

基于条件生成对抗网络的电力二次设备智能故障诊断策略

朱美莲¹ 高净净¹

ZHU Meilian GAO Jingjing

摘要

电力二次设备承担继电保护、测控和安全自动控制等功能,其故障诊断结果直接影响电网运行处置。现场数据中故障样本占比低,少数类故障特征学习不足,容易降低智能诊断模型的识别能力。针对这一问题,文章提出一种基于条件生成对抗网络(CGAN)的电力二次设备故障诊断策略。先构建CGAN故障样本生成模型,引入故障类别条件信息生成指定类型的少数类样本,扩充训练集;再将自适应密度峰值聚类(ADPC)与梯度提升决策树(GBDT)结合,利用聚类结果补充故障特征空间的分布信息,并完成故障类型判别。仿真结果显示,在样本不平衡条件下,所提方法仍保持较高诊断准确率,能够改善少数类故障识别效果。

关键词

电力二次设备;故障诊断;条件生成对抗网络;样本扩充;自适应密度峰值聚类;梯度提升决策树

doi: 10.3969/j.issn.1672-9528.2026.06.026

0 引言

随着电力系统规模扩大,继电保护、安全自动装置、测控装置和故障录波装置等二次设备承担了更多监测、控制和保护任务。这类设备长期处于电磁干扰、温湿度变化和连续运行工况下,叠加设备老化和操作因素,故障并不少见。一旦诊断滞后或误判,可能影响保护动作和调度处置。因此,有必要研究适用于现场数据特点的二次设备故障诊断方法。

传统二次设备故障诊断主要依赖专家经验和规则库。面对复合故障、隐性故障或运行边界频繁变化的场景,这类方法的适应性有限。近年来,机器学习和深度学习方法被用于故障识别^[1-3],可以从历史数据中提取故障特征,并建立监测量与故障类型之间的映射关系^[4-5]。但在现场数据中,正常样本通常远多于故障样本,少数类故障记录更少,模型训练时容易偏向正常工况或高频故障,进而影响诊断结果。

为缓解故障样本不足,生成对抗网络(generative adversarial network, GAN)可用于合成训练样本。GAN通过生成器和判别器的对抗训练学习数据分布,并生成与真实样本接近的合成数据。条件生成对抗网络(conditional generative adversarial network, CGAN)在GAN中加入类别条件,使生成样本能够对应指定故障类型^[6]。将CGAN用于二次设备故障诊断,可以补充少数类故障样本,改善训练集分布,从而提高模型对低频故障的识别能力。

在诊断模型选择上,支持向量机、决策树等传统方法处理高维复杂数据时容易受到特征分布和参数设置的影响。密度聚类和集成学习为这类问题提供了另一种思路。自适应

密度峰值聚类(adaptive density peak clustering, ADPC)可在无需预先指定聚类数量的情况下识别不同形状的样本簇,适合分析故障特征分布^[7]。梯度提升决策树(gradient boosting decision tree, GBDT)通过多棵弱分类树的迭代组合处理非线性分类问题^[8]。将ADPC得到的分布信息输入GBDT,有助于分类器利用故障样本在特征空间中的聚集关系。

基于上述问题,本文提出基于CGAN的电力二次设备故障诊断策略。首先,利用CGAN生成少数类故障样本,缓解样本不平衡;随后,将ADPC用于故障特征空间聚类,提取不同故障模式的分布信息;最后,以原始特征和聚类标签为输入训练GBDT分类器。仿真实验用于检验该方法在样本不平衡条件下的诊断效果。

1 基于条件生成对抗网络的故障样本扩充方法

电力二次设备故障样本少,是智能诊断模型训练中的常见限制。针对这一问题,本节采用条件生成对抗网络扩充故障样本。首先,对运行过程中采集的电压、电流、功率、温度和谐波含量等监测数据进行特征提取与预处理。由于不同特征的量纲和数值范围差异较大,本文采用Z-score标准化方法处理特征数据,其归一化公式为:

$$\bar{x} = \frac{x - \mu}{\sigma} \quad (1)$$

式中: x 为原始特征数据, μ 为特征数据的均值, σ 为特征数据的标准差, $\bar{x}$ 为标准化后的特征数据。标准化后,不同特征的量纲差异被削弱,模型训练更稳定,收敛过程也更平稳。

条件生成对抗网络由生成器 G 和判别器 D 两个神经网络组成。生成器用于生成接近真实分布的故障样本,判别

1. 国网江苏省电力有限公司泗阳县供电分公司 江苏泗阳 223700

器用于区分真实样本和生成样本。在条件生成对抗网络中，两者均以故障类别标签 c 作为条件输入。生成器接收随机噪声向量 z 和条件标签 c ，生成故障样本 x_{gen} ，其生成过程可以表示为：

$$x_{\text{gen}} = G(z, c; \theta_g) \quad (2)$$

其中， $z \sim p_z(z)$ 为从先验分布（通常为高斯分布或均匀分布）中采样的随机噪声向量， c 为故障类别的独热编码向量， θ_g 为生成器的网络参数。生成器通常由多层全连接网络或卷积网络构成，通过反向传播算法学习从噪声空间到数据空间的映射关系。

判别器的作用是判断输入样本的真实性，并同时考虑样本与条件标签的匹配程度。判别器的输出可以表示为：

$$D(x, c; \theta_d) \rightarrow [0, 1] \quad (3)$$

式中： x 为输入样本（可以是真实样本 x_r 或生成样本 x_{gen} ）， θ_d 为判别器的网络参数。判别器输出样本为真实样本的概率。在交替训练过程中，生成器逐步逼近真实故障样本分布。

条件生成对抗网络的训练目标是求解如下的最小 - 最大优化问题：

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_r} [\log D(x, c)] + \mathbb{E}_{z \sim p_z} [\log(1 - D(G(z, c), c))] \quad (4)$$

式中： $V(D, G)$ 表示生成对抗网络的目标函数， p_r 表示真实样本的数据分布， p_z 表示噪声的先验分布， $\mathbb{E}$ 表示期望运算。第一项为判别器正确识别真实样本的对数似然，第二项为判别器正确识别生成样本的对数似然。交替优化后，生成样本分布逐步接近真实故障样本分布。

2 基于自适应密度峰值聚类与梯度提升决策树的故障诊断方法

样本扩充完成后，需要建立故障诊断模型。本节将自适应密度峰值聚类与梯度提升决策树结合使用。ADPC 先对故障特征空间进行聚类，获得故障模式的分布信息和聚类中心；GBDT 再利用原始特征及聚类结果完成故障类别识别。

自适应密度峰值聚类算法的核心思想是，聚类中心具有较高的局部密度，且与其他高密度点之间的距离较大。首先，定义样本点 i 的局部密度 ρ_i 为：

$$\rho_i = \sum_{j \neq i} \exp\left(-\frac{d_{ij}^2}{d_c^2}\right) \quad (5)$$

式中： d_{ij} 为样本点 i 和样本点 j 之间的欧氏距离， d_c 为截断距离。该定义用于描述样本点邻域内的密集程度。

随后，定义样本点 i 的相对距离 δ_i 为该点到所有密度大于 ρ_i 的样本点的最小距离：

$$\delta_i = \begin{cases} \min_{j: \rho_j > \rho_i} d_{ij}, & \text{if } \exists j, \rho_j > \rho_i \\ \max_j d_{ij}, & \text{otherwise} \end{cases} \quad (6)$$

聚类中心应同时具有较高的 ρ_i 和 δ_i 值。为了自动识别聚类中心，定义决策值 $\gamma_i = \rho_i \cdot \delta_i$ ，其中 γ_i 为样本点 i 的聚类中心决策值，将 γ_i 按降序排列，选择前 k 个样本点作为聚类中心， k 为聚类数量。本文采用自适应方法确定聚类数量 k ，通过分析 γ_i 的变化梯度识别跳跃点，并据此确定聚类数量。

确定聚类中心后，其余样本点按照最近邻原则划入对应簇。对每个非中心样本点，选择距离最近且密度高于自身的样本点，并继承该样本点所属的聚类标签。这样可以在不预设簇形状的情况下描述故障样本的聚集区域。

完成聚类后，将聚类标签作为附加特征输入 GBDT 分类器。GBDT 属于基于决策树的集成学习方法，每轮迭代拟合上一轮的残差，并将多棵树的输出累加得到最终预测结果。其预测模型可表示为：

$$F_M(x) = \sum_{m=1}^M \alpha_m h_m(x) \quad (7)$$

式中： $F_M(x)$ 为 GBDT 的最终预测模型， M 为决策树的数量， $h_m(x)$ 为第 m 棵决策树的预测函数， α_m 为第 m 棵决策树的权重系数， x 为输入特征向量（包括原始特征和聚类标签特征）。

GBDT 训练采用前向分步算法，每次迭代通过最小化损失函数确定新的决策树。对于多分类故障诊断任务，本文采用 Softmax 输出和交叉熵损失函数：

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{ik} \log(p_{ik}) \quad (8)$$

式中： L 为交叉熵损失函数， N 为样本数量， K 为故障类别数量， y_{ik} 为样本 i 属于类别 k 的真实标签（0 或 1）， p_{ik} 为模型预测样本 i 属于类别 k 的概率。最小化交叉熵损失后，GBDT 模型建立特征空间与故障类别之间的映射。

模型训练中，本文结合网格搜索和交叉验证优化 GBDT 超参数，包括学习率、树最大深度和叶节点最小样本数。为降低过拟合风险，训练过程设置早停条件：当验证集损失连续若干轮不再下降时停止迭代。训练完成后，GBDT 模型接收二次设备监测数据，并输出对应的故障类型，为运维判断提供参考。

3 仿真分析

为检验所提策略，本文采用某省电力公司电力二次设备运行数据开展仿真实验。数据集覆盖继电保护装置、测控装置和故障录波装置等设备，包含正常运行及故障状态记录。单条记录包括电压幅值、电流幅值、有功功率、无功功率、频率、谐波含量、装置温度和运行时长等特征。故障样本分为 8 类，包括继电器拒动、误动、参数漂移、通信故障、电源故障、软件异常、硬件损坏和环境干扰。

数据集中故障样本明显少于正常样本，因此先采用 CGAN 对 8 类故障样本分别扩充。仿真设置如下：原始数据

包含正常样本 18 500 条、8 类故障样本共 2 300 条；每类故障样本扩充至 1 500 条，扩充后故障样本总数为 12 000 条；生成样本与真实样本的平均 FID 值为 23.6；扩充后的数据集按 7:2:1 划分为训练集、验证集和测试集，其中训练集用于模型拟合，验证集用于超参数调优，测试集用于最终评价；CGAN 学习率为 0.000 2，批大小为 128，训练 200 轮；GBDT 最大树深度为 6，学习率为 0.1，树数量为 100 棵。

对比方法包括支持向量机 (SVM)、随机森林 (RF)、仅使用原始样本训练的 GBDT，以及先经 SMOTE 扩充样本后再训练的 SMOTE-GBDT。评价指标采用准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 和 F_1 分数。仿真结果如图 1~3 及表 1 所示。

图 1 为各方法在测试集上的诊断准确率。CGAN-ADPC-GBDT 的准确率为 96.8%，比 SVM 高 11.3 个百分点，比未扩充样本的 GBDT 高 8.5 个百分点。与 SMOTE-GBDT 相比，该方法仍高 3.2 个百分点，说明 CGAN 生成样本在本实验中更接近真实故障分布，对分类器训练更有帮助。




图 1 不同方法的故障诊断准确率对比

图 2 比较了本文方法与 GBDT 在各故障类别上的 F_1 分数。对于硬件损坏、环境干扰等样本较少的类别，GBDT 的 F_1 分数分别为 0.72 和 0.68，本文方法分别提高到 0.94 和 0.91。




图 2 各故障类别的 F_1 分数对比

结果说明，少数类样本经 CGAN 扩充后，模型能够学习到更多低频故障特征。对于继电器拒动、通信故障等样本本对较多的类别，本文方法的 F_1 分数均保持在 0.95 以上。

为观察 CGAN 的训练过程，图 3 为生成器、判别器损失变化以及生成样本质量指标 FID 的变化曲线。




图 3 CGAN 训练过程的损失曲线及样本质量评估

由图 3 可见，训练初期生成器和判别器损失分别约为 2.5 和 2.0，随后逐步下降并趋于稳定。训练结束时，生成器损失约为 0.3，判别器损失约为 0.5，表明生成样本已经使判别器难以稳定区分真假样本。FID 分数由约 150 下降至 23.6，说明生成样本与真实样本在特征空间中的距离缩小。该结果表明，CGAN 能够为后续故障诊断提供可用的补充训练样本。

实验还考察了 ADPC 聚类特征的作用。表 1 汇总了各方法在测试集上的综合指标。加入聚类特征后，诊断准确率较仅使用原始特征提高 2.3 个百分点。原因在于 ADPC 提供了故障样本在特征空间中的分布信息，使 GBDT 能够利用故障模式的聚集关系，从而提高分类结果的区分度。

表 1 各方法性能指标对比

方法	准确率/%	精确率/%	召回率/%	F_1 分数
SVM	85.5	84.2	83.8	0.840
RF	89.2	88.6	88.9	0.888
GBDT	88.3	87.9	87.5	0.877
SMOTE-GBDT	93.6	93.1	92.8	0.930
本文方法	96.8	96.5	96.2	0.964

综合仿真结果表明，所提 CGAN-ADPC-GBDT 策略能够缓解故障样本不平衡对模型训练的影响，并提高电力二次设备故障诊断精度。

4 结论

本文针对电力二次设备故障样本不足和诊断精度受限的问题，提出了基于条件生成对抗网络的故障诊断策略。该策略先利用 CGAN 生成少数类故障样本，改善训练集类别分布；再采用 ADPC 提取故障特征空间的分布信息，并与 GBDT 分类器结合完成故障识别。仿真结果表明，该方法在诊断准确率和少数类故障识别方面均优于对比方法，硬件损坏、环境干扰等低频故障类别的 F_1 分数提升较明显。后续研究可进一步引入面向时序运行数据的生成模型和在线更新机制，使诊断模型更好适应电力系统运行状态变化。

(下转第 124 页)

所提出的方法不仅在效率上得到了提升,在最终的图像恢复精度上也有些许的提升,在表2中可以看出图1中图像恢复的PSNR值,GUIG-MCP的快速低秩矩阵补全的方法对缺失的彩色图像能够恢复到一个较好的效果。

表2 图1中各个图像恢复的PSNR(dB)

图像	1	2	3	4
GUIG_L0	34.10	38.66	32.60	41.13
MC_LogDet	18.30	24.50	20.92	25.7
GUIG-MCP	34.84	39.10	32.73	41.89

5 结论

从BSDS数据集随机选择彩色图像作为测试集对传统的GUIG_L0矩阵补全方法与MC_LogDet矩阵补全方法进行实验分析比较。实验数据表明,所提GUIG-MCP方法,同时结合了Nesterov动量和幂方法的一种加速近端交替线性最小化方法提升了整体的计算效率。

参考文献:

[1]Wu Di, Shang Mingsheng, Luo Xin, et al. An L_1 -and- L_2 -norm-oriented latent factor model for recommender systems[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 33(10): 5775-5788.

[2]王巍凤,岳亚辉,冯越,等.基于四元数鲁棒主成分分析的彩色视频背景建模[J].信息技术与信息化,2025(4):80-83.

[3]Jia Xixi, Feng Xiangchu, WangWeiwei, et al.Generalized

unitarily invariant gauge regularization for fast low-rank matrix recovery[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021,32(4):1627-1641.

[4]罗孝敏,彭定涛,张弦.基于MCP正则的最小一乘回归问题研究[J].系统科学与数学,2021,41(8):2327-2337.

[5]张弦.几类低秩稀疏矩阵优化问题非凸正则化理论与算法研究[D].贵阳:贵州大学,2024.

[6]Zhang Hengmin, Wen Bihan, Zha Zhiyuan, et al. Accelerated PALM for nonconvex low-rank matrix recovery with theoretical analysis[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 34(4): 2304-2317.

【作者简介】

李慧勇(1999—),男,河南商丘人,硕士研究生,研究方向:高维数据与图像处理。

马鑫(1996—),男,河南郑州人,硕士研究生,研究方向:基于广义矩阵的图像分类算法。

邱枫(2001—),男,浙江金华人,硕士研究生,研究方向:轴承寿命预测。

顾强(2000—),男,江苏扬州人,硕士研究生,研究方向:图像处理与模式识别。

廖亮(1975—),通信作者(email:liaoliangis@126.com),男,河南郑州人,博士,教授、研究生导师,研究方向:高维数据分析与图像处理通信。

(收稿日期:2025-11-03 修回日期:2026-06-01)

(上接第120页)

参考文献:

[1] Zhang Yahui, Zhou Taotao, Huang Xufeng, et al. Fault diagnosis of rotating machinery based on recurrent neural networks[J]. Measurement, 2023, 171: 108774.

[2] Pandhare V, Singh J, Lee J. Convolutional neural network based rolling-element bearing fault diagnosis for naturally occurring and progressing defects using time-frequency domain features[C]//2019 Prognostics and System Health Management Conference (PHM-Paris).Piscataway: IEEE, 2023: 320-326.

[3] Shao Siyu, McAleer S, Yan Ruqiang, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. IEEE Transactions on Industrial Informatics, 2022, 15(4): 2446-2455.

[4] Wang Zhijian, Zheng Likang, Du Wenhua, et al. A novel method for intelligent fault diagnosis of bearing based on capsule neural network[J]. Complexity, 2023: 6943234.

[5] Rodriguez A, Laio A. Clustering by fast search and find of density peaks[J]. Science, 2014, 344(6191): 1492-1496.

[6] Chen Tianqi, Guestrin C. XGBoost: A scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016: 785-794.

[7] Mirza M, Osindero S. Conditional generative adversarial nets[PP/OL].(2014-11-06)[2026-05-29].https://doi.org/10.48550/arXiv.1411.1784.

[8] Li Xiang, Zhang Wei, Ding Qian. Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction[J]. Reliability Engineering & System Safety, 2023, 182: 208-218.

【作者简介】

朱美莲(1978—),女,江苏宿迁人,本科,高级工程师、调控值长,研究方向:配网调控运行。

高净净(1996—),女,山西大同人,本科,工程师,研究方向:通信运检及调度自动化。

(收稿日期:2025-10-27 修回日期:2026-06-11)