

DOI:10.13296/j.1001-1609.hva.2026.06.011

基于SDAE-SVM的高压电缆局部放电类型识别

杨帆¹, 程琛¹, 黄乐¹, 彭小圣²

(1. 国网陕西省电力有限公司西安供电公司, 西安 710032; 2. 华中科技大学电气与电子工程学院强电磁工程与新技术国家重点实验室, 武汉 430074)

摘要: 提出一种基于改进堆栈去噪自编码器(SDAE-SVM)的深度学习方法,用于高压电缆不同绝缘缺陷局部放电(PD)信号的模式识别。首先在高压实验室中对5种类型的人工缺陷进行PD测试,并提取3 500组PD瞬时脉冲,构建了34种特征参数。其次,详细介绍了SDAE-SVM的原理和网络架构。然后,使用所提模型识别不同缺陷类型的PD信号,获得了93.56%的识别精度。接着,使用t分布随机邻接嵌入(t-SNE)对SDAE-SVM逐层输出进行了可视化,说明了深度神经网络SDAE-SVM逐层优化的本质。最后,将所提方法与反向传播神经网络(BPNN)、支持向量机(SVM)和堆栈去噪自编码器(SDAE)进行了对比。结果表明,相比BPNN、SVM和SDAE,SDAE-SVM的总体识别精度分别提高了7.46%、6.70%、1.37%,具备较高的工程应用价值。

关键词: 高压电缆; 局部放电; 模式识别; 深度学习; 堆栈去噪自编码器

Partial Discharge Pattern Recognition of High Voltage Cables Based on SDAE-SVM

YANG Fan¹, CHENG Chen¹, HUANG Le¹, PENG Xiaosheng²

(1. Xi'an Power Supply Company, State Grid Shaanxi Electric Power Company, Xi'an 710032, China; 2. State Key Laboratory of Advanced Electromagnetic Engineering and Technology, School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: A deep learning method based on an improved stacked denoising autoencoder (SDAE-SVM) is proposed for pattern recognition of partial discharge (PD) signals generated by different insulation defects in high-voltage cables. First, PD tests are conducted on five types of artificial defects in a high-voltage laboratory, and 3 500 sets of PD instantaneous pulses are extracted to construct 34 types of characteristic parameters. Then, the principles and network architecture of SDAE-SVM are introduced in detail. After that, the proposed model is used to recognize the PD signals of different types of defects and the pattern recognition accuracy of 93.56% is obtained. Moreover, the layer-wise outputs of the SDAE-SVM are visualized using t-distributed stochastic neighbor embedding (t-SNE), illustrating the essence of layer-wise optimization of the deep neural network SDAE-SVM. Finally, the proposed method is compared with back propagation neural network (BPNN), support vector machine (SVM) and stacked denoising autoencoders (SDAE). The results show that compared with BPNN, SVM, and SDAE, the overall recognition accuracy of SDAE-SVM has increased by 7.46%, 6.70%, and 1.37%, respectively, demonstrating high engineering application value.

Key words: high voltage cables; partial discharge; pattern recognition; deep learning; stacked denoising autoencoder

0 引言

高压电力电缆在现代电网中发挥着非常重要的作用,其状态关系着整个电力系统的安全与可靠

运行^[1-5]。

局部放电(PD)监测是评价高压电缆绝缘状态的有效方式^[6-7]。由于高压电缆不同绝缘缺陷诱发的PD信号存在差异,根据检测到的PD信号可以区分

收稿日期:2025-11-07; 修回日期:2026-01-25

基金项目:国家自然科学基金资助项目(51541705)。

Project Supported by National Natural Science Foundation of China(51541705).

缺陷类型,从而评估电缆绝缘状态^[8-9]。然而许多绝缘缺陷类型差异非常小,导致某些PD信号相似度非常高而难以区分。

针对PD模式识别问题,学者们不断地进行了研究,其中支持向量机(SVM)与反向传播神经网络(BPNN)由于其优异的性能得到了较为广泛的应用。文[8]结合小波分析去噪和SVM进行电力系统PD的检测与识别。文[9]通过小波包分解提取能量信息并使用SVM进行开关柜PD信号的区分。文[10]通过融合PRPD模式和TRPD模式下的两个BPNN模型来提高对不同PD的识别精度。然而,SVM和BPNN等这些传统浅层机器学习方法由于其特征提取能力上的不足导致了PD模式识别精度上的限制^[11-13]。

近年来,深度学习理论深刻影响了人工智能的发展。各类深度学习算法在工业生产与人类生活等诸多领域得到了成功应用,在PD识别领域也引起了研究人员的广泛关注^[14-16]。文[14]使用卷积神经网络识别高压电缆不同绝缘缺陷类型,研究了不同因素对识别效果的影响。文[15]使用自适应矩估计优化算法改进深度信念网络,进行直流电缆的局部放电模式识别。文[16]使用小波包分解算法来实现典型局部放电信号特征的提取,然后使用LSTM模型实现对振荡波局部放电信号的识别与检测。

SDAE是深度学习算法中的一种典型结构设计,由多个去噪自编码器(DAE)堆叠形成,在多个领域得到了广泛应用^[17-18]。SDAE具有深层次的网络结构,能够捕捉传统浅层结构无法学习到的高维非线性和复杂相关性,得到更高级的特征表示,为解决电缆PD模式识别问题带来了新的契机。然而,在实际应用中,传统深度学习算法常常使用Softmax分类器,该分类器性能有限。在对识别精度要求较高、缺陷模式复杂的情况下,使用SVM分类器替换掉传统SDAE最后一层的Softmax分类器可以有效提升深度网络的鲁棒性和泛化能力。这是因为SVM分类器是在高维空间中构造分类平面来区分不同类别的样本,能够有效提升分类的精度。

文中提出一种基于SDAE-SVM的高压电缆局部放电模式识别算法,并通过实验数据证明了该方法相比于现有模型的优越性。首先利用实验室环境下的5种电缆绝缘缺陷获取了大量PD数据,构建了34种用于模式识别的特征参数。接着,介绍了SDAE-SVM的数学原理、网络架构。然后,将SDAE-SVM用于不同缺陷类型PD信号的识别,并对SDAE-SVM网络逐层输出进行了可视化。最后,为

证明所提方法的有效性,文中将SDAE-SVM识别效果与SDAE以及传统的浅层分类器SVM和BPNN进行了比较。结果表明,SDAE-SVM具有出色的特征提取和分类能力,在识别精度上优于SDAE以及传统的BPNN和SVM模式识别方法,且对高相似度PD类型的识别效果更优。

1 局部放电数据与特征

1.1 实验电缆与缺陷构造

实验使用的11 kV乙丙橡胶(EPR)电缆结构见图1。构建的5种典型绝缘缺陷见图2、3^[19]。




图1 EPR电缆样品示意图

Fig. 1 The dimensions and layers of the EPR cable sample




图2 缺陷类型1-4

Fig. 2 Defect type 1-4

缺陷类型1,模拟绝缘层空穴,使用直径0.4 mm的钻头向电缆本体钻孔得到圆柱形孔,然后用与外导体接触的铜带覆盖在圆柱形孔上来进行密封,直径0.4 mm,深2 mm,见图2(a)。

缺陷类型2,外半导体尖刺缺陷,使用印刷电路板钻头钻入电缆中来模拟外半导体尖刺缺陷,直径0.4 mm,深2 mm,见图2(b)。




图3 缺陷类型5: 端部沿面放电

Fig. 3 Defect type 5: Surface discharge around end termination

缺陷类型3与2类似,也是使用印刷电路板钻头钻入电缆中来模拟外半导体非接触性尖刺缺陷,直径0.4 mm,深2 mm,见图2(c)。缺陷类型3与2的区别是,缺陷类型3中的钻头不和外导体及PVC接触,缺陷类型2中钻头则与两者接触。由此可知,缺陷类型3与2具有相当高的相似度。

缺陷类型4,电缆外护套破损,从电缆护套切割7 mm×7 mm的一块来模拟电缆外护套破损,见图2(d)。

缺陷类型5,将电缆屏蔽铜带的一部分暴露并接地来模拟电缆端部沿面放电,见图3。

1.2 局部放电数据获取

加压实验使用的测试系统参见文[4]。实验系统连接示意图见图4。




图4 PD测试系统原理图

Fig. 4 The principle of the PD testing system

在实验过程中,外施电压从0开始以1 kV为限升压到放电起始电压,直到确定的最大电压为止。缺陷类型2、3的最大电压分别为13、12 kV。缺陷类型1、4、5的最大电压则为11 kV。从PD测试原始数据中进行PD瞬时脉冲提取,得到每种缺陷类型中对应的700个脉冲共计3 500个样本用于后续研究。

1.3 局部放电特征

文中利用1.2节得到的3 500组PD瞬时脉冲信号构建了34个PD脉冲的特征参数^[14]。包括单位和示例在内的PD特征数据的详细信息见表1。

表1 PD特征

Table 1 PD features

索引	特征名	单位	示例
特征1	峰值电压	mV	3.65
特征2	脉冲极性	-1或+1	-1
特征3	平均电压	mV	2.28
特征4	均方根值	mV	2.61
特征5	标准差	mV	1.31
特征6	脉冲宽度	ns	150
特征7	上升时间	ns	70
特征8	下降时间	ns	80
特征9	偏度	—	0.35
特征10	峰度	—	0.53
特征11	波峰因数	—	1.39
特征12	形状因子	—	1.14
特征13	主频	Hz	0
特征14	相位角	°	175.3
特征15	等效时间长度	—	23.5
特征16	等效宽度	—	8.37
特征17	放电量	pC	72.9
特征18	PD位置	—	1 042 249
特征19-23	$E_{01}-E_{05}$	—	15.08
特征24	E_{A5}	—	49.49
特征25-29	$E_{01}-E_{05}$	—	682.47
特征30-34	$E_{01}-E_{05}$	—	149.65

5种类型PD的相位谱图见图5。从图5可以看出,5种缺陷类型对应的PD信号混叠在一起,区分难度较大。

2 基于SDAE-SVM的PD模式识别

2.1 SDAE-SVM算法

自编码器由输入层、隐藏层、输出层组成,其训练目标是使得输出尽可能等于输入^[20-21]。

DAE在自编码器的基础上在训练过程中主动将随机噪声添加到样本数据中,使得网络得到的特征表达更具鲁棒性^[18]。

将DAE堆叠组合便可形成具有深度学习层级结构的SDAE,提取得到原始数据的高阶表示,从而用于模式识别,获得更好的效果,模型构建见图6。

在SDAE预训练阶段,每个DAE模块得到的输出都被作为下一个DAE的输入,直至得到每层的初始参数^[18]。在预训练得到初始化网络后,往往通过分类器基于梯度的反向传播算法对参数进一步调优。这种微调使得网络学习到的特征更具判别性。

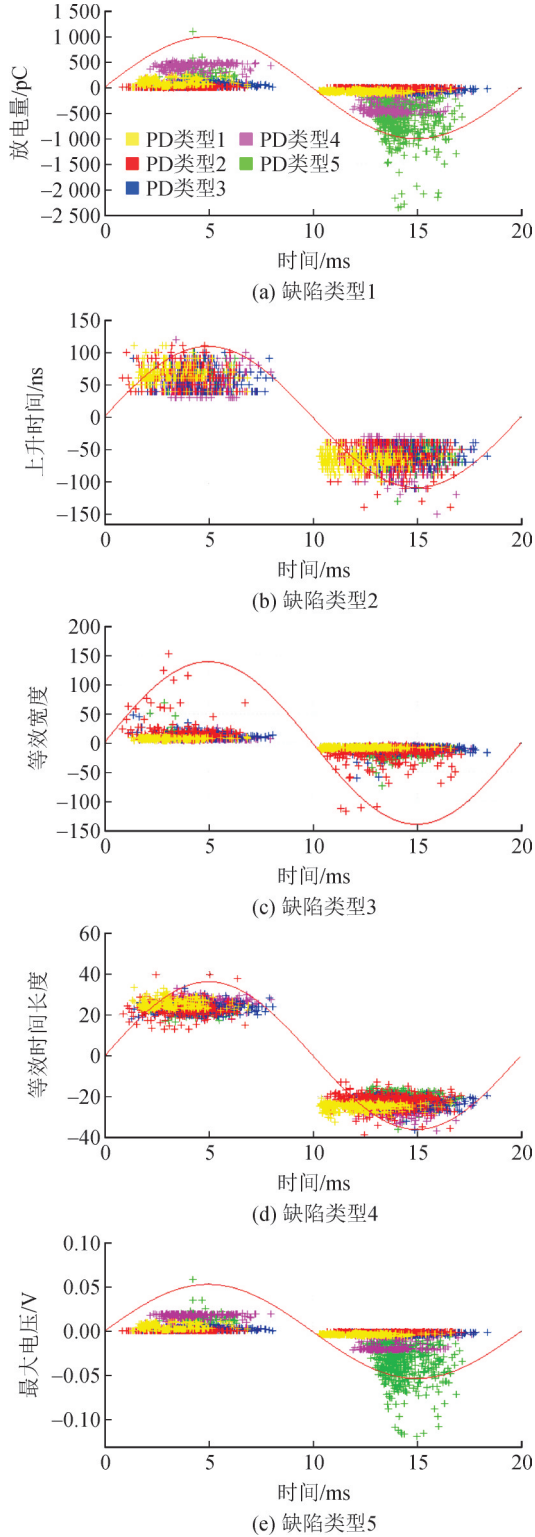


图5 HFCT耦合的5种PD信号的相位图谱
Fig. 5 Phase resolved PD pattern of five types of PD signals detected by HFCT

Softmax分类器通常用于神经网络的最后一层,将神经元的输出转换为各个类别的概率分布。然而,在实际应用中,Softmax分类器的分类性能有限。文中采用了一种更好的线性支持向量机分类器和深度网络结合,其目标函数为

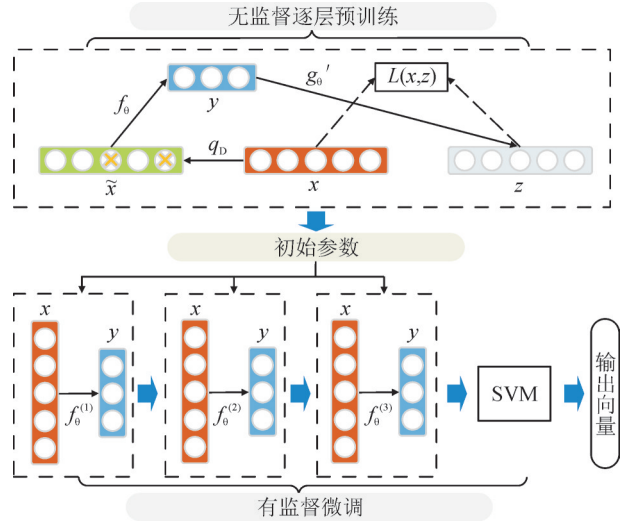


图6 SDAE-SVM模型架构(以3层为例)

Fig. 6 Architecture of SDAE-SVM model(e.g. 3 layers)

$$l(\mathbf{w}) = \min_{\mathbf{w}} \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^n \max(1 - \mathbf{w}^T \mathbf{x}_i t_i, 0)^2 \quad (1)$$

式(1)中: $l(\mathbf{w})$ 为线性支持向量机的目标函数; \mathbf{w} 为线性支持向量机的权值; i 为样本编号; n 为样本总数; C 为惩罚项常数; \mathbf{x}_i 为第 i 个输入向量; t_i 为第 i 个样本的标签。可以看出,线性支持向量机有着更优的正则项,能够有效缓解过拟合。

将目标函数的值即模型误差通过对分类器输入求导来向神经网络底层传递,从而完成深度神经网络的微调。文中使用线性支持向量机代替 Softmax 分类器对 SDAE 网络进行微调,其关键在于线性支持向量机的目标函数对于 SDAE 网络顶层输出的求导公式,见式(2)

$$\frac{\partial l(\mathbf{w})}{\partial \mathbf{x}_i} = -2C t_i \mathbf{w} [\max(1 - \mathbf{w}^T \mathbf{x}_i t_i, 0)] \quad (2)$$

式(2)中, $t_i \in \{-1, +1\}$ 。

通过式(2),便可使用梯度下降法对 SDAE 的网络权值进行微调。值得注意的是,线性支持向量机是一种二分类器,不能直接应用于多分类问题。为此,可以采用多个线性支持向量机,将每一个线性支持向量机对应于一类样本,也就是使用一对多的方式。比如对于第二类样本对应于第二个分类器,当所有样本输入第二类对应的分类器中训练时,令第二类样本标签为+1,其余所有样本标签为-1。另外,在采用多个分类器时,每个线性支持向量机都要配合采用一个对应的深度 SDAE 网络,每个 SDAE 网络结构与参数都相同,且网络权值均初始化为预训练好的网络参数。也就是说,每个线性支持向量机只微调其对应的 SDAE 网络。

在每个 SDAE 网络微调完成后,便可将测试样

本输入所有类别对应的模型中进行计算,每个测试样本都可以得到所有类别模型的输出,通过比较这些输出的大小就可以决定该测试样本属于哪一类^[22]。

2.2 基于SDAE-SVM的PD模式识别流程

文中所提出的用于高压电缆PD模式识别的SDAE-SVM架构见图6。基于SDAE-SVM的模式识别步骤详述如下:

步骤1,进行5种电缆绝缘缺陷的PD测试并收集试验数据。

步骤2,进行数据预处理并提取PD瞬时脉冲,构建得到包含34个特征的PD特征数据集。

步骤3,将得到的含有3 500个样本的PD特征数据集划分为训练集、验证集和测试集(三者比例为7.0:1.5:1.5)。

步骤4,将PD特征参数按照式(3)所示进行归一化处理,以避免不同特征物理单位的干扰。

$$x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad i = 1, 2, \dots \quad (3)$$

式(3)中: x_i 和 x_i^* 分别为 x_i 原始特征参数和归一化后的特征参数; x_{\max} 和 x_{\min} 分别为输入特征参数集的最大和最小值。

步骤5,设置SDAE-SVM参数,确定网络层数,每层神经元数目,学习率、噪声系数和迭代轮数。

步骤6,在训练集上先通过逐层预训练获取SDAE-SVM初始参数,然后使用基于梯度的反向传播算法微调和优化网络参数,接着在验证集上验证模型效果。

步骤7,在测试集上评估基于SDAE-SVM算法的PD模式识别方法的性能。

3 结果与评估

本节对SDAE-SVM的分类性能进行评估,得到SDAE-SVM识别的混淆矩阵,将其与SDAE以及BPNN和SVM进行了比较,通过对SDAE-SVM逐层输出进行可视化,进一步直观的说明了SDAE-SVM出色的特征表达能力。

3.1 SDAE-SVM识别混淆矩阵

经过试探,文中采用含有3个隐藏层的SDAE-SVM网络,各个隐含层神经元数目分别为100、200、100,学习率为0.15,噪声系数为0.2,迭代次数为300,输入与输出维度分别为34和5。SDAE-SVM模式识别的混淆矩阵见表2。

由表2可知,缺陷类型1、4、5识别较为容易,识别准确率较高,而缺陷类型2和3的识别误差则相对较大。表2中缺陷类型2的105个样本中有12个

表2 SDAE-SVM识别混淆矩阵

Table 2 Confusion matrix of SDAE-SVM

实际PD类型	预测PD类型				
	T ₁	T ₂	T ₃	T ₄	T ₅
T ₁	103	1	2	0	0
T ₂	0	93	12	0	0
T ₃	3	14	88	0	0
T ₄	0	0	0	105	0
T ₅	0	0	1	1	103

被误识别为类型3,缺陷类型3的105个样本中则有14个被误识别为缺陷类型2,这两种缺陷类型的识别结果之间存在较大程度的混淆,这在很大程度上降低了模型的识别精度。这印证了2.3节中关于PD相位谱图的分析。

3.2 SDAE-SVM逐层可视化

为了更加直观的说明SDAE-SVM的特征抽象与表达能力,文中还使用t-SNE可视化方法将PD原始特征数据和SDAE-SVM每个隐藏层的输出映射到了二维平面上。可视化展示结果分别见图7、8。作为目前效果最好的一种降维可视化方法,t-SNE可以有效地处理异常值和复杂的流形结构,非常适用于将高维数据降维到2维或者3维^[4]。




图7 原始特征空间的2维可视化

Fig. 7 2D visualization of the original PD feature

从图7可看出,原始特征空间中各缺陷类型样本掺杂在一起,缺陷类型2和3对应样本的混叠程度尤为严重。从图8展示的SDAE-SVM隐藏层输出的可视化结果可明显看出,随着层数的逐渐增加,5种缺陷类型的样本逐渐被区分开。经第1个隐藏层处理后,5种缺陷类型的样本较原始特征空间有了一定程度的分离,类型1、4、5区分的相对更加明显。经过第2个隐藏层处理后,5种缺陷类型的样本区分度更高,缺陷类型2和3也有了一定程度的分离。经过第3个隐藏层处理后,每种缺陷类型的样本各自更加集中,彼此区分的更加清楚。

3.3 与现有分类器的比较

为证明基于SDAE-SVM的PD模式识别方法的

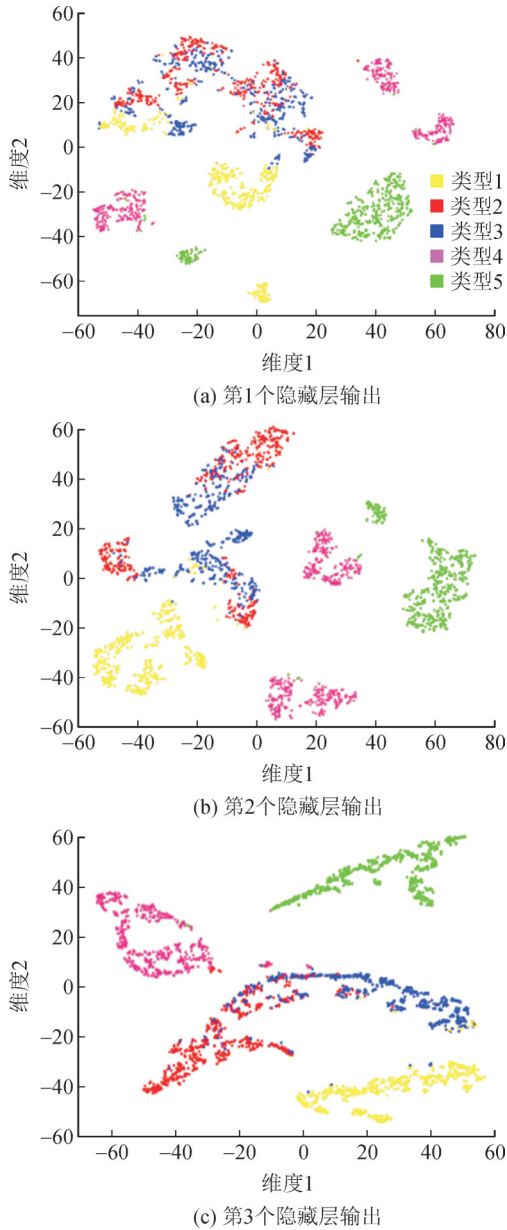


图8 SDAE-SVM 隐含层2维可视化

Fig. 8 2D visualization of the layer-wise SDAE-SVM

优势,文中还将所提方法与SDAE(采用和SDAE-SVM相同的网络参数)、BPNN(隐含层包含100个神经元)和SVM的性能进行了比较,结果见表3。

表3 不同方法识别精度的比较

Table 3 Comparison of recognition accuracy of different methods

方法	精度/%					总体识别
	T ₁	T ₂	T ₃	T ₄	T ₅	
SDAE-SVM	97.17	86.11	85.44	99.06	100.00	93.56
SDAE	97.14	80.17	85.11	99.06	100.00	92.19
BPNN	90.99	70.87	69.31	99.05	99.05	86.10
SVM	90.99	73.74	70.48	99.05	99.05	86.86

SDAE-SVM具备更加优异的分类性能。从表3可知,4种方法中SDAE-SVM总体识别准确率最高,

达到了93.56%;SDAE其次,为92.19%;SVM再次,为86.86%;BPNN最差,为86.10%。相比BPNN、SVM和SDAE、SDAE-SVM的总体识别精度分别提高了7.46%、6.70%、1.37%,且对5种缺陷类型样本的识别精度都有提升。由于缺陷类型1、4、5的区分度相对较大,SDAE-SVM对三者的识别准确率分别达到了97.17%、99.06%、100.00%。而缺陷类型2和3的相似度较高,识别难度相对较大。SDAE-SVM具有出色的数据特征挖掘能力,可以较好的学习到有用信息,能够捕捉到更具特异性的特征,能较好地识别高相似度缺陷类型。SDAE-SVM对缺陷类型2的识别准确率为86.11%,相比BPNN、SVM、SDAE分别提高了15.24%、12.37%、5.94%;SDAE-SVM对缺陷类型3的识别准确率为85.44%,相比BPNN、SVM、SDAE分别提高了16.13%、14.96%、0.33%。

4 结论

文中研究了SDAE-SVM在高压电缆PD模式识别问题的表现,并与传统方法的识别效果进行了比较,得到结论如下:

1)文中提出的基于SDAE-SVM的PD模式识别方法是有效的,对于5种缺陷类型PD信号的总体识别精度达到了93.56%,相比BPNN、SVM、SDAE分别提高了7.46%、6.70%、1.37%。

2)SDAE-SVM具有出色的数据特征挖掘能力,能够捕捉到更具特异性的特征,对于高相似度缺陷类型2和3的识别准确率,相比BPNN和SVM有了10%以上的提升,相比SDAE分别提高了5.94%和0.33%。

未来将更先进的人工智能方法应用于局部放电类型的识别,或将成为电缆状态检测领域未来的研究方向。

参考文献:

[1] 周彦,常俊,曹好婕,等. 高压开关柜局部放电多物理信号特性对比研究[J]. 高压电器, 2023, 59(8): 196-202.
ZHOU Yan, CHANG Jun, CAO Yujie, et al. Comparative study on multi-physical signal characteristics of partial discharge in high voltage switchgear cabinet[J]. High Voltage Apparatus, 2023, 59(8): 196-202.

[2] 祝学海. 在线局部放电检测技术在工厂配电设备运行中的应用[J]. 自动化应用, 2023, 64(13): 153-156.
ZHU Xuehai. Application of online partial discharge detection technology in the operation of power distribution equipment in factories[J]. Automation Application, 2023, 64(13): 153-156.

[3] 黄辉,杨智豪,魏建国,等. 变压器套管局部放电射频信号在外部分布特征[J]. 中国电力, 2023, 56(4): 175-183.
HUANG Hui, YANG Zhihao, WEI Jianguo, et al. Distribution char-

- acteristics of partial discharge radio frequency signal in transformer tank and bushing[J]. *Electric Power*, 2023, 56(4): 175-183.
- [4] PENG Xiaosheng, YANG Fan, WANG Ganjun, et al. A convolutional neural network-based deep learning methodology for recognition of partial discharge patterns from high-voltage cables[J]. *IEEE Transactions on Power Delivery*, 2019, 34(4): 1460-1469.
- [5] 任保瑞,郑德芳,关鹤,等.高压电力电缆行波传播特性研究[J]. *西安工程大学学报*, 2025, 39(4): 63-72.
REN Baorui, ZHENG Defang, GUAN He, et al. Characterization of traveling wave propagation in high voltage power cables[J]. *Journal of Xi'an Polytechnic University*, 2025, 39(4): 63-72.
- [6] 严亚兵,江志文,肖俊先,等.基于高频电流信号的电缆局部放电故障特征分析研究[J]. *供用电*, 2024, 41(3): 96-102.
YAN Yabing, JIANG Zhiwen, XIAO Junxian, et al. Fault characteristics analysis of cable partial discharge based on the highfrequency current signal[J]. *Distribution & Utilization*, 2024, 41(3): 96-102.
- [7] 刘浩,侯春光,高有华.基于多传感信息融合的电缆附件局部放电诊断算法研究[J]. *电器与能效管理技术*, 2024(10): 36-41.
LIU Hao, HOU Chunguang, GAO Youhua. Research on partial discharge diagnosis algorithm for cable accessories based on multi sensor information fusion[J]. *Electrical & Energy Management Technology*, 2024(10): 36-41.
- [8] 王建伟,郑祥.基于高压电缆局部放电TDR法的便携式转发器研究[J]. *电器与能效管理技术*, 2024(7): 36-41.
WANG Jianwei, ZHENG Xiang. Research on portable transponder based on partial discharge TDR method of high voltage cable[J]. *Electrical & Energy Management Technology*, 2024(7): 36-41.
- [9] 陈峰,姜伊欣,娄雨靖.基于小波包分解和支持向量机的局部放电识别方法研究[J]. *山东电力技术*, 2020, 47(6): 5-9.
CHEN Feng, JIANG Yixin, LOU Yujing. Partial discharge classification method based on wavelet packet decomposition and support vector machines[J]. *Shandong Electric Power*, 2020, 47(6): 5-9.
- [10] LI Ping, TANG Ju, LIU Yilu. Partial discharge recognition in gas insulated switchgear based on multi-information fusion[J]. *IEEE Transactions on Dielectrics and Electrical Insulation*, 2015, 22(2): 1080-1087.
- [11] 郑业爽,李世春,鲁玲.基于多策略ISOA优化SVM的变压器故障诊断研究[J]. *智慧电力*, 2023, 51(2): 38-44.
ZHENG Yeshuang, LI Shichun, LU Ling. Transformer fault diagnosis based on multi-strategy ISOA optimized SVM[J]. *Smart Power*, 2023, 51(2): 38-44.
- [12] 吉兴全,陈金硕,张玉敏,等.基于CNN-SVM的配电网故障分类研究[J]. *智慧电力*, 2022, 50(1): 94-100.
JI Xingquan, CHEN Jinshuo, ZHANG Yumin, et al. Fault classification in distribution network based on CNN-SVM[J]. *Smart Power*, 2022, 50(1): 94-100.
- [13] 刘文浩,吴毅江,李文泽,等.基于随机决策森林的高压电缆局部放电模式识别[J]. *高压电器*, 2022, 58(6): 165-170.
LIU Wenhao, WU Yijiang, LI Wenzhe, et al. Partial discharge pattern recognition of high-voltage cables based on random forest method[J]. *High Voltage Apparatus*, 2022, 58(6): 165-170.
- [14] 杨帆,王干军,彭小圣,等.基于卷积神经网络的高压电缆局部放电模式识别[J]. *电力自动化设备*, 2018, 38(5): 123-128.
YANG Fan, WANG Ganjun, PENG Xiaosheng, et al. Partial discharge pattern recognition of high-voltage cables based on convolutional neural network[J]. *Electric Power Automation Equipment*, 2018, 38(5): 123-128.
- [15] 黄光磊,李喆,许永鹏,等.基于改进深度信念网络的直流XLPE电缆局部放电模式识别[J]. *高电压技术*, 2020, 46(1): 327-334.
HUANG Guanglei, LI Zhe, XU Yongpeng, et al. Partial discharge pattern recognition of XLPE DC cable based on improved deep belief networks[J]. *High Voltage Engineering*, 2020, 46(1): 327-334.
- [16] 韩雪源.基于LSTM算法的高压交联电缆线路振荡波局部放电检测方法[J]. *电机与控制应用*, 2022, 49(12): 41-46.
HAN Xueyuan. Oscillating wave partial discharge detection method of high voltage cross-linked cable line based on LSTM algorithm[J]. *Electric Machines & Control Application*, 2022, 49(12): 41-46.
- [17] 张怡,张恒旭,李常刚,等.深度学习在电力系统频率分析与控制中的应用综述[J]. *中国电机工程学*, 2021, 41(10): 3392-3406.
ZHANG Yi, ZHANG Hengxu, LI Changgang, et al. Review on deep learning applications in power system frequency analysis and control[J]. *Proceedings of the CSEE*, 2021, 41(10): 3392-3406.
- [18] 杨帆.基于深度学习的短期风电功率预测技术研究[D]. 武汉: 华中科技大学, 2020.
YANG Fan. Research on short-term wind power prediction based on deep learning methodology[D]. Wuhan: Huazhong University of Science and Technology, 2020.
- [19] PENG Xiaosheng, WEN Jinyu, LI Zhaohui, et al. SDMF based interference rejection and PD interpretation for simulated defects in HV cable diagnostics[J]. *IEEE Transactions on Dielectrics and Electrical Insulation*, 2017, 24(1): 83-91.
- [20] 张金水,蒋伟,潘伟杰.基于栈式降噪自编码器的GIS绝缘缺陷识别研究[J]. *电气自动化*, 2021, 43(4): 81-83.
ZHANG Jinshui, JIANG Wei, PAN Weijie. GIS insulation defect recognition based on stacked denoising autoencoder[J]. *Electrical Automation*, 2021, 43(4): 81-83.
- [21] 马良玉,孙佳明.基于SDAE预测模型和改进SSA的NO_x排放优化[J]. *中国电机工程学报*, 2022, 42(14): 5194-5201.
MA Liangyu, SUN Jiaming. NO_x emission optimization based on SDAE prediction model and improved SSA[J]. *Proceedings of the CSEE*, 2022, 42(14): 5194-5201.
- [22] 贾庆超.基于稀疏表示和深度学习分类器的SAR目标图像的分割与分类[D]. 西安: 西安电子科技大学, 2017.
JIA Qingchao. SAR target image segmentation and classification based on sparse representation and deep learning[D]. Xi'an: Xidian University, 2017.
- 杨帆(1995—),男,硕士,工程师,主要研究方向为电力设备状态监测与新能源功率预测(E-mail: 2632460413@qq.com)。
黄乐(1986—),男,本科,工程师,主要研究方向为电力设备状态监测(通信作者)(E-mail: 3230540009@qq.com)。