

基于循环卷积生成对抗网络的风机齿轮箱故障诊断

赵承利, 张璐, 钟麦英

(山东科技大学 电气与自动化工程学院, 山东 青岛 266590)

摘要: 风机齿轮箱是风力涡轮传动系统中的关键部分, 其故障发生随机、故障样本数量不足, 严重影响故障诊断的准确性。针对此问题, 提出一种基于循环卷积生成对抗网络的风机齿轮箱故障诊断方法。首先, 构建基于循环卷积生成对抗网络的样本生成模型, 利用卷积网络和循环网络作为生成器增强样本间的时间相关性; 借助 Wasserstein 距离与梯度惩罚项改进目标函数, 并通过博弈对抗机制优化生成器和判别器, 提高模型的泛化能力。然后, 结合真实样本和生成样本, 设计基于堆叠去噪自编码器的故障诊断方法, 实现齿轮箱的故障诊断。最后, 利用风力涡轮传动系统数据集验证所提出的风机齿轮箱故障诊断方法的性能。结果显示, 所提方法能够有效平衡故障样本数据集, 进一步提高风机齿轮箱故障诊断的准确率。

关键词: 故障诊断; 风机齿轮箱; 生成对抗网络; 循环卷积网络; 样本生成

中图分类号: TP277

文献标志码: A

Fault diagnosis for wind turbine gearbox based on recurrent convolutional generative adversarial network

ZHAO Chengli, ZHANG Lu, ZHONG Maiying

(College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266590, China)

Abstract: Wind turbine gearbox is a key part of the wind turbine transmission system, but its faults are relatively random and the number of fault samples is insufficient, which seriously affect the accuracy of fault diagnosis. To solve this problem, a fault diagnosis method based on recurrent convolutional generative adversarial network was proposed in this paper. First, a sample generation model based on recurrent convolutional generative adversarial network was constructed, in which convolutional networks and recurrent networks were used as generators to enhance the temporal correlation between samples. Wasserstein distance and gradient penalty terms were introduced to improve the objective function and the game confrontation mechanism was used to optimize the generator and discriminator so that the generalization ability of the model could be strengthened. Then a fault diagnosis method based on stacked denoising autoencoder was designed by combining real samples and generated samples to realize the fault diagnosis of gearbox. Finally, the performance of the proposed fault diagnosis method was verified by the data set from the wind turbine transmission system. The results show that the proposed method can effectively balance the fault sample data set, which further improves the fault diagnosis accuracy of the wind turbine gearbox.

Key words: fault diagnosis; wind turbine gearbox; generative adversarial network; recurrent convolutional networks; sample generation

风机齿轮箱作为风力涡轮传动系统的核心装置, 常用于动力传动, 承受不规则的机械应力。由于此类零

收稿日期: 2022-04-09

基金项目: 国家自然科学基金项目(62233012, 61873149, 62103246); 中国博士后科学基金项目(2021M691966)

作者简介: 赵承利(1998—), 男, 山东枣庄人, 硕士研究生, 主要从事机器学习故障诊断研究。

钟麦英(1965—), 女, 山东博兴人, 教授, 博士生导师, 主要从事故障诊断与容错控制研究, 本文通信作者。

E-mail: myzhong@sdust.edu.cn

部件长时间工作在高温、高速、高负荷等恶劣工况下,极易发生故障,造成财产损失甚至引起灾难性事故。因此,研究齿轮箱的故障诊断方法至关重要^[1]。针对齿轮箱的故障诊断研究主要集中于运动学机理模型和数据驱动两方面。由于传感器技术的高速发展,数据收集量指数式增长,数据驱动的故障诊断方法得到更广泛的应用,主要包括随机森林、人工神经网络、深度学习等方法^[2]。文献[3]提出一种基于随机森林的旋转机械齿轮组故障诊断方法;文献[4]提出一种基于图的半监督学习随机森林算法,实现对旋转机械齿轮箱的故障诊断;文献[5]利用改进的经验模态分解与人工神经网络相结合,实现对电机转子轴承的故障诊断。深度学习方法相较于其他方法具有更深的特征学习结构,所需数据量更多,能更有效地描述复杂模型。文献[6]提出一种多尺度卷积核动态融合方法来提取齿轮箱故障信号特征,并结合全局稀疏网络实现对齿轮箱的故障诊断。以上方法虽表现良好,但都基于足够多的故障样本,而实际应用中,齿轮箱常因故障样本不足导致总体样本不平衡,很大程度上影响传统故障诊断方法的准确性^[7]。

近年来,以生成对抗网络(generative adversarial network,GAN)为代表的增强方法为解决样本不平衡问题提供了新思路。GAN是Goodfellow于2014年提出的一种对抗生成模型新框架^[8],随着对抗机制的不断完善,GAN也在图像生成、语义分割等领域有着广泛应用,并衍生出不同功能的变体^[9]。条件生成对抗网络^[10]在原始GAN无监督的基础上加入条件信息,能更有效地捕捉原始数据分布。针对于原始GAN训练不稳定、梯度爆炸、梯度消失等问题,Wasserstein生成对抗网络(Wasserstein GAN,WGAN)^[11]和带有梯度惩罚的WGAN(WGAN with gradient penalty,WGAN-GP)^[12]相继提出。这些方法已经在图像生成方面取得了良好的效果,而GAN在一维数据增强方面应用较少。2017年,GAN开始用于故障诊断领域。Lee等^[13]利用GAN解决异步电机中数据样本不平衡问题;文献[14]提出改进辅助分类生成对抗网络用于风机齿轮箱故障数据的生成;文献[15]提出一种新的条件辅助分类器GAN框架,结合模型不可知元学习实现轴承故障诊断。

上述方法虽然表现良好,但对于一维时序信号进行特征提取时,并未针对性地考虑到时域数据内在关系和时间方向上的深度联系,因此本研究提出一种带有梯度惩罚的Wasserstein循环卷积生成对抗网络(Wasserstein recurrent convolutional GAN-GP,WRCGAN-GP)诊断方法。首先,利用卷积网络数据降维和循环网络提取时间信息,生成具有周期性变化的时间序列信号;然后,以随机噪声作为输入,通过对抗机制不断学习少数类故障样本特征,生成与真实数据相似的平衡数据集;最后,将平衡数据集输入到堆叠去噪自编码器(stacked denoising autoencoder,SDAE)^[16]模型实现风机齿轮箱故障诊断。

1 生成对抗网络

GAN主要包含生成器和判别器两部分,结构如图1所示。其中,生成器用于捕捉真实样本分布,生成新样本;判别器用于分辨输入样本来自真实样本还是生成样本。GAN损失函数定义为:

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

式中: x 为服从 P_{data} 分布的真实数据, $E_{x \sim P_{data}}$ 为 x 的期望; z 为服从 P_z 分布的随机噪声, $E_{z \sim P_z}$ 为 z 的期望; $D(x)$ 为判别器 D 的输出; $G(z)$ 为生成器 G 的输出。在训练过程中, G 的目标是最小化真实数据与生成数据之间的误差,以求最大程度学习真实数据的分布; D 的目标是最大化真实数据与生成数据之间的差距以区分彼此。当训练达到纳什平衡时, G 可以生成与真实数据分布相似的数据。

实验表明,训练中若生成器与判别器能力平衡,模型更易收敛,因此在训练模型时,应首先优化判别器,而后优化生成器。但判别器过强,生成器也不能有效更新参数,容易出现梯度消失、梯度爆炸等问题。虽然GAN已经在图像生成方面有着不错的表现,但对一维数据特征捕捉、数据增强方面仍有一




图1 GAN结构图

Fig. 1 GAN structure

定局限性。

2 基于循环卷积生成对抗网络的故障诊断

为了更好地解决风机齿轮箱样本不平衡问题,设计了基于循环卷积生成对抗网络的故障诊断方法,主要分为样本生成模型构建和故障分类方法设计两阶段,如图 2 所示。其中,WRCGAN-GP 用来生成少数类故障样本以平衡数据集,再利用 SDAE 对平衡数据集进行故障分类。

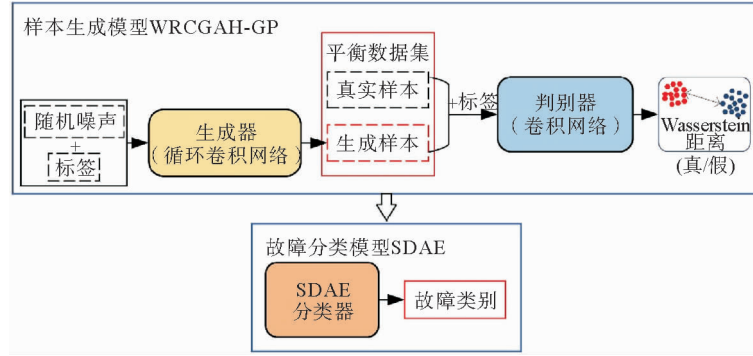


图 2 基于 WRCGAN-GP 的故障诊断方法架构

Fig. 2 Architecture of fault diagnosis method based on WRCGAN-GP

2.1 样本生成模型构建

针对故障样本数量不足的问题,设计了 WRCGAN-GP 样本生成模型,该模型包含生成器 G 和判别器 D 两部分,其结构如图 3 所示。 G 采用循环卷积网络结构,卷积模块由两层卷积和两层池化交替组成,循环模块采用长短期记忆网络(long short-term memory, LSTM)单元结构,其卷积输出作为循环网络的输入。 G 的输入为 (z^T, c^T) 。其中, z 为随机噪声,维度为 100×1 ; c 为样本标签,维度为 $m \times 1$, m 为样本类别数。 G 的输出为 x_g , 维度为 $n \times 1$, G 中第 i 层卷积运算的输出为 o_i :

$$o_i = f_c \left(\sum_{l \in M} o_{i-1}^l \cdot k_i^l + a_i \right), \quad (2)$$

$$f_c(x) = \begin{cases} x, & x > 0; \\ 0, & x \leq 0. \end{cases} \quad (3)$$

式中: f_c 为卷积层激活函数; M 为输入特征图矩阵; o_{i-1} 为 $i-1$ 层输出; k_i 和 a_i 分别为第 i 层的卷积核与偏置。通常卷积块的激活函数选用 ReLu 函数,如式(3)所示,该激活函数在输入值大于零的部分导数值恒定,能在权值更新时克服梯度消失问题,并可以有效驱使网络逼近全局最优。

经过卷积运算得到信号特征,并重塑为符合循环模块输入的形状,表示为 $R = [r_1, r_2, \dots, r_t]$, r_t 的维度为 $\xi \times 1$, $t \in \{1, 2, \dots, \omega\}$ 。循环模块中 LSTM 单元结构图 4 所示, t 时刻运算如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}^l, r_t] + b_f), \quad (4)$$

$$i_t = \sigma(W_q \cdot [h_{t-1}^l, r_t] + b_q), \quad (5)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}^l, r_t] + b_c), \quad (6)$$

$$o_t^l = \sigma(W_o \cdot [h_{t-1}^l, r_t] + b_o). \quad (7)$$

式中: W_f 、 W_q 、 W_c 及 W_o 为各门控单元的权重矩阵; b_f 、 b_q 、 b_c 及 b_o 为偏置向量; $\sigma(\cdot)$ 、 $\tanh(\cdot)$ 为激活函数; h_{t-1}^l 为 $t-1$ 时刻的隐层输出; \tilde{C}_t 为状态候选值; f_t 、 i_t 和 o_t^l 分别代表遗忘门、输入门和输出门。输入值 r_t 和隐层输出值 h_{t-1}^l 经由输入门 i_t 确定此时刻信息的保留比例,同时上一时刻状态 C_{t-1} 经由遗忘门 f_t 确定有多少信息能够传递到 C_t 中。不同于传统的循环神经网络,LSTM 通过其独特的门控制单元,对以往状态进行筛选,更有效地获得对目标有用的信息,并非机械性地选择就近状态。最终经过遗忘门和输入门删除和更新,实现对状态 C_t 的计算:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t. \tag{8}$$

输出门用来计算隐藏层的输出,计算式为:

$$h_t^l = o_t^l \cdot \tanh(C_t). \tag{9}$$

LSTM 隐层单元数为常数值 τ , 则循环网络所有时刻隐层输出为 $\mathbf{H} = [h_1^l, h_2^l, \dots, h_t^l]$, 其中 h_t^l 的维度为 $\tau \times 1, t \in \{1, 2, \dots, \omega\}$, 由 Sigmoid 激活函数处理, 最终经全连接层得到生成样本 x_g 。

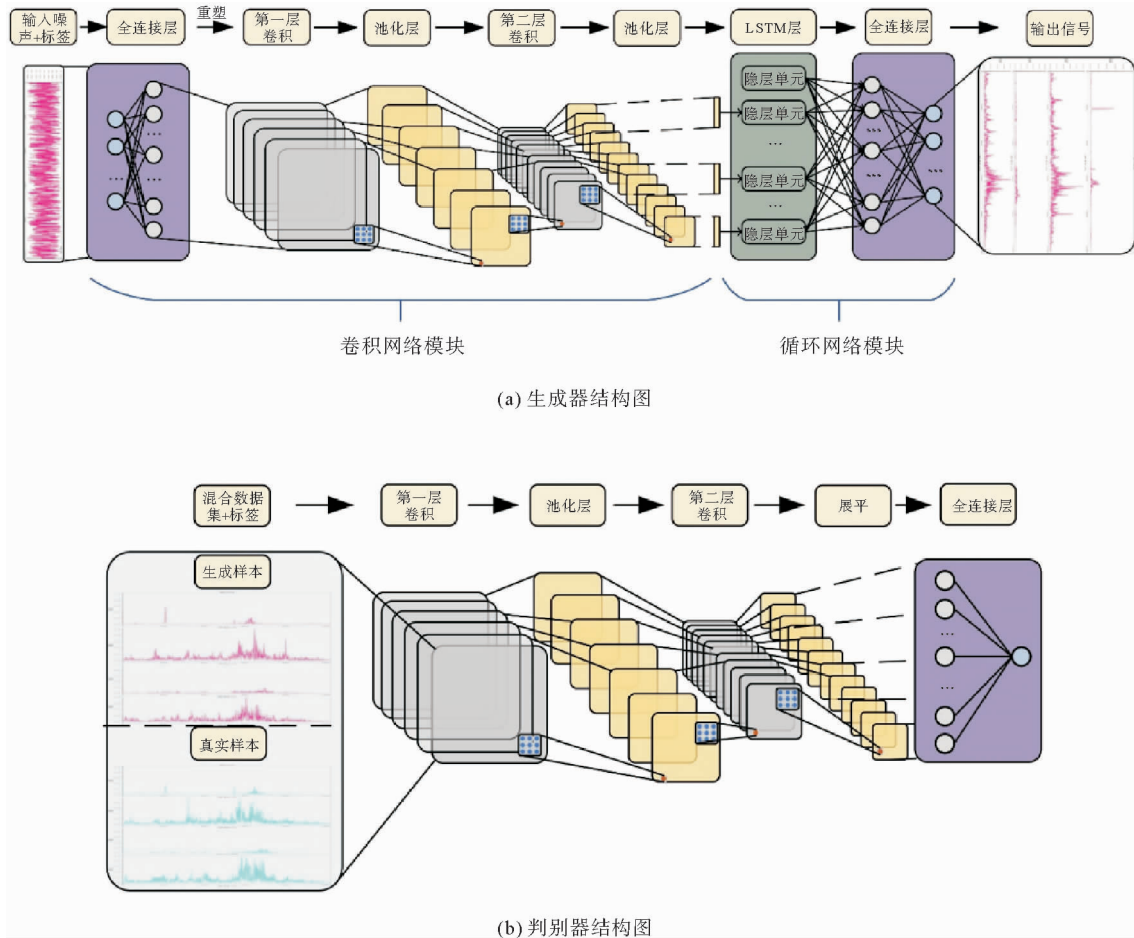


图 3 WRCGAN-GP 结构图

Fig. 3 WRCGAN-GP structure

如图 3(b)所示, WRCGAN-GP 的 D 由两个卷积块构成, 通过对 x_g 及 x_{data} 特征提取、数据降维, 以分辨输入样本的真假性。 D 的输入分别为 $(x_g^T, c^T), (x_{data}^T, c^T)$ 。

WRCGAN-GP 是在 WGAN-GP 的基础上进行架构改进, 通过最小化损失函数 $L(d)$ 和 $L(g)$ 进行对抗训练, 交替更新参数, 其损失函数为:

$$L(d) = -E_{x_{data} \sim P_{data}} [D(x_{data}, c)] + E_{x_g \sim P_g} [D(x_g, c)] + \lambda E_{\hat{x} \sim P_{\hat{x}}} [\|\nabla D(\hat{x}, c)\|_2 - 1]^2, \tag{10}$$

$$L(g) = -E_{x_g \sim P_g} [D(x_g, c)]. \tag{11}$$

式中: ∇ 表示梯度; $\|\cdot\|_2$ 为 2 范数; λ 为惩罚系数, 常取小于 1 的正数; \hat{x} 为真实样本与生成样本之间的随机采样值; $P_{\hat{x}}$ 为采样分布, 其范围介于真实数据分布 P_{data} 与生成数据分布 P_g 之间。

训练时, 先将条件信息 c 与噪声 z 拼接, 通过 G 产生新样本 x_g ; 然后将 x_g 和 x_{data} 进行快速傅里叶变换, 变换后的样本再分别与条件信息 c 拼接并作为 D 的输入, 通过 D 判别输入样本的真假, 最终对抗学习达到

纳什平衡, WRCGAN-GP 生成符合真实数据分布的样本。将生成样本与真实样本相结合得到平衡数据集 \mathbf{B} , $\mathbf{B} = [\mathbf{x}_b^{(1)}, \mathbf{x}_b^{(2)}, \dots, \mathbf{x}_b^{(k)}]$ 。其中, $\mathbf{x}_b^{(k)}$ 的维度为 $n \times 1$, $k = 1, 2, \dots, l$, l 为样本数量。




图 4 LSTM 结构图

Fig. 4 LSTM structure

2.2 故障分类

堆叠去噪自编码器近年来因其优异的性能被广泛用于故障诊断领域,其结构见图 5。将平衡数据集 \mathbf{B} 作为 SDAE 的输入实现齿轮箱故障分类。SDAE 由数个去噪自编码器(denoising autoencoder, DAE)模块堆叠而成,其基础模块 DAE 是一种通过特征提取并最小化重构误差来拟合样本的单隐层神经网络,主要由输入层、隐藏层及输出层三部分构成。输入层与隐藏层构成编码器 f_s , 隐藏层与输出层构成解码器 g_s , 结构如图 6 所示。

以第一个 DAE 模块为例,输入向量 $\mathbf{x}_b^{(k)}, \hat{\mathbf{x}}_b^{(k)}$ 为夹杂噪声 ε 的输入向量,通过编码器 f_s 将数据降维得到 $\mathbf{h}_b^{(k)}$, 编码过程为:

$$\mathbf{h}_b^{(k)} = f_s(\mathbf{W}\hat{\mathbf{x}}_b^{(k)} + \mathbf{b}). \quad (12)$$

式中: \mathbf{W} 为输入权重矩阵, \mathbf{b} 为输入偏置向量。解码阶段, 向量 $\mathbf{h}_b^{(k)}$ 通过解码器 g_s 得到重构输出向量 $\tilde{\mathbf{x}}_b^{(k)}$, 解码过程为:

$$\tilde{\mathbf{x}}_b^{(k)} = g_s(\mathbf{W}'\mathbf{h}_b^{(k)} + \mathbf{b}'). \quad (13)$$

式中: \mathbf{W}' 为输出权重矩阵, \mathbf{b}' 为输出偏置向量。最后通过最小化重构误差优化自编码器:

$$L_s = \frac{1}{l} \sum_{k=1}^l \|\mathbf{x}_b^{(k)} - \tilde{\mathbf{x}}_b^{(k)}\|_2^2. \quad (14)$$

训练时, 每个 DAE 模块单独训练, 前一个 DAE 模块训练完成后, 其隐藏层输出作为下一个 DAE 模块的输入, 如此往复, 直到第 δ 个 DAE 模块层训练完成。将训练好的 DAE 模块逐层级联, 形成 SDAE。SDAE 属于无监督网络, 本身不具备分类能力, 因此需要在网络最后一层增添 Softmax 层^[17] 以实现故障分类。Softmax 层可将复杂多维空间向量映射到同一维度, 并使映射后向量元素大小限定在 $(0, 1)$ 之间, 表示此类样本在某一类别上的得分, 并以最大值所在类别表示此样本归类。Softmax 层输出为 $s(\mathbf{h}_{b\delta}^{(k)})$:

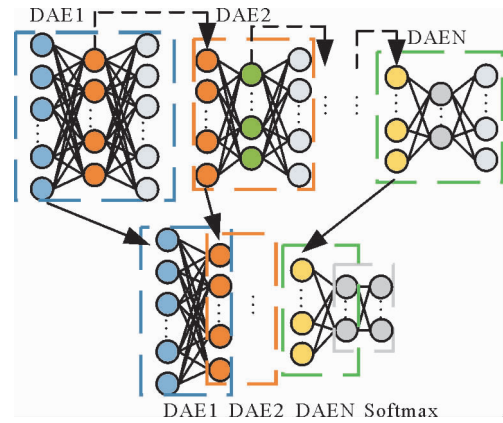


图 5 SDAE 结构图

Fig. 5 SDAE structure




图 6 DAE 结构图

Fig. 6 DAE structure

$$s(\mathbf{h}_{b\delta}^{(k)}) = \begin{bmatrix} p(c=1 | \mathbf{h}_{b\delta}^{(k)}) \\ p(c=2 | \mathbf{h}_{b\delta}^{(k)}) \\ \vdots \\ p(c=m | \mathbf{h}_{b\delta}^{(k)}) \end{bmatrix} = \frac{e^{\mathbf{h}_{b\delta}^{(k)}(j)}}{\sum_{j=1}^m e^{\mathbf{h}_{b\delta}^{(k)}(j)}} \quad (15)$$

式中： $\mathbf{h}_{b\delta}^{(k)}$ 表示 SDAE 第 δ 个 DAE 模块隐层输出。实验中，利用平衡数据集预先训练 SDAE 网络，待训练完成，使用训练完成的模型对测试集数据进行故障分类，以实现故障诊断。

3 实验分析

3.1 数据集介绍


本研究采用的数据集来自山东科技大学电气与自动化工程学院实验室风力涡轮传动系统故障诊断模拟器，平台结构如图 7 所示，传感器主要有振动传感器、扭力传感器以及压力传感器等。负载工作电压分别有 8、5 V，电机工作频率有 6、10、14 Hz。以上装置中所涉及到的硬件，如齿轮等，均可被替换成故障型齿轮以输入故障，故障形态有缺齿、断齿、齿裂以及磨损等。

实验负载工作电压 8 V、电机工作频率 6 Hz，信号取自振动传感器，共有 5 种信号类型，分别为正常信号、缺齿信号、断齿信号、齿裂信号和表面磨损信号，原始信号样本维度为 2048×1 。为了凸显每种样本类型的信号特点，首先进行快速傅里叶变换，截取样本前半段作为最终使用样本，维度为 1024×1 ，共选取数据样本 980 个，各类型样本数量及标签设置如表 1 所示。WRCGAN-GP 生成的各类故障样本数量为原始数据集中正常样本与故障样本数量的差值，即 380 个，以达到平衡数据集的目的。

3.2 结果与分析

模型训练需设置若干超参数值，损失函数中 λ 取 10，优化器选择为 Adam，学习率设置为 0.000 5。为使多层之间协调更新，训练更易收敛，每一层后跟随批量归一化层，且训练时每训练 1 次生成器更新 5 次判别器，迭代次数为 500。WRCGAN-GP 与 SDAE 具体网络结构设置如表 2、表 3 所示。将训练集数据输入到 WRCGAN-GP 中训练并得到生成样本，其损失函数随迭代次数的变化情况如图 8 所示。可以看出，生成器损失与判别器损失在训练初期波动较大，但随着迭代次数的增加，损失值在迭代 200 次附近时趋于平稳。

图 9 为 4 种故障类型真实样本与生成样本的对比图，可以看出，虽然生成样本与真实样本并不完全相同，在某些峰值处存在小的偏差，但分布趋势基本一致，可以作为原始数据扩展集。



1—负载制动器；2—行星轴齿轮箱；3—平行轴齿轮箱；
4—动力装置；5—传感器

图 7 风力涡轮传动系统故障诊断方法模拟器

Fig. 7 Simulator for fault diagnosis method of wind turbine drive system

表 1 样本及标签设置

Table 1 Sample and label settings

标签	样本类型	训练集样本数/个	测试集样本数/个
1	正常	400	100
2	缺齿	20	100
3	断齿	20	100
4	齿裂	20	100
5	磨损	20	100

表 2 WRCGAN-GP 网络架构

Table 2 Network architecture of WRCGAN-GP

网络层	输出通道数	卷积核尺寸	步长	输出尺寸
判别器	—	—	—	—
全连接层 1	—	—	—	4 096
卷积层 1	64	(3,3)	2	(31,31,64)
最大池化层 1(LReLU)	64	(2,2)	2	(15,15,64)
卷积层 2	128	(3,3)	2	(7,7,128)
最大池化层 2(LReLU)	128	(2,2)	2	(3,3,128)
全连接层 2	—	—	—	1
生成器	—	—	—	—
全连接层 1	—	—	—	1 024
卷积层 1	16	(5,5)	1	(28,28,16)
最大池化层 1(ReLU)	16	(2,2)	2	(14,14,16)
卷积层 2	32	(5,5)	1	(10,10,32)
最大池化层 2(ReLU)	32	(2,2)	2	(5,5,32)
LSTM层	—	—	—	(5,160)
全连接层 2(Sigmoid)	—	—	—	1 024

表 3 SDAE 网络架构

Table 3 Network architecture of SDAE

网络层	输出尺寸
输入层	1 024
全连接层 1(Sigmoid)	512
全连接层 2(Sigmoid)	256
全连接层 3(Softmax)	5




图 8 损失值变化情况

Fig. 8 Changes in loss value

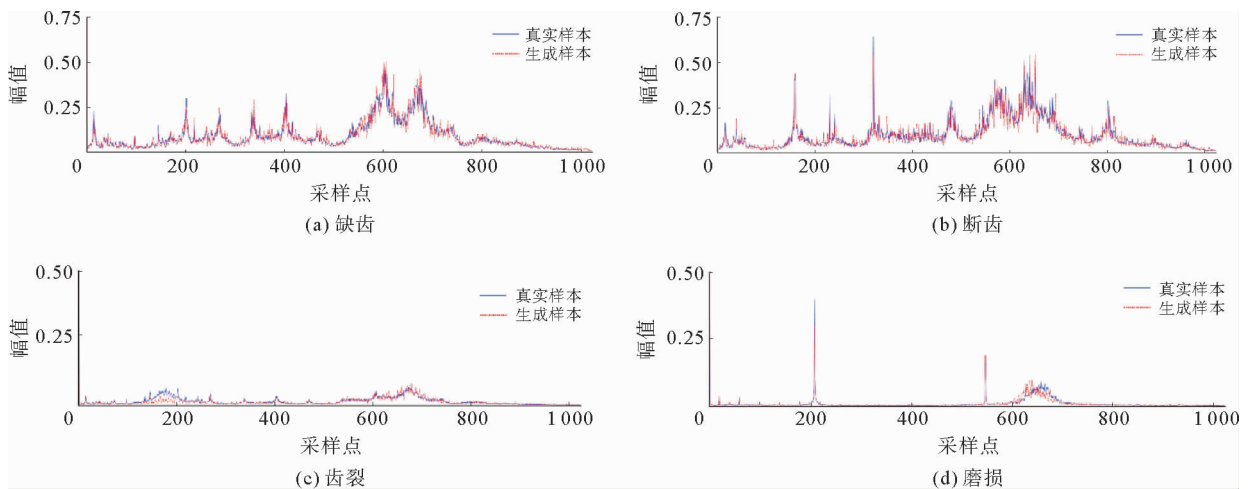


图 9 样本对比图

Fig. 9 Sample comparison chart

t 分布随机近邻嵌入算法^[18]可以更直观地观察到原始样本与生成样本分布相似情况,该算法可将高维数据映射到低维空间,以此分析数据在高维空间的分布。相似程度较高的样本相互聚集,反之相互排斥,增

强前后样本数据可视化结果如图 10 所示。由图 10 可以看出,数据增强后各类样本的聚类效果更加明显。




图 10 增强数据前后可视化结果对比

Fig. 10 Comparison of visualization results before and after data enhancement

针对不平衡数据集,通常采用以下指标进行样本质量评价: G_{mean} ^[19]、 F_1 ^[20]、ROC 曲线以及 AUC 值^[21]。 G_{mean} 为正类准确率与负类准确率的综合指标,可表示为:

$$G_{\text{mean}} = \sqrt{\frac{T_P}{T_P + F_N} \times \frac{T_N}{T_N + F_P}} \quad (16)$$

式中: T_P 为正类预测为正类的比例,即正类准确率; T_N 为负类预测为负类的比例,即负类准确率; F_N 为正类预测为负类的比例; F_P 为负类预测为正类的比例。

F_1 相较于 G_{mean} 更加注重少数类分类性能的评价,其计算式为:

$$F_1 = \frac{2 \times T_P}{2 \times T_P + F_N + F_P} \quad (17)$$

ROC 是以假正率(F_{PR})为 x 轴和真正率(T_{PR})为 y 轴构成的曲线,曲线下方围成的面积即为 AUC 值,其值越接近于 1,分类准确率越高。其中,

$$T_{PR} = \frac{T_P}{T_P + F_N}, F_{PR} = \frac{F_P}{T_N + F_P} \quad (18)$$

为进一步说明 WRCGAN-GP 的优越性,设置消融实验进行对比验证。方法 1:加入标签信息的梯度惩罚 Wasserstein 卷积生成对抗网络(Wasserstein convolutional GAN-GP, WCGAN-GP),即去掉 WRCGAN-GP 生成器中的 LSTM 结构。方法 2:不加入标签信息的 WGAN-GP(WGAN-GP),即去掉 WCGAN-GP 中的标签信息。方法 3:加入标签信息的 WGAN,即去掉 WCGAN-GP 损失函数中的梯度惩罚项。另外,将所设计的故障诊断方法与卷积神经网络(convolutional neural network, CNN)^[22]、随机森林(random forest, RF)^[4]进行对比。

根据不同方法的故障诊断结果,计算评价指标,结果如表 4 所示。首先,针对三种生成算法的生成样本,均利用 SDAE 分类器进行故障分类。由表 4 可以看出,在正常样本量与故障样本量之比为 20 : 1 的极不平衡情况下,WGAN-GP-SDAE 中由于没有标签信息约束,训练不稳定, F_1 与 AUC 值均较低, G_{mean} 甚至出现 0 值情况;WGAN-SDAE 本身训练不稳定,即使有标签信息约束,但指标仍低于 WCGAN-GP-SDAE 与 WRCGAN-GP-SDAE;而本研究提出的方法在保证训练稳定的前提下,引入标签信息约束,且加入 LSTM 结构以读取数据潜藏的故障信息,相较于单一卷积结构的 WCGAN-GP-SDAE,其三项指标值均有所提高。其次,将原始不平衡数据集作为 CNN 与 RF 的输入,由于原始数据集中故障样本量极少,CNN 不能发挥有效性, G_{mean} 出现 0 值, F_1 也仅有 27.16%;RF 由于多棵树结构优势, G_{mean} 和 F_1 较 CNN 有所提升,但仍低于 WRCGAN-GP-SDAE。从图 11 ROC 曲线也可以看出,WRCGAN-GP-SDAE 曲线距离坐标轴左上角更近,曲线下方围成的面积也更接近于 1,生成样本也更符合真实样本分布。

为了更详细地展示生成样本质量,将故障分类准确率汇总如表 5 所示。由表 5 可以看出,WGAN-SDAE 仅有缺齿和磨损分类效果良好,对于另外几种特征较为相似的故障类别不能实现有效分类;WGAN-GP-SDAE 结构上无改变,且缺少标签信息的约束,故障分类也仅有正常和磨损正确率在 95%以上;在 WCGAN-GP-SDAE 中,缺齿有 14%被误分类,断齿有 5%被误分类,可见对于极为相似、难以分辨的故障样本,单一卷积结构不能完全有效地获得故障信息并进行准确分类;由于原始数据集的不平衡特性,CNN 仅能对正常和磨损样本准确分类;RF 分类准确率较 CNN 有所提升,但对于缺齿仍然有 18%的误分类率。而所提出的方法在进行故障分类时,所有故障类别分类准确度都在 95%以上。

综上对比实验结果表明,本研究提出的故障诊断方法在样本特征相似、故障信息难以提取的情况下,能够生成质量更高的样本,有效平衡数据集且显著提升故障诊断准确率。

4 结论

针对风机齿轮箱实际工况中故障样本数量少的问题,提出一种基于 WRCGAN-GP 的故障诊断方法,将样本生成模型在原始 WGAN-GP 中加入标签信息,并将原有的多层感知器替换成为具有描述数据内在关系和分析时间深度上相关性能力的循环卷积网络,挖掘样本中更深层次的故障信息,生成了更高质量的新样本,同时通过 SDAE 进行特征提取并实现故障诊断。将所提出方法在风力涡轮传动系统数据集上进行对比分析,结果表明,所提出的方法可以有效捕捉难以提取的深层次故障特征分布,生成高质量样本并提高故障诊断准确率。值得指出的是,WRCGAN-GP 中的循环卷积结构在一定程度上增加了模型参数,使训练耗时大于传统 GAN,因此如何进一步优化网络结构、提高网络的训练速度是下一步研究内容。

参考文献:

[1] 李林,齐莹,李银强,等.风力发电机组故障诊断与状态预测的研究进展[J].电力系统自动化,2021,45(4):180-191.
 LI Lin,QI Ying,LI Yinqiang,et al. Research progress on fault diagnosis and state prediction of wind turbine[J]. Automation of Electric Power Systems,2021,45(4):180-191.

表 4 评价指标对比

Table 4 Comparison of evaluation indicators

方法	评价指标准确率/%		
	G_{mean}	F_1	AUC
WGAN-SDAE	0	46.18	80.08
WGAN-GP-SDAE	0	46.02	85.67
WCGAN-GP-SDAE	95.84	96.01	99.73
RF	96.10	96.37	99.94
CNN	0	27.16	55.27
WRCGAN-GP-SDAE	98.79	98.80	99.93

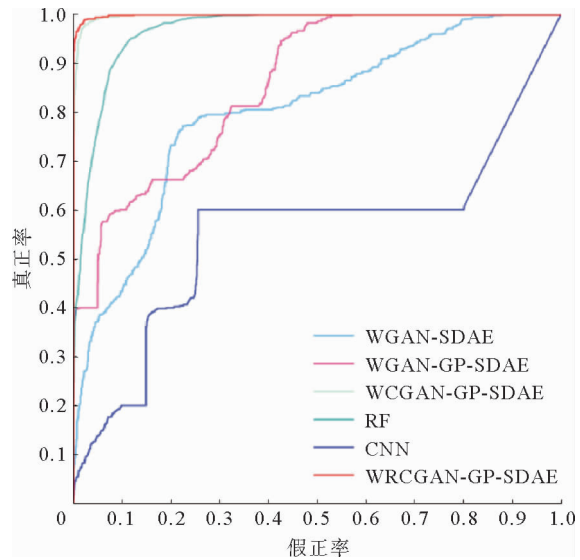


图 11 ROC 曲线结果对比

Fig. 11 Comparison of ROC curve results

表 5 故障分类准确率对比

Table 5 Comparison of fault classification accuracy

算法	不同样本分类准确率/%				
	正常	缺齿	断齿	齿裂	磨损
WGAN-SDAE	54.0	100.0	0	11.0	92.0
WGAN-GP-SDAE	100.0	7.0	48.0	0	100.0
WCGAN-GP-SDAE	100.0	86.0	95.0	100.0	99.0
RF	100.0	82.0	100.0	100.0	100.0
CNN	100.0	0	0	0	93.0
WRCGAN-GP-SDAE	100.0	98.0	99.0	100.0	97.0

- [2] LIU R N, YANG B Y, ZIO E, et al. Artificial intelligence for fault diagnosis of rotating machinery: A review[J]. *Mechanical Systems and Signal Processing*, 2018, 108: 33-47.
- [3] 王子兰, 杨瑞. 基于随机森林算法的旋转机械齿轮组故障诊断[J]. *山东科技大学学报(自然科学版)*, 2019, 38(5): 104-112.
WANG Zilan, YANG Rui. Fault diagnosis of rotating machinery gearbox based on random forest algorithm[J]. *Journal of Shandong University of Science and Technology (Natural Science)*, 2019, 38(5): 104-112.
- [4] CHEN S Z, YANG R, ZHONG M Y. Graph-based semi-supervised random forest for rotating machinery gearbox fault diagnosis[J/OL]. *Control Engineering Practice*, 2021, 117. DOI:10.1016/j.conengprac.2021.104952.
- [5] YANG Z S, KONG C Z, WANG Y H, et al. Fault diagnosis of mine asynchronous motor based on MEEMD energy entropy and ANN[J/OL]. *Computers & Electrical Engineering*, 2021, 92(4). DOI:10.1016/j.compeleceng.2021.107070.
- [6] YU J B, ZHOU X K, LU L, et al. Multiscale dynamic fusion global sparse network for gearbox fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-11.
- [7] ZHANG W, LI X, JIA X D, et al. Machinery fault diagnosis with imbalanced data using deep generative adversarial networks[J/OL]. *Measurement*, 2020, 152. DOI:10.1016/j.measurement.2019.103377.
- [8] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//*Proceeding of the 27th International Conference on Neural Information Processing Systems (NIPS)*. Montreal, Dec. 8-13, 2014: 2672-2680.
- [9] YI X, WALIA E, BABYN P. Generative adversarial network in medical imaging: A review[J/OL]. *Medical Image Analysis*, 2019, 58. DOI:10.1016/j.media.2019.101552.
- [10] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: An overview[J]. *IEEE Signal Processing Magazine*, 2018, 35(1): 53-65.
- [11] ARJOSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks[C]//*International Conference on Machine Learning*. Sydney, Aug. 6-11, 2017: 214-223.
- [12] WANG W, WANG C, CUI T, et al. Study of restrained network structures for Wasserstein generative adversarial networks (WGANs) on numeric data augmentation[J]. *IEEE Access*, 2020, 8: 89812-89821.
- [13] LEE Y, JO J, HWANG J. Application of deep neural network and generative adversarial network to industrial maintenance: A case study of induction motor fault detection[C]//*2017 IEEE International Conference on Big Data (Big Data)*. Boston, Dec. 11-14, 2017: 3248-3253.
- [14] 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.
- [15] DIXIT S, VERMA N, GHOSH A. 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.
- [16] WANG Z R, WANG J, WANG Y R. An intelligent diagnosis scheme based on generative adversarial learning deep neural networks and its application to planetary gearbox fault pattern recognition[J]. *Neurocomputing*, 2018, 310: 213-222.
- [17] ZHANG T C, CHEN J L, LI F D, et al. A small sample focused intelligent fault diagnosis scheme of machines via multi-modules learning with gradient penalized generative adversarial networks[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(10): 10130-10141.
- [18] LIU J W, LI Q, YANG H Q, et al. Sequence fault diagnosis for PEMFC water management subsystem using deep learning with t-SNE[J]. *IEEE Access*, 2019, 7: 92009-92019.
- [19] MAO W T, HE L, YAN Y J, et al. Online sequential prediction of bearings imbalanced fault diagnosis by extreme learning machine[J]. *Mechanical Systems and Signal Processing*, 2017, 83: 450-473.
- [20] HE L, LI Z X, SHEN C. Performance evaluation of an anomaly-detection algorithm for keystroke-typing based insider detection[J]. *Tsinghua Science and Technology*, 2018, 23(5): 513-525.
- [21] HAND D J. Measuring classifier performance: A coherent alternative to the area under the ROC curve[J]. *Machine Learning*, 2009, 77(1): 103-123.
- [22] 鲁其东. 基于神经网络的旋转机械故障诊断[D]. 青岛: 山东科技大学, 2019.
LU Qidong. Fault diagnosis of rotating machinery based on neural network[D]. Qingdao: Shandong University of Science and Technology, 2019.