

基于改进辅助分类生成对抗网络的风机主轴承故障诊断

卢锦玲, 张祥国, 张伟, 郭鲁豫, 闻若彤
(华北电力大学电气与电子工程学院, 河北省保定市 071003)

摘要: 基于振动信号的风电机组故障诊断方法是风电安全运维领域研究的重点之一。风电机组主轴承较少发生故障,给运用数据挖掘方法判断故障类型带来很大困难。针对该问题,文中提出了一种用于风电机组主轴承故障诊断的数据增强方法。通过对辅助分类生成对抗网络(ACGAN)的适应性进行改进,引入梯度惩罚,构建了改进ACGAN框架,以提高其学习稳定性;在判别器网络中引入池化层,以提升其在多分类场景下提取数据特征的能力。仿真结果表明,所提出的改进ACGAN框架能够实现对原始数据分布特征的有效学习,抗噪声干扰性强,相对于原框架训练过程更稳定,生成数据的质量更高;能够有效平衡风电机组主轴承故障振动数据,进一步提升了风电机组主轴承故障诊断的正确率。

关键词: 风电机组; 故障诊断; 数据增强; 辅助分类生成对抗网络; 梯度惩罚

0 引言

随着大规模风电机组的投入运行,机组运行故障出现次数也随之增加。为保证风电场安全高效的运行,有必要开展风电机组状态监测和故障诊断研究^[1-2]。风电机组主轴承故障维修成本较高,其主要采用基于信号处理和模型的故障诊断方法,且采用的信号以振动信号为主^[3-10]。

近年来,国内外不少学者利用人工智能算法对风电机组主轴承故障进行了广泛的研究。与传统方法相比,人工智能框架学习能力强,能够自动从原始数据中提取出更多的数据特征,有利于提高故障诊断精度。文献[5]提出一种基于贝叶斯网络的轴承故障诊断方法;文献[6]提出一种基于决策树的模糊分类算法,能够自动学习滚动轴承故障特征。文献[7-8]利用支持向量机实现了对风电机组轴承故障的诊断;文献[9]提出基于极限学习机的轴承状态监测方法,分别利用重构激活函数和核函数提升了故障诊断性能。文献[11]提出一种基于全卷积神经网络的分类模型,在频域中挖掘故障信息,实现了故障分类。文献[12-13]分别利用反向传播与长短期记忆(LSTM)网络提取轴承故障特征。文献[14]提出一种多尺度学习的神经网络,通过学习轴承振动数据中相邻和非相邻区间的局部相关性提取故障特

征。文献[15]提出一种基于深度自编码网络,融合XGBoost算法,实现了轴承的多分类故障识别。

上述文献利用人工智能算法在风电机组轴承故障诊断上取得相当大的进展,但主要是在人为划分的平衡数据的基础上进行研究。主轴承故障在各种风电机组故障中占比较低,导致其正常样本和故障样本存在严重的数据不平衡问题。这种情况下,训练一个模型来实现风电机组主轴承故障的精确诊断比较困难。

生成对抗网络(GAN)作为一种生成式模型^[16],能够学习数据的分布规律,产生新的样本数据,为解决原始数据的不平衡问题提供了一种新方法。GAN模型在训练时容易出现不稳定和梯度消失现象,随后提出深度卷积GAN(DCGAN)^[17]和WGAN(Wasserstein GAN)^[18],改善了相关问题。在进一步研究过程中,将GAN与半监督学习相结合,提出辅助分类GAN(ACGAN)^[17-20],在优化生成效果的同时也让生成网络具备了更强的能力。以上几种GAN已被证明在图像生成方面是有效的,而在一维时间序列数据方面的研究及其应用较少。文献[21]利用条件式GAN对电力系统暂态稳定评估样本进行了数据增强;文献[22]利用WGAN对电力系统量测缺失数据进行了重建;文献[23]利用ACGAN对心电信号进行了样本扩充。这些研究显示出GAN在生成时间序列数据方面的潜力。

本文针对风电机组主轴承故障样本不足的问题,提出一种基于一维深度卷积的改进ACGAN数

据增强框架,用于扩充风电机组主轴振动信号数据。该改进 ACGAN 使用梯度惩罚代替权值剪裁,增强网络的表现能力,进一步提高训练的稳定性,同时将深度卷积神经网络中的最大池化层、全局平均池化层引入判别器中,提升判别器提取数据特征的能力,达到更好的分类效果。

1 改进 ACGAN 算法

1.1 WGAN

GAN 是由生成器 G 和判别器 D 这 2 个相互对立的部分组成,两者属于博弈关系。博弈双方的决策组合会形成一个纳什平衡点,在该博弈平衡点下,博弈中的任何一方将无法通过自身行为而增加自己的利益^[19]。GAN 框架如附录 A 图 A1(a) 所示,在训练过程中,生成器 G 构建了一个满足联合高斯分布的映射空间 P_z ,使输入噪声 z 逐渐拟合真实样本 x 的分布 P_{data} 以生成新的样本分布 P_g 。判别器将真实样本分布 P_{data} 和生成样本分布 P_g 同时作为输入,区分样本的真假,最终找到使生成器 G 和判别器 D 代价函数都最小的位置,即达到纳什平衡。博弈过程目标函数为:

$$\min_G \max_D V(D, G) = E_{x \sim P_{\text{data}}} [\log_2 D(x)] + E_{z \sim P_z} [\log_2 (1 - D(G(z)))] \quad (1)$$

式中: $E[\cdot]$ 为对应分布的期望; $G(z)$ 为生成器生成数据; $D[\cdot]$ 为判别器网络输出。

生成器与判别器的损失函数 L_G 和 L_D 分别如下:

$$L_G = E_{z \sim P_z} [\log_2 (1 - D(G(z)))] \quad (2)$$

$$L_D = E_{x \sim P_{\text{data}}} [\log_2 D(x)] + E_{z \sim P_z} [\log_2 (1 - D(G(z)))] \quad (3)$$

上述目标函数表明,训练结束后,生成器将无监督地获得真实数据分布规律,使判别器无法判断数据是否来自真实数据。

以 Wasserstein 距离衡量描述式(1)中的优化目标,与传统的 KL 距离或 JS 距离相比,采用 Wasserstein 距离能够减轻训练过程中梯度消失及训练不稳定的问题^[18]。Wasserstein 距离的表达式为:

$$W(P_{\text{data}}, P_g) = \inf_{\gamma \in \Pi(P_{\text{data}}, P_g)} E_{(x, \tilde{x}) \sim \gamma} [\|x - \tilde{x}\|] \quad (4)$$

式中: $\Pi(P_{\text{data}}, P_g)$ 为 P_{data} 与 P_g 的联合概率分布 γ 的集合; $\inf$ 表示下确界; $\tilde{x}$ 为生成样本; $\|\cdot\|$ 为真实样本与生成样本之间的距离。

$W(P_{\text{data}}, P_g)$ 的值越小,表明真实数据和生成数据之间的相似度越高。为保证网络能够保持正常的

梯度优化,使 $f(x)$ 的梯度变化不会过大,这里加入 K -Lipschitz 条件,其表达式为:

$$W(P_{\text{data}}, P_g) = \frac{1}{K} \sup_{\|f\|_L \leq K} E_{x \sim P_{\text{data}}} [f(x)] - E_{x \sim P_g} [f(x)] \quad (5)$$

式中: K 为常数; $\sup$ 表示上确界; $\|f\|_L \leq K$ 表示函数 $f(x)$ 满足 K -Lipschitz 连续,其导函数绝对值存在上界。

为使所有函数 $f(x)$ 在 K -Lipschitz 条件上成立,在网络中使用权值剪裁,该方法将权值的范围严格限制在 $[-l, l]$,当网络更新权值且权值在范围外时,将其剪裁为 l 或 $-l$ 。

1.2 改进 ACGAN

ACGAN 框架如附录 A 图 A1(b) 所示, ACGAN 是 GAN 的一种变体,能够利用辅助分类标签生成更高质量的样本,并将判别器与分类器结合,使改进的判别器不仅可以识别数据真假,还可以区分数据的不同类别^[20]。因此,图 A1(a) 中的 $G(z)$ 变换为图 A1(b) 的 $G(c, z)$,其中 c 表示对应数据的类标签。ACGAN 的损失函数包含 2 个部分,分别如式(6)和式(7)所示。

$$L_S = E_{x \sim P_{\text{data}}} [\log_2 D(x)] + E_{z \sim P_z} [\log_2 (1 - D(G(z)))] \quad (6)$$

$$L_C = E_{c \sim P_{\text{data}}} [\log_2 D(c)] + E_{c \sim P_z} [\log_2 (1 - D(G(c)))] \quad (7)$$

式中: L_S 为记录数据为真的概率; L_C 为记录数据分类正确的概率。

由于判别器应尽可能区分生成数据和真实数据并有效地对数据进行分类,因此判别器能被训练的最大值为 $L_S + L_C$,同时希望生成器生成的数据被判别器识别为真实数据且被有效分类,因此生成器能被训练的最大值为 $L_C - L_S$ 。

在 ACGAN 框架基础上中使用 Wasserstein 距离计算生成数据和真实数据的差别,构建改进 ACGAN。权值剪裁能够满足 K -Lipschitz 条件,但使网络权值被限制在固定范围,限制了网络的表现能力,并且权值剪裁容易设置不恰当,会导致梯度爆炸或梯度消失^[24]。使用一种梯度惩罚 (gradient penalty, GP) 来代替权值剪裁实现 K -Lipschitz 条件,提高网络训练过程的稳定性。 K -Lipschitz 条件要求判别器的梯度不超过 K ,梯度惩罚即为设置一个额外的损失项来实现梯度与 K 之间的联系。梯度惩罚项 L_{gp} 定义为:

$$L_{\text{gp}} = \lambda E_{\tilde{x} \sim P_g} [(\|\nabla_{\tilde{x}} D(\tilde{x})\|_2 - 1)^2] \quad (8)$$

式中: ∇ 表示梯度; $\|\cdot\|_2$ 为 2 范数; λ 为惩罚系数; $\hat{x} = \epsilon x + (1 - \epsilon)\bar{x}$, 其中 $\bar{x} \sim P_g$, $\epsilon \sim U[0, 1]$, U 为均匀分布; $P_{\hat{x}}$ 为采样分布, 其范围是真实数据分布与生成数据分布中间分布。

在原有损失函数的基础上添加 L_{gp} , 改进 ACGAN 的整体训练的损失函数为:

$$L_S = E_{x \sim P_{data}} [\log_2 D(x)] + E_{z \sim P_z} [\log_2 (1 - D(G(z)))] + \lambda E_{\hat{x} \sim P_{\hat{x}}} [(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1)^2] \quad (9)$$

$$L_C = E_{c \sim P_{data}} [\log_2 D(c)] + E_{c \sim P_z} [\log_2 (1 - D(G(c)))] \quad (10)$$

优化判别器 D 可以提升分类器 C 的性能, 优化分类器 C 同样会提升判别器 D 的性能。真假判别性在一定程度上涵盖分类性能, 故本文将梯度惩罚仅放置在判别真假损失 L_S 中。

2 模型框架及训练

2.1 模型框架

本文使用改进 ACGAN 框架生成高质量的风电机组主轴故障样本, 补充不平衡的数据集, 用于风电机组主轴故障诊断。设计的一种改进 ACGAN 框架如图 1 所示。




图 1 改进 ACGAN 框架
Fig. 1 Structure of improved ACGAN

网络结构及超参数选择是在文献[17]基础上进行试验的结果, 优化器将 Adam 梯度下降算法改为使用 RMSProp 方法, 能够有效改善训练不稳定问题^[18]。卷积核的大小及滤波器数量的选择由试验决定, 调整思路是以 2 或 4 为倍数提高或缩减整个网络的滤波器数量, 在精度非常近似的情况下选择较小的滤波器值, 以减少整个网络的参数, 提高训练速度^[22]。模型梯度惩罚项的惩罚系数 λ 取值为 10, 与真假损失和分类损失设置权重比例为 [10:1:1]。该模型详细网络层结构如附录 A 表 A1 所示。生成器网络输入的隐变量为 100 维, 通过全连接层和上采样层使数据维度进行膨胀。考虑到采用的风电机组主轴故障数据是一维时序振动信号数据, 使用一维卷积层对维度进行缩减。每个一维卷积层后采用 ReLU 作为激活函数, 在输出层采

用 tanh 激活函数, 能使模型更快地进行学习。为保证最终生成样本维度与算例中振动信号维度保持一致, 每个卷积层参数都经过人为设计。

判别器网络基本与生成器网络对称, 不同点在于 DCGAN 中提出的架构设计规则之一是使用卷积层替代池化层, 本文为提升判别器在多分类场景下进行分类的能力, 在判别器网络结构中重新引入最大池化层、全局平均池化层。每个一维卷积层后采用 LeakyReLU 作为激活函数。在判别数据真假功能上, 使用 Wasserstein 距离进行真假判别; 在对标签进行分类的功能上, 使用 Softmax 激活函数进行分类。

2.2 模型训练过程

基于 1.2 节的损失函数, 对模型参数进行迭代更新。模型训练采用 RMSProp 方法, 生成器与判别器的学习率分别设置为 0.000 2 和 0.000 1。在每个训练单元中, 训练过程可以分为 2 个步骤。

1) 生成器从潜在空间的随机噪声中产生带有特定标签的序列样本, 生成数据与真实数据混合在一起, 传送至判别器。判别器使用混合数据进行训练, 基于其损失函数计算判别器网络损失值, 使用 RMSProp 优化器更新网络参数。

2) 训练判别器后, 组合结构开始训练。在这一阶段, 保持判别器网络权重不变, 同样基于损失函数计算生成器网络损失值, 采用 RMSprop 优化器更新网络参数。在每一次更新生成器网络参数之前, 先执行判别器网络参数的更新以提高训练速度^[25]。

在训练完组合结构后, 即一个 epoch 结束, 训练过程重新开始。通过足够多次数的迭代训练, 整个模型在判别器和生成器损失函数的损失值上达到纳什均衡, 此时生成器可以根据给定的标签生成不同故障类型的风电机组主轴振动信号数据。

3 仿真分析

3.1 数据集准备

仿真 PC 硬件配置为 Intel® Core (TM) i7-8565U CPU @1.80 GHz、32.00 GB 运行内存和 11 GB 内存 NVIDIA GeForce RTX 2080ti GPU, 数据增强模型基于深度学习框架 Tensorflow1.4 和 Keras 构建。

本文所采用的风电机组主轴信号来自美国凯斯西储大学(CWRU)的滚动轴承数据集, 通过电火花加工单点损伤, 故障位置有内圈、外圈、滚动体 3 类, 故障直径有 0.18、0.355 6、0.533 4、0.711 2 mm 共 4 类, 电机载荷有 0、0.735、1.47、2.205 kW 共 4 类, 采样频率有 12 kHz 和 48 kHz 这 2 类。本文选取 12 kHz

采样频率,载荷为0、0.735、1.47、2.205 kW共4类工况下包含正常轴承在内的10种类型样本,以1 024个数据点作为1个样本,共选取了5 200个试验样本,实验数据如附录A表A2所示。

将所选试验样本划分为训练集和测试集两部分,使用训练集对改进ACGAN模型进行训练,使用测试集对其进行验证。从5 200个试验样本中随机选取每一类故障的100个样本作为测试集形成数据集1,剩余样本形成数据集2。为模拟实际风电机组主轴故障样本数目稀少的情况,从数据集2中随机选取每一类故障的一定数量的样本作为原始不平衡训练集,形成数据集3,并从数据集3中随机选取每一类故障的150个样本作为改进ACGAN的训练集,形成数据集4。以上数据集划分情况如附录A表A3所示。

3.2 模型训练和数据生成

该模型将对包含风电机组主轴正常样本的10种类型样本全部进行生成。将数据集4作为训练集,数据集1作为测试集,训练epoch设置为1 000次,每种样本生成数量预设为1 500个。原ACGAN框架同样使用附录A表A1的网络层结构,但相关池化层用同尺寸、同步长的卷积层代替,进行试验并形成对比,记录模型性能,结果如图2所示。图2(a)和(b)分别表示改进ACGAN与原ACGAN预测正确样本来源(来自真实数据或生成数据)的能力,生成器损失表示在生成数据和真实数据之间的损耗,判别器损失表示分辨样本来源真实数据还是生成数据的损耗。由图2(a)和(b)可见,改进ACGAN因加入梯度惩罚,在开始迭代时,生成器损失较大,但快速下降,与判别器损失在接近于零值的位置形成纳什均衡;原ACGAN生成器损失并没有快速下降,随迭代次数的增加,虽然同样接近于判别器损失,但变化幅度相对于改进ACGAN较大,没有与判别器损失在零值附近形成明显的纳什均衡。

图2(c)为2种框架在分类损失上的对比。由图2(c)可见,在迭代次数接近450次的位置,2种框架的分类损失均降至零值附近,但随迭代次数的增加,原ACGAN的分类损失出现较大幅度波动(箭头所指位置)。判别性能、分类性能与生成性能会在交替训练过程中趋向一个理想的平衡点,故分类损失的较大幅度波动一定程度反映出生成性能的不稳定。图2(d)为2种框架在分类精度上的对比。由图2(d)可见,在迭代次数接近450次的位置,2种框架的分类精度均升至1附近。分类精度上的较大幅度波动(箭头所指位置)同样反映出原ACGAN生成性能的不稳定。




图2 改进ACGAN和原ACGAN的性能对比
Fig. 2 Performance comparison of improved ACGAN and original ACGAN

综上,改进ACGAN框架从生成损失、分类损失和分类精度上都优于原ACGAN框架。

3.3 生成数据的评估及应用

使用 Wasserstein 距离描述生成数据与真实数

据之间的相似性,如附录 A 图 A2 所示。在训练过程中,Wasserstein 距离不断减小并在最后趋向于零,表明生成数据分布接近真实数据分布。与原 ACGAN 相比,改进 ACGAN 的 Wasserstein 距离值更小,且迭代过程中其变化幅度也更小。因此,改进 ACGAN 比原方案能够更有效地学习原始数据的分布特征,运行更加稳定,生成数据的质量更高。

使用改进 ACGAN 和原 ACGAN 框架进行样本扩充,每类风电机组主轴承故障样本按照预设扩充 1 500 个,分别形成数据集 5 和数据集 6。利用改进 ACGAN 生成数据集 5 与原 ACGAN 生成数据集 6 分别将原始不平衡数据集 3 扩充至每种类别故障 1 500 个,形成改进 ACGAN 扩充平衡数据集 7 与原 ACGAN 扩充平衡数据集 8,实现数据平衡。数据集扩充后划分情况如附录 A 表 A4 所示,其中数据集 7 和 8 括号内为每种类别故障的扩充数量。采用一种传统卷积神经网络(CNN)算法用于生成数据的分类性能测试,记为 C_CNN,网络层结构如附录 A 表 A5 所示。

将数据集 3、5、6、7 和 8 分别作为训练集,数据集 1 作为测试集进行分类性能测试,迭代足够多次数后,分类性能如图 3 所示。同时使用精确率、召回率、平衡分数和准确率 4 类指标对分类性能进行评估,指标量度值越接近于 1,表示性能越好,结果如附录 A 表 A6 所示。由图 3 可见,数据集 3 因存在严重的数据不平衡问题,在前 400 次迭代中,分类精度的上升与分类损失的下降速度均较为缓慢;数据集 5 与数据集 8 分类性能接近,但数据集 5 收敛速度较快;数据集 7 的分类精度最高,分类损失最接近于零;数据集 6 的分类精度最低,且分类损失随迭代次数的增加而逐渐增大,表明随着迭代次数的增加,C_CNN 学到更多分类细节,原 ACGAN 生成数据质量差的问题逐渐暴露。

由表 A6 可见,数据集 3 中第 6、7 类故障的召回率和平衡分数均低于 0.9,表明分类模型在这 2 类故障上没有得到较好的训练,尤其第 6 类故障为极少数类,模型很难进行处理。在数据集 5、7 中,第 6、7 类故障的召回率和平衡分数均有明显的提高。此外,数据集 5、7、8 与数据集 3、6 相比,4 类指标均有提高,其中数据集 7 的综合性能最高。

为了与 C_CNN 进行对比,本文考虑了一些其他常用的分类算法,包括支持向量机(SVM)、极限学习机(ELM)和 LSTM 网络算法。所有方法均使用数据集 1 作为测试集,分类准确率如表 1 所示。




图 3 不同数据集的分类性能
Fig. 3 Classification performance of different data sets

表 1 各种分类算法的准确率对比
Table 1 Accuracy comparison of various classification algorithms

算法	准确率				
	原始不平衡数据集	原 ACGAN 生成数据集	原 ACGAN 扩充平衡数据集	改进 ACGAN 生成数据集	改进 ACGAN 扩充平衡数据集
C_CNN	0.961	0.941	0.976	0.980	0.991
SVM	0.949	0.933	0.968	0.970	0.983
ELM	0.958	0.939	0.971	0.975	0.988
LSTM	0.955	0.928	0.960	0.981	0.990

由表 1 可见,其他算法的分类性能与 C_CNN 的基本一致,均表现为数据集 5、7 的分类准确率更高。

综上所述,改进 ACGAN 能够对真实数据分布进行有效建模,且在生成数据与原不平衡数据集混合使用下分类性能更好。

为了进一步研究改进 ACGAN 的抗噪能力,在训练数据集 4 和测试数据集 1 中添加不同程度的白噪声,以仿真风电机组运行现场复杂噪声环境下改进 ACGAN 生成数据的质量。分别在信噪比为 25、30、35、45 dB 的噪声环境下测试生成数据的质量。25、30、35、45 dB 的噪声环境下的生成数据与原不平衡数据混合使用,经多种分类算法测试,分类准确

率如表2所示。由表2可见,不同噪声程度下,各算法均保持良好的准确率。表明改进ACGAN框架网络层结构具有良好的特征提取和抗噪能力。

表2 不同噪声下各种分类算法的准确率对比
Table 2 Accuracy comparison of various classification algorithms with different noises

算法	准确率				
	25 dB 噪声	30 dB 噪声	35 dB 噪声	45 dB 噪声	无噪声
C_CNN	0.970	0.977	0.982	0.984	0.991
SVM	0.960	0.966	0.971	0.977	0.983
ELM	0.968	0.972	0.979	0.983	0.988
LSTM	0.971	0.975	0.978	0.982	0.990

通过以上评估分析,可以看出本文设计的改进ACGAN框架能够有效针对风电机组主轴轴承故障的不平衡数据集进行数据扩充,实现数据平衡,进而有效提高其故障诊断精度。

4 结语

针对风电机组主轴轴承故障诊断存在故障样本少且类别之间数据不平衡的问题,提出了一种基于一维深度卷积的改进ACGAN数据增强框架,该框架具有以下优点。

1)将基于一维深度卷积的ACGAN应用到风电机组主轴轴承故障诊断领域,从有限的非平衡故障样本中提取数据特征,生成高质量的样本,实现数据增强,提升了风电机组主轴轴承故障诊断的能力;同时该框架具有较好的抗噪能力。

2)将梯度惩罚应用到ACGAN中,增强了网络的表现能力,进一步提高了训练过程的稳定性,提高了生成数据的质量。

3)在判别器中引入最大池化层和全局平均池化层,增加判别器提取数据特征的能力,达到更好的分类效果,优化了生成器、判别器之间的均衡状态,进一步提高了多分类场景下生成器的生成性能。

本文的主要工作是利用CWRU的轴承数据集验证了该改进ACGAN框架的有效性,如何在风电机组不同位置的更多复杂故障种类下,构建强健的数据增强框架并现场验证是未来研究的重点。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

参考文献

[1] 张少敏,毛冬,王保义.大数据处理技术在风电机组齿轮箱故障诊断与预警中的应用[J].电力系统自动化,2016,40(14):129-134.

ZHANG Shaomin, MAO Dong, WANG Baoyi. Application of big data processing technology in fault diagnosis and early warning of wind turbine gearbox [J]. Automation of Electric Power Systems, 2016, 40(14): 129-134.

[2] 李刚,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 Gang, 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.

[3] 曾军,陈艳峰,杨苹,等.大型风力发电机组故障诊断综述[J].电网技术,2018,42(3):849-860.

ZENG Jun, CHEN Yanfeng, YANG Ping, et al. Review of fault diagnosis methods of large-scale wind turbines [J]. Power System Technology, 2018, 42(3): 849-860.

[4] LIU Z, ZHANG L. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings [J]. Measurement, 2019, 149: 1-6.

[5] TSUI K L, WANG D, ZHOU Q, et al. Novel Gauss-Hermite integration based Bayesian inference on optimal wavelet parameters for bearing fault diagnosis [J]. Mechanical Systems and Signal Processing, 2016, 72: 80-91.

[6] SUGUMARAN V, RAMACHANDRAN K I. Automatic rule learning using decision tree for fuzzy classifier in fault diagnosis of roller bearing [J]. Mechanical Systems and Signal Processing, 2007, 20: 2237-2247.

[7] SANTOS P, VILLA L, RENONES A, et al. An SVM-based solution for fault detection in wind turbines [J]. Sensors, 2015, 15(3): 5627-5648.

[8] TANG B, SONG T, LI F, et al. Fault diagnosis for a wind turbine transmission system based on manifold learning and Shannon wavelet support vector machine [J]. Renewable Energy, 2014, 62: 1-9.

[9] XIN Y, LI S, WANG J. A novel roller bearing fault diagnosis method based on the wavelet extreme learning machine [C]// 2017 Prognostics and System Health Management Conference, July 9-12, 2017, Harbin, China.

[10] ZHU S, JIAO B. Fault diagnosis of wind bearing based on multi-scale wavelet kernel extreme learning machine [C]// The 2nd Annual International Conference on Information System and Artificial Intelligence (ISAI2017), July 14-16, 2017, Tianjin, China.

[11] ZHANG W, ZHANG F, CHEN W, et al. Fault state recognition of rolling bearing based fully convolutional network [J]. Computing in Science & Engineering, 2019, 21(5): 55-63.

[12] HOU R Z. Rolling bearing fault diagnosis based on wavelet packet and improved BP neural network for wind turbines [J]. Applied Mechanics & Materials, 2013, 347-350: 117-120.

[13] ZHANG Jianfu, SONG Yu, LI Gang, et al. A method of fault diagnosis for rolling bearing of wind turbines based on long short-term memory neural network [J]. Computer Measurement & Control, 2017, 25(1): 16-19.

[14] WANG D, GUO Q, SONG Y, et al. Application of multiscale learning neural network based on CNN in bearing fault diagnosis [J]. Journal of Signal Processing Systems, 2019, 91(10): 1205-1217.

[15] 赵洪山,闫西慧,王桂兰,等.应用深度自编码网络和XGBoost

- 的风电机组发电机故障诊断[J]. 电力系统自动化, 2019, 43(1): 81-90.
- ZHAO Hongshan, YAN Xihui, WANG Guilan, et al. Fault diagnosis of wind turbine generator based on deep autoencoder network and XGBoost [J]. Automation of Electric Power Systems, 2019, 43(1): 81-90.
- [16] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [EB/OL]. [2020-01-01]. <https://arxiv.org/pdf/1406.2661v1.pdf>.
- [17] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks [EB/OL]. [2020-01-01]. <https://arxiv.org/abs/1511.06434>.
- [18] ARJOVSKY M, CHINTALA S, BOTTOU L. Wasserstein generative adversarial networks [C]// International Conference on Machine Learning, August 6-11, 2017, Sydney, Australia: 214-223.
- [19] 史丹青. 生成对抗网络入门指南[M]. 北京: 机械工业出版社, 2018.
- SHI Danqing. Generative adversarial network: a primer [M]. Beijing: Machinery Industry Press, 2018.
- [20] ODENA A, OLAH C, SHLENS J. Conditional image synthesis with auxiliary classifier GANs [EB/OL]. [2020-01-01]. <https://arxiv.org/abs/1610.09585>.
- [21] 谭本东, 杨军, 赖秋频, 等. 基于改进CGAN的电力系统暂态稳定评估样本增强方法[J]. 电力系统自动化, 2019, 43(1): 149-160.
- TAN Bendong, YANG Jun, LAI Qiupin, et al. Data augment method for power system transient stability assessment based on improved conditional generative adversarial network [J]. Automation of Electric Power Systems, 2019, 43(1): 149-160.
- [22] 王守相, 陈海文, 潘志新, 等. 采用改进生成式对抗网络的电力系统量测缺失数据重建方法[J]. 中国电机工程学报, 2019, 39(1): 56-64.
- WANG Shouxiang, CHEN Haiwen, PAN Zhixin, et al. A reconstruction method for missing data in power system measurement using an improved generative adversarial network [J]. Proceedings of the CSEE, 2019, 39(1): 56-64.
- [23] WANG Pu, HOU Borui, SHAO Siyu, et al. ECG arrhythmias detection using auxiliary classifier generative adversarial network and residual network [J]. IEEE Access, 2019, 7: 100910-100922.
- [24] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of Wasserstein GANs [EB/OL]. [2017-08-09]. <https://arxiv.org/abs/1704.00028>.
- [25] 姚乃明, 郭清沛, 乔逢春, 等. 基于生成式对抗网络的鲁棒人脸表情识别[J]. 自动化学报, 2018, 44(5): 865-877.
- YAO Naiming, GUO Qingpei, QIAO Fengchun, et al. Robust facial expression recognition with generative adversarial networks [J]. Acta Automatica Sinica, 2018, 44(5): 865-877.
-
- 卢锦玲(1971—), 女, 副教授, 硕士生导师, 主要研究方向: 电力系统分析、稳定和控制等。E-mail: lujinling@126.com
- 张祥国(1996—), 男, 通信作者, 硕士研究生, 主要研究方向: 风电机组故障诊断、深度学习等。E-mail: 1754556098@qq.com
- 张伟(1995—), 男, 硕士研究生, 主要研究方向: 微电网运行与控制、深度学习等。E-mail: 1132036911@qq.com
- (编辑 代长振)

Fault Diagnosis of Main Bearing of Wind Turbine Based on Improved Auxiliary Classifier Generative Adversarial Network

LU Jinling, ZHANG Xiangguo, ZHANG Wei, GUO Luyu, WEN Ruotong

(School of Electrical and Electronic Engineering, North China Electric Power University, Baoding 071003, China)

Abstract: The fault diagnosis method of wind turbines based on vibration signals is one of the focuses in the field of safe operation and maintenance of wind power units. Faults in the main bearing of the wind turbine rarely happen, which makes it difficult to use data mining methods to determine the fault type. To solve this problem, a data enhancement method for fault diagnosis of wind turbine main bearings is proposed. By improving the adaptability of auxiliary classifier generative adversarial network (ACGAN) and introducing gradient penalty, an improved ACGAN framework is constructed to improve its learning stability. And a pooling layer is introduced into the discriminator network to enhance its ability to extract data features in multiple classification scenarios. The simulation results show that the improved ACGAN framework can effectively learn the distribution characteristics of the original data, has strong anti-noise interference, is more stable than the original framework in the training process, and has higher quality of generated data; it can effectively balance the fault vibration data of the main bearing of the wind turbine, and further improves the accuracy of fault diagnosis for the main bearing of the wind turbine.

This work is supported by National Key Technology R&D Program of China (No. 2015BAA06B03).

Key words: wind turbine; fault diagnosis; data enhancement; auxiliary classifier generative adversarial network; gradient penalty

