

引用格式: 郭小鹏, 杜少辉, 安中彦, 等. 基于自注意力和改进 ACGAN 的航空发动机轴承故障诊断方法[J]. 航空发动机, 2026, 52(1): 59-65. GUO Xiaopeng, DU Shaohui, AN Zhongyan, et al. A bearing fault diagnosis method for aeroengines based on self-attention and improved ACGAN[J]. Aeroengine, 2026, 52(1): 59-65.

基于自注意力和改进 ACGAN 的航空发动机轴承故障诊断方法

郭小鹏¹, 杜少辉¹, 安中彦¹, 李修文^{2,3}, 金贻涛², 路 阳¹

(1. 中国航发沈阳发动机研究所, 沈阳 110015; 2. 唐智科技湖南发展有限公司, 长沙 410083;

3. 北京唐智科技发展有限公司, 北京 100038)

摘要: 为了解决在实际航空发动机工程应用中不允许发动机带故障运行导致故障样本稀少, 其样本的不平衡性严重降低了基于数据驱动轴承故障诊断模型的准确性和稳定性, 需减轻对轴承故障数据依赖性的问题, 提出了基于自注意力和改进条件生成式对抗网络 (ACGAN) 的航空发动机轴承故障诊断方法。运用振动数据和工况数据建立原始输入特征数据集, 极大保留了原始数据的特性和运行工况; 运用基于自注意力和改进 ACGAN 建立数据增强模型得到合成数据, 并融合原始数据和合成数据作为输入特征训练 Softmax 分类器, 建立航空发动机轴承故障诊断模型; 基于融合数据集增强了 4 种轴承故障数据集, 并对轴承故障诊断模型进行了验证。结果表明: 基于自注意力和改进 ACGAN 模型生成的数据用于航空发动机轴承故障诊断准确率为 98.9%、精确率为 90.59%、召回率准确率为 96.25%、平衡 F 分数为 93.33%, 该模型能够显著提高故障诊断模型的性能。

关键词: 轴承; 自注意力; 改进条件生成式对抗网络; 故障诊断; 航空发动机

中图分类号: V233.4+5

文献标识码: A

doi: 10.12482/ISSN.1672-3147.20231013001

A Bearing Fault Diagnosis Method for Aeroengines Based on Self-Attention and Improved ACGAN

GUO Xiaopeng¹, DU Shaohui¹, AN Zhongyan¹, LI Xiuwen^{2,3}, JIN Yitao², LU Yang¹

(1. AECC Shenyang Engine Research Institute, Shenyang 110015, China;

2. Tangzhi Technology Hunan Development Co., Ltd., Changsha 410083, China;

3. Beijing Tangzhi Technology Development Co., Ltd., Beijing 100038, China)

Abstract: In practical aeroengine engineering applications, engines are not allowed to operate with faults, resulting in a scarcity of fault samples. This sample imbalance significantly degrades the accuracy and stability of data-driven bearing fault diagnosis models, necessitating a reduction in reliance on bearing fault data. To address these issues, this paper proposes a bearing fault diagnosis method for aeroengines based on self-attention and an improved auxiliary classifier generative adversarial network (ACGAN). Firstly, the original input feature dataset is constructed using vibration data and operating condition data, which effectively preserves the characteristics and operating conditions of the original data. Secondly, a data augmentation model based on self-attention and improved ACGAN is developed to generate synthetic data. The original and synthetic data are then fused and used as input features to train the Softmax classifier, thereby establishing the aeroengine bearing fault diagnosis model. Finally, the fused dataset is employed to enhance four types of bearing fault datasets, and the proposed model is verified. The results show that the model based on self-attention and improved ACGAN achieves a diagnostic accuracy of 98.9%, precision of 90.59%, recall of 96.25%, and a balanced F-score of 93.33%, demonstrating its ability to significantly improve the performance of the aeroengine bearing fault diagnosis.

Key words: bearings; self-attention; improved auxiliary classifier generative adversarial network; fault diagnosis; aeroengine

0 引言

航空发动机是飞机的核心部件^[1], 其滚动轴承起着支撑转子的关键作用。随着发动机性能不断提升, 其轴承长期处于高速、高温、重载、强扰动等极端环境

下运行, 导致轴承故障频发, 是发动机故障概率较高的部件, 严重威胁发动机的安全运行^[2]。因此, 诊断其轴承状况, 利用故障诊断技术预测潜在的故障, 分析故障原因并及时维修, 降低机械设备的维护成本, 避免重大事故的发生, 是当前研究的重点和难点^[3-5]。振

收稿日期: 2023-10-13 基金项目: 国家航空科技研究项目资助

作者简介: 郭小鹏 (1982), 男, 硕士, 高级工程师。

动信号中富含大量的冲击,间接反映了轴承的故障现象,学者们已经开发了许多基于振动信号的轴承智能故障诊断方法。其中,深度学习作为一种数据驱动方法,能够从振动信号中自动提取故障特征,实现故障模型的故障识别。为了实现在线诊断,不仅需要选择合理的深度学习模型,还需要使用足够的故障样本来完成诊断模型的训练和建模^[6-7]。然而,在实际工程中,故障样本的采集往往成本高、数量有限且不均,极大地限制了模型的应用范围和行业推广^[8]。

Bousmalis^[9]提出了一种生成式对抗网络(Generative Adversarial Networks, GAN),通过学习初始样本的潜在分布来生成新样本(伪样本),然而GAN存在梯度爆炸或精度消失、收敛速度慢、在训练过程中学习数据特征能力差等问题。为了解决上述问题,学者们对GAN模型进行了相应地改进。Liu等^[10]将GAN与叠加降噪自动编码器相结合,解决了轴承故障样本数据不平衡的问题;Zhou等^[11]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;李俊卿等^[12]利用条件生成式对抗网络(Conditional GAN, CGAN)模型生成带标签信息的数据,将GAN模型由无监督转变为有监督;Ding等^[13]提出了在CGAN中引入Wasserstein距离和梯度罚项(Gradient Penalty, GP)的CGAN-GP模型生成指定的故障样本;刘宁等^[14]在CGAN引入SMOTEENN(SMOTE+ENN)方法,但其过采样算法产生的数据会引入一定的噪声。虽然上述方法提高了训练的稳定性和生成数据的质量,但存在故障样本集数量不足、容易出现梯度爆炸等问题。卢锦玲等^[15]和孙灿飞等^[16]运用辅助分类器生成对抗网络(Auxiliary Classifier GAN, ACGAN)极大程度地克服了CGAN模型训练困难的缺点,并且可以生成指定目标类别的高质量数据。

基于此,本文提出基于自注意力和改进ACGAN的航空发动机轴承故障诊断方法。

1 基于自注意力和改进ACGAN算法原理

1.1 GAN基本理论

基于对抗博弈的思想,最早由Ian Goodfellow于2014年提出GAN模型。该模型由生成器 G 和判别器 D 组成。其中生成器 G 输入的是噪声矢量 z ,输出的是

合成数据 $X_{syn} = G(z)$;判别器 D 的输入是真实数据 X_{rea} 和合成数据 X_{syn} ,输出是真或假的标记。基于判别损失和分类损失的联合损失通过反向传播算法计算,联合损失函数为

$$L(D, G) = E_{S \sim P_{data}} [\log_2 D(s)] + E_{Z \sim P_z} [\log_2 (1 - D(G(z)))] \quad (1)$$

式中: s 为判别器的输入矢量; P_{data} 为真实数据的概率分布; z 为生成器的输入矢量; P_z 为噪声数据的概率分布; $E[\cdot]$ 为数据的数学期望。

优化模型简化为最大最小函数问题为

$$Goal = \arg \min_G \max_D L(G, D) \quad (2)$$

其优化目标是训练GAN模型,使判别器 D 对应最大的损失为 $L(G, D)$ 时,生成器 G 对应最小的损失。

1.2 ACGAN基本理论

Mirza等^[17]提出了CGAN,即在GAN的基础上将生成器和判别器中加入辅助分类标签 c ,用来指导数据生成的方向,实现监督学习。

ACGAN^[18]在CGAN的基础上加以改进,标签信息只作用于生成器,将辅助分类器 C 引入判别器用于判别样本的类别。能够通过辅助分类器在生成过程中控制样本生成的方向,以生成高质量的结果。ACGAN的网络结构如图1所示。

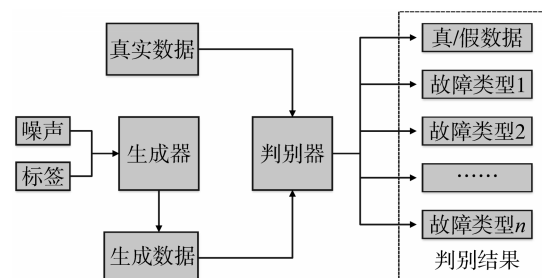


图1 ACGAN的网络结构

Fig.1 Network architecture of ACGAN

ACGAN的生成器为 $X'_{syn} = G(z, c)$,其中 y 为标签向量。判别器不仅可以判断数据的真实性即真假损失函数 $L_{T-F} = L(D, G)$,还可判断数据的类别即标签损失函数 L_{class}

$$L_{class} = E_{S \sim P_{data}} [\log_2 P(C = clX_{rea})] + E_{Z \sim P_z} [\log_2 P(C = clX_{syn})] \quad (3)$$

该模型训练过程为:

(1)判别器 D 参数固定,训练生成器 G ,得到损失函数 $L_{T-F} - L_{class}$;

(2)生成器 G 参数固定,训练判别器 D ,得到损失函数 $L_{T-F} + L_{class}$ 。

判别器网络的训练目标是最大化对数似然 $L_{T-F} - L_{class}$,而生成器网络的训练目标是最大化对数似然 $L_{T-F} + L_{class}$ 。由于辅助分类生成对抗网络增加了标签信息,因此能提高产生比无监督 GAN 和有监督 CGAN 更高的样本质量,适用于航空发动机轴承故障诊断模型训练数据的扩充任务。

1.3 改进 ACGAN 的基本理论

对常规 ACGAN 的生成器和判别器网络结构进行改进,得到改进 ACGAN 的网络结构,其分为由卷积神经网络(Convolutional Neural Network, 2D-CNN)-长短期记忆网络(Long Short-Term Memory, LSTM)组成的生成器网络和由多层感知器(Multilayer Perceptron, MLP)组成的判别器网络 2 部分。

在生成器网络方面,改进 ACGAN 采用 2D-CNN 和 LSTM 相结合,整个生成器模型采用端到端学习架构,提高了整个模型的故障分类精度。不同的神经网络组合成一个深度网络,增强了模型的非线性,避免产生模型训练中的过拟合现象。此外该组合模型能够有效地学习轴承故障数据的数学分布和特征信息,使得生成的数据更接近真实数据。在判别器网络方面,由全连通层神经网络构成的 MLP 可以加快模型的训练速度,克服了判别器由于网络过于复杂、层次较深而在进行判别时丢失轴承故障数据重要特征的缺点。

生成器和判别器网络结构如图 2 所示。从图 2 (a)中可见,生成器网络结构中设计的 2D-CNN 模型采用 3 个卷积层,在第 1 卷积层后添加池化层;第 2、3

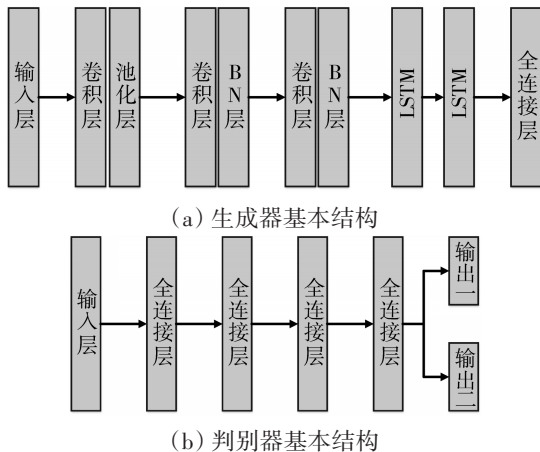


图 2 生成器和判别器网络结构

Fig. 2 Network architectures of generator and discriminator

卷积层取消了池化层,添加了批归一化(全称 BN)层,以改善流经网络的梯度,防止梯度消失,增强所生成样本的多样性,提高训练网络的稳定性。从图 2(b)中可见,判别器网络设计采用 4 层全连接层,激活函数选择 LeakyReLU。输出层有 2 个输出:一个输出使用 Sigmoid 激活函数,用于判断输入数据的真实性,1 表示真数据,反之为伪数据;另一个输出使用 Softmax 分类器确定轴承不同故障类型的判别结果。

1.4 自注意力模型

基于自注意力模型网络结构如图 3 所示。

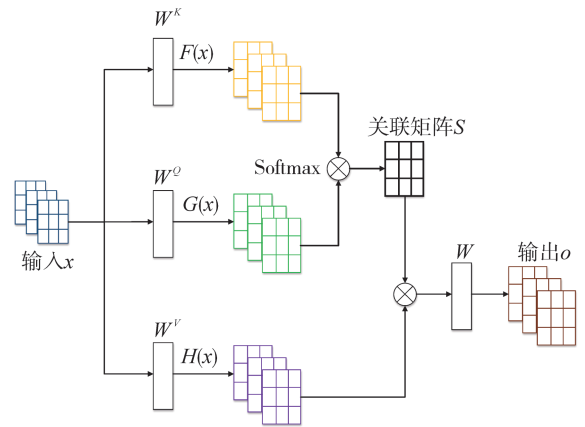


图 3 自注意力模型网络结构

Fig. 3 Network architecture of self-attention model

图中 \otimes 表示矩阵乘法,并使用 Softmax 进行激活。其在改进 ACGAN 的基础上,将自注意力机制加入 G 和 D ,解决了改进 ACGAN 只能计算特定邻域内的数据特征的限制性,帮助模型捕捉样本长距离特征间的联系。其具体过程如下。

(1)输入 x 乘上不同权重矩阵,得到

$$\begin{cases} F(x) = W^K \cdot x \\ G(x) = W^Q \cdot x \\ H(x) = W^V \cdot x \end{cases} \quad (4)$$

(2)计算 $F(x)$ 和 $G(x)$ 之间的关联矩阵 S

$$S = F^T \cdot G \quad (5)$$

(3)计算 $F(x)$ 和 $G(x)$ 之间的相关程度

$$\beta_{j,i} = \frac{e^{s_{ij}}}{\sum_{i=1}^N e^{s_{ij}}} \quad (6)$$

式中 s_{ij} 为关联矩阵 S 的元素。

(4)得到自注意力模型的输出特征

$$o_i = \sum_{i=1}^N \beta_{j,i} H(x_i) \quad (7)$$

(5)加入权重系数 γ ,实现领域信息与远距离特

征的整合

$$y_i = \gamma o_i + x_i \quad (8)$$

加入自注意力机制后得到判别器 D 的真假损失

函数 $L_{T-F_attention} = L'(D, G)$

$$L(D, G) = E_{S-P_data} \left[\min(0, -1 + D(s, y)) \right] + E_{Z-P_z} \left[\min(0, -1 + D(G(z), y)) \right] \quad (9)$$

将自注意力机制引入到 ACGAN 模型, 能够充分捕捉特征, 学习数据的时间依赖性, 有助于进一步提高模型识别效率。

2 轴承故障诊断模型

2.1 原始输入特征数据集

构建原始输入特征是航空发动机轴承快速故障诊断的一项至关重要的工作。通过振动数据提取出影响轴承健康状态的主要因素有运行工况、时域和频域特征, 共构建 128 维特征构成振动原始输入特征数据集。其中:

(1) 运行工况特征。由于航空发动机在不同工况下轴承的运行状态存在差异, 通过引入运行工况特征反映轴承运行状态差异构造振动特征值输入数据集。选取输入轴转速的平均值、最大值、最小值、方差和扭矩的平均值、最大值、最小值、方差, 以及飞行高度、环境温度、大气压力, 共 11 个特征值。

(2) 时域特征。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。选取加速度和速度的有效值、峰峰值、波形指标、峰值指标、脉冲指标、裕度指标、峭度指标, 共 14 个特征值。

(3) 频域特征。对轴承振动情况进行频域指标提取, 通过振动频域指标反映表征轴承的不同健康状态。选取轴承所在轴转频第 1~3 阶幅值、频谱中幅值前 50 的频率值和幅值, 共 103 个特征值。

为了生成支持网络输入的 2D 数据, 选择较长时间样本, 生成得到 128×128 数据样本。例如: 设实际中每 1 s 样本提出 128 维特征, 则选取 128 s 样本分段共计提取 128×128 数据样本。

2.2 轴承故障诊断模型

为了快速有效地进行航空发动机轴承在线诊断,

本文建立了一种基于自注意力和改进 ACGAN 的航空发动机轴承故障诊断模型, 如图 4 所示。

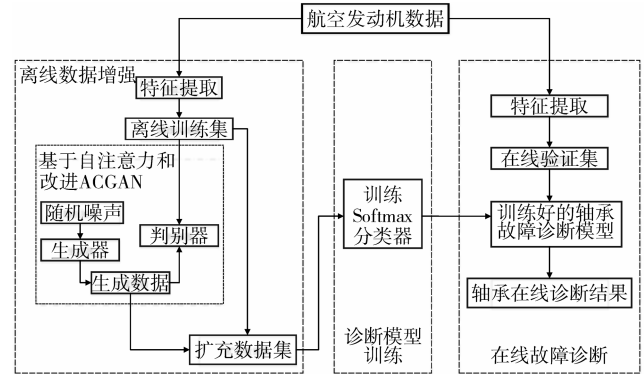


图4 航空发动机轴承故障诊断模型

Fig. 4 Fault diagnosis model for aeroengine bearings

航空发动机轴承故障诊断模型分为离线数据增强、诊断模型训练和在线故障诊断 3 部分。

(1) 离线数据增强。引入沃瑟斯坦度量 (Wasserstein) 构建整体训练的目标函数, 度量生成样本和真实样本的差别, 基于自注意力和改进 ACGAN 构建数据增强模型, 生成高质量的故障样本, 用于航空发动机轴承故障诊断。针对梯度爆炸或梯度消失问题, 建立梯度惩罚项

$$L_{gp} = \lambda E_{\hat{x} \sim \hat{p}} \left[\left\| \nabla_{\hat{x}} D(\hat{x}) \right\|_p - 1 \right]^2 \quad (10)$$

式中: $\|\cdot\|_p$ 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。

则基于自注意力和改进 ACGAN 的数据增强模型整体训练的目标函数为

$$\min_G \max_D \left\{ \begin{aligned} & E_{x \sim p} \left[\min(0, -1 + D(x, y)) \right] + \\ & E_{z \sim p_z} \left[\min(0, -1 + D(G(z), y)) \right] + \\ & \lambda E_{\hat{x} \sim \hat{p}} \left[\left\| \nabla_{\hat{x}} D(\hat{x}) \right\|_p - 1 \right]^2 \end{aligned} \right. \quad (11)$$

(2) 诊断模型训练。对增强生成的数据集与降维后的数据集进行融合得到新的数据集, 然后训练得到在线故障诊断 Softmax 分类器。

(3) 在线故障诊断。采集航空发动机在线数据, 提取得到振动特征值输入数据集, 得到 128×128 数据样本, 作为离线增强训练得到的在线故障诊断 Softmax 分类器的输入, 该分类器模型可以在线做出准确、快速地判断, 诊断发动机轴承故障。

在轴承故障诊断中用以下指标来定义模型精度

$$\begin{cases} a_{AMC1} = \frac{f_{00}}{f_{00} + f_{01}} \times 100\% \\ a_{AMC2} = \frac{f_{11}}{f_{11} + f_{10}} \times 100\% \\ a_{AMC3} = \frac{f'_{11}}{f_{11} + f_{10}} \times 100\% \\ \lambda_{mean} = \sqrt{a_{AMC1} \times a_{AMC2}} \times 100\% \end{cases} \quad (12)$$

式中: a_{AMC1} 为预测轴承正常正确分类占总分类数目的比例; a_{AMC2} 为预测轴承故障正确分类占总分类数目的比例; a_{AMC3} 为预测轴承故障类型分类正确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'_{11} 为故障轴承被预测为故障且故障类预测正确的数量; 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; λ_{mean} 为 a_{AMC1} 和 a_{AMC2} 的几何平均,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诊断的优越性。

3 轴承故障仿真研究

3.1 原始数据集

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

从航空发动机轴承案例库中共获取 10000 个样本,其中 9200 个正常轴承样本,800 个故障轴承样本(其中保持架故障样本 80 个,外环故障样本 320 个,内环故障样本 240 个,滚子故障样本 160 个),将 7000 个样本用作训练集输入模型进行训练,3000 个样本用作测试集验证模型的有效性。

3.2 样本增强模型训练

用训练集对判别器和生成器进行训练,在训练过程中的损失曲线和分类准确率曲线分别如图 5、6 所示。




图 5 判别器和生成器损失曲线

Fig. 5 Loss curves of discriminator and generator




图 6 判别器和生成器分类准确率曲线

Fig. 6 Classification accuracy curves of discriminator and generator

从图中可见,该模型在大约 1000 次训练后判别器和生成器达到纳什均衡。判别器和生成器在训练过程中的分类精度波动提高,在充分训练后该发生器已经具有合成高质量故障样本数据的能力。

在训练过程中,超参数设置如下:学习率为 0.0002,批量大小为 10,优化器为 Adam。

3.3 轴承故障诊断对比分析

本文将使用原始数据训练得到的 Softmax 分类器、使用 ACGAN 训练增强得到的 Softmax 分类器、使用基于自注意力和改进 ACGAN 训练增强得到的 Softmax 分类器、采用合成少数类过采样技术 (Synthetic Minority Oversampling, SMOTE) 合成新样本增强方法得到的 Softmax 分类器和采用自适应综合过采样技术 (Adaptive Synthetic Sampling, ADASYN) 合成新样本增强方法得到的 Softmax 分类器进行性能对比分析,验证本文所提基于自注意力和改进 ACGAN 进行数据增强方法的有效性。在测试集上得到结果见表 1。

表 1 不同模型性能诊断对比分析

Table 1 Comparative analysis of performance diagnosis for different models

方法	a_{AMC1}	a_{AMC2}	a_{AMC3}	λ_{mean}
原始数据	95.94	62.50	33.75	77.44
SMOTE	97.61	81.25	57.08	89.05
ADASYN	97.14	80.83	58.33	88.61
ACGAN	98.62	86.25	82.08	92.23
基于自注意力和改进 ACGAN	99.13	96.25	92.50	97.68

航空发动机轴承原始数据由于轴承故障样本极少(占总样本 8.70%),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, a_{AMC2} 识别正确率仅 62.32%,且故障类别 a_{AMC3} 识别正确率仅 33.75%。

为了验证基于自注意力和改进 ACGAN 在航空发动机轴承故障诊断中的性能,本文采用 4 种对比方法

来证明所提方法的优越性。包括:数据合成方法 SMOTE、ADASYN 和 ACGAN,其故障轴承 a_{AMC2} 识别正确率分别为 81.25%、80.83% 和 86.25%,故障类别 a_{AMC3} 识别正确率分别为 57.08%、58.33% 和 82.08%,漏警率较高。而采用本文所提基于自注意力和改进 ACGAN 方法进行数据增强训练,故障轴承 a_{AMC2} 识别正确率可达 96.25%,故障类别 a_{AMC3} 识别正确率可达 92.50%,说明该方法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,从而极大提高了识别正确率。因此,本文所提基于自注意力和改进 ACGAN 方法更加适用于航空发动机轴承在线诊断。

为了更有效、更全面地评估模型的泛化能力与分类能力。以故障为正,正常为负,各指标的计算方法为

$$\left\{ \begin{array}{l} P_{Acc} = \frac{f_{00} + f_{11}}{f_{00} + f_{10} + f_{01} + f_{11}} \times 100\% \\ P_{Pre} = \frac{f_{11}}{f_{11} + f_{01}} \times 100\% \\ P_{Rec} = a_{ACM2} = \frac{f_{11}}{f_{11} + f_{10}} \times 100\% \\ P_{F1-Score} = 2 \times \frac{P_{Pre} \times P_{Rec}}{P_{Pre} + P_{Rec}} \end{array} \right. \quad (13)$$

式中: P_{Acc} 为准确率; P_{Pre} 为精确率; P_{Rec} 为召回率; $P_{F1-Score}$ 为平衡 F 分数。

在测试集上不同模型各指标结果对比见表 2。

表 2 不同模型各指标结果对比

Table.2 Comparison of results of various indicators across different models

方法	P_{Acc}	P_{Pre}	P_{Rec}	$P_{F1-Score}$
原始数据	93.27	57.25	62.5	59.76
SMOTE	96.3	74.71	81.25	77.84
ADASYN	95.83	71.06	80.83	75.63
ACGAN	97.63	84.49	86.25	85.36
基于自注意力和改进 ACGAN	98.9	90.59	96.25	93.33

从表中可见,基于自注意力和改进 ACGAN 模型各指标结果优于其他方法的,能够很好地从数据中挖掘出更全面的特征信息,充分体现了模型良好的泛化能力和分类能力。

4 结论

(1)生成器模型将 2D-CNN 和 LSTM 相结合使生成的数据更接近真实的数据分布。而在网络过于复

杂、层数过多的情况下,将 MLP 应用于判别器可以防止轴承故障数据的显著特征丢失。

(2)与传统的 SMOTE、ADASYN、ACGAN 数据合成算法相比,基于自注意力和改进 ACGAN 模型能够合成高质量的故障样本数据,有效地提高了故障数据少情况下的诊断精度。

(3)基于自注意力和改进 ACGAN 的轴承故障诊断模型的准确率、精确率、召回率和平衡 F 分数高,能够准确识别航空发动机轴承故障及故障类型。

参考文献:

- [1] 郑波,马昕.改进的 Kohonen 网络在航空发动机分类故障诊断中的应用[J].航空发动机,2020,46(2):23-29.
ZHEN Bo, MA Xin. Application of improved kohonen network in aero-engine classification fault diagnosis[J]. Aeroengine, 2020, 46(2):23-29.(in Chinese)
- [2] 于庆杰,张大鹏,刘新宇,等.航空发动机附件机匣轴承失效故障复现试验[J].航空发动机,2021,47(增刊1):120-123.
YU Qingjie, ZHANG Dapeng, LIU Xinyu, et al. Fault recurrence test for aeroengine accessory gearbox bearing failure[J]. Aeroengine, 2021, 47(S1):120-123. (in Chinese)
- [3] Li W, Huang R, Li J, et al. A perspective survey on deep transfer learning for fault diagnosis in industrial scenarios: Theories, applications and challenges[J]. Mechanical Systems and Signal Processing, 2022, 167:108487.
- [4] 李修文,唐德尧,杨荣华.基于整周期时域回归识别滚子间距变化的保持架故障诊断方法[J].振动与冲击,2019,38(17):45-50.
LI Xiuwen, TANG Deyao, YANG Ronghua. Cage fault diagnosis method based on whole periodic time domain regression to recognize roller spacing[J]. Journal of vibration and shock, 2019, 38(17):45-50. (in Chinese)
- [5] Xiyang Liu, Guo Chen, Xunkai Wei, et al. A rolling bearing fault evolution state indicator based on deep learning and its application[J]. Journal of Mechanical Science and Technology, 2023, 37(6):2755-2769.
- [6] Deva Chaitanya Sanakkayala, Vijayakumar Varadarajan, Namy Kumar, et al. Explainable AI for bearing fault prognosis using deep learning techniques[J]. Micromachines, 2022, 13(9):1471.
- [7] 钱思宇,秦东晨,陈江义,等.基于卷积神经网络的领域适配模型的多工况迁移的轴承故障诊断[J].振动与冲击,2022,41(24):192-200.
QIAN Siyu, QIN Dongchen, CHEN Jiangyi, et al. Bearing fault diagnosis based on a domain adaption model of convolutional neural network under multiple working conditions[J]. Journal of Vibration and Shock, 2022, 41(24):192-200. (in Chinese)
- [8] Hu T, Tang T, Lin R, et al. A simple data augmentation algorithm and a self-adaptive convolutional architecture for few-shot fault diagnosis under different working conditions - ScienceDirect[J]. Measurement,

- 2020, 156: 107539.
- [9] Bousmalis K, Silberman N, Dohan D, et al. Unsupervised Pixel-Level domain adaptation with generative adversarial networks[J]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017, 95-104.
- [10] Liu J, Zhang C, Jiang X. Imbalanced fault diagnosis of rolling bearing using improved MsR-GAN and feature enhancement-driven CapsNet [J]. Mechanical Systems and Signal Processing, 2022, 168: 108664.
- [11] Zhou F, Yang S, Fujita H, et al. Deep learning fault diagnosis method based on global optimization GAN for unbalanced data[J]. Knowledge-Based Systems, 2020, 187: 104837.
- [12] 李俊卿, 李斯璇, 陈雅婷, 等. 一种基于 CGAN-CNN 的同步电机转子绕组匝间短路故障诊断方法[J]. 电力自动化设备, 2021, 41(8): 169-174.
- LI Junqing, LI Sixuan, CHEN Yating, et al. Fault diagnosis method of inter-turn short circuit of rotor winding of synchronous motor based on CGAN-CNN[J]. Electric Power Automation Equipment, 2021, 41(8): 169-174. (in Chinese)
- [13] Ding Y, Ma L, Ma J, et al. A Generative Adversarial Network-Based Intelligent Fault Diagnosis Method for Rotating Machinery Under Small Sample Size Conditions[J]. IEEE Access, 2019, 7: 149736-149749.
- [14] 刘宁, 朱波, 阴艳超, 等. 一种混合 CGAN 与 SMOTEENN 的不平衡数据处理方法[J]. 控制与决策, 2023, 38(9): 2614-2621.
- LIU Ning, ZHU Bo, YIN Yanchao, et al. An imbalanced data processing method based on hybrid CGAN and SMOTEENN[J]. Control and Decision. 2023, 38(9): 2614-2621. (in Chinese)
- [15] 卢锦玲, 张祥国, 张伟, 等. 基于改进辅助分类生成对抗网络的风机主轴轴承故障诊断[J]. 电力系统自动化, 2021, 45(7): 148-154.
- LU Jinling, ZHANG Xiangguo, ZHANG Wei, et al. Fault diagnosis of main bearing of wind turbine based on improved auxiliary classifier generative adversarial network[J]. Automation of Electric Power Systems, 2021, 45(7): 148-154. (in Chinese)
- [16] 孙灿飞, 王友仁, 夏裕彬. 基于 SCAE-ACGAN 的直升机行星齿轮裂纹故障诊断[J]. 振动测试与诊断, 2021, 41(3): 495-502, 620-621.
- SUN Chanfei, WANG Youren, XIA Yubin. Experimental study on mean aerodynamic characteristics of two square cylinders arranged inline[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(3): 495-502, 620-621. (in Chinese)
- [17] Mirza M, Osindero S. Conditional Generative Adversarial Nets[J]. ArXiv, 2014, abs/1411.1784: 2672-2680.
- [18] Dash A, Gamboa J C B, Ahmed S, et al. TAC-GAN-text conditioned auxiliary classifier generative Adversarial Network[J]. ArXiv, 2017, 1703: 6412.

(编辑: 李华文)