

doi: 10.3969/j.issn.1007-2691.2026.04.08

基于 Wasserstein 生成对抗网络和多模态故障特征提取的光电流互感器故障辨识方法

李振东^{1 2 3}, 安海清^{2 3}, 金海望^{2 3}, 戴浩男⁴, 刘崇茹^{1 5}, 王 飞^{4 5}

(1. 华北电力大学 电气与电子工程学院, 北京 102206; 2. 国网冀北电力有限公司超高压分公司, 北京 102488;
3. 河北省柔性直流输电装备与技术实证重点实验室, 天津 300100; 4. 华北电力大学 电力工程系, 河北
保定 071003; 5. 新能源电力系统全国重点实验室 (华北电力大学), 北京 102206)

摘要: 光电流互感器 (光 CT) 发生故障将严重影响直流输电系统的稳定运行, 因此准确辨识光 CT 故障发生类型具有重要意义。针对光 CT 运行数据中正常工况与故障工况比重严重失衡和故障工况下光 CT 状态参量变化特性复杂导致光 CT 故障辨识模型训练效果差、辨识精度低的问题, 创新提出了一种基于 Wasserstein 生成对抗网络和多模态故障特征提取的光 CT 故障辨识方法。首先, 采用基于 Wasserstein 距离度量的生成对抗网络扩充原始故障样本以确保不同类型故障样本与正常样本的均衡性; 其次, 采用奇异谱分析法将光 CT 多维状态参量分解为多个子信号以获取各参量的多模态信息; 最后, 构建 CNN-LSTM 神经网络实现光 CT 故障的准确辨识。仿真结果表明, 相较于最优基准模型, 辨识准确性提高了 1.25%, 验证了本文所提方法的有效性。研究成果可为光 CT 的运维工作提供参考。

关键词: 生成对抗网络; 光电流互感器; 故障辨识; CNN-LSTM; 奇异谱分析

中图分类号: TM452.93 **文献标志码:** A **文章编号:** 1007-2691 (2026) 04-0072-12

Fault Identification Method of Optical Current Transformer Based on Wasserstein Generation Adversarial Network and Multi-modal Fault Feature Extraction

LI Zhendong^{1 2 3}, AN Haiqing^{2 3}, JIN Haiwang^{2 3}, DAI Haonan⁴, LIU Chongru^{1 5}, WANG Fei^{4 5}

(1. School of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China; 2. EHV Power Transmission Company, State Grid Jibei Electric Power Co., Ltd., Beijing 102488, China; 3. Hebei Key Laboratory of Equipment and Technology Demonstration of Flexible DC Transmission, Tianjin 300100, China; 4. Department of Power Engineering, North China Electric Power University, Baoding 071003, China; 5. State Key Laboratory of Alternate Electrical Power System with Renewable Energy Sources (North China Electric Power University), Beijing 102206, China)

Abstract: The failure of an optical current transformer (optical CT) can seriously affect the stability of HVDC transmission systems, making accurate identification of optical CT fault types highly significant. Aiming at the problems of poor training effectiveness and low identification accuracy of fault identification model due to the serious imbalance between normal and fault condition data, and the complex change characteristics of optical CT state parameters under fault working conditions, a fault identification method of optical CT based on Wasserstein generation adversarial network and multi-modal fault feature extraction is innovatively proposed. Firstly, the original fault samples are proposed based on the generation adversarial network optimized with the Wasserstein distance, ensuring the balanced distribution between different types of fault samples and normal samples. Secondly, the multi-dimensional state parameters of optical CT are

收稿日期: 2024-04-18.

基金项目: 国家自然科学基金联合基金重点支持项目 (U23B20126); 国网冀北电力有限公司超高压分公司科技项目资助 (B3018H230003).

decomposed into multiple sub-signals by singular spectrum analysis to obtain the multi-modal information of each parameter. Finally, a CNN-LSTM neural network is constructed to achieve accurate optical CT fault identification. The simulation results show that the proposed method improves identification accuracy by 1.25% compared with the optimal benchmark model, validating its effectiveness. The research results can provide references for the operation and maintenance of optical CT.

Key words: generative adversarial network; optical current transformer; fault identification; CNN-LSTM; singular spectrum analysis

0 引言

随着我国提出“双碳”目标,电力行业正积极转型,致力于构建新型电力系统。为实现这一目标,必须大力推动新能源的大规模开发,并同步提升电网对新能源的消纳与调控能力。《“十四五”可再生能源发展规划》中明确提出要加快推进西北地区大型风电光伏基地建设。然而我国负荷中心主要分布在中东部经济发达地区,能源资源与负荷中心呈逆向分布的特征。为促进电力资源优化配置与东西部协调发展,拓宽绿电输送“大通道”,我国积极推进“西电东送”跨省跨区输电工程建设。截至2022年底,我国已建成“西电东送”跨省跨区输电工程共计60余项。直流输电工程因其在高电压等级、远距离、大功率电能传输方面的经济性和灵活性,已经成为远距离跨区域直流输电的重要手段^[1,2]。

作为直流输电工程的关键节点,换流站内大量应用了光电流互感器(简称光CT)进行电流的监测,为直流系统的控制保护及运行状态监测提供可靠的测量信息。但是由于光CT长期运行在换流站强磁场和高低温变化的复杂环境中,其内部大量光电器件的运行状态会受到较大干扰,甚至出现故障^[3]。一旦发生故障,会使得电流量测量失真,导致保护系统误动作,严重影响电力系统的正常运行。对光CT故障快速、准确的辨识有助于运维人员及时进行维护,延长设备寿命,避免电力系统故障的误判,提高系统稳定性。因此,快速、准确辨识光CT发生故障类型具有十分重要的意义。

目前已有较多学者针对故障辨识问题^[4]开展研究,研究对象主要包括变压器^[5]、输电线路^[6,7]等。故障辨识方法主要有基于解析模型的方法、基于信号处理的方法和基于数据驱动与人工智能的辨识方法^[8]。对于解析模型的方法,文献[9]从系统元件的物理电气特性出发,构建了输电线路和变压器的电流观测器模型,对比观测器输出与

互感器输出的残差故障信息来辨识互感器渐变性故障。文献[10]对气体绝缘输电线路(gas insulated transmission line, GIL)温度场进行了研究,建立GIL有限元模型,通过仿真验证以温度变化率作为故障辨识判据的可行性。基于解析模型的方法需要对研究对象准确建模,但是对于光CT等结构较为复杂且实际运行环境恶劣的电力器件,建模难度较大^[11]。因此也有学者从信号处理的角度进行故障辨识。文献[12]利用消除趋势波分析确定变分模态分解层数,并且采用互信息法确定相关模态,用sym8小波变换进行去噪处理,保留了信号特征。文献[13]构建了基于Allan方差的光纤电流互感器状态诊断分析模型,根据Allan方差计算结果诊断互感器状态,并实现自身故障定位。文献[14]针对并联电容器常见的四种缺陷,提出了一种基于振动信号马尔可夫转移场变换的并联电容器故障诊断方法。然而光CT不同类型故障发生时各状态参量具有差异化的时序变化特性,一种故障的发生表现为多个参量同时变化且变化特性各不相同,不同故障的参量变化情况相互耦合。基于信号处理的方法难以高效辨识这类具有复杂变化特性的故障。近些年由于人工智能方法具有对先验知识较好的学习能力,许多学者在故障辨识的研究中也广泛采用了人工智能算法。文献[15]提取了光学电压互感器故障模式的特征向量,构建反向传播(backpropagation, BP)神经网络进行训练,从而实现对光学电压互感器的故障辨识。文献[16]提出了一种基于深度卷积测量网络的滚动轴承压缩域故障特征提取方法,用于滚动轴承压缩域故障辨识。文献[17]则使用支持向量机多分类模型和长短期记忆神经网络对光CT的渐变性故障进行辨识。尽管上述文献在一定程度上解决了复杂故障的辨识诊断问题,但是大多忽略了故障样本数量对模型性能的影响。较少的故障样本会造成数据集中故障时段数据与正常时段数据之间的不平衡,可能会使得模型倾向于预测

数量较多的正常情况从而最大程度地减小总体错误率,并且难以学习到少数类别的特征,导致辨识模型泛化能力差。

换流站光 CT 在实际运行中故障发生频次较低,正常运行数据远多于故障时段数据,难以获取大量故障时段的数据。针对故障数据缺乏的问题,传统的小样本分析法难以解决机理复杂的故障辨识问题,而迁移学习、主动学习等方法^[18]无法保证模型的适应性,因此部分文献研究了数据扩充的办法,如:文献[19]提出了一种基于经验知识的样本扩充方法从而解决数据数量少且质量也不高的问题,文献[20]利用改进的相似度准则进行样本扩充,再通过小波降噪处理得到新的样本作为数据集。然而这类基于准则的数据扩充方法需要具有关于数据特征的先验知识。生成对抗网络(generative adversarial network, GAN)是一种扩充数据的有效办法,文献[21]使用生成对抗网络生成高质量的红外热成像图片,用于转子-轴承系统故障的诊断,文献[22]则使用生成对抗网络分别对每组判别器进行增强训练,从而预测旋转机械的运行状态。然而 GAN 本身会存在因梯度消失导致的训练不稳定问题,导致所生成数据的质量不佳。

为此,本文提出基于 Wasserstein 生成对抗网络和多模态故障特征提取的光电流互感器故障辨识方法。首先采用基于 Wasserstein 距离度量的生成对抗网络扩充光 CT 原始故障样本以确保不同类型故障样本与正常样本的均衡性。然后采用奇异谱分析法将光 CT 多维状态参量分解为多个子信号以获取各参量的多模态信息。最后构建 CNN-LSTM 神经网络以挖掘各类故障发生时相应状态参量变化的特性,实现光 CT 故障的快速、准确辨识。

1 故障样本扩充

考虑到光 CT 实际运行中发生故障的次数较少,因此本节针对不同类型的故障,扩充状态参量故障工况的样本,包括 LED 光源驱动电流、调制器驱动电压、二次谐波电压、输入电压峰值、输入电压平均偏差等状态参量数据。生成对抗网络由生成器和判别器组成,针对每一个光 CT 状态参量,通过将随机噪声输入生成器得到新数据,接着判

别器将判断生成器生成的数据是否符合原始状态参量的数据分布,并将结果反馈回生成器使得生成器能够逐步改进,最终得到判别器无法判断为“假”的数据,最终完成目标光 CT 状态参量的扩充。在这个训练过程中,生成器与判别器的目标是相矛盾的,生成器的学习目标是让自身生成的故障期间状态参量越来越接近真实值,而判别器的学习目标是让自身判别准确性越来越高,能识别出假数据。结合两者的学习目标,设计出了损失函数:

$$\min_G \max_D [V(D, G)] = \min_G \max_D [E_{x \sim p(x)} \log D(x) + E_{z \sim p(z)} \log(1 - D(G_z))] \quad (1)$$

式中: V 表示特殊交叉熵, x 表示某一类型故障期间任意光 CT 状态参量的真实数据; G_z 表示生成器生成的任意状态参量数据; $D(x)$ 和 $D(G_z)$ 分别表示将真实光 CT 状态参量数据和生成器生成数据输入判别器的输出结果,当判别结果为“真”时其值为 1,反之则为 0; $E_{x \sim p(x)} \log D(x)$ 表示所有 x 都是光 CT 原始真实状态参量数据时 $\log D(x)$ 的期望, $E_{z \sim p(z)} \log(1 - D(G_z))$ 表示所有数据都是生成数据时 $\log(1 - D(G_z))$ 的期望。

在求最优解过程中,存在以下两个过程:

1) 固定生成器,求解令损失函数最大的判别器,即对于判别器来说,需要尽可能找出生成器生成的数据与真实数据分布之间的差异。而输入判别器的数据由两部分组成,一部分是光 CT 真实数据,设其分布为 $P(x)$,另一部分是生成器生成的数据,设其分布为 $P_G(x)$,化简判别器的输入为

$$D^* = \operatorname{argmax}_D V(D, G) = \operatorname{argmax}_D [P(x) \log D(x) + P_G(x) \log(1 - D(x))] \quad (2)$$

固定生成器生成的数据后损失函数可化简为

$$\max_D [V(G, D)] = V(G, D^*) = 2J_S(P(x) \parallel P_G(x)) - 2\log 2 \quad (3)$$

即损失函数可以用 $P(x)$ 和 $P_G(x)$ 的散度 J_S 来表示,两者之间的差异越大,其散度也就越大,最终损失函数值也越大。

2) 固定判别器,求解令损失函数最小的生成器,即针对判别器某次识别能力,生成器需要尽可能生成与真实数据非常接近的数据,损失函数如下:

$$\begin{aligned} \min_G \max_D [V(D, G)] &= \min_G [V(G, D^*)] = \\ \min_G [2J_s(P(x) \parallel P_G(x)) - 2\log 2] &= \quad (4) \\ \min_G [J_s(P(x) \parallel P_G(x))] \end{aligned}$$

同样可将损失函数化简为 $P(x)$ 和 $P_G(x)$ 的散度, 散度越小, 损失函数值也就越小。

然而 J_s 散度本身存在一定问题。当两个分布没有重叠时, 无论相隔多远, J_s 散度值恒为 $\log 2$, 尤其在迭代初始阶段, 如果两个分布的差距很大, 可能造成两个分布没有重叠的问题, 即发生梯度消失的现象。同时判别器只能鉴别单个样本是否为真实样本分布, 输出非 0 即 1 的结果导致生成的数据多样性不足。为解决上述所提问题, 使用 Wasserstein 距离改进原损失函数, 构建 Wasserstein GAN 模型, 其数据扩充框架如图 1 所示, Wasserstein 距离优势在于

即使两个分布没有重叠, Wasserstein 距离仍然能够反映它们的远近。此时总体的损失函数变为

$$L_{\text{oss}}(\bar{G}, D) = -E_{x \sim P_r}[D(x)] + E_{x \sim P_g}[D(x)] \quad (5)$$

$$L_{\text{oss}}(G, \bar{D}) = -E_{x \sim P_g}[D(G(z))] \quad (6)$$

式中: P_r 为真实样本的分布, P_g 为生成器样本的分布, x 为输入的样本。

此时判别器的结果也就是拟合 Wasserstein 距离, 而不是做 0-1 分类任务。

需要注意的是, 使用 Wasserstein 距离时需要满足 K-Lipschitz 条件^[23]。K-Lipschitz 条件是指函数具有连续的梯度, 即函数的图像不会太陡峭, 其斜率不大于 k_1 。K-Lipschitz 条件限制了函数变化的剧烈程度, 使函数的梯度上界被限制, 从而降低梯度爆炸的发生概率, 使模型的更新更稳定。




图1 WGAN 数据扩充模型架构图

Fig.1 WGAN data expansion model architecture diagram

2 光 CT 故障类型的识别

2.1 模态信息分解

光 CT 在实际运行中会发生多种故障, 也会记录多种状态参量的数据。文献[24]中指出光 CT 中故障率最高的是电子单元(约 49.35%)和光纤回路(约 33.77%)。因此本文选取换流站光 CT 较为频发的五种故障及相关的状态参量进行分析。

为充分利用光 CT 在各种工况下状态参量的信息, 本文采用奇异谱分析(singular spectrum analysis, SSA)的方法对各个状态参量的数据进行模态分解, 获取到多模态信息, 便于学习各种工况的参

量特征。

奇异谱分析是一种非参数分解技术, 常用于时间序列分析, 能够有效地提取出序列数据中的主要信息^[25], 如整体趋势、周期信号和噪声信号等。奇异谱分析的过程包括两个阶段: 分解和重构, 可以分为嵌入、奇异值分解、分组、对角平均化 4 个步骤^[26], 具体步骤如下:

1) 嵌入

对于单个状态参量的有限长一维时间序列 $[x_1, x_2, \dots, x_N]$, 其中 N 为序列长度。首先需要选择合适的窗口长度 L , 并将时间窗在原始时间序

列之上滑动从而得到轨迹矩阵 X :

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_{N-L+1} \\ x_2 & x_3 & \cdots & x_{N-L+2} \\ \vdots & \vdots & & \vdots \\ x_L & x_{L+1} & \cdots & x_N \end{bmatrix} \quad (7)$$

通常情况下窗口长度 $L < N/2$, 令 $K = N - L + 1$, 则轨迹方程 X 变为 $L \times K$ 的矩阵:

$$X = \begin{bmatrix} x_1 & x_2 & \cdots & x_K \\ x_2 & x_3 & \cdots & x_{K+1} \\ \vdots & \vdots & & \vdots \\ x_L & x_{L+1} & \cdots & x_N \end{bmatrix} \quad (8)$$

2) 奇异值分解

对轨迹矩阵进行奇异值分解 (singular value decomposition, SVD) 即:

$$X = U \Sigma V^T \quad (9)$$

式中: U 与 V 为单位正交阵, 满足 $UU^T = I$, $VV^T = I$, Σ 为奇异值矩阵, 在主对角线上有值。

由于直接对轨迹矩阵分解比较困难, 因此首先计算轨迹矩阵的协方差矩阵: $S = XX^T$ 。

将协方差矩阵 S 进行特征值分解后, 得到特征值并按大小降序排列, 排列后特征值的序列记为 $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_m \geq 0$ 相应的特征向量为 $U_1, U_2, \cdots, U_m$, 则轨迹方程 X 可表示为

$$X = X_1 + X_2 + \cdots + X_m = \sum_{m=1}^L \sqrt{\lambda_m} U_m V_m^T \quad (10)$$

$$V_m = X^T U_m / \sqrt{\lambda_m}, \quad m = 1, 2, \cdots, L \quad (11)$$

式中: U_m 为矩阵 X 的经验正交函数 (empirical orthogonal functions, EOF), V_m 为主成分 (principle components, PC)。

3) 分组

将下标集合 $\{1, 2, \cdots, m\}$ 划分为 n 个互不相关的子集 $I_1, I_2, \cdots, I_n$, 则对应于将轨迹矩阵 X 分为 n 个互不相关的子矩阵, 即: $X = X_{I_1} + \cdots + X_{I_n}$, 其中包括高频矩阵和低频矩阵。

4) 对角平均化

在矩阵分组后, 将每个子矩阵都还原为长度为 N 的新序列, 即可得到状态参量分解后的新序列, 每个子矩阵 X_i 为 $L \times K$ 的矩阵, 其中, 每一个元素为 X_{ij} , 令 $L^* = \min(L, K)$, $K^* = \max(L, K)$, $N = L + K - 1$ 。如果 $L < K$ 则 $y_{ij}^* = y_{ij}$; 否则 $y_{ij}^* = y_{ji}$ 。

利用下式进行对角线求平均, 将各子矩阵 X_i 转

化为目标状态参量的多模态时间序列 $y_{I1}, \cdots, y_{IN}$ 。

$$y_{Ik} = \begin{cases} \frac{1}{k} \sum_{m=1}^k y_{m, k-m+1}^* & 1 \leq k < L^* \\ \frac{1}{L^*} \sum_{m=1}^{L^*} y_{m, k-m+1}^* & L^* \leq k \leq K^* \\ \frac{1}{N-k+1} \sum_{m=k-K^*+1}^{N-K^*+1} y_{m, k-m+1}^* & K^* < k \leq N \end{cases} \quad (12)$$

式中: $k = 1, 2, \cdots, N$ 。

至此, 得到光 CT 状态参量序列经奇异谱分析后的多种子序列, 包含多模态信息。

2.2 故障类型识别

针对奇异谱分析后得到的多种子序列, 采用神经网络模型学习光 CT 不同运行状况下的特征, 进行故障类别的辨识。

卷积神经网络 (convolutional neural networks, CNN) 主要包括以下结构: 输入层、卷积层、激活层、池化层、全连接层、激活层、输出层等。由于光 CT 一种故障的发生往往伴随多个状态参量的变化, 一种参量的变化也可能导致多种故障的发生, 具有较为复杂的关联关系, 因此 CNN 使用卷积层进行特征提取时, 采用了局部连接的方式, 同时还具有权值共享的特点, 池化操作也提高了特征提取的效率和泛化能力, 因此具有优异的特征学习能力, 可用于光 CT 故障的内部关联关系学习。

CNN 在特征提取中涉及到三个关键操作: 局部感受野、权值共享、池化层。感受野指卷积神经网络每一层输出的特征上每个元素映射回输入数据上的区域大小, 神经元感受野的范围越大表示能学习更为全局, 可以学习到高维模态信号的特征信息; 相反, 范围越小则表示其所包含的故障类型特征越趋向局部和细节。其次在卷积运算中采用权值共享可以有效减少需要求解的参数; 池化层夹在连续的卷积层之中, 用于压缩数据和参数的数量, 减小过拟合, 增强了故障参量特征的鲁棒性和不变性。

特征提取的计算如下式所示:

$$H_i = \sigma(H_{i-1} \otimes W_i^k + b_i) \quad (13)$$

式中: W_i^k 为第 i 层中第 k 个卷积核的权重; b_i 为偏置; $\otimes$ 表示卷积运算; σ 为激活函数。

考虑到光 CT 正常运行与故障发生时段参量的时间特性不同, 正常运行时某些参量基本不变, 而故障发生时参量具有波动性, 且波动范围会包

括正常运行范围,因此针对光 CT 的故障辨识问题中需要考虑参量变化的时间特性。

长短期记忆网络(long short-term memory networks, LSTM)是一种时间循环神经网络,与一般前馈式神经网络不同,长短期记忆神经网络可以利用时间序列对输入进行分析,合理利用了上一时刻神经元输入的内容,使得模型学习更加全面。同时 LSTM 还加入了遗忘门、记忆门和输出门来判断哪些状态信息需要记忆、哪些状态信息需要更新以及哪些信息需要特别注意,有助于 LSTM 对信息进行长期跟踪,提取数据的时间特征,解决了 RNN 使用中梯度消失和梯度爆炸的问题。LSTM 单元的结构图如图 2 所示。

其中,遗忘门决定了上一时刻的单元状态是否保留到当前时刻,由计算得到的 f_t 决定是否进行遗忘,计算公式为

$$f_t = \sigma(W_f \cdot [h_{t-1} \ x_t] + b_f) \quad (14)$$

式中: W_f 为遗忘门的权重, $[h_{t-1} \ x_t]$ 表示把上一时刻输出 h_{t-1} 和当前时刻 x_t 输入连接起来, b_f 为遗忘门的偏置, σ 为激活函数。

输入门决定当前时刻网络的输入 x_t 如何让保存到当前输入单元状态 $\tilde{C}_t$, 计算公式为

$$i_t = \sigma(W_i \cdot [h_{t-1} \ x_t] + b_i) \quad (15)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1} \ x_t] + b_c) \quad (16)$$

式中: i_t 表示当前输入门状态, W_i 和 b_i 分别表示输入门的权重和偏置, W_c 和 b_c 分别表示细胞单元对应的权重和偏置。




图2 LSTM 单元结构图

Fig.2 LSTM cell structure diagram

细胞更新决定了如何计算当前序列下的细胞值 C_t , 具体计算公式为

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (17)$$

式中: $\odot$ 表示哈达玛积,即按元素乘。

输出门控制单元状态 C_t 有多少能输出到 LSTM 当前的输出值 h_t , 计算公式为

$$o_t = \sigma(W_o \cdot [h_{t-1} \ x_t] + b_o) \quad (18)$$

$$h_t = o_t \odot \tanh(C_t) \quad (19)$$

式中: W_o 和 b_o 分别表示输出门的权重和偏置。

将 CNN 与 LSTM 连接起来构造了多输入多输出的 CNN-LSTM 神经网络,整个神经网络包括 1-D 卷积层、池化层、LSTM 层和全连接层,通过卷积操作捕捉光 CT 状态参量中的空间模式,通过 LSTM 层处理光 CT 状态参量中的时间依赖性,从而提取光 CT 状态参量的时空特征。本文所用辨识方法的整体架构如图 3 所示。

3 评价指标

在辨识问题中,预测分类与真实类别一致则为真,不一致则为假。为便于建立多分类问题的评价指标,首先定义二分类问题的混淆矩阵如表 1 所示。其中,1 和 0 代表两种类别,为提高阅读性,采用 P 和 N 表示 1 和 0 两种结果;T 和 F 分别代表预测正确和预测错误两种情况。

本文采用以下 4 个指标:准确率、精确率、召回率、F 综合分数。计算公式如下:

$$A = \frac{C_{TP} + C_{TN}}{C_{FP} + C_{FN} + C_{TP} + C_{TN}} \quad (20)$$

$$P = \frac{C_{TP}}{C_{TP} + C_{FP}} \quad (21)$$

$$R = \frac{C_{TP}}{C_{FN} + C_{TP}} \quad (22)$$

$$F_M = \frac{(1 + \beta^2) \times P \times R}{\beta^2 \times (P + R)} \quad (23)$$

式中: A 、 P 、 R 、 F_M 分别表示准确率、精确率、召回率和 F 综合分数, C_{TP} 、 C_{TN} 、 C_{FP} 、 C_{FN} 分别表示类别 1 判断的准确个数、类别 0 判断准确的个数、误报个数和漏报个数。

表 1 二分类问题混淆矩阵

Tab.1 Confusion matrix for binary classification problems

		真实值	
		1	0
预测值	1	C_{TP}	C_{FP}
	0	C_{FN}	C_{TN}

当 $\beta = 1$ 时,综合分数 F_M 变为 $F_1 = 2 \frac{P \times R}{P + R}$,

为精确率和召回率的调和平均值,即 F_1 分数。




图3 基于 WGAN 和多模态故障特征提取的辨识模型架构

Fig.3 Identification model architecture based on WGAN and multi-modal fault feature extraction

由于光 CT 可能发生的故障包括多种类型,即为多分类问题。对于多分类问题,每种类别都可以用这四种指标来衡量辨识的准确性,从整体上评估分类效果时则需要用到宏平均和微平均。

宏平均即为将每个类别的准确率、精确度、召回率和 F_1 分数求算术平均数,计算公式如下:

$$A_{\text{ma}} = \frac{1}{k} \sum_{i=1}^k A_i \quad P_{\text{ma}} = \frac{1}{k} \sum_{i=1}^k P_i \quad (24)$$

$$R_{\text{ma}} = \frac{1}{k} \sum_{i=1}^k R_i \quad F_{1\text{ma}} = \frac{1}{k} \sum_{i=1}^k F_{1i} \quad (25)$$

微平均则通过计算数据集中四类辨识结果的数量,建立全局混淆矩阵,计算公式如下:

$$A_{\text{mi}} = \frac{\sum_{i=1}^k l_i}{\sum_{i=1}^k a_i} \quad P_{\text{mi}} = \frac{\sum_{i=1}^k l_i}{\sum_{i=1}^k m_i} \quad (26)$$

$$R_{\text{mi}} = \frac{\sum_{i=1}^k l_i}{\sum_{i=1}^k n_i} \quad F_{1\text{mi}} = \frac{2}{\frac{1}{P_{\text{mi}}} + \frac{1}{R_{\text{mi}}}} \quad (27)$$

式中: l 为辨识正确的样本数, a_i 为第 i 类样本总数, m_i 为辨识为第 i 类样本的数量, n_i 为实际为第 i 类样本的样本数。

4 案例分析

4.1 数据说明

本文以华北某地区换流站光 CT 实际运行数据为例对所提出的模型进行验证分析。案例仿真采用了换流站内的某个光 CT 设备测点,数据采样间隔为 30 min,共记录 5 种光 CT 状态参量。选取其中较为频发的五种故障,使用标签编码对六种运行情况进行编码,编码的结果如表 2 所示。

表2 各类工况标签号

Tab.2 Label number of various working conditions	
运行情况	标签号
正常运行情况	0
E2000 插头破损	1
光纤熔接点异常	2
电子单元光源衰弱	3
调制电容问题	4
调制罐故障	5

4.2 数据扩充

采用所提 WGAN 模型对五种故障的原始数据进行扩充用于后续故障辨识模型训练。数据扩充过程中几乎不可能引入误差,即产生故障扩充样本故障特性显著区别于原始故障样本故障特性的情况。这是因为训练 WGAN 模型需要对生成器与判别器的损失函数在迭代多次后是否处于平稳状态进行校验,只有两者达到势均力敌的平稳状态、说明采用该模型扩充得到的故障样本在数据分布特性上与原样本保持高度一致时,才会保存和选用该模型。WGAN 训练过程中生成器 G 和判别器 D 的损失函数值变化情况如图 4 所示。可以看出,随着训练次数的上升,生成器 G 的损失函数值升高,判别器 D 的损失函数值降低,两者的损失函数值趋于稳定,表示两者达到势均力敌的状态,体现了光 CT 故障时段数据扩充过程中生成器与判别器之间的动态博弈过程。





图 4 损失函数值变化趋势

Fig.4 Loss function value change trend


以电子单元光源衰弱为例,扩充其故障参量的结果如图 5 所示,其余结果见附录。电子单元光源衰弱时,随着反射光强的降低,输入电压峰值与二次谐波逐渐降低,对比 WGAN 生成的数据,可见生成数据同样能够体现这种变化,并且生成数据与原始故障样本的分布范围一致,WGAN 有效地扩充了故障样本。

4.3 奇异谱分析结果

针对数据集包含的 5 种状态参量,对每一参量逐一进行奇异谱分析,分解为 4 个信号,获取到各参量的多模态信息,代表了整体趋势信息和波动信息,以调制罐故障时 5 个状态参量的奇异谱分析结果为例,如图 6 所示。可以看到后三个子信号的频率远大于第一个子信号。为使辨识模型充分学习故障特征却又不至于信息冗杂,本文将后三个子信号合成为一个子信号,代表波动信号,而第一个子信号为整体趋势信号。将两类子信号



(a) 电子单元故障时相关参量原始数据



(b) 电子单元故障时相关参量生成数据

图 5 原始数据与生成数据对比

Fig.5 Comparison between original data and generated data

作为后续辨识模型的输入以学习故障特征。

4.4 CNN-LSTM 故障辨识模型

将总的数据集划分为测试集和训练集,训练集和测试集的数据数量比例为 5:1。为便于训练集学习到光 CT 不同工况下各参量的空间模式与时间依赖性,本文在训练集中均匀分布六种工况数据,以各参量奇异谱分析后的两种子信号作为分类模型的输入 X 。模型的输出设置为对应的 6 类运行情况,包括 5 种故障类别和正常运行情况。

优化器采用 SGD,冲量设置为 0.5,损失函数为交叉熵损失函数,度量训练过程中识别为某类别和正确类别两个概率分布之间的距离,计算公式为

$$E = -\frac{1}{m} \sum_{i=1}^m \sum_{k=1}^n y_k^{(i)} \log(p_k^{(i)}) \quad (28)$$

式中: $y_k^{(i)}$ 表示第 i 个样本对第 k 类标签的真实标记, $p_k^{(i)}$ 表示该样本被识别为第 k 类标签的概率。

所提故障辨识模型的超参数设置如表 3 所示。

表 3 辨识模型超参数设置

Tab.3 Identify model hyperparameter settings	
结构名称	超参数设置
小样本批次	64
丢弃率	0.2
学习率	0.1
时间窗	4
卷积核	2




图6 子信号示意图

Fig.6 Sub signal diagram

4.5 结果和对比

4.5.1 分类结果

将奇异谱分析得到的各参量的子信号输入到 CNN-LSTM 辨识模型,得到测试集的分类结果如表 4 所示。

表4 测试集上的混淆矩阵

预测值	真实值					
	正常运行情况	E2000 插头破损	光纤熔接点异常	电子单元光源衰弱	调制电容问题	调制罐故障
正常运行情况	2 090	5	8	3	7	4
E2000 插头破损	5	37	0	0	0	0
光纤熔接点异常	4	0	63	0	0	0
电子单元光源衰弱	2	0	3	40	0	0
调制电容问题	1	1	0	0	60	0
调制罐故障	1	1	0	0	3	58

通过分类结果的混淆矩阵可以看出,本文所用方法较好地完成了故障辨识,仅有个别时刻的运行状态被误判。

光 CT 的各类运行工况辨识准确率如表 5 所示。可以看出除 E2000 与电子单元光源衰弱的辨识准确率较低以外,其余工况的辨识准确率都处于较高水平。结合光 CT 实际运行情况可知,E2000 故障发生时,发生变化的状态参量较少,且变化水平也不大,持续时间较短,因此辨识模型在学习过程中容易发生混淆,视为正常运行工况。而电子单元光源衰弱时,二次谐波电压与输入电压峰值会逐渐降低,在故障发生与结束初期,模型容易辨识不准,视为正常运行情况。

表5 各类工况辨识准确率

运行工况	辨识准确率/%
正常运行情况	99
E2000 插头破损	88
光纤熔接点异常	94
电子单元光源衰弱	89
调制电容问题	97
调制罐故障	92

4.5.2 算法对比

为客观分析本文所提方法的有效性,本文进行消融实验,设置了另外 4 种方法作为对照模型:

方法 1: 将未经过 WGAN 扩充故障样本但经

过奇异谱分析的数据输入 CNN-LSTM 辨识模型中。

方法 2: 将经过 WGAN 扩充故障样本但未经过奇异谱分析的数据输入 CNN-LSTM 辨识模型中。

方法 3: 将经过 WGAN 扩充故障样本和奇异谱分析的数据输入到 CNN 辨识模型中。

方法 4: 将经过 WGAN 扩充故障样本和奇异谱分析的数据输入到 XGBoost 辨识模型中。

消融实验的结果如表 6 所示,通过 WGAN 完成的数据扩充使模型有效地学习到光 CT 不同运行工况的特点,同时通过奇异谱分析也使模型获取到故障发生时更多的参量特征。除此之外, LSTM 对故障发生阶段时间特性的学习有效地避免了参量重叠可能带来的辨识混淆问题。相比于传统的 XGBoost 分类模型,本文提出的方法有效地提高了光 CT 的辨识准确率。

表 6 各类方法辨识性能对比

Tab.6 Comparison of identification performance of various methods

	准确率/%	精确度/%	召回率/%	F1 分数/%
本文方法	97.99	98.09	98.00	98.03
方法 1	88.33	78.02	88.33	82.85
方法 2	95.10	95.91	95.10	95.37
方法 3	96.74	98.08	96.74	97.24
方法 4	94.29	97.72	94.29	95.38

5 结 论

对换流站光 CT 故障的准确辨识可以有效帮助运维人员及时清除故障,确保直流输电系统可靠运行。为此,本文提出了基于 Wasserstein 生成对抗网络和多模态故障特征提取的光电流互感器故障辨识方法,仿真实验结果表明:

1) 利用 WGAN 扩充故障工况样本可以有效解决实际数据中故障工况与实际工况样本数量不均衡而导致的训练效果差、辨识精度低等问题。

2) 利用 SSA 对光 CT 状态参量进行分解可以帮助神经网络模型捕捉多模态的参量特征和故障信息,有效提高了神经网络分类的准确率。

3) 使用 LSTM 分析故障时段参量的时间特性,通过对时间特性差异的学习,有效解决了部分工况参量波动范围互相涵盖的问题。

本文所提方法能够准确辨识换流站光 CT 故障,有助于换流站准确监测光 CT 运行状态。在实际应用中,换流站内复杂多变运行环境可能导致

光 CT 故障特性发生改变,进而影响故障辨识的准确性。现场状态参量采集数据的异常或缺失也是影响所提方法落地应用的障碍。未来可引入异常数据辨识和修复模块以增强所提方法的适用性。

(附录请见网络版,印刷版略)

参考文献:

- [1] 陆书豪,潘恒毅,贾秀芳,等. 特高压混合三端直流输电系统定功率 MMC 交流故障穿越策略 [J]. 华北电力大学学报(自然科学版), 2024, 51 (2): 11-22.
LU Shuhao, PAN Hengyi, JIA Xiufang, et al. Fault ride-through strategy for fixed power MMC converter station in three-terminal hybrid UHVDC transmission system [J]. Journal of North China Electric Power University (Natural Science Edition), 2024, 51 (2): 11-22 (in Chinese).
- [2] 穆文凯,王涛,刘文轩,等. 基于虚拟电容的高压直流后续换相失败抑制方法 [J]. 华北电力大学学报(自然科学版), 2021, 48 (5): 25-35.
MU Wenkai, WANG Tao, LIU Wenxuan, et al. Virtual-capacitance-based method to suppress the subsequent commutation failure in HVDC system [J]. Journal of North China Electric Power University (Natural Science Edition), 2021, 48 (5): 25-35 (in Chinese).
- [3] 肖燕,李军,庞福滨,等. 基于合成概率法的光学电流互感器运行可靠性 [J]. 电网技术, 2022, 46 (1): 336-342.
XIAO Yan, LI Jun, PANG Fubin, et al. Operation reliability of optical current transformer based on synthetic probability [J]. Power System Technology, 2022, 46 (1): 336-342 (in Chinese).
- [4] 马明晗,侯岳佳,李永刚,等. 基于二维 CNN 与多源机电信息融合的同步电机转子匝间短路故障诊断方法 [J]. 华北电力大学学报(自然科学版), 2024, 51 (2): 123-135.
MA Minghan, HOU Yuejia, LI Yonggang, et al. Synchronous motor rotor interturn short circuit fault diagnosis method based on two-dimensional CNN and multi-source electromechanical information fusion [J]. Journal of North China Electric Power University (Natural Science Edition), 2024, 51 (2): 123-135 (in Chinese).
- [5] KIM S, JO S H, KIM W, et al. A semi-supervised autoencoder with an auxiliary task (SAAT) for power transformer fault diagnosis using dissolved gas analysis [J]. IEEE Access, 2020, 8: 178295-178310.

- [6] SUN P, LIU X, LIN M, et al. Transmission line fault diagnosis method based on improved multiple SVM model [J]. IEEE Access, 2023, 11: 133825–133834.
- [7] 刘英培, 王祥宇, 王鑫明, 等. 基于感应电压特征停运输电线路故障识别方法 [J]. 华北电力大学学报 (自然科学版), 2022, 49 (4): 14–22+32.
- LIU Yingpei, WANG Xiangyu, WANG Xinming, et al. Fault identification method of outage transmission lines based on induced voltage features [J]. Journal of North China Electric Power University (Natural Science Edition), 2022, 49 (4): 14–22+32 (in Chinese).
- [8] 钱文晓, 靳俊杰, 司磊, 等. 光纤电流互感器故障诊断方法研究综述 [J]. 高压电器, 2020, 56 (8): 43–51.
- QIAN Wenxiao, JIN Junjie, SI Lei, et al. Review of fault diagnosis methods for fiber optical current transformer [J]. High Voltage Apparatus, 2020, 56 (8): 43–51 (in Chinese).
- [9] 王洪彬, 唐昆明, 徐瑞林, 等. 数字化变电站电子式互感器渐变故障诊断方法研究 [J]. 电力系统保护与控制, 2012, 40 (24): 53–58.
- WANG Hongbin, TANG Kunming, XU Ruilin, et al. Diagnosis of soft fault of electronic transformer in digital substation [J]. Power System Protection and Control, 2012, 40 (24): 53–58 (in Chinese).
- [10] 赵科, 丁然, 李洪涛, 等. 基于热特性差异的 GIL 故障辨识研究 [J]. 电力系统保护与控制, 2021, 49 (4): 13–20.
- ZHAO Ke, DING Ran, LI Hongtao, et al. Research on GIL fault identification based on thermal characteristic difference [J]. Power System Protection and Control, 2021, 49 (4): 13–20 (in Chinese).
- [11] 张文鹏. 基于深度学习的光纤电流互感器故障诊断方法研究 [D]. 南京: 东南大学, 2022.
- ZHANG Wenpeng. Research on fault diagnosis method of fiber optic current transformer based on deep learning [D]. Nanjing: Southeast University, 2022 (in Chinese).
- [12] 刘美, 纽春萍, 姬忠校, 等. 基于变分模态分解的光纤电流传感器小波去噪方法 [J]. 电气技术, 2021, 22 (4): 7–11.
- LIU Mei, NIU Chunping, JI Zhongxiao, et al. Wavelet de-noising method of all-fiber optical current transformer based on variational mode decomposition [J]. Electrical Engineering, 2021, 22 (4): 7–11 (in Chinese).
- [13] 周刚, 张代新, 谢善益, 等. 基于 Allan 方差理论的光纤电流互感器运行状态诊断 [J]. 高压电器, 2017, 53 (10): 204–208.
- ZHOU Gang, ZHANG Daixin, XIE Shanyi, et al. Operation status diagnosis of fiber optic current transducer based on Allan variance theory [J]. High Voltage Apparatus, 2017, 53 (10): 204–208 (in Chinese).
- [14] 郜志, 杨海运, 宫艳朝, 等. 基于振动信号 MTF 变换的并联电容器故障诊断 [J]. 计量学报, 2023, 44 (9): 1339–1346.
- GAO Zhi, YANG Haiyun, GONG Yanchao, et al. Fault diagnosis of shunt capacitor based on Markov transfer field transformation of vibration signal [J]. Acta Metrologica Sinica, 2023, 44 (9): 1339–1346 (in Chinese).
- [15] 蒋愈勇, 王军龙, 李俊一, 等. 人工神经网络在光学电压互感器故障诊断中的应用 [J]. 电力系统及其自动化学报, 2018, 30 (6): 134–139.
- JIANG Yuyong, WANG Junlong, LI Junyi, et al. Application of artificial neural network to fault diagnosis for optical voltage transformer [J]. Proceedings of the CSU-EPSA, 2018, 30 (6): 134–139 (in Chinese).
- [16] 林慧斌, 王洪畅, 习慈羊. 基于深度卷积测量网络的滚动轴承压缩域故障特征提取方法 [J]. 振动工程学报, 2024, 37 (3): 485–496.
- LIN Huibin, WANG Hongchang, XI Ciyang. Rolling bearing fault feature extraction in the compressed domain with deep convolutional measurement network [J]. Journal of Vibration Engineering, 2024, 37 (3): 485–496 (in Chinese).
- [17] 赵凯. 光纤电流互感器渐变故障特征及诊断算法研究 [D]. 南京: 东南大学, 2022.
- ZHAO Kai. Research on signal characteristics and fault diagnosis method of gradual failure for fiber optic current transformer [D]. Nanjing: Southeast University, 2022 (in Chinese).
- [18] 王建, 吴昊, 张博, 等. 不平衡样本下基于迁移学习-AlexNet 的输电线路故障辨识方法 [J]. 电力系统自动化, 2022, 46 (22): 182–191.
- WANG Jian, WU Hao, ZHANG Bo, et al. Fault identification method for transmission line based on transfer learning-AlexNet with imbalanced samples [J]. Automation of Electric Power Systems, 2022, 46 (22): 182–191 (in Chinese).
- [19] 谢硕, 陈奕宏, 强以铭, 等. 基于经验知识的船舶螺旋桨水动力样本扩充方法及其在预报代理模型中的应用 [J]. 船舶力学, 2024, 28 (1): 36–44.
- XIE Shuo, CHEN Yihong, QIANG Yiming, et al. A method of data expansion for marine propeller hydrodynamic performance based on priori knowledge and its application [J]. Journal of Ship Mechanics, 2024, 28

- (1): 36-44 (in Chinese).
- [20] 程俊斌. 基于数据扩充的深度置信网络地铁轨排故障识别方法研究 [J]. 铁道建筑技术, 2023 (11): 43-47.
- CHENG Junbin. Research on the method of subway track fault identification of deep belief network based on data enrichment [J]. Railway Construction Technology, 2023 (11): 43-47 (in Chinese).
- [21] 邵海东, 李伟, 刘翊, 等. 时变转速下基于双阈值注意力生成对抗网络和小样本的转子-轴承系统故障诊断 [J]. 机械工程学报, 2023, 59 (12): 215-224.
- SHAO Haidong, LI Wei, LIU Yi, et al. Fault diagnosis of rotor-bearing system under time-varying speeds by using dual-threshold attention-embedded GAN and small samples [J]. Journal of Mechanical Engineering, 2023, 59 (12): 215-224 (in Chinese).
- [22] 高玉才, 付忠广, 王诗云, 等. 基于集成 GAN 的旋转机械故障诊断方法研究 [J]. 汽轮机技术, 2022, 64 (3): 213-216.
- GAO Yucui, FU Zhongguang, WANG Shiyun, et al. Research on the method of rotating machinery fault diagnosis based on integrated GAN [J]. Turbine Technology, 2022, 64 (3): 213-216 (in Chinese).
- [23] 臧海祥, 郭镜玮, 黄蔓云, 等. 基于改进 Wasserstein 生成式对抗网络的电力系统不良数据辨识 [J]. 电力自动化设备, 2022, 42 (9): 50-56+110.
- ZANG Haixiang, GUO Jingwei, HUANG Manyun, et al. Bad data identification of power system based on WGAN-GP [J]. Electric Power Automation Equipment, 2022, 42 (9): 50-56+110 (in Chinese).
- [24] PANG F, WANG L, WU H, et al. Online diagnosis algorithm for random drift error in fiber optic current sensor [J]. Optical Fiber Technology, 2022, 68: 1-7.
- [25] 肖白, 肖志峰, 姜卓, 等. 基于降噪自编码器、奇异谱分析和长短期记忆神经网络的空间电力负荷态势感知 [J]. 中国电机工程学报, 2021, 41 (14): 4858-4867.
- XIAO Bai, XIAO Zhifeng, JIANG Zhuo, et al. Spatial load situation awareness based on denoising autoencoder, singular spectrum analysis and long short-term memory neural networks [J]. Proceedings of the CSEE, 2021, 41 (14): 4858-4867 (in Chinese).
- [26] QIAO T, REN J, WANG Z, et al. Effective denoising and classification of hyperspectral images using curvelet transform and singular spectrum analysis [J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 55 (1): 119-133.

作者简介:

李振动(1984) 男, 高级工程师, 研究方向为柔性直流输电技术, E-mail: pheace@163.com;

戴浩男(1999) 男, 博士研究生, 研究方向为机器学习、人工智能技术在电力系统中的应用, E-mail: 1203436462@qq.com。

附录:




图 A1 其余四种故障原始数据与生成数据对比

Fig.A1 Comparison of original data and generated data for the remaining four types of faults