2024 年 第 24 卷 第 14 期
2024, 24(14):05804-08

科 学 技 术 与 工 程
Science Technology and Engineering

ISSN 1671—1815
CN 11—4688/T

DOI:10.12404/j.issn.1671-1815.2302923
引用格式:何鹏, 罗智浩, 胡蓉, 等. 基于改进 GAN 的水力测功器轴承故障在线诊断方法[J]. 科学技术与工程, 2024, 24(14): 5804-5811.
He Peng, Luo Zhihao, Hu Rong, et al. Online fault diagnosis method of hydraulic dynamometer bearing based on improved GAN[J]. Science Technology and Engineering, 2024, 24(14): 5804-5811.

能源与动力工程

基于改进 GAN 的水力测功器轴承故障在线诊断方法

何鹏, 罗智浩, 胡蓉, 田震
(中国航发湖南动力机械研究所, 株洲 412002)

摘 要 基于数据驱动的轴承故障诊断方法已成为轴承故障诊断领域研究的重点,但由于水力测功器轴承故障情况极少,导致基于数据驱动的轴承故障诊断准确率低。针对上述问题,提出了一种基于改进生成对抗神经网络(generative adversarial networks,GAN)的水力测功器轴承故障在线诊断方法,首先对生 GAN 训练方法进行改进,用改进的 GAN 交替训练判别器和生成器学习原始数据的分布特性,建立了水力测功器轴承故障数据增强模型得到合成数据。然后结合原始数据和合成数据训练得到基于 SVM 的轴承故障诊断模型。最后采用该轴承故障诊断模型实现水力测功器轴承故障在线诊断。仿真结果表明,所提出的故障在线诊断方法通过改进 GAN 增强训练极大提升了轴承故障诊断的实时准确率,并具有抗噪声干扰性强的特点。

关键词 水力测功器; 轴承故障诊断; 改进 GAN; 数据增强
中图法分类号 TK730.7; **文献标志码** A

Online Fault Diagnosis Method of Hydraulic Dynamometer Bearing Based on Improved GAN

HE Peng, LUO Zhi-hao, HU Rong, TIAN Zhen
(AECC Hunan Aviation Powerplant Research Institute, Zhuzhou 412002, China)

[**Abstract**] Bearing fault diagnosis methods based on data driven have been considered as a research focus in the field of bearing fault diagnosis. However, it is low in the accuracy of bearing fault diagnosis based on data drive because the bearing fault of hydraulic dynamometer is rare. It leads to low accuracy of bearing fault diagnosis based on data-driven. To solve this problem, an on-line fault diagnosis method of hydraulic dynamometer bearing based on improved generative adversarial neural network (GAN) was proposed. Firstly, GAN training method was improved. The distribution properties of the raw data were learned by the discriminator and the generator, and alternately trained with an improved GAN. The data enhancement model of bearing fault of hydraulic dynamometer was established to obtain synthetic data. Then the bearing fault diagnosis model based on SVM was obtained by combining the original data and synthetic data training. Finally, the bearing fault diagnosis model was adopted to realize the bearing fault diagnosis of hydraulic dynamometer on line. Through the simulation results, the real-time accuracy of bearing fault diagnosis is greatly improved by the proposed online fault diagnosis method through improved GAN enhanced training. And it has the characteristics of strong anti-noise interference.

[**Keywords**] hydraulic dynamometer; bearing fault diagnosis; improved GAN; data enhancement

水力测功器主要由测力机构、供水系统、制动器等几部分组成[1]。水力测功器是利用水与运动体之间产生摩擦阻力来吸收发动机扭矩的。

水力测功器能否在发动机不同工作状态下正常运行和正确测量发动机输出功率,直接关系到发动机试验的成败。而滚动轴承是保证水力测功器正常运行的重要组成零部件部件之一,其故障状态直接决定了水力测功器的运行状态,准确实时诊断水力测功器轴承的故障状态及可靠性对保障试验安全稳定进行意义重大[2-5]。

水力测功器轴承在工作过程中,由于发动机高速运转,其经常受到来自负载、摩擦、冲击及复杂工作环境等多方面非线性因素影响,其振动具有非线性、非平稳的特征,难以有效在线自动从信号中提取故障特

收稿日期: 2023-04-21 **修订日期**: 2024-02-20
第一作者: 何鹏(1990—),男,汉族,安徽亳州人,硕士,高级工程师。研究方向:航空发动机整机试验。E-mail:302077898@qq.com。

征进行实时轴承故障诊断,无法满足水力测功器试验现场应用的需要[6-7]。因此快速、准确地对水力测功器轴承状况进行诊断是试验安全运行的保障。

目前基于数据驱动的轴承故障诊断方法研究思路是利用机器学习算法构建原始数据集和轴承故障状态之间的映射,从而根据这个映射关系直接通过实时数据对应轴承的故障状态[8-10]。现有数据驱动这方面的研究工作集中于不同分类算法的研究,从而提升其使用分类性能及应用范围,如各种神经网络[11-12]和支持向量机[13-15]等方法。

但是基于数据驱动的轴承故障诊断方法存在着严重的故障数据数量有限、数量不均、分布不平衡等问题,极大地限制了模型的应用范围和行业推广。由于在实际试验中需保证试验安全稳定运行,因此水力测功器发生故障几率低,导致只有极少的水力测功器轴承故障样本。如果直接使用振动数据训练算法模型[16],由于大部分均为正常样本,将导致轴承故障发生时出现误判。但常用基于 SMOTE 算法的数据合成方法属于线性插值方法,其合成数据与真实数据的运行状态存在相关性不强的问题,无法应用于水力测功器轴承故障的特征数据合成。

生成对抗网络(generative adversarial network, GAN)通过学习初始样本的潜在分布来生成新样本,解决了故障样本少的问题。Zhou 等[17]对 GAN 的鉴别器进行改进。采用全局优化方案产生更多的判别性故障样本,弥补了小样本故障诊断造成的数据分布不均匀的问题。

针对实际中极少的水力测功器轴承故障样本,现提出一种基于改进 GAN 的水力测功器轴承故障在线诊断方法。该方法具有更高的学习稳定性,并且通过交替训练判别器和生成器的方式,学习原始数据的分布特性,建立水力测功器轴承故障数据增强模型,解决提取训练得到合成数据的不平衡问题,从而实现水力测功器轴承故障在线诊断。

1　改进 GAN 算法

1.1　生成对抗神经网络

GAN[18-19]作为深度学习领域的一个重要生成模型,由两个网络即生成器和判别器组成,并通过极小化极大算法(minimax)在同一时间训练生成器和判别器,使其相互进行竞争,最终博弈达到纳什均衡。在文中下标“g”表示生成器相关的参数,下标“d”表示判别器相关参数。

GAN 不仅能够学习到原始数据的分布,且适用于在故障样本少的水力测功器轴承故障在线诊断的机器学习问题。在水力测功器轴承故障在线诊断过程中,对抗框架使用多层神经网络。定义数据集 $X=\{x_1,x_2,\cdots,x_N\}$,其中 x_i 为第 i 个样本,N 为样本总数。

生成器 G 的目标是生成能够迷惑判别器数据的目的,其生成的数据接近真实分布。设生成器 G 构建从真实分布 P_z 到生成分布 P_g 的映射关系 $G(z;\theta_g)$,其中 z 为生成器的输入(符合先验分布),θ_g 为生成器的参数。生成器 G 由多层神经网络构成,其损失函数定义为 $E_{z\sim P_z}\{-D[G(z)]\}$,$E_{z\sim P_z}\{D[G(z)]\}$ 的值越小生成的数据不够逼真。即可定义生成器 G 的目标函数为

$$\min(E_{z\sim P_z}\{-D[G(z)]\}) \tag{1}$$

式(1)中:z 为随机变量;P_z 为真实样本分布;$G(z)$ 为生成器生成的数据;$D[G(z)]$ 为判别器将生成样本识别为真的概率;$E_{z\sim P_z}\{\cdot\}$ 为在随机高斯噪声 z 的分布 P_z 下计算的期望。

判别器 D 的目标是构建一种函数 $D(\boldsymbol{I};\theta_d)$ 来判断输入时实际数据还是生成器 G 生成的迷惑数据。其中 $\boldsymbol{I}$ 为判别器 D 的输入,θ_d 为判别器 D 的参数。其输入向量 $\boldsymbol{I}$ 是实际数据或生成数据,输出是属于实际数据或者生成数据的概率。损失函数定义为 $E_{x\sim P_r}[D(x)]+E_{z\sim P_z}\{-D[G(z)]\}$,由于判别器是区分实际数据和生成数据,因此定义判别器的目标函数为

$$\max(E_{x\sim P_r}[D(x)]+E_{z\sim P_z}\{-D[G(z)]\}) \tag{2}$$

式(2)中:$D(x)$ 为判别器将真实样本 x 识别为真的概率;$E_{x\sim P_r}[\cdot]$ 为在真实样本 x 的分布 P_r 下计算的期望。

本文研究引入沃瑟斯坦度量(Wasserstein)构建整体训练的目标函数。Wasserstein 距离 $W(P_r,P_g)$ 用于描述数据分布 P_r 和 P_g 的期望距离,值越小表明 P_r 和 P_g 两分布的相似度越高。并根据 Kantorovich-Rubinstein duality 定律,可以将 $W(P_r,P_g)$ 表示为

$$\max\left(E_{x\sim P_r}[D(x)]+E_{z\sim P_z}\{-D[G(z)]\}+\lambda E_{\hat{x}\sim\hat{P}_r}[\|\nabla\hat{x}D(\hat{x})\|_p-1]^2\right) \tag{3}$$

式(3)中:$\|\cdot\|_p$ 为 p 范数;λ 为正则项系数;$\hat{x}=\varepsilon x+[1-G(z)]$,其中 $\varepsilon\sim U(0,1)$,U 为均匀分布;$E_{\hat{x}\sim\hat{P}_r}[\cdot]$ 为在样本 $\hat{x}$ 的分布 $\hat{P}_r$ 下计算的期望。

则 GAN 整体训练的目标函数为

$$\min_G\max_D\left(E_{x\sim P_r}[D(x)]+E_{z\sim P_z}\{-D[G(z)]\}+\lambda E_{\hat{x}\sim\hat{P}_r}[\|\nabla\hat{x}D(\hat{x})\|_p-1]^2\right) \tag{4}$$

通过采用交替训练的方式,学习获得有效 GAN 模型的判别器 D 和生成器 G,即进行多轮训练,每轮训练训练判别器 k 次再训练生成器 1 次。其训练过程如图 1 和图 2 所示。

当判别器 D 和生成器 G 之间的博弈达到纳什均衡时训练模型完成。

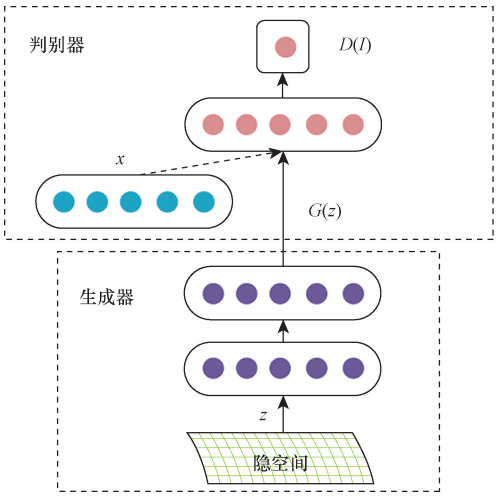

图 1 GAN 训练过程示意图

Fig. 1 Schematic representation of the GAN training process

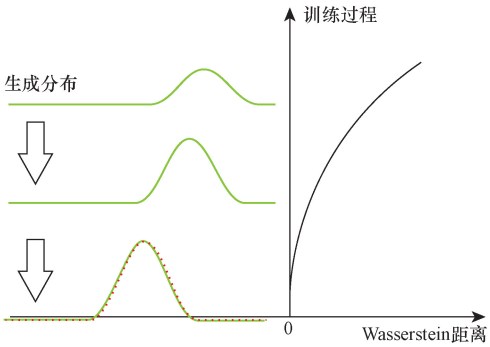

图 2 GAN 训练过程生成分布图

Fig. 2 The GAN training process generates a distribution diagram

1.2 改进后的 GAN

GAN 方法只能学习到实际数据的整体分布,但对于水力测功器轴承在线故障诊断,需要知道轴承具体的故障状态,为了进一步加入有关轴承健康状态的额外信息,同时对判别器 D 和生成器 G 的输入融入类别 one-hot 向量 $\boldsymbol{Y}=\{y_1,y_2,y_3,y_4\}$,其中 y_1 表示保持架故障,y_2 表示外环故障,y_3 表示内环故障,y_4 表示滚子故障,则轴承健康状态可归类为多分类问题。本文提出了一种改进 GAN,其网络结构如图 3 所示。

在先验分布 P_z 中结合向量 $\boldsymbol{y}$ 一起作为判别器 D 和生成器 G 的输入。因此改进后的 GAN 目标函数为

$$\min_G \max_D \left(E_{x\sim P_r}[D(x|y)] + E_{z\sim P_z}\{-D[G(z|y)]\} + \lambda E_{\hat{x}\sim \hat{P}_r}[\,\|\nabla_{\hat{x}} D(\hat{x}|y)\|_p - 1]^2 \right) \quad (5)$$

改进后的 GAN 算法采用神经网络,其采用 Relu 函数作为隐含层激活函数,同时采用粒子群算[19]对隐含层节点数量进行优化,确定出训练神经网络最优的隐含层节点数。具体优化流程如图 4 所示。基于粒子群算法的隐含层节点优化流程如下。

(1)初始化粒子群算法的相关参数,包括种群个数、学习因子等。

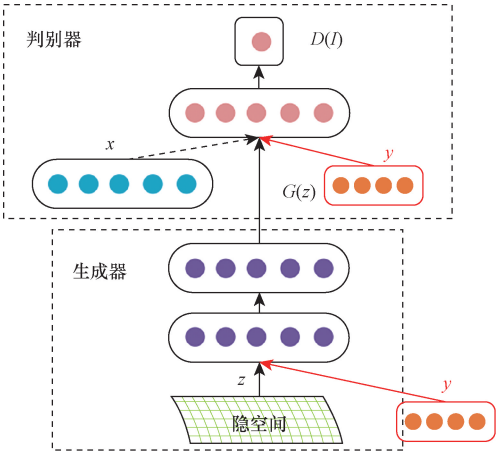

图 3 改进的生成对抗神经网络

Fig. 3 Improved generative adversarial neural networks

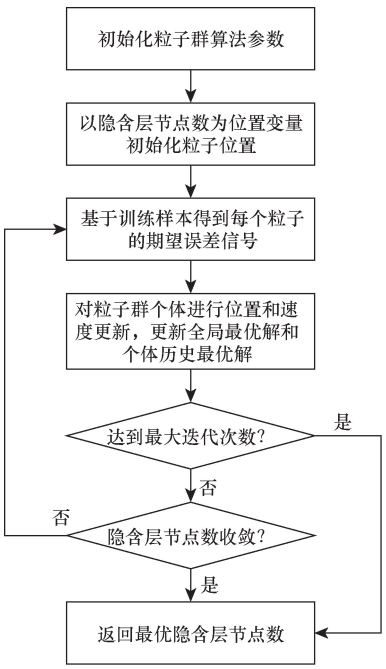

图 4 基于粒子群优化的隐含层节点流程图

Fig. 4 Flow chart of hidden layer nodes based on particle swarm optimization

(2)根据神经网络隐含层节点数经验公式,得到初始隐藏层节点数 L_0 ,即

$$L_0 = 2n + 1 \tag{6}$$

式(6)中:n 为输入层节点数。

选择初始节点数数据初始化粒子位置,得到 $L = [L(i)]$,其中 L 为正态分布 $N(L_0, n^2)$ 。

(3)计算得到第 i 个粒子的误差期望为 $\xi(i)$ 。通过训练得到每个粒子的 $L(i)$ 以及隐含层神经元的权重,从而进一步计算得到 $\xi(i)$ 。

(4)通过粒子适应度函数选择得到粒子的最优解(对应的适应度函数值最大),并保存、更新粒子最优解和全局最优解,同时更新粒子的相关参数。其中适应度函数为 $1/\xi^2(i)$ 。

(5)判断迭代次数是否达到最大迭代次数,达到则输出全局最优解;否则迭代次数加 1,返回步骤(3)。

神经网络输入层的激活函数为 sigmoid 函数,其将数据归一化至 [0,1] 区间内。在优化时采用基于动量的梯度下降的策略。

从基于数据驱动的水力测功器轴承故障在线诊断角度来看,改进后的 GAN 方法其生成器的生成分布可以看成一种非线性插值的过程。增加了故障样本的数目,能够有效帮助识别水力测功器运行中的轴承故障信息。

2　原始输入特征构建

构建原始输入特征是水力测功器轴承故障在线诊断的一项至关重要的工作。因此,原始输入特征的构建从根本上决定了轴承故障在线诊断的精度。通过机理分析,影响水力测功器轴承健康状态的主要因素有运行工况状态、轴承振动情况以及轴承冲击情况等。

首先,由于水力测功器在不同工况下轴承的运行状态存在一定差异,固通过引入运行工况状态反应轴承运行状态差异构造原始输入特征。因此,本文研究选取如下特征集:水力测功器转速瞬时值、单位时间转速变化值、水力测功器扭矩瞬时值、单位时间扭矩变化值。

其次,对轴承振动情况进行时域指标提取,通过振动时域指标反映表征轴承的不同运行状态。固选取以下特征值:有效值、波形指标、峰值指标、脉冲指标、裕度指标、峭度指标。其中不同振动时域指标作用如表 1 所示。

最后,当运转的轴承出现局部损伤后,损伤部位会与轴承的其他部位发生撞击,产生能量集中的冲击信号。不同故障类型产生的冲击重复频率不同,不同故障频率计算如表 2 所示,所以通过选取冲击指标反映表征轴承故障状态。

表 1　各振动时域指标作用

Table 1　Function of each vibration time domain index

参数指标	计算公式	作用
有效值	$x_{\mathrm{rms}} = \sqrt{\frac{1}{N}\sum_{k=1}^{N} x_k^2}$	反应信号的能量大小,相同工况下,能量值越大轴承振动越强烈
波形指标	$S_{\mathrm{f}} = \frac{x_{\mathrm{rms}}}{\lvert \bar{X} \rvert}$	波形指标的数值过大,表明滚动轴承可能有点蚀;波形指标较小,有可能发生磨损
峰值指标	$C_{\mathrm{f}} = \frac{x_{\max}}{x_{\mathrm{rms}}}$	正常轴承的振动的峰值指标为 4 ~ 5,故障初期不断增大,后期开始降低
脉冲指标	$I_{\mathrm{f}} = \frac{x_{\max}}{\lvert \bar{X} \rvert}$	辅助判断有无冲击信号的存在,对点蚀、划痕等冲击有很好的监测效果
裕度指标	$\mathrm{CL_f} = \frac{x_{\max}}{x_{\mathrm{r}}}$, $x_{\mathrm{r}} = \left(\frac{1}{N}\sum_{k=1}^{N}\sqrt{\lvert x_k \rvert}\right)^2$	裕度指标和脉冲指标一起使用,能够识别冲击脉冲的多少以及幅值分布形状的变化
峭度指标	$K_v = \frac{\beta}{x_{\mathrm{rms}}^4}$, $\beta = \frac{1}{N}\sum_{k=1}^{N}(\lvert x_k \rvert - \lvert \bar{X} \rvert)^4$	在故障初期该指标不断增大,晚期减小

注:x_{rms} 为振动有效值;N 为样本长度;x_k 为样本的第 k 个采样数;S_{f} 为波形指标;$\lvert \bar{X} \rvert$ 为振动平均值;C_{f} 为峰值指标;$x_{\max}$ 为样本最大值;I_{f} 为脉冲指标;$\mathrm{CL_f}$ 为裕度指标。

表 2　轴承故障特征频率

Table 2　Bearing fault characteristic frequency

故障部位	故障特征频率
保持架碰外环故障	$f_{\mathrm{bw}} = (D_0 - d\cos A)f_{\mathrm{n}}/(2D_0)$
保持架碰内环故障	$f_{\mathrm{bn}} = (D_0 + d\cos A)f_{\mathrm{n}}/(2D_0)$
外环故障	$f_{\mathrm{w}} = (D_0 - d\cos A)Zf_{\mathrm{n}}/(2D_0)$
内环故障	$f_{\mathrm{n}} = (D_0 + d\cos A)Zf_{\mathrm{n}}/(2D_0)$
滚子端面故障	$f_{\mathrm{D}} = (D_0{}^2 - d^2\cos^2 A)f_{\mathrm{n}}/(2D_0 d)$
滚子圆周故障	$f_{\mathrm{S}} = (D_0{}^2 - d^2\cos^2 A)f_{\mathrm{n}}/(D_0 d)$

注:D_0 为轴承中径;d 为滚动体直径;A 为接触角;Z 为滚动体数量;f_{n} 为所在轴转频;f_{bw} 为保持架碰外环故障频率;f_{bn} 为保持架碰内环故障频率;f_{w} 为外环故障频率;f_{n} 为内环故障频率;f_{D} 为滚子端面故障频率;f_{S} 为滚子圆周故障频率。

固选取以下特征值:冲击数据保持架碰外环 dB 值、冲击数据保持架碰内环 dB 值、冲击数据外环 dB 值、冲击数据内环 dB 值、冲击数据滚单 dB 值、冲击数据滚双 dB 值。其中 dB 值计算公式为

$$A_{\mathrm{dB}} = 20\lg\frac{2\,000\mathrm{SV}}{ND^{0.6}} \tag{7}$$

式(7)中:N 为轴承内外环相对运转转速;D 为轴承轴径;SV 为冲击值,不同故障对应的冲击值不同。

构建的轴承故障在线自动诊断原始特征输入特征集需具有完备性,能够全面反映某时刻轴承故障状态变化。本文研究共构建 22 维特征构成原始特征集,其中特征描述如表 3 所示。

表 3 原始输入特征

Table 3 Original input features

序号	特征描述
1	水力测功器转速瞬时值
2	单位时间转速变化值
3	水力测功器扭矩瞬时值
4	单位时间扭矩变化值
5	加速度有效值
6	加速度波形指标
7	加速度峰值指标
8	加速度脉冲指标
9	加速度裕度指标
10	加速度峭度指标
11	速度有效值
12	速度波形指标
13	速度峰值指标
14	速度脉冲指标
15	速度裕度指标
16	速度峭度指标
17	冲击数据保持架碰外环 dB 值
18	冲击数据保持架碰内环 dB 值
19	冲击数据外环 dB 值
20	冲击数据内环 dB 值
21	冲击数据滚单 dB 值
22	冲击数据滚双 dB 值

3 基于改进 GAN 的轴承故障在线诊断模型

3.1 基于支持向量机的基础分类器

支持向量机 SVM 是一种基于统计学习理论的机器学习方法。其决策边界是对学习样本求解的最大边距超平面,可以将问题化为一个求解凸二次规划的问题。其具有计算复杂度低,学习速率快的特点;并且其目标函数作为凸函数,具有唯一最优解实现全局最优。由于 SVM 优秀的泛化性能,因此本文分类器选择 SVM 算法。

3.2 模型性能评估

水力测功器轴承在线故障诊断中最核心的问题是研究哪种评估模型最好,如何对该模型的优越性进行评估。为了能够更好地反映轴承在线故障诊断的正确性,在轴承在线故障诊断中用以下指标来定义模型精度。

$$\begin{cases} a_{\mathrm{AMC1}} = \dfrac{f_{00}}{f_{00}+f_{01}} \times 100\% \\ a_{\mathrm{AMC2}} = \dfrac{f_{11}}{f_{11}+f_{10}} \times 100\% \\ \lambda_{\mathrm{AMC}} = \dfrac{f_{00}+f_{11}}{f_{00}+f_{01}+f_{11}+f_{10}} \\ \lambda_{\mathrm{mean}} = \sqrt{a_{\mathrm{AMC1}}a_{\mathrm{AMC2}}} \times 100\% \\ \lambda_{\mathrm{FA}} = \dfrac{f'_{11}}{f_{11}} \times 100\% \end{cases} \tag{8}$$

式(8)中:a_{AMC1} 为预测轴承正常正确分类占总分类数目的比例;a_{AMC2} 为预测轴承故障分类占总分类数目的比例;λ_{AMC} 为预测轴承状态正确占总分类数目的比例;λ_{FA} 为预测轴承故障正确但故障类型错误占总分类数目的比例;f_{11} 为故障轴承被预测为故障的数量;f_{00} 为正常轴承被预测为正常的数量;f_{10} 为故障轴承被预测为正常的数量;f_{01} 为正常轴承被预测为故障的数量;f'_{11} 为故障轴承虽被预测为故障,但预测类型错误的数量;λ_{mean} 为 a_{AMC1} 和 a_{AMC2} 的几何平均,能够有效衡量不平衡数据的评估性能。a_{AMC} 则代表了总体正确率。

该评估模型能够全面对模型的优越性进行评估,通过 λ_{mean}、λ_{AMC} 和 λ_{FA} 评估指标全面反映评估的正确性和评估中出现每种误判的概率,并直观表现轴承故障在线诊断的优越性。

3.3 基于改进 GAN 的轴承故障在线诊断数据增强模型

为了能够有效增强轴承在线诊断数据,本文研究提出了一种轴承故障在线诊断数据增强模型,如图 5 所示。

3.3.1 离线增强训练

(1)首先用原始数据训练得到 SVM 分类器,评估改进 GAN 在训练过程中生成数据有效性。

(2)其次,将原始训练数据输入改进 GAN 算法模型中,训练得到相应的生成器和判别器,同时,通过判别器促进生成器的进化。其中采用交替训练模式训练改进 GAN,即在每训练判别器 k 次之后训练生成器 1 次。则每训练 1 轮生成一组轴承故障样本数目与轴承正常样本数目相同的数据。因此在 m 轮后生成 m 组合成数据。

(3)利用①中训练好的 SVM 分类器评估 λ_{mean} 值满足阈值的生成数据,与原始训练数组合成新的原始训练数据,从而实现数据增强的功能。

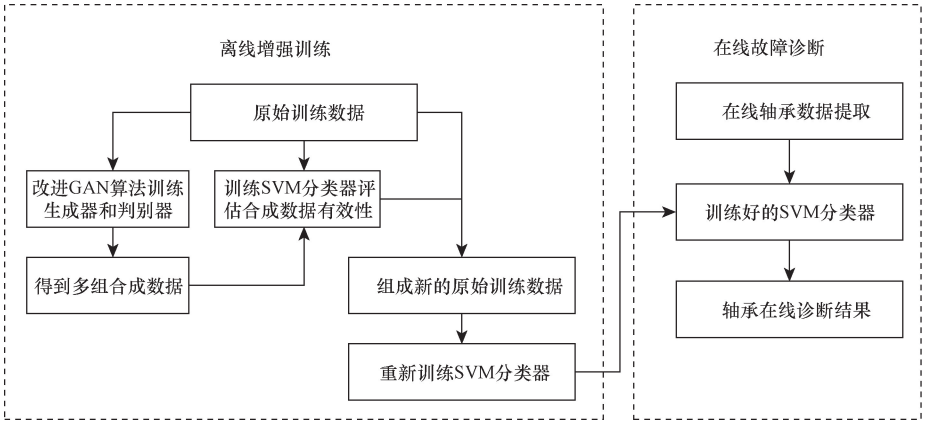

图 5　轴承故障在线诊断数据增强模型框架

Fig. 5　Data enhancement model framework for online diagnosis of bearing faults

(4)对增强后的数据运用 SVM 方法进行重新训练,得到在线故障诊断 SVM 分类器。

3.3.2　在线故障诊断

将离线增强训练得到的在线故障诊断 SVM 分类器进行在线应用,有效善数据的不平衡度,降低误判率。在线轴承故障诊断时,首先通过加装的振动冲击复合传感器采集轴承数据,然后提取水力测功器工况以及轴承的振动、冲击特征数据,最后通过轴承故障诊断分类器模型在线快速诊断水力测功器轴承故障情况。

4　仿真分析

4.1　原始数据集

仿真硬件为 Intel@ Core(TM) i5-12500H 2.50 GHz, 16.0 GB 内存。数据增强模型基于深度学习框架 Tensorflow1.4 和 Keras 构建。

本文研究收集了 Froude 某型水力测功器的转子轴承数据,从中共计获取 36 000 个样本,其中 34 000个正常轴承样本,2 000 个故障轴承样本(其中保持架故障样本 200,外环故障样本 800,内环故障样本 500,滚子故障样本 500)。将其中 25 200 个样本用作训练集输入模型进行训练,10 800 个样本用作测试集验证模型的有效性。

4.2　改进 GAN 数据增强方法有效性对比

将使用原始数据训练得到的 SVM 分类器、使用改进 GAN 训练增强得到的 SVM 分类器、以及使用 SMOTE 或 ADASYN 数据增强方法得到的 SVM 分类器进行性能对比分析,验证本文改进 GAN 进行数据增强的有效性。在测试集上得到结果如表 4 所示。

水力测功器原始数据由于轴承故障样本极少(占总样本 5.56%),即将样本识别为轴承故障状态时所对应的分类器泛化能力较弱,故障样本 a_{AMC2} 识别正确率仅有 62.3% 且故障类别 λ_{FA} 判断正确率仅有 52.73%。而使用数据合成方法 SMOTE 或 ADASYN可以一定提升分类器在故障轴承识别上的泛化性能,故障轴承识别正确率仅 77.3% 或 84.4%,漏警率较高。而使用本文所提改进 GAN 方法进行数据增强训练,生成新的数据在数据分布特性上接近原始数据分布,可以合成新的“真实”数据,从而极大提高了故障轴承识别正确率 a_{AMC2} 和故障类识别正确率 λ_{FA},能够有效降低故障样本少带来的在线诊断风险。

表 4　不同数据性能对比分析

Table 4　Comparative analysis of different data performance

方法	a_{AMC1} /%	a_{AMC2} /%	λ_{AMC} /%	λ_{mean} /%	λ_{FA} /%
未使用	95.96	62.30	94.09	77.32	52.73
SMOTE	98.61	77.30	97.43	87.31	78.37
ADASYN	97.14	84.40	96.43	90.55	91.95
改进 GAN	98.62	96.25	98.49	97.43	97.66

因此,本文所提出的改进 GAN 数据增强方法更加适用于水力测功器轴承故障在线诊断,极大提高了 Froude 水力测功器使用安全性。

4.3　改进 GAN 对噪声的鲁棒性

为了准确模拟传感器的测量误差,在原始数据中加入信噪比为 40 db 的高斯白噪声,再进行不同模型轴承故障诊断正确率对比,在测试集上得到结果如表 5 所示。

表 5　噪声情况下不同数据性能对比分析

Table 5　Comparative analysis of different data performance under noise condition

方法	a_{AMC1} /%	a_{AMC2} /%	λ_{AMC} /%	λ_{mean} /%	λ_{FA} /%
未使用	90.29	54.45	88.30	70.12	58.13
SMOTE	91.40	66.10	89.99	77.73	82.45
ADASYN	93.62	76.25	92.66	84.49	84.79
改进 GAN	95.68	91.25	95.43	93.44	3.56

在相同的信噪比下,改进 GAN 的诊断正确率远高于 SMOTE、ADASYN 和不适用数据增强方法的情况,说明该方法在抗噪声方面优于其他方法,具有较强的泛化能力。

5 结论

针对水力测功器轴承故障样本稀少的情况,提出了一种基于改进 GAN 的轴承故障在线诊断方法,能够有效学习故障样本数据分布特性,增强轴承故障样本数量,有效降低轴承故障在线识别的误判率。并运用实际水力测功器轴承案例库上进行仿真验证,得到如下结论。

(1)改进 GAN 能够有效增强故障样本数量,学习故障样本特征分布特性。并通过仿真验证其优于其他数据增强方法。

(2)改进 GAN 是基于博弈论的方式,因此在抗噪能力上更具优点,更适用于水力测功器复杂环境背景下的轴承故障诊断。

(3)基于改进 GAN 的轴承故障在线诊断模型具有诊断准确率高的特点,能够准确识别水力测功器轴承故障及故障类型。

综上所述,本文提出的基于改进 GAN 算法的水力测功器轴承故障在线诊断模型具有诊断精度高、抗噪声干扰能力强、轴承故障类型识别错误率低的特点,提高了水力测功器试验装备故障预警率。

参 考 文 献

[1] Khan M A, Singh S, Ji O, et al. Parameter determination of hydraulic dynamometer [J]. International Journal of Engineering Technologies and Management Research, 2020, 5(2): 137-147.

[2] 罗亭, 王晓东, 马军, 等. 基于 ICFE 和 WPHM 的滚动轴承健康状态评估[J]. 电子测量与仪器学报, 2021, 35(12): 116-125.
Luo Ting, Wang Xiaodong, Ma Jun, et al. Health status assessment of rolling bearings based on ICFE and WPHM[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(12): 116-125.

[3] Liu F, Gao J, Liu H. The feature extraction and diagnosis of rolling bearing based on CEEMD and LDWPSO-PNN[J]. IEEE Access, 2020 (99): 1-10.

[4] 刘万宇, 李宇鹏, 石怀涛, 等. 基于 WDCNN- DLSTM 的滚动轴承故障诊断方法[J]. 科学技术与工程, 2023, 23(13): 5522-5529.
Liu Wanyu, Li Yupeng, Shi Huaitao, et al. Fault diagnosis method for rolling bearing based on WDCNN-DLSTM[J]. Science Technology and Engineering, 2023, 23(13): 5522-5529.

[5] 陈志刚, 蔡春雨, 王莹莹, 等. 基于 GOA 优化支持向量机滚动轴承故障诊断[J]. 科学技术与工程, 2023, 23(19): 8194-8200.
Chen Zhigang, Cai Chunyu, Wang Yingying, et al. Fault diagnosis of rolling bearing based on GOA optimized support vector machine [J]. Science Technology and Engineering, 2023, 23(19): 8194-8200.

[6] Sun C, Yin H, Liu Y, et al. A novel rolling bearing vibration impulsive signals detection approach based on dictionary learning[J]. IEEE/CAA Journal of Automatica Sinica, 2020 (99): 1-11.

[7] Zhen D, Guo J, Xu Y, et al. A novel fault detection method for rolling bearings based on non-Stationary vibration signature analysis [J]. Sensors, 2019, 19(18): 3994-3999.

[8] 鲁夕瑶, 张成彬, 皋军, 等. 基于卷积神经网络与 CatBoost 的轴承故障诊断算法[J]. 机电工程, 2023, 40(5): 715-722.
Lu Xiyao, Zhang Chengbin, Gao Jun, et al. Bearing fault diagnosis algorithm based on convolutional neural network and CatBoost[J]. Journal of Mechanical & Electrical Engineering, 2023, 40(5): 715-722.

[9] 张星星, 李少波, 柘龙炫, 等. 基于机器学习算法的滚动轴承故障诊断研究[J]. 组合机床与自动化加工技术, 2020(7): 36-39, 44.
Zhang Xingxing, Li Shaobo, Tuo Longxuan, et al. Research on fault diagnosis of rolling bearings based on machine learning algorithm[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020(7): 36-39, 44.

[10] 刘艾强. 基于数据驱动的滚动轴承故障诊断研究与应用[D]. 大连: 大连理工大学, 2022.
Liu Aiqing. Research and application of fault diagnosis of rolling bearing[D]. Daliang: Dalian University of Technology, 2022.

[11] 李中, 卢春华, 王星, 等. 考虑滚动轴承故障位置与损伤程度的双分支卷积神经网络故障诊断方法[J]. 科学技术与工程, 2022, 22(4): 1441-1448.
Li Zhong, Lu Chunhua, Wang Xing, et al. Double-branch convolutional neutral network fault diagnosis method considering the fault location and damage degree of rolling bearings[J]. Science Technology and Engineering, 2022, 22(4): 1441-1448.

[12] Yang S J, Yang P K, Yu H, et al. A 2DCNN-RF model for offshore wind turbine high-speed bearing-fault diagnosis under noisy environment[J]. Energies, 2022, 15(9): 3340-3340.

[13] 焦静, 岳建海, 裴迪. 基于 MSK-SVM 的滚动轴承故障诊断方法[J]. 电子测量与仪器学报, 2022, 36(1): 109-117.
Jiao Jing, Yue Jianhai, Pei Di. Rolling fault fault method based on MSK-SVM[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 109-117.

[14] 但长林, 李三雁, 张彬. 基于样本熵和 SVM 的滚动轴承故障诊断方法研究[J]. 中国测试, 2020, 46(11): 37-42.
Dan Changlin, Li Sanyan, Zhang Bin. Tudy on fault diagnosis method of rolling bearings based on sample entropy and SVM[J]. China Measurement & Test, 2020, 46(11): 37-42.

[15] 黄海松, 魏建安, 任竹鹏, 等. 基于失衡样本特性过采样算法与 SVM 的滚动轴承故障诊断[J]. 振动与冲击, 2020, 39(10): 65-74, 132.
Huang Haisong, Wei Jian'an, Ren Zhupeng, et al. Rolling bearing fault diagnosis based on the oversampling algorithm and SVM [J]. Journal of Vibration and Shock, 2020, 39(10): 65-

74, 132.

[16] 刘建伟, 谢浩杰, 罗雄麟. 生成对抗网络在各领域应用研究进展[J]. 自动化学报, 2020, 46(12): 2500-2536.
Liu Jianwei, Xie Haojie, Luo Xionglin. Progress in the application of generated adversarial network in various fields[J]. Acta Automatica Sinica, 2020, 46(12): 2500-2536.

[17] Zhou F, Yang S, Fujita H, et al. Deep learning fault diagnosis method based on global optimization GAN for unbalanced da-ta[J]. Knowl Based Systerm, 2020, 187: 104837. 1-104837. 19.

[18] 郭小龙, 李子康, 刘灏, 等. 基于增强生成对抗网络的 PMU 丢失数据恢复方法[J]. 电网技术, 2022, 46(6): 2114-2121.
Guo Xiaolong, Li Zikang, Liu Hao, et al. PMU loss data recovery method based on enhanced generation adversarial network[J]. Power System Technology, 2022, 46(6): 2114-2121.

[19] 王虹, 徐佑宇, 谭冲, 等. 基于改进粒子群的 BP 神经网络 WSN 数据融合算法[J]. 中国科学院大学学报, 2020, 37(5): 673-680.
Wang Hong, Xu Youyu, Tan Chong, et al. WSN data fusion algorithm based on improved particle swarm[J]. Journal of University of Chinese Academy of Sciences, 2020, 37(5): 673-680.