

基于多特征图谱和 CNN-BKA-LSSVM 的 隔离开关故障诊断方法

申张亮¹, 陈旖旎¹, 杨 阳¹, 王馥珏¹, 张 驰^{2*}, 马宏忠²

(1. 国网江苏省电力有限公司 南京供电分公司, 江苏 南京 210019;

2. 河海大学 电气与动力工程学院, 江苏 南京 211100)

Fault Diagnosis Method for Disconnecter Based on Multi-Characteristic Map and CNN-BKA-LSSVM

SHEN Zhangliang¹, CHEN Yini¹, YANG Yang¹, WANG Fujue¹,
ZHANG Chi^{2*}, MA Hongzhong²

(1. Nanjing Power Supply Company, State Grid Jiangsu Electric Power Co., Ltd.,
Nanjing 210019, China;

2. School of Electrical and Power Engineering, Hohai University, Nanjing 211100, China)

Abstract: [Objective] The traditional methods for extracting fault characteristics of disconnector are not reliable enough, and the fault identification accuracy is not high. To address this issue, a fault diagnosis method for disconnector based on multi-characteristic map and convolutional neural network (CNN)-black-winged kite algorithm (BKA)-least squares support vector machine (LSSVM) is proposed. [Methods] Firstly, three characteristic maps were constructed in the frequency domain, time domain, and time-frequency domain using the Markov transition field (MTF), Gramian angular field (GAF), and short-time Fourier transform (STFT) respectively. Then, three CNN models were established separately, three characteristic maps were input, effective fault characteristics were extracted through convolution, pooling, and other steps. And the t-distributed stochastic neighbor embedding algorithm was used to reduce the dimension of the characteristic data in the fully connected layer of the CNN model. Finally, the extracted characteristic vectors were fused and spliced, the BKA-optimized LSSVM was used instead of the Softmax layer, and the fused characteristic vectors were input into the BKA-LSSVM for fault identification. [Results] Through on-site fault simulation tests, vibration signal data of the disconnector in

four different states were collected, and comparative analysis was carried out. The results showed that the model proposed in this paper has higher accuracy, stronger reliability and generalization ability compared with other fault diagnosis models, and the average diagnostic accuracy of the proposed model for 8 runs reached 97.08%. The experimental results verified the feasibility of the proposed model. [Conclusion] The proposed method in this paper extracts the characteristic maps from multiple dimensions, which overcomes the limitations of the single dimension method. By introducing the CNN-BKA-LSSVM model, it can better extract the key characteristics and improve the precision and accuracy of fault identification. The proposed method provides a reliable theoretical basis and technical reference for the fault diagnosis of disconnectors, and also provides new ideas for the maintenance of disconnector equipment, which has important application value.

Key words: disconnector; fault diagnosis; multi-characteristic map; convolutional neural network; least squares support vector machine

摘 要: [目的] 传统隔离开关故障特征提取方法不够可靠, 故障识别准确率不高。针对此问题, 提出了一种基于多特征图谱和卷积神经网络 (CNN)-黑翅鸢算法 (BKA)-最小二乘支持向量机 (LSSVM) 的隔离开关故障诊断方法。[方法] 首先, 通过马尔科夫转移场 (MTF)、格拉姆角场 (GAF) 和短时傅里叶变换 (STFT) 分别构建频域、时域

基金项目: 国网江苏省电力有限公司重点科技项目资助 (J2024047)

Funded by the Key Technology Project of State Grid Jiangsu Electric Power Co., Ltd. (J2024047)

和时频域三种特征图谱;然后,分别建立三种 CNN 模型,输入三种特征图谱,通过卷积、池化等步骤提取有效的故障特征,并在 CNN 模型的全连接层使用 t 分布随机邻域嵌入算法对特征数据进行降维;最后,将提取出的特征向量进行融合拼接,采用 BKA 优化的 LSSVM 代替 Softmax 层,并将融合后的特征向量输入到 BKA-LSSVM 中进行故障识别。【结果】通过现场故障模拟试验,采集了四种状态下的隔离开关振动信号数据,并进行了对比分析。结果表明,本文所提模型相较于其他故障诊断模型具有更高的精度、更强的可靠性和泛化能力,其运行 8 次的平均诊断准确率达到 97.08%。试验结果验证了所提模型的可行性。【结论】本文所提方法从多维度提取特征图谱,克服了单一维度方法的局限性;通过引入 CNN-BKA-LSSVM 模型,能够更好地提取关键特征,提高故障识别的精度和准确性。所提方法为隔离开关的故障诊断提供了可靠的理论依据和技术参考,也为隔离开关设备维护提供了新的思路,具有重要的应用价值。

关键词: 隔离开关;故障诊断;多特征图谱;卷积神经网络;最小二乘支持向量机

0 引言

隔离开关是电力系统中重要的分断设备,起着保护和控制作用,一旦发生故障,将造成供电中断或维修危险。隔离开关长期露天工作,不可避免地会因雨雪侵蚀、污染物长期沉积等而导致生锈,造成一系列故障^[1-4]。受制造工艺和监测条件的限制,隔离开关的故障率一直居高不下。当前针对隔离开关故障诊断的深入研究较少。因此,有必要开展相关研究,及时排除故障,从而提高系统运行的可靠性^[5-8]。

国内外有关隔离开关故障诊断的研究主要包括特征提取和故障识别两个方面。在特征提取方面,隔离开关设备表面的振动信号包含了各部件的工作状态信息,且振动信号具有灵敏度高、无创传感的优点,已成为隔离开关故障诊断的主流特征信号^[9-12]。传统的特征提取方法大多利用经验模态分解(Empirical Mode Decomposition, EMD)、动态时间规整(Dynamic Time Warping, DTW)以及变分模态分解(Variational Mode Decomposition, VMD)等信号分解方法处理一维振动信号,进而提取特征^[13-15]。由于振动信号具有显著的非线性特性以及复杂的频率成分,以往的特征提取算法难以全面呈现故障信息,导致有效信息提取不

够充分,最终影响识别精度。

近年来,深度学习在分类领域的快速发展推动了电气设备智能诊断的发展,深度学习模型的应用逐渐普及。其中,卷积神经网络(Convolutional Neural Network, CNN)模型具有自动提取特征能力强、对故障信息反映全面的优点,在二维图像识别中应用广泛且技术相对成熟,因此将一维信号转换为二维图像后,使用 CNN 模型进行特征提取具有显著优势^[16-20]。

目前,使用较为广泛的转换图像算法有马尔科夫转移场(Markov Transition Field, MTF)、格拉姆角场(Gramian Angular Field, GAF)、短时傅里叶变换(Short-Time Fourier Transform, STFT)以及递归图(Recurrence Plot, RP)等。文献[21]利用自适应白噪声完备集成经验模态分解对变压器机械故障振动信号进行重构并应用 GAF 变换获得重构信号的二维图像,对二维图像进行灰度处理、二值化后将所得二值矩阵输入径向基函数(Radial Basis Function, RBF)神经网络,实现对机械故障的诊断。文献[22]利用 MTF 将变压器油纸绝缘局部放电数据转化为二维图像,输入到添加卷积块注意力模块的 CNN 模型中实现局部放电类型的识别。文献[23]利用 STFT 获得开关柜局部放电超声波信号的时频图,再基于稀疏表示算法对时频图进行分类。文献[24]根据变压器有载分接开关振动信号的相空间分布构建距离映射 RP,并输入到 CNN 模型中进行故障识别。

上述方法均成功应用于各自领域的故障诊断中,但是存在提取特征角度单一且关键故障信息部分丢失的问题。为解决这些问题,本文提出了一种基于多特征图谱和 CNN-黑翅鸢算法(Black-winged Kite Algorithm, BKA)-最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)的隔离开关故障诊断方法。首先,通过 GAF、MTF 和 STFT 分别从时域、频域和时频域多角度构建特征图谱;然后,搭建 3 个 CNN 模型,分别输入三种特征图谱,通过卷积、池化等步骤提取有效的故障特征并将提取出的特征向量进行融合,采用 BKA-LSSVM 代替 Softmax 层,输入融合后的特征向量并进行故障识别;最后,通过现场试验验证本文所提方法的可靠性和优越性。

1 基于多特征图谱的隔离开关振动信号特征提取

1.1 时域特征提取

(1) 压缩数据

利用 GAF 提取时域特征信息,对给定的 n 维振动信号时间序列 $\mathbf{X}$ 进行归一化处理,将数据压缩到 $[-1,1]$ 内,避免结果趋于较大值。归一化处理过程如式(1)和式(2)所示:

$$\mathbf{X} = [x_1, x_2, \dots, x_n] \quad (1)$$

$$x_i^* = \frac{x_i - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

式中: x_i 为序列 $\mathbf{X}$ 中第 i 个数值, $i=1, \dots, n$; $X_{\max}$ 、 $X_{\min}$ 分别为序列中的最大值和最小值; x_i^* 为压缩后的第 i 个数值。

(2) 坐标转换

对压缩后的振动数据进行坐标变化,将其从笛卡尔坐标系转换到极坐标系,进而生成角度数据,用于格拉姆矩阵的计算。角度变量 ϕ_i 和半径变量 r_i 的计算式为

$$\begin{cases} \phi_i = \arccos(x_i^*) \\ r_i = \frac{i}{n} \end{cases} \quad (3)$$

(3) 矩阵生成

利用角度数据计算生成格拉姆和矩阵 (Gramian Angular Summation Field, GASF) 和格拉姆差矩阵 (Gramian Angular Difference Field, GADF)。由于 GASF 矩阵^[25] 能够更完整地将信号特征与特征图中相应位置的颜色、点和线等进行映射,因此本文仅保留 GASF 矩阵,其表达式为

$$\mathbf{G} = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (4)$$

(4) 图谱生成

将 GASF 矩阵中元素对应的灰度值匹配到彩色图像 3 通道构成时域特征图谱,如图 1 所示。

1.2 频域特征提取

(1) 频域转换

利用傅里叶变换,提取振动信号频点的幅值构建一维序列 $\mathbf{Y}$:




图 1 时域特征图谱构建过程

Fig. 1 The constructing process of time domain characteristic map

$$\mathbf{Y} = [y_1, y_2, \dots, y_i, \dots, y_n] \quad (5)$$

式中: y_i 为第 i 个振动信号频点的幅值

(2) 构建转移矩阵

将一维序列 $\mathbf{Y}$ 分成 Q 个区域,则 y_i 被分配到对应的区域 $q_j, j \in [1, Q]$ 。以一阶马尔科夫链计算区域之间的跃迁来构造马尔科夫转移矩阵 $\mathbf{W}$:

$$\mathbf{W} = \begin{bmatrix} w_{11|P(y_1 \in q_1 | y_{t-1} \in q_1)} & \cdots & w_{1Q|P(y_1 \in q_1 | y_{t-1} \in q_Q)} \\ w_{21|P(y_1 \in q_2 | y_{t-1} \in q_1)} & \cdots & w_{2Q|P(y_1 \in q_2 | y_{t-1} \in q_Q)} \\ \vdots & w_{ij|P(y_i \in q_i | y_{t-1} \in q_j)} & \vdots \\ w_{Q1|P(y_1 \in q_Q | y_{t-1} \in q_1)} & \cdots & w_{QQ|P(y_1 \in q_Q | y_{t-1} \in q_Q)} \end{bmatrix} \quad (6)$$

式中: w_{ij} 为转移矩阵 $\mathbf{W}$ 的第 i 行第 j 列元素,其在数值上等于区域 q_i 中元素被区域 q_j 中元素跟随的概率 $P(y_i \in q_i | y_{t-1} \in q_j)$ 。

(3) 构建 MTF 矩阵

由于 $\mathbf{W}$ 忽略了 $\mathbf{Y}$ 的分布与频率步长之间的依赖关系,故构造 MTF 矩阵 $\mathbf{M}$ 来弥补这一不足。MTF 通过沿频率顺序排列每个概率来扩展矩阵 $\mathbf{W}$ 。 $\mathbf{M}$ 包含每个区域与频率步长之间的相关性,其表达式为

$$\mathbf{M} = \begin{bmatrix} m_{ij|x_1 \in q_i, x_1 \in q_j} & \cdots & m_{ij|x_1 \in q_i, x_n \in q_j} \\ m_{ij|x_2 \in q_i, x_1 \in q_j} & \cdots & m_{ij|x_2 \in q_i, x_n \in q_j} \\ \vdots & \ddots & \vdots \\ m_{ij|x_n \in q_i, x_1 \in q_j} & \cdots & m_{ij|x_n \in q_i, x_n \in q_j} \end{bmatrix} \quad (7)$$

式中: m_{ij} 为区域 q_i 中的元素转移到区域 q_j 中的概率。

(4) 图谱生成

利用 MTF 构建频域特征图谱,具体过程如图 2 所示。

1.3 时频域特征提取

STFT 是一种时频分析方法,相较于傅里叶变换只适用于分析稳态信号,STFT 可用于分析时变以及非平稳信号。STFT 可将一维振动信号




图 2 频域特征图谱构建过程

Fig. 2 The constructing process of frequency domain characteristic map

转换为包含时频域特征信息的二维矩阵,采用窗函数对一维信号筛选后进行傅里叶变换,通过窗函数的滑动得到一系列的频谱函数,将结果依次拼接得到一个二维的时频图,其计算式为^[26]

$$STFT_z(\omega, \tau) = z(t)g(t - \tau)e^{-j\omega\tau}dt \quad (8)$$

式中: $z(t)$ 为一维时域信号; $g(\cdot)$ 为窗函数, τ 为当前窗口的起始时刻; ω 为频率; $STFT_z(\omega, \tau)$ 为 τ 时刻频率为 ω 的信号成分在窗口的贡献。

2 基于 CNN-BKA-LSSVM 的隔离开关故障诊断模型

2.1 CNN

CNN 是一种前馈神经网络,其前向传播过程主要由输入层、卷积层、池化层、全连接层和输出层等组成。输入层主要对输入数据进行归一化等预处理;全连接层将输入和输出之间进行全连接,将卷积层和池化层提取的特征进行汇总,实现全局优化^[27];输出层采用 BKA-LSSVM 代替 Softmax 层。卷积层和池化层的介绍如下。

(1) 卷积层

卷积层通过卷积核实现权值共享,提取出图像的特征后输出至下一层网络,其表达式为

$$x_j^l = f\left(\sum_{i \in m_j} x_i^{l-1} \cdot k_{ij}^l + b_j^l\right) \quad (9)$$

式中: l 为卷积层数; x_j^l 为第 l 层的输出; x_i^{l-1} 为第 l 层的输入; k_{ij}^l 为第 l 层卷积核的权重; b_j^l 为偏置; m_j 为特征网络; $f(\cdot)$ 为非线性激活函数。

(2) 池化层

池化层多在卷积层之后,主要用于减少计算的数据量以及保留有效的提取特征。最大池化表达式为

$$P^{l(i,t)} = \max_{(j-1)c+1 \leq t \leq jc} a^{l(i,t)} \quad (10)$$

式中: c 为池化宽度; $a^{l(i,t)}$ 为 l 层第 i 个特征图的第 t 个激活值。

2.2 BKA

BKA 均匀地分配每只黑翅鸢的初始位置^[28]:

$$X_i = BK_{lb} + rand(BK_{ub} - BK_{lb}) \quad (11)$$

式中: i 为 $1 \sim pop$ 之间的整数, pop 为黑翅鸢种群个数; BK_{lb} 和 BK_{ub} 分别为第 i 只黑翅鸢在第 j 维的下界和上界; $rand$ 为 $[0,1]$ 之间的随机数。

黑翅鸢攻击行为用于全局搜索,其数学模型为

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + n \times (1 + \sin r) \times y_t^{i,j}, & p < r \\ y_t^{i,j} + n \times (2r - 1) \times y_t^{i,j}, & \text{else} \end{cases} \quad (12)$$

$$n = 0.05 \times e^{-2 \times \left(\frac{t}{T}\right)^2} \quad (13)$$

式中: $y_t^{i,j}$ 、 $y_{t+1}^{i,j}$ 分别为第 i 只黑翅鸢在第 j 维第 $t+1$ 次、 t 次迭代中的位置; r 为 $0 \sim 1$ 之间的随机数; $p = 0.9$ 为一个固定的概率阈值; T 为总迭代次数; t 为已完成的迭代次数。

黑翅鸢迁移行为的数学模型为

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + C(0,1) \times (y_t^{i,j} - L_t^j), & F_i < F_{r_i} \\ y_t^{i,j} + C(0,1) \times (L_t^j - m \times y_t^{i,j}), & \text{else} \end{cases} \quad (14)$$

$$m = 2\sin(r + \pi/2) \quad (15)$$

式中: L_t^j 为第 j 维黑翅鸢迭代至第 t 次时的领导者; F_i 和 F_{r_i} 分别为任一黑翅鸢在第 t 次迭代中第 j 维的当前位置和随机位置对应的适应度值; $C(0,1)$ 为以原点为中心的柯西变异。

2.3 LSSVM

LSSVM 的优化目标和约束条件为^[29]

$$\min J = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i^2$$

$$\text{s. t. } y_i [\mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}_i) + \mathbf{b}] = 1 - \xi_i, i = 1, 2, 3, \dots, n \quad (16)$$

式中: $\mathbf{w}$ 为权重向量; C 为惩罚因子; ξ_i 为松弛变量; $\mathbf{b}$ 为偏差向量; J 为优化的目标函数; $\boldsymbol{\varphi}(\cdot)$ 为将输入空间映射到高维特征空间的函数; $\mathbf{x}_i$ 为第 i 个输入特征向量; y_i 为 $\mathbf{x}_i$ 对应的输出值。

消去 ξ_i 和 $\mathbf{w}$ 后,得到分类函数 $f(\mathbf{x})$ 为

$$f(\mathbf{x}) = \text{sgn} \left[\sum_{i=1}^n \alpha_i K(\mathbf{x}, \mathbf{x}_i) + \mathbf{b} \right] \quad (17)$$

式中: α_i 为拉格朗日算子; $K(\mathbf{x}, \mathbf{x}_i)$ 为高斯径向基核函数,其表达式为

$$K(\mathbf{x}, \mathbf{x}_i) = \exp \left[-\frac{(\mathbf{x} - \mathbf{x}_i)^T (\mathbf{x} - \mathbf{x}_i)}{2\sigma^2} \right] \quad (18)$$

式中: σ 为高斯径向基核函数宽度。

2.4 故障诊断流程

基于理论分析,隔离开关故障诊断的主要流程如图 3 所示,具体步骤如下。




图 3 隔离开关故障诊断流程

Fig. 3 Fault diagnosis flow chart of disconnecter

(1) 构建图像样本集

利用隔离开关振动试验平台,采集四种工况下隔离开关的振动信号,并分别从时域、频域以及时频域构建特征图谱,继而依据不同工况构建图像样本集。

(2) 模型训练

将图像样本集按 7:2:1 分为训练集、验证集和测试集,并确定 CNN 模型预训练参数;将训练样本输入,通过不断迭代寻优,进行误差判定,观察是否满足要求;完成训练后,利用验证集评估模型并进行微调,直到获得最佳参数;将测试集输入

到训练好的模型中,在全连接层输出样本特征向量及类别,通过张量拼接的形式将特征向量进行融合拼接。

(3) 故障诊断

利用 BKA-LSSVM 代替 CNN 模型中的 Softmax 层,将融合后的特征性向量输入至 BKA-LSSVM 中进行故障诊断,最终输出诊断结果。

3 隔离开关故障试验及结果分析

3.1 试验平台与数据采集

图 4 为隔离开关振动试验平台,由 GW4-252

型隔离开关、DH5922D 型动态信号采集仪、1A212E 型振动传感器及信号传输线等组成。振动传感器安装于 A 相横梁中。隔离开关三种典型机械故障的模拟方法如图 5 所示。



图 4 隔离开关振动试验平台

Fig. 4 Disconnector vibration experimental platform




图 5 故障模拟方法

Fig. 5 Fault simulation methods

设置采样频率为 20 kHz, 采样时间为 10 s, 每种工况下测试 120 组以增加样本量。启动检测后, 进行电动合闸操作, 完成合闸后停止检测。将采集到的信号利用小波包降噪算法进行预处理^[30], 得到四种工况降噪后的振动信号, 如图 6 所示。

3.2 多特征图谱样本集的建立

从时域、频域以及时频域三个角度分别建立 GASF、MTF 和 STFT 图像样本集。数据标签 1~4 分别代表正常、机构卡涩、机构松动以及三相不同期四种工况, 且每个数据标签都包含 GASF、MTF 和 STFT 3 种特征图像。隔离开关振动信号的基频为 100 Hz, 试验采样频率为 20 kHz, 一个完整周期包含 200 个采样点。为了充分提取图像的信




图 6 四种工况下降噪后的振动信号

Fig. 6 Vibration signals after noise reduction for four working conditions

号特征, 选择 10 个周期即 2 000 个采样点生成一张图像。在四种工况的振动信号中分别随机取 2 000 个连续的采样点, 构建 GASF、MTF 和 STFT 3 个图像样本, 重复进行 200 次以集成四种工况的图像样本集, 部分展示如图 7 所示。




图 7 部分特征图谱样本集

Fig. 7 Part of the characteristic map sample set

3.3 故障诊断模型

故障诊断模型如图 8 所示。模型的学习率为 0.001,各层激活函数为 ReLU,池化方式为最大池

化,填充方式为 same,使用 Adam 算法进行优化。以时域特征模型为例,其训练集和验证集的损失值和准确率曲线如图 9 所示。




图 8 故障诊断模型

Fig. 8 Fault diagnosis model




图 9 训练集和验证集的损失值和准确率曲线

Fig. 9 The curves of loss value and accuracy of training set and validation set

由图 9 可知,在迭代 28 次以后,训练集和验证集的准确率和损失值趋于稳定,说明模型已经训练完成。

在 CNN 的全连接层使用 t 分布随机邻域嵌入 (t-distributed Stochastic Neighbor Embedding, t-SNE)算法对特征数据进行降维,结果如图 10 所示。由图 10 可知,不同工况的特征数据区分度较为明显,验证了 CNN 模型提取故障特征的有效性。

3.4 故障识别结果分析

利用 BKA 对 LSSVM 进行优化,设置 C 、 σ 的初值分别为 100、1,搜索范围为 $[0, 1\ 000]$,种群数为 100,最大迭代次数为 300,迭代过程如图 11




图 10 t-SNE 算法降维结果

Fig. 10 t-SNE algorithm dimension reduction results




图 11 BKA 寻优迭代过程

Fig. 11 BKA optimization iteration process

所示。由图 11 可知,迭代 70 次后适应度值不再

变化,此时 $C=294.54$ 、 $\sigma=28.22$ 。
利用 BKA-LSSVM 分类器得到测试集的分类结果如图 12 所示,可见总体识别准确率达到 97.92%。




图 12 测试集分类结果
Fig. 12 Test set classification results
为了避免结果的偶然性,对程序共运行 8 次,结果如图 13 所示。




图 13 多特征图谱-CNN-BKA-LSSVM 模型 8 次试验识别准确率
Fig. 13 Multi-characteristic map CNN-BKA-LSSVM model recognition accuracy in 8 experiments

由图 13 可知,多特征图谱-CNN-BKA-LSSVM 模型运行 8 次的识别率中最高为 97.92%,最低为 95.83%,平均准确率为 97.08%。为了验证多特征图谱-CNN-BKA-LSSVM 模型的优越性,将其与其他模型进行对比分析,每种模型也分别运行 8 次取平均值,最终得到诊断结果如表 1 所示。

表 1 模型诊断结果对比

Tab. 1 Comparison of model diagnostic results	
模型名称	准确率/%
多特征图谱-CNN-BKA-LSSVM	97.08
GASF-CNN-BKA-LSSVM	91.67
MTF-CNN-BKA-LSSVM	90.65
STFT-CNN-BKA-LSSVM	93.33
多特征图谱-CNN	94.50
多特征图谱-CNN-WOA-LSSVM	94.81

3.5 故障诊断方法的应用
将所提模型扩展应用,以某 110 kV 变电站内运行的一台 GW4-126 型隔离开关为例,搭建隔离开关故障检测试验平台,如图 14 所示。




图 14 GW4-126 型隔离开关故障检测试验平台
Fig. 14 GW4-126 disconnector fault detection experimental platform

对采集到的故障信号进行降噪处理,其波形如图 15 所示。将降噪后的故障信号按算法流程处理后输入到故障诊断模型中进行分类,预测结果为故障类型 3,即机构松动。




图 15 故障信号波形
Fig. 15 Fault signal waveform

经过人工检测,发现实际故障为 B 相主动极连杆关节螺栓松动,如图 16 所示,可见预测结果与实际吻合。本案例验证了本文所提方法的可行性。

4 结语

本文提出了一种基于多特征图谱和 CNN-BKA-LSSVM 的隔离开关故障诊断方法。通过搭建户外隔离开关故障诊断试验平台,验证了所提故障诊断方法的有效性,得出如下结论。

(1) 从时域、频域和时频域等多角度提取振



图 16 隔离开关故障检测结果

Fig. 16 Disconnecter fault detection results

动信号特征,避免了提取角度过于单一,提高了振动信号的利用率。

(2)CNN 模型可以有效挖掘多特征图谱的关键特征信息,且通过改进网络框架,将输出的特征向量融合成新的特征向量,相较于单特征故障识别方法,准确率更高。

(3)采用 BKA-LSSVM 代替 Softmax 层以实现故障分类,克服了 Softmax 计算速度较慢、受干扰大的缺点。

(4)本文所提多特征图谱-CNN-BKA-LSSVM 模型具有较强的泛化能力,其运行 8 次的平均诊断准确率达 97.08%,相较于其他故障诊断模型准确率更高。本文方法为基于振动信号的隔离开关故障诊断提供了新的思路。

利益冲突声明

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

作者贡献

申张亮进行了方案设计、内容总结与论文撰写,陈旖旎进行了试验研究与数据收集,杨阳参与了数据分析,王馥珏、张驰参与了论文的审核与修改,马宏忠提供了整体指导。所有作者均阅读并同意了最终稿件的提交。

The scheme design, content summary, and paper writing were carried out by Shen Zhangliang. The experimental research and data collection were conducted by Chen Yini. The data analysis was conducted by Yang Yang. The manuscript was

reviewed and revised by Wang Fujue and Zhang Chi. The overall guidance was provided by Ma Hongzhong. All authors have read and approved the final version of the manuscript for submission.

参考文献

- [1] LIN S, ZHANG K P, WANG Q. Fault diagnosis method of disconnecter based on operating torque in closing process [C]//2021 IEEE 2nd China International Youth Conference on Electrical Engineering, Chengdu, 2021.
- [2] 蒋健,陈宇昇,蔡润庆,等. 电网高压隔离开关机械故障诊断[J]. 沈阳工业大学学报, 2023, 45(2): 127-132.
- JIANG J, CHEN Y S, CAI R Q, et al. Mechanical fault diagnosis of a power grid high voltage isolating switch [J]. Journal of Shenyang University of Technology, 2023, 45(2): 127-132.
- [3] 张一茗,李少华,陈士刚,等. 基于 ReliefF 特征量优化及 BP 神经网络识别的高压隔离开关故障类型与位置诊断方法[J]. 高压电器, 2018, 54(2): 12-19.
- ZHANG Y M, LI S H, CHEN S G, et al. Fault type and position diagnosis method of high-voltage disconnectors based on reliefF characteristic quantity optimization and BP neural network recognition [J]. High Voltage Apparatus, 2018, 54(2): 12-19.
- [4] 咸日常,李云溟,刘焕国,等. 电力变压器内部故障的递进分层诊断方法[J]. 电网技术, 2025, 49(4): 1726-1734.
- XIAN R C, LI Y H, LIU H G, et al. Progressive hierarchical diagnosis of internal faults in power transformers [J]. Power System Technology, 2025, 49(4): 1726-1734.
- [5] 马佳琪,王丰华,盛戈崑,等. 基于同步挤压变换和深度迁移学习的 GIS 隔离开关故障诊断[J]. 电力自动化设备, 2024, 44(2): 218-224.
- MA J Q, WANG F H, SHENG G H, et al. Fault diagnosis of GIS disconnecter based on synchrosqueezing transform and deep transfer learning [J]. Electric Power Automation Equipment, 2024, 44(2): 218-224.
- [6] 赵廷刚,刘浩,苏旭辉,等. 基于振动信号的 GIS 隔离开关触头接触缺陷试验研究[J]. 水电能源科学, 2020, 38(4): 158-161.

- ZHAO T G, LIU H, SU X H, et al. Experimental study of contacting defects of GIS isolation switch contact based on vibration signals [J]. *Water Resources and Power*, 2020, 38(4): 158-161.
- [7] 陈富国, 蔡杰, 李中旗. 基于长短时记忆网络的高压隔离开关故障诊断研究[J]. *中国测试*, 2022, 48(7): 114-119.
- CHEN F G, CAI J, LI Z Q. Study on fault diagnosis of high voltage disconnector based on long-short term memory network [J]. *China Measurement & Test*, 2022, 48(7): 114-119.
- [8] 李可萌, 陈富国, 杨晖, 等. 基于姿态传感器的高压隔离开关机械故障智能诊断研究[J]. *电网技术*, 2023, 47(9): 3781-3790.
- LI K M, CHEN F G, YANG H, et al. Intelligent diagnosis for mechanical faults of high voltage disconnector based on attitude sensor [J]. *Power System Technology*, 2023, 47(9): 3781-3790.
- [9] 陈则宇. 敞开式隔离开关机械故障诊断技术研究[D]. 南昌: 南昌大学, 2023.
- CHEN Z Y. Research on mechanical fault diagnosis technology of open-type disconnector mechanism [D]. Nanchang: Nanchang University, 2023.
- [10] WANG Q, ZHANG K P, LIN S. Fault diagnosis method of disconnector based on CNN and D-S evidence theory [J]. *IEEE Transactions on Industry Applications*, 2023, 59(5): 5691-5704.
- [11] 崔星, 陈静, 孙婧琪, 等. 基于 ICEEMDAN 多尺度模糊熵和 MVO-KELM 的变压器绕组铁心机械故障诊断[J]. *电机与控制应用*, 2023, 50(10): 81-90.
- CUI X, CHEN J, SUN J Q, et al. Mechanical fault diagnosis for transformer winding core based on ICEEMDAN multi-scale fuzzy entropy and MVO-KELM [J]. *Electric Machines & Control Application*, 2023, 50(10): 81-90.
- [12] 臧旭, 张甜瑾, 邵心悦, 等. 基于时变滤波经验模态分解和 SSA-LSSVM 的变压器内部机械故障诊断方法[J]. *电机与控制应用*, 2023, 50(9): 49-56.
- ZANG X, ZHANG T J, SHAO X Y, et al. A transformer internal mechanical fault diagnosis method based on TVFEMD and SSA-LSSVM [J]. *Electric Machines & Control Application*, 2023, 50(9): 49-56.
- [13] GUAN X Y, WU L, SHU N Q, et al. Finite element analysis on forces, currents, and magnetic fluxes of misaligned GIS disconnector [J]. *IEEE Transactions on Power Delivery*, 2018, 33(5): 2484-2491.
- [14] MA J Q, WANG F H. Mechanical fault diagnosis of GIS disconnector based on synchrosqueezing wavelet transform and stacked autoencoder [C]//2022 IEEE International Conference on High Voltage Engineering and Applications, Chongqing, 2022.
- [15] 薛健侗, 马宏忠. 基于 VMD 和 WOA-SVM 的变压器绕组松动故障诊断[J]. *电机与控制应用*, 2023, 50(8): 84-90.
- XUE J T, MA H Z. Fault diagnosis for winding looseness of transformer based on VMD and WOA-SVM [J]. *Electric Machines & Control Application*, 2023, 50(8): 84-90.
- [16] 张开普. 基于振动和力矩信号融合的高压隔离开关故障诊断方法[D]. 成都: 西南交通大学, 2022.
- ZHANG K P. Research on fault diagnosis of high voltage disconnector based on the fusion of vibration signal and torque signal [D]. Chengdu: Southwest Jiaotong University, 2022.
- [17] 马宏忠, 李楠, 杨启帆, 等. 基于多特征声纹图谱的变压器绕组松动在线故障诊断方法[J]. *电机与控制学报*, 2023, 27(5): 76-87.
- MA H Z, LI N, YANG Q F, et al. On-line fault diagnosis method of transformer winding looseness based on multi-characteristic voiceprint maps [J]. *Electric Machine and Control*, 2023, 27(5): 76-87.
- [18] 薛健侗, 马宏忠, 杨洪苏, 等. 基于格拉姆角场与迁移学习-AlexNet 的变压器绕组松动故障诊断方法[J]. *电力系统保护与控制*, 2023, 51(24): 154-163.
- XUE J T, MA H Z, YANG H S, et al. A fault diagnosis method for transformer winding looseness based on Gramian angular field and transfer learning-AlexNet [J]. *Power System Protection and Control*, 2023, 51(24): 154-163.
- [19] 肖雨松, 马宏忠. 基于格拉姆角场和深度残差网络的变压器绕组松动故障诊断模型[J]. *电机与控制应用*, 2024, 51(1): 29-38.
- XIAO Y S, MA H Z. Transformer winding looseness fault diagnosis model based on GAF and depth residual network [J]. *Electric Machines & Control Application*, 2024, 51(1): 29-38.

- [20] 谢锋云, 汪淦, 王玲岚, 等. STFT 结合 2D CNN-SVM 的齿轮箱故障诊断方法[J]. 噪声与振动控制, 2024, 44(4): 103-109.
- XIE F Y, WANG G, WANG L L, et al. Fault diagnosis method of gearbox based on STFT and 2D CNN-SVM [J]. Noise and Vibration Control, 2024, 44(4): 103-109.
- [21] 罗兵, 徐立, 王婷婷, 等. 基于 CEEMDAN-GAF 的变压器机械故障检测方法[J]. 电测与仪表, 2024, 61(7): 169-176.
- LUO B, XU L, WANG T T, et al. Mechanical faults detection method for transformers based on CEEMDAN-GAF [J]. Electrical Measurement & Instrumentation, 2024, 61(7): 169-176.
- [22] 王彦彪, 陈华泰, 刘军伟, 等. 基于马尔可夫转移场和 CBAM-CNN 的换流变压器油纸绝缘局部放电识别[J]. 武汉大学学报(工学版), 2023, 56(10): 1245-1254.
- WANG Y B, CHEN H T, LIU J W, et al. Recognition of partial discharge in oil-pressboard insulation of converter transformer based on Markov transfer field and CBAM-CNN [J]. Engineering Journal of Wuhan University, 2023, 56(10): 1245-1254.
- [23] 刘云鹏, 王江伟, 裴少通, 等. 基于短时傅里叶变换和稀疏表示的局放识别分类方法[J]. 电测与仪表, 2019, 56(23): 31-36.
- LIU Y P, WANG J W, PEI S T, et al. Method for identifying and classifying partial discharge based on short time Fourier transform and sparse representation [J]. Electrical Measurement & Instrumentation, 2019, 56(23): 31-36.
- [24] 曾全昊, 王丰华, 郑一鸣, 等. 基于卷积神经网络的变压器有载分接开关故障识别[J]. 电力系统自动化, 2020, 44(11): 144-151.
- ZENG Q H, WANG F H, ZHENG Y M, et al. Fault recognition of on-load tap-changer in power transformer based on convolutional neural network [J]. Automation of Electric Power Systems, 2020, 44(11): 144-151.
- [25] 陈力, 王海江, 吴凯. 基于卷积神经网络的车载网络入侵检测方法[J]. 浙江科技学院学报, 2021, 33(1): 59-66+84.
- CHEN L, WANG H J, WU K. In-vehicle network intrusion detection method based on convolutional neural networks [J]. Journal of Zhejiang University of Science and Technology, 2021, 33(1): 59-66+84.
- [26] 刘志坚, 黄建, 骆军. 基于 STFT 图像和迁移学习的次同步振荡源定位方法[J]. 电机与控制应用, 2024, 51(7): 119-131.
- LIU Z J, HUANG J, LUO J. Localization method for sub-synchronous oscillation sources based on STFT images and transfer learning [J]. Electric Machines & Control Application, 2024, 51(7): 119-131.
- [27] 朱瑞雨, 崔江. 一种航空发电机电枢绕组匝间短路故障诊断技术[J]. 电机与控制应用, 2025, 52(1): 22-35.
- ZHU R Y, CUI J. A fault diagnosis technique for armature winding inter-turn short circuit in aerospace generators [J]. Electric Machines & Control Application, 2025, 52(1): 22-35.
- [28] WANG J, WANG W C, HU X X, et al. Black-winged kite algorithm: A nature-inspired meta-heuristic for solving benchmark functions and engineering problems [J]. Artificial Intelligence Review, 2024, 57(4): 1-53.
- [29] 赵金涛, 郭凯凯, 高雄, 等. 基于电流矢量分析的 PMSM 系统开路故障诊断方法[J]. 电机与控制应用, 2025, 52(1): 64-73.
- ZHAO J T, GUO K K, GAO X, et al. Open-circuit fault diagnosis method for PMSM systems based on current vector analysis [J]. Electric Machines & Control Application, 2025, 52(1): 64-73.
- [30] 郭煜敬, 陈士刚, 李少华, 等. 基于经验模态分解及支持向量机的高压隔离开关机械故障诊断方法[J]. 高压电器, 2018, 54(9): 12-18.
- GUO Y J, CHEN S G, LI S H, et al. Mechanical fault diagnosis method of high-voltage disconnecter based on empirical modal decomposition and support vector machine [J]. High Voltage Apparatus, 2018, 54(9): 12-18.

收稿日期:2025-04-12

收到修改稿日期:2025-05-15

作者简介:

申张亮(1985-),男,博士,高级工程师,研究方向为变电检修及配网调度,alex7776@126.com;

*通信作者:张驰(1997-),男,博士研究生,研究方向为电力设备故障分析与诊断,zc970131@163.com。