后的平衡数据集进行健康诊断。实验表明该方法可以提高不平衡数据下的健康诊断准确率,而且通过与其他常用的数据扩充方法相比,验证了其有效性。

1 理论背景

1.1 GAN

受博弈论的启发,GOODFELLOW I J 等^[11]提出了生成对抗网络。生成对抗网络主要由两个部分构成:生成器和判别器,如图 1 所示。GAN 的核心逻辑是生成器和判别器之间的对抗和博弈。

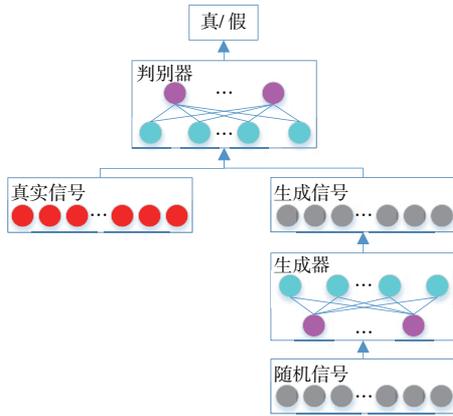


图 1 GAN 结构

GAN 的目标函数如下:

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

判别器的目标是最大化 $\log D(x)$ 和 $\log [1 - D(G(z))]$,即最大化 $V(D, G)$,使判别器最大限度地识别真实数据并区分出生成信号。而生成器的目的是最小化 $\log [1 - D(G(z))]$,即最小化 $V(D, G)$,使生成信号欺骗判别器,最终生成器和判别器达到纳什均衡^[12]。

1.2 WGAN-GP

传统 GAN 在训练过程中会出现梯度消失和模式崩溃的问题,导致训练无法收敛。为此 ARJOVSKY M 等^[13]分析了原始 GAN 存在的问题,并提出 Wasserstein 距离生成对抗网络(WGAN),WGAN 使用 Wasserstein 距离代替 JS 散度来衡量真实样本和生成样本之间的分布距离。WGAN 的目标函数如下所示:

$$V(G, D) = \min_G \max_{D \in 1-L_{Lipschitz}} \{ E_{x \sim P_{data}} [D(x)] - E_{z \sim P_z} [D(G(z))] \}$$

式中 $1-L_{Lipschitz}$ 表示 1-Lipschitz 函数集。

虽然 WGAN 解决了传统 GAN 存在的问题,但由于使用 Lipschitz 函数强行让目标函数变得平滑,导致 WGAN 训练时会遇到训练困难、收敛缓慢的问题。因此

GULRAJANI I 等^[14]对 WGAN 进行改进,增加了梯度惩罚项,最终解决了梯度消失的问题。其目标函数如下所示:

$$V(G, D) = \min_G \max_D \left\{ \begin{aligned} & E_{x \sim P_{data}} [D(x)] - E_{z \sim P_z} [D(G(z))] \\ & \text{(Original Loss)} \\ & - \lambda \int_x \max(0, \|\nabla_x D(x)\| - 1) dx \\ & \text{(Gradient Penalty)} \end{aligned} \right\}$$

式中 $\lambda \int_x \max(0, \|\nabla_x D(x)\| - 1) dx$ 是梯度惩罚项。

2 健康诊断方法

由于生产现场设备的故障数据有限,从而导致基于深度学习的设备健康诊断样本不足,最终影响了健康诊断的准确性。因此针对不平衡数据下的健康诊断,提出了一种改进 WGAN-GP 的健康诊断方法。该方法可以根据有限的故障样本学习其分布,产生大量的生成样本,然后使用生成的样本扩充不平衡数据集,最终使数据集平衡。该方法的诊断流程如图 2 所示。

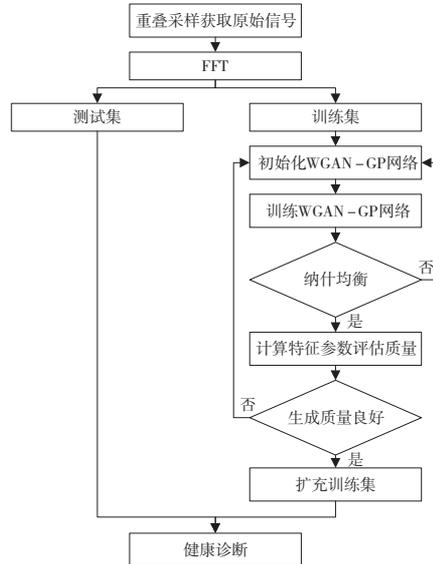


图 2 诊断流程图

2.1 改进 WGAN-GP 网络结构

针对不平衡数据下的健康诊断,提出一种改进 WGAN-GP 网络。将随机噪声信号 z 输入生成器以产生生成信号,将生成信号和真实信号一起输入判别器进行对抗训练。在达到纳什均衡后,将生成信号输入训练集对故障信号进行扩充,最终使训练集达到数据平衡。

当希望从整体数据集的定长片段中获得有用的特征,并且该特征与在该片段中的位置不相关时,卷积神经网络会非常有效。相比于二维卷积神经网络,一维卷积神经网络能很好地应用于传感器数据的时间序列分析。

由于 CNN 具有强大的特征提取能力,而且传感器信号是一维时序信号,因此使用一维 CNN 作为生成器和判别器每一层函数。生成器和判别器的具体结构如图 3 所示。

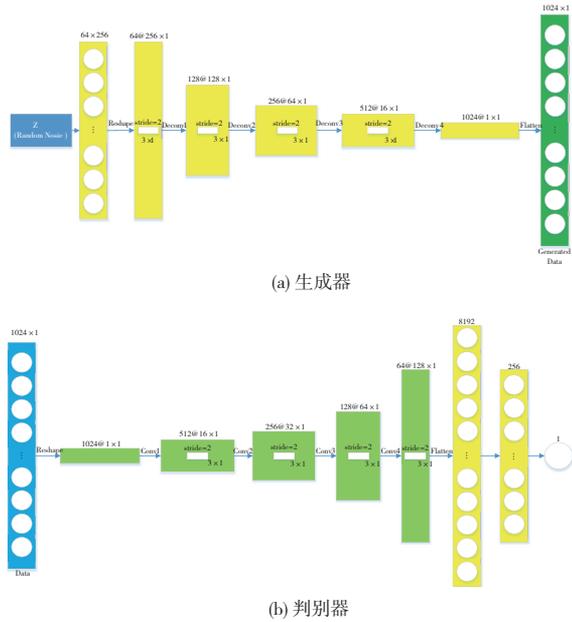


图3 生成器和判别器结构

经过生成器和判别器的对抗训练,生成高质量的生成样本用于不平衡数据下的健康诊断。

2.2 评估参数

获得生成数据后,需要通过一些参数来评估生成信号的质量,质量良好的生成信号才会对不平衡数据下的健康诊断有帮助。本文通过3种方式对生成信号进行评估:频谱、皮尔逊相关系数(PCC)和余弦值(CV)。

PCC是一个统计指标,用于表征两个变量之间的线性相关程度,其值介于-1~1之间,绝对值越接近1,则两个分布之间线性相关程度越高,PCC的计算公式如下所示。

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

CV是通过计算两分布之间的余弦值,其值介于-1~1之间,越接近1,证明两个分布越相似,计算公式如下所示。

$$\cos(X, Y) = \frac{\sum_{i=1}^n X_i Y_i}{\sqrt{\sum_{i=1}^n X_i^2} \sqrt{\sum_{i=1}^n Y_i^2}}$$

通过以上3种方式对生成信号的质量进行评估,并不断优化生成器和判别器的结构。使用高质量的生成样本进行不平衡数据下的健康诊断,有助于提高诊断精度。

3 验证实验和结果分析

为了验证提出方法的有效性,本文使用美国凯斯西储大学(CWRU)轴承数据集进行验证实验,模拟实际加工过程中采集到的数据不平衡的情况。使用改进WGAN-GP网络生成样本,并将生成样本添加到原始数据集进行扩充,最后进行健康诊断。

3.1 数据集和数据预处理

美国凯斯西储大学轴承数据集由CWRU轴承数据中心提供,数据集的详细信息可以在其网站上找到。本文验证实验选用采样频率12kHz,负载为0.735kW(1hp)的驱动端数据作为实验数据。故障类型分为3类,每种故障类型的故障尺寸分为3种,还有一种为正常类型。因此实验所用数据有10种状态,分别表示为:B007、B014、B021、IR007、IR014、IR021、OR007、OR014、OR021、Normal。对以上10种类型的源数据进行重叠采样。由于时域信号可用于健康诊断的信息较少,而频域信号包含的特征更多,因此对每段时域信号进行快速傅里叶变换(FFT)获得其频域信号。

3.2 验证结果分析

使用本文提出的改进WGAN-GP方法,对9种故障数据进行扩充,使用平衡后的数据集用于CNN、多层感知器(MLP)和支持向量机(SVM)的训练,并进行健康诊断。

在样本生成的过程中,记录每次迭代生成器和判别器的损失函数值表征该方法的性能,图4为生成IR007故障类型样本的损失函数变化图。从图中可以看出在大约2500步后达到了纳什均衡。在这种情况下对9种故障类型进行数据生成,每类生成500个样本。为了直观观察生成样本和真实样本之间的相似度,对生成样本和真实样本的频谱进行对比,如图5所示。可以看出,在忽略一些偏差的情况下,生成样本与真实样本基本相似。

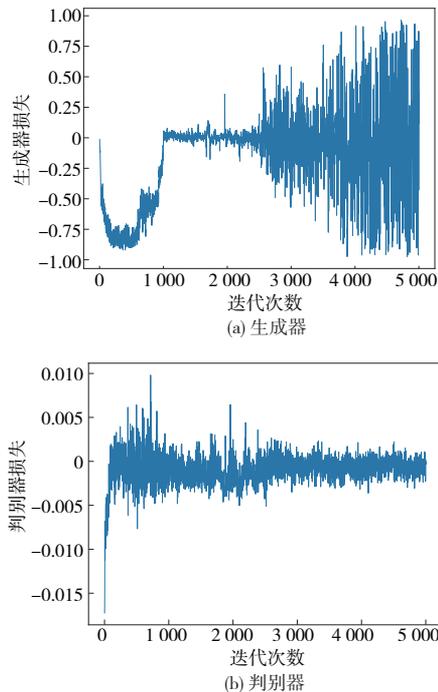


图4 IR007 损失函数

为了进一步评估生成信号的质量,计算生成信号和原始信号的PCC和CV的平均值,其结果如表1所示。可以看出生成样本的CV值大于0.8,PCC值大于0.75,这表明了生成信号与原始信号之间分布相似度很高。

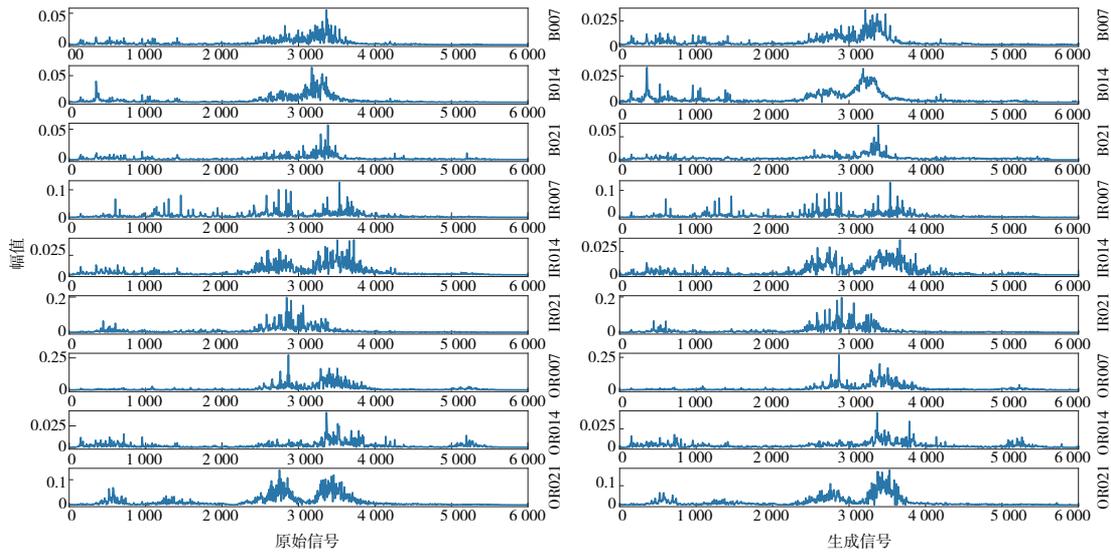


图5 原始信号和生成信号的频谱

表1 故障类生成样本和原始样本的 CV 值和 PCC 值

项目	标签类型								
	0	1	2	3	4	5	6	7	8
CV 值	0.892	0.874	0.873	0.930	0.862	0.908	0.907	0.882	0.859
PCC 值	0.857	0.827	0.830	0.906	0.805	0.884	0.883	0.826	0.805

为了模拟现实中故障越严重的情况,可以获得到的样本数量越少,设置训练集 A 和训练集 B 对改进 WGAN-GP 方法进行验证。相比于训练集 A,训练集 B 的不平衡度更高,用于模拟极度不平衡数据情况,验证用数据集组成如表 2 所示。

表2 CWRU 数据集

损伤状态	标签类型	训练集 A	训练集 B	测试集
B007	0	200	20	300
B014	1	100	10	300
B021	2	50	5	300
IR007	3	200	20	300
IR014	4	100	10	300
IR021	5	50	5	300
OR007	6	200	20	300
OR014	7	100	10	300
OR021	8	50	5	300
Normal	9	500	500	300

在没有扩充数据集时,由于 SVM 和 MLP 的特征提取能力较差,导致少数类被分类到多数类,诊断精度低下。使用生成样本对训练集进行扩充,使每种状态的样本数均为 500。扩充前后的诊断准确率如表 3 所示。

表3 数据集 A 和 B 扩充前后诊断准确率

状态	数据集 A			数据集 B		
	MLP	SVM	CNN	MLP	SVM	CNN
扩充前	0.502	0.608	0.878	0.300	0.460	0.100
扩充后	0.987	0.947	0.998	0.984	0.947	0.995

可以看出不平衡的训练集无法为网络训练提供足够的特征信息,导致诊断网络无法提取出有效的故障信息来区分少数类样本和多数类样本,使得大多数的少数类被分到了多数类中。

3.3 与其他方法的对比

为了进一步证明所提出方法的有效性,将改进 WGAN-GP 与其他常用来解决数据不平衡的方法进行了对比,包括随机过采样(ROS)和合成少数过采样技术(SMOTE)。使用上述两种方法产生生成样本,并计算生成样本与原始样本之间的 CV 值和 PCC 值,结果如表 4 和表 5 所示。可以看出,大多数情况下改进 WGAN-GP 生成样本的 PCC 值和 CV 值都高于其他两种方法生成的样本,但在部分频谱特征区分度很高的情况下,过采样生成样本的 PCC 值和 CV 值会更高。

表4 故障类生成样本和原始样本的 CV 值

方法	标签类型								
	0	1	2	3	4	5	6	7	8
WGAN-GP	0.892	0.874	0.873	0.930	0.862	0.908	0.907	0.882	0.859
ROS	0.854	0.815	0.844	0.932	0.862	0.908	0.893	0.891	0.845
SMOTE	0.862	0.832	0.863	0.937	0.860	0.918	0.895	0.901	0.860

表5 故障类生成样本和原始样本的 PCC 值

方法	标签类型								
	0	1	2	3	4	5	6	7	8
WGAN-GP	0.857	0.827	0.830	0.906	0.805	0.884	0.882	0.826	0.805
ROS	0.809	0.753	0.795	0.909	0.796	0.885	0.865	0.844	0.787
SMOTE	0.819	0.773	0.820	0.915	0.796	0.897	0.868	0.858	0.807

将改进 WGAN-GP、ROS 和 SMOTE 用于不平衡数据下的健康诊断,数据集 C 的情况如表 6 所示。

表 6 数据集 C 组成

项目	标签类型									
	0	1	2	3	4	5	6	7	8	9
训练集 C	10	10	10	10	10	10	10	10	10	500
测试集	300	300	300	300	300	300	300	300	300	300

使用改进 WGAN-GP、ROS 和 SMOTE 生成的生成数据不断扩充训练集直到达到完全平衡,比较扩充的过程中 3 种方法的诊断精度,其结果如图 6 所示。随着不平衡程度的降低,诊断精度逐渐上升,这证明了 3 种方法对于不平衡数据下的健康诊断都是有效的。但整体上来看,改进 WGAN-GP 诊断准确率是优于其他两种方法的。相比于 SMOTE,整体诊断准确率提高 3.72%,相比于 ROS,提高 7.46%。

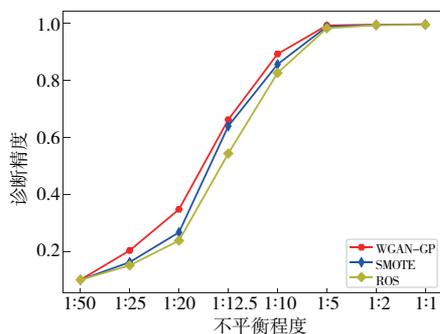


图 6 扩充过程中诊断精度

4 结语

1) 本文提出了一种改进 WGAN-GP 方法,该方法解决了 GAN 存在的梯度消失和模式崩溃的问题,并考虑到振动信号是一维时序信号,在生成器和判别器中使用一维 CNN 代替全连接层。

2) 使用改进 WGAN-GP 方法可以生成高质量的生成样本,对数量较少的故障类进行扩充,以提高不平衡数据情况下的健康诊断精度。

3) 通过 SVM、MLP 和一维 CNN 3 种分类方法,同时与 SMOTE 和 ROS 进行对比,验证了改进 WGAN-GP 方法可以解决不平衡数据下的轴承健康诊断的问题,并可以将该方法推广到旋转机械的健康诊断中。

参考文献:

[1] YU J B, ZHOU X K. One-dimensional residual convolutional

autoencoder-based feature learning for gearbox fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(10): 6347-6358.

- [2] ZHU X X, LUO X Z, ZHAO J H, et al. Research on deep feature learning and condition recognition method for bearing vibration[J]. Applied Acoustics, 2020, 168: 107435.
- [3] 刘冰洁,陈炳发,丁力平. 基于卷积神经网络的微电机装配故障诊断研究[J]. 机械制造与自动化, 2021, 50(3): 171-174, 189.
- [4] ZHANG H L, WANG R, PAN R L, et al. Imbalanced fault diagnosis of rolling bearing using enhanced generative adversarial networks[J]. IEEE Access, 2020, 8: 185950-185963.
- [5] MAO W T, LIU Y M, DING L, et al. Imbalanced fault diagnosis of rolling bearing based on generative adversarial network: a comparative study[J]. IEEE Access, 2019, 7: 9515-9530.
- [6] XIE Y, ZHANG T. Imbalanced learning for fault diagnosis problem of rotating machinery based on generative adversarial networks[J]. 201837th Chinese Control Conference(CCC), 2018: 6017-6022.
- [7] WEI J N, HUANG H S, YAO L G, et al. New imbalanced bearing fault diagnosis method based on sample-characteristic oversampling technique (SCOTE) and multi-class LS-SVM[J]. Applied Soft Computing, 2021, 101: 107043.
- [8] TRA V, DUONG B P, KIM J M. Improving diagnostic performance of a power transformer using an adaptive over-sampling method for imbalanced data[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2019, 26(4): 1325-1333.
- [9] HAN B K, JIA S X, LIU G F, et al. Imbalanced fault classification of bearing via Wasserstein generative adversarial networks with gradient penalty[J]. Shock and Vibration, 2020: 8836477.
- [10] LI Z X, ZHENG T S, WANG Y, et al. A novel method for imbalanced fault diagnosis of rotating machinery based on generative adversarial networks[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-17.
- [11] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]// Neural Information Processing Systems. Cambridge: MIT Press, 2014.
- [12] NASH J. Non-cooperative games[J]. The Annals of Mathematics, 1951, 54(2): 286.
- [13] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein Gan[J/OL]. (2017-01-26) [2021-08-10]. https://www.researchgate.net/publication/313044478_Wasserstein_GAN.
- [14] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs[EB/OL]. (2017-03-31) [2021-08-10]. <https://arxiv.org/abs/1704.00028>.

收稿日期: 2021-10-14