基于卷积神经网络的高压电缆局部放电模式识别

杨 帆¹,王干军²,彭小圣¹,文劲宇¹,陈清江²,杨光垚¹,李朝晖¹ (1.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,湖北 武汉 430074; 2.广东电网公司中山供电局,广东 中山 528400)

摘要:由高压电缆不同类型缺陷诱发的局部放电(PD)的识别难度较大,尤其是某些相似度较高的电缆绝缘 缺陷类型难以区分。提出了一种基于卷积神经网络(CNN)的高压电缆 PD 模式识别方法,研究了不同网络 层数、不同激活函数以及不同池化方式对识别效果的影响,并与传统的支持向量机(SVM)和反向传播神经网 络(BPNN)算法进行了对比。结果表明,相比 SVM 和 BPNN, CNN 的总体识别精度分别提高了 3.71%和 4.06%,且能较好地识别具有高相似度的电缆缺陷类型。

关键词:高压电缆;局部放电;卷积神经网络;模式识别;深度学习

中图分类号:TM 761 文献标识码:A

DOI:10.16081/j.issn.1006-6047.2018.05.018

0 引言

高压电缆是电力系统重要的电力设备,其运行 状态影响着电网供电的安全性与可靠性^[1]。然而由 于设计缺陷、安装过程中的工艺缺陷、外力破坏、水 树入侵等因素,电缆系统中不可避免地会产生绝缘 缺陷^[1-2]。局部放电 PD(Partial Discharge)既是绝缘 劣化的主要原因,又是电缆绝缘缺陷和绝缘老化的 重要表征^[2]。电缆绝缘缺陷形式多样,不同缺陷类 型引发的 PD 具有不同的表现形式,对设备安全运 行的影响以及绝缘的危害程度也不同^[34]。准确识 别出电缆 PD 类型进而判断绝缘缺陷类型有着十分 重要的意义。利用电缆不同绝缘缺陷下 PD 产生机 理存在的差异性,通过对 PD 信号进行检测和特征 分析,可以识别绝缘缺陷类型,评估电缆的绝缘状 态,及时发现故障征兆,实现故障预警,为制定合理 的检修计划提供科学依据^[56]。

不同类型的电缆绝缘缺陷诱发的 PD 信号具有 一定的差异性,但是部分绝缘缺陷类型之间具有很 高的相似度,这给电缆 PD 模式识别带来了很大挑 战。电缆 PD 模式识别方面已有大量的研究成果, 其中以反向传播神经网络(BPNN)和支持向量机 (SVM)的应用较为广泛^[7-10]。传统 BPNN 由于网络 层数限制,对大规模样本的学习能力有限,在深层次 特征提取方面存在不足^[7-8]。SVM 也因核函数受 Mercer 条件限制、规则化参数选取困难以及当识别

收稿日期:2018-02-15;修回日期:2018-04-02

基金项目:国家自然科学基金资助项目(51541705);湖北省 自然科学基金资助项目(2016CFB536);中国南方电网公司 科技项目资助(GDKJXM20172769)

Project supported by the National Natural Science Foundation of China (51541705), the Natural Science Foundation of Hubei Province (2016CFB536) and the Science and Technology Program of China Southern Power Grid (GDKJXM20172769) 对象类型多时计算复杂等特点,而在实际应用中具有一定的局限性^[9-10]。

近年来深度学习理论引领了人工智能的前沿, 以卷积神经网络(CNN)为典型代表的深度学习算法 在语音识别、图像识别等诸多领域取得了很高的识 别精度,并在电力行业也引起了研究人员的广泛关 注^[11]。深度神经网络在敏感性与鲁棒性特征提取 与构建方面表现优异,能从海量数据中自动学习特 征信息,为电缆 PD 模式识别带来了新的契机。

本文提出了基于 CNN 的高压电缆 PD 模式识别 方法,首先在实验室环境下模拟了 5 种电缆绝缘缺 陷类型,通过加压测试获取了大量 PD 实验数据,然 后提取 PD 瞬时脉冲,并构建了 34 个特征参数,最 后利用 CNN 实现缺陷类型的识别。为证明所提方 法的有效性,本文分别研究了不同网络层数、不同激 活函数以及不同池化方式对 CNN 性能的影响,并在 电缆绝缘缺陷识别效果方面将 CNN 与传统的浅层 分类器 SVM 和 BPNN 进行了比较,结果表明 CNN 在识别精度和识别速度上都具有一定的优势,优于 传统的 BPNN 和 SVM 模式识别方法。

1 实验数据获取与特征构建

1.1 乙丙橡胶电缆与人工缺陷

实验选取实际电力系统中应用的 11 kV 乙丙橡 胶 EPR(Ethylene Propylene Rubber)电缆进行 PD 测 试。EPR 电缆由铝芯、内半导电层、EPR 层、外半导 电层、屏蔽铜带、铝铠甲层及聚氯乙烯 PVC(PolyVinyl Chloride)护套构成,如图 1 所示。实验采用无缺陷 电缆构建 5 种典型的电缆绝缘缺陷^[12-13] 如图 2 所 示,图中,各数据单位为 mm。

a. 电缆绝缘缺陷类型 1:绝缘层空穴,直径 0.4 mm, 深 2 mm。通过以下方法得到:使用直径 0.4 mm 的钻 头从外壁向电缆本体钻孔,在主绝缘产生圆柱形空 穴,然后将铜带固定在空穴上,与 PVC 护套接触,用





Fig.2 Five kinds of typical cable insulation defects 以密封缺陷。

b. 电缆绝缘缺陷类型 2:外半导体尖刺缺陷,直径 0.4 mm,深 2 mm,通过将印刷电路板钻头插入电缆中得到。

c. 电缆绝缘缺陷类型 3: 外半导体非接触性尖 刺缺陷,直径 0.4 mm, 深 2 mm, 通过将印刷电路板钻 头插入电缆中得到。电缆绝缘缺陷类型 3 与电缆绝 缘缺陷类型 2 的区别在于, 电缆绝缘缺陷类型 2 中 尖刺与外导体及 PVC 护套接触, 而缺陷类型 3 中的 尖刺则不与外导体及 PVC 护套接触。

d. 电缆绝缘缺陷类型 4:电缆外护套破损,通过 在电缆护套上切下面积为 7 mm×7 mm 的区域得到。 e. 电缆绝缘缺陷类型 5: 电缆端部沿面放电, 通 过将电缆样品屏蔽铜带的一部分暴露并接地得到。

1.2 实验建立与数据获取

采用结合高频电流互感器 HFCT (High Frequency Current Transformer)和 IEC60270的实验系统进行 PD 测试^[12-13],实验系统的连接示意图见图 3。图中,电压探头用于获取 50 Hz 相位信息并作为 PD 数据采集的触发装置,宽带放大器用于将 HFCT 耦合到的信号调整到示波器输入范围(±10 V)内,示波器以 100 MS/s(S/s 为采样点/s)的采样率采集原始数据。



图 3 实验系统原理图

Fig.3 Principle diagram of experiment system

EPR 电缆样品的长度为 1.5~2 m,每根电缆设 置图 2 所示的 5 种缺陷之一,然后连接到实验系统 进行 PD 测试。采样时间长度设置为 20 ms,即 50 Hz 工频周期。

实验电压从 0 开始以 1 kV 的步长增加到 PD 起始电压,直至超过预先设定的最大电压。对于电缆绝缘缺陷类型 1、4 和 5,最大电压为电缆额定电压,即 11 kV。对于缺陷类型 2 和 3,最大电压分别为 13 kV和 12 kV。表 1 列出了每次 PD 测试的电压水平和获取的相应原始数据的数目。

表 1 每种电缆绝缘缺陷的 PD 测试电压和原始数据数目

 Table 1 PD testing voltage and number of original data for each cable insulation defect type

| 绝缘 | | | | 厦 | 原始数: | 据数目 | | | | 台井 |
|----|----------|-------|------|----------|------|------------|-------|-----------|-------|-----|
| 类型 | $5 \ kV$ | 6 kV | 7 kV | $8 \ kV$ | 9 kV | $10 \; kV$ | 11 kV | $12 \ kV$ | 13 kV | 心口 |
| 1 | 50 | 50 | 50 | 50 | 50 | 50 | 50 | 0 | 0 | 350 |
| 2 | 0 | 50 | 50 | 50 | 54 | 50 | 54 | 53 | 52 | 409 |
| 3 | 0 | 51 | 50 | 50 | 26 | 50 | 52 | 61 | 0 | 340 |
| 4 | 0 | 0 | 50 | 50 | 51 | 52 | 51 | 0 | 0 | 254 |
| 5 | 0 | 0 | 10 | 10 | 10 | 10 | 10 | 0 | 0 | 50 |

基于 PD 测试原始数据提取 PD 瞬时脉冲,获得 了 5 种电缆绝缘缺陷对应的 PD 瞬时脉冲样本,并 对每种缺陷类型各挑选了 700 个样本用于后续的 PD 模式识别研究。5 种类型缺陷的 PD 相位谱图如 图 4 所示。从图 4 可以看出,电缆绝缘缺陷类型 2 和 3 对应 PD 信号的混叠程度相对较大。而结合 1.1 节中人工缺陷的构造可知,电缆绝缘缺陷类型 2 和 3 的区别为尖刺是否与外导体及 PVC 护套接触,差别 较小,因而诱发的局放信号区分度较低。



图 4 HFCT 耦合的 5 种 PD 信号的相位图谱

Fig.4 Phase diagram of five types of PD signals detected by HFCT

1.3 特征构建

特征构建是开展模式识别的基础。本文基于 1.2 节得到的 3 500 组 PD 瞬时脉冲信号,从频率、幅值、 相位图谱方面考虑并参考其他文献中广泛使用的特征,构建了 34 个 PD 脉冲的特征参数如下。

a. 幅值特征:放电量、峰值电压、平均电压、均方 根值、标准差。

b. 频率特征:脉冲宽度、上升时间、下降时间、 等效时间长度^[12-13]、等效宽度^[12-13]、主频、小波特征 参数(ED1-ED5,EA5,Ea1-Ea5,Ed1-Ed5)。其 中,小波特征参数获取方法为:使用小波变换对信号 进行5层分解,根据小波系数构造信号的小波特征 参数。ED1-ED5为分解后5层信号的细节能量比 参数,Ea1-Ea5为分解后5层信号的细节能量比参 数,Ed1-Ed5为分解后5层信号的细节能量参数, EA5为全局的能量比参数。

c. 相位图谱特征:相位角。

d. 其他特征:脉冲极性、偏度、峰度、波峰因数、 形状因子、PD 位置。

包括单位和示例在内的 PD 脉冲的特征参数的 详细信息如表 2 所示。

2 CNN

CNN 是受生物视觉系统结构的启发提出,能够 学习和识别视觉图像中的特定特征和模式^[11,14]。 20 世纪 60 年代,Hubel 等发现视觉信息从视网膜传 递到大脑进行处理由多层次的感受野激发完成^[14]。 1980 年 Fukushima 第一次提出基于感受野思想的自 组织多层神经网络模型 Neocognitron^[14]。1998 年 LeCun 等提出采用基于梯度的反向传播算法进行有 监督训练的 CNN—LeNet-5^[15]。2012 年 Krizhevsky 等提出的 AlexNet 在 ImageNet 图像分类竞赛中夺 冠,使得以 CNN 为代表的深度学习成为学术界关注 的焦点^[16-17]。CNN 由于出色的特征提取能力已经 被广泛的应用在图像识别、语音识别等领域。

2.1 典型 CNN 架构

典型 CNN 结构见图 5,其由输入层、1 个或多个 交替连接的卷积层和池化层、全连接层以及输出层 组成^[11]。CNN 的输入为二维数据矩阵,即原始图像。

表 2 PD 特征 Table 2 PD features

| 索引 | 特征名 | 单位或取值 | 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 | ED1—ED5 | — | 15.08 |
| 特征 24 | EA5 | — | 49.49 |
| 特征 25—29 | Ea1—Ea5 | — | 682.47 |
| 特征 30—34 | Ed1—Ed5 | | 149.65 |

卷积层可直接从二维图像中提取特征并形成特征 图,多个卷积层间穿插池化层能够减小特征图大小 并逐渐建立更高程度的空间和结构不变性。经过多 个卷积层和池化层的交替传递,全连接层使用所提 取的特征进行预测。最后由输出层给出识别结果。 CNN本质上是使原始输入经过多个层次的数据变换 与降维而映射到一个新的特征表达的数学模型^[14]。



Fig.5 Structure of CNN

a. 卷积层。

卷积层的卷积核完成感受野的功能,可以将低 层的局部区域信息通过卷积核激发到更高层次。前 一层的输入特征图与可学习的卷积核进行卷积运 算,卷积后的数据经激活函数作用后得到该层的输 出特征图。

b. 非线性激活函数层。

激活函数用来在网络中加入非线性,对 CNN 性能有着重要影响。典型的非线性激活函数有双曲正切函数(tanh)、Sigmoid 函数和 ReLU 函数等^[17]。

Google Brain 团队提出了一种新型自门控激活 函数 Swish,其具备无上界有下界、平滑且非单调的 特性^[18]。Google Brain 团队指出,Swish 在深度学习 模型上的性能优于 ReLU 函数,训练 Swish 网络时使用稍低于 ReLU 网络的学习率可取得更好效果^[18]。

c. 池化层。

原始输入特征图包含的特征数目较多,直接使 用从卷积层得到的所有特征可能会使计算开销过 大。池化操作对池化窗口内的特征进行聚合统计, 能减小特征图尺寸,实现数据降维。不同池化方法 的效果存在差异。目前2种主流的池化方式为最大 池化和平均池化。最大池化选取池化窗口内的最大 值形成输出特征,是现阶段应用最广泛的池化方式, 平均池化函数则是在池化窗口内取输入的平均值。

d. 全连接层。

在 CNN 架构的最后通常设置一个全连接层。 该层网络使用卷积层和池化层的输出特征进行预测 和分类。

2.2 训练方法

CNN 一般使用梯度下降法进行有监督训练。 CNN 中所有滤波器的权重都通过训练过程进行迭 代更新以使损失函数最小化。标准梯度下降法在整 个训练数据集上更新权重,计算开销太大。小批量 随机梯度下降算法通过小批量训练样本集上的平均 梯度来更新权重,可以有效减小计算代价^[18]。

3 基于 CNN 的 PD 模式识别

基于 CNN 的 PD 模式识别流程如图 6 所示。首 先开展 5 种电缆绝缘缺陷的测试实验并收集原始数 据,进行数据去噪和 PD 脉冲提取,构建 34 个 PD 特 征参数得到 PD 特征数据集。然后将特征数据集分 为训练集和测试集(两者所占比重分别为 85% 和 15%),通过在训练集上使用小批量随机梯度下降算 法以最小化模型预测输出和实际输出之间的误差来 训练优化 CNN,通过测试集来评估基于 CNN 的 PD 模式识别性能。





Fig.6 Flowchart of PD pattern recognition based on CNN

4 结果与评估

本节对 CNN 的分类性能进行评估,研究了不同

网络层数、不同激活函数和不同池化方式对 PD 模式识别效果的影响,并与浅层分类器 BPNN 和 SVM 进行了比较。所使用的计算机配置为:Windows 7 操 作系统,Intel i5-4200M CPU,12 G 内存。

4.1 不同网络层数 CNN 的比较

研究表明,CNN 分类性能与网络层数有较大相 关性^[19]。本文分别测试了1层、2层、3层、4层、6 层和9层 CNN 的性能,使用的池化方式为最大池 化,激活函数采用 ReLU 函数,每层的卷积核数目均 为32,卷积核大小均为3×3,测试结果见表3和图7。

表 3 不同层数 CNN 的识别精度

Table 3 Recognition accuracy of CNN with different layers

| 网络层数 | 识别精度/% | 网络层数 | 识别精度/% |
|------|--------|------|--------|
| 1 | 87.32 | 4 | 84.36 |
| 2 | 89.97 | 6 | 82.21 |
| 3 | 86.07 | 9 | 79.89 |
| 0.7 | r . Û | | |



图 7 不同网络层数的 CNN 的 PD 模式识别误差对比 Fig.7 Comparison of PD pattern recognition error among CNN with different layers

当网络层数减少时,CNN 对样本数据的拟合能 力会降低;当网络层数增加时,CNN 的学习能力增 强,但所需训练的参数会增多,对样本数据量的需求 也会相应增大,对于小样本数据会产生过拟合的风 险^[18-19]。而本文有3500个样本,数量较少,对应的 最佳网络层数也应该较少。由图7可知,2层 CNN 效果最好,不同迭代轮次的误差率均低于其他网络 层数的 CNN,并且当步数达到40时,模型误差率降 低到10.03%。

4.2 采用不同激活函数的 CNN 的比较

不同类型的激活函数对识别效果会产生较大的 影响^[18]。基于前文设计的 2 层 CNN,本文比较了 Swish 函数的 ReLU 函数的性能,结果如图 8 所示。



---- CNN(Swish,最大池化)

图 8 不同池化方式和激活函数 CNN 识别误差对比

Fig.8 Comparison of recognition error among CNN with different pooling modes and activation functions Swish 函数无上界有下界、平滑且非单调的特点 使其收敛性能好于 ReLU 函数。由图 8 可见,使用 Swish 函数的 CNN 在不同迭代轮次的误差均小于使 用 ReLU 函数的 CNN;在迭代至 40 轮的时候,采用 Swish 函数的识别精度比使用 ReLU 函数高 0.7%。

4.3 采用不同池化方式的 CNN 的比较

基于 Swish 函数的 2 层 CNN,本文还比较了最 大池化和平均池化方式的性能,结果见图 8。由图 8 可见,最大池化方式由于能够提取最有表征能力的 特征,相比平均池化方式具有更好的识别精度。

4.4 CNN 识别混淆矩阵

根据前文分析,本文最终使用的 CNN 架构包含 2 个卷积层和 2 个池化层,采用最大池化方式和 Swish 激活函数,每个卷积层的卷积核数目为 32,卷 积核大小为 3×3。CNN 模式识别的混淆矩阵见表4。

表 4 CNN 识别混淆矩阵 Table 4 Confusion matrix of CNN recognition

| | | | | | | _ |
|------|--------|--------|--------|--------|--------|---|
| 混淆程度 | 目标 1/% | 目标 2/% | 目标 3/% | 目标 4/% | 目标 5/% | |
| 输出1 | 95.37 | 1.68 | 1.83 | 0 | 0 | |
| 输出2 | 0.93 | 80.86 | 18.21 | 0 | 0 | |
| 输出3 | 3.70 | 17.40 | 78.90 | 0 | 0 | |
| 输出4 | 0 | 0.84 | 0 | 99.07 | 0.85 | |
| 输出5 | 0 | 0 | 0 | 0.93 | 99.15 | |

由表4可知,电缆绝缘缺陷类型2和3是PD模 式识别误差的主要来源,这2种类型的识别结果之 间存在较大程度的混淆。电缆绝缘缺陷类型3的样 本有17.40%被误识别为电缆绝缘缺陷类型2,电缆 绝缘缺陷类型2的样本则有18.21%被误识别为电 缆绝缘类型3,这在很大程度上降低了总体识别率。 5种电缆绝缘缺陷类型中,电缆绝缘缺陷类型4和5 与其他3种类型的表现形式差异最大,识别精度也 最高,分别达到了99.07%和99.15%,这印证了1.3 节中关于PD相位谱图的分析。

4.5 与传统浅层分类器的比较

本文比较了 CNN 与 BPNN 和 SVM 的性能,结 果如表 5 和图 9 所示。

从表5可知:3种方法中CNN的总体精度最高, 达到了90.67%;SVM其次,总体精度为86.96%; BPNN最差,总体精度为86.61%;CNN方法的总体

| 表 5 | CNN. | BPNN | 和 | SVM | 的识别精 | 度对り |
|-----|------|------|---|-----|------|-----|
|-----|------|------|---|-----|------|-----|

Table 5 Comparison of recognition accuracy among CNN BPNN and SVM

| among C. | among CNN, BPNN and SVM | | | | | |
|----------|-------------------------|--------|-------|--|--|--|
| 山桃旗坞劫吃米刑 | | 识别精度/% |) | | | |
| 电现纪缘吠阳关望 | CNN | BPNN | SVM | | | |
| 1 | 95.37 | 95.37 | 95.37 | | | |
| 2 | 80.86 | 77.31 | 66.66 | | | |
| 3 | 78.90 | 62.39 | 73.70 | | | |
| 4 | 99.07 | 99.07 | 98.13 | | | |
| 5 | 99.15 | 99.15 | 99.15 | | | |
| 总体精度 | 90.67 | 86.61 | 89.96 | | | |



图 9 CNN、BPNN 和 SVM 的识别误差对比 Fig.9 Comparison of recognition error among CNN, BPNN and SVM

精度分别比 BPNN 和 SVM 高 4.06% 和 3.71%。

由于电缆绝缘缺陷类型 1、4、5 的差异较为明显,比较容易识别,CNN 对三者的识别精度分别为 95.37%、99.07%和 99.15%,与 BPNN 和 SVM 方法相同。而电缆绝缘缺陷类型 2 和 3 的相似度较高,识别难度较大。CNN 特殊的网络结构能够对数据特征进行深入挖掘,可以较好地捕捉细节信息并学习到更全面、更抽象的特征。CNN 对电缆绝缘缺陷类型 2 的识别精度为 80.86%,相比 BPNN 和 SVM 分别提高了 3.55%和 14.20%;CNN 对电缆绝缘缺陷类型 3 的识别精度为 78.90%,相比 BPNN 和 SVM 分别提高了 16.51%和 5.20%。

5 结论

本文将 CNN 应用于 5 种高压电缆缺陷类型的 模式识别,研究了不同网络层数、不同激活函数和不 同池化方式下 CNN 的性能,并与传统方法的识别效 果进行了比较,得到的结论如下:

a. 网络层数、激活函数、池化方式、迭代轮数对 CNN 的识别精度具有较大的影响,在 CNN 构建时, 应该充分考虑这些因素;

b. 采用 Swish 函数的情况下,CNN 的识别精度比 采用 ReLU 函数的情况高 0.70%,Swish 函数无上界有 下界、平滑且非单调的特点使其收敛性能好于 ReLU;

c. CNN 中的卷积层和池化层具有优异的特征 学习能力,可以捕捉到数据的细节特征,信息丢失 少,对高相似度缺陷识别能力强、鲁棒性好,对于相 似度较高的电缆绝缘缺陷类型 2 和 3 的识别精度, 相比 SVM 分别提高了 14.20%和 5.20%,相比 BPNN 分别提高了 3.55%和 16.51%;

d. CNN 能更全面地捕捉到输入数据表现的高阶相关性,在顶层形成更具表征能力的高维抽象特征向量,相比传统浅层分类器 BPNN 和 SVM,总体识别精度分别提高了4.06%和3.71%。

参考文献:

- [1] WANG X, WANG C C, WU K, et al. An improved optimal design scheme for high voltage cable accessories [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2014, 21(1):5-15.
- [2] 王德文,刘晓建. 基于 MapReduce 的电力设备并行故障诊断方法[J]. 电力自动化设备,2014,34(10):116-120.

WANG Dewen, LIU Xiaojian. Parallel fault diagnosis based on Map-Reduce for electric power equipments[J]. Electric Power Automation Equipment, 2014, 34(10):116-120.

[3] International Electrotechnical Commission. High-voltage test techniques: partial discharge measurements: IEC60270 [S]. Geneva, Switzerland: International Electrotechnical Commission, 2015.

128

 [4] 孙文星,李朝晖,程时杰,等.一种发电机故障放电信号特征实时在线自动识别方法及其应用[J].电网技术,2015,39(2): 543-549.

SUN Wenxing, LI Zhaohui, CHENG Shijie, et al. A real time on-line method for automatic signal feature recognition of fault discharge in generator and its application [J]. Power System Technology, 2015, 39(2):543-549.

- [5]魏振,齐波,左健,等. 基于局部放电图像特征的换流变压器油 纸绝缘缺陷诊断方法[J]. 电网技术,2015,39(4):1160-1166.
 WEI Zhen,QI Bo,ZUO Jian, et al. A method to diagnose defects in oil-paper insulation of converter transformer based on image feature of partial discharge[J]. Power System Technology,2015,39(4): 1160-1166.
- [6]常文治,李成榕,苏錡,等. 电缆接头尖刺缺陷局部放电发展过程的研究[J]. 中国电机工程学报,2013,33(7):192-201,S25.
 CHANG Wenzhi,LI Chengrong,SU Qi, et al. Study on development of partial discharges at the defect caused by a needle damage to a cable joint [J]. Proceedings of the CSEE, 2013, 33(7):192-201,S25.
- [7] SCHAIK N V, CZASZEJKO T. Conditions of discharge-free operation of XLPE insulated power cable systems [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2008, 15(4):1120-1130.
- [8] WU M, CAO H, CAO J, et al. An overview of state-of-the-art partial discharge analysis techniques for condition monitoring [J]. IEEE Electrical Insulation Magazine, 2015, 31(6):22-35.
- [9] 尹金良,朱永利,俞国勤,等. 相关向量机及其在变压器故障诊断中的应用[J]. 电力自动化设备,2012,32(8):130-134.
 YIN Jinliang, ZHU Yongli, YU Guoqin, et al. Relevance vector machine and its application in transformer fault diagnosis[J]. Electric Power Automation Equipment,2012,32(8):130-134.
- [10] 张哲,赵文清,朱永利. 基于支持向量机的电力变压器状态评估
 [J]. 电力自动化设备,2010,30(4):81-84.
 ZHANG Zhe,ZHAO Wenqing,ZHU Yongli. Power transformer condition evaluation based on support vector machine [J]. Electric Power Automation Equipment,2010,30(4):81-84.
- [11] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015,521(7553):436-444.

- [12] PENG X, WEN J, LI Z, 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.
- [13] PENG X, WEN J, LI Z, et al. Rough set theory applied to pattern recognition of partial discharge in noise affected cable data [J].
 IEEE Transactions on Dielectrics and Electrical Insulation, 2017, 24 (1):147-156.
- [14] LEE Y P. Multidimensional Hebbian learning with temporal coding in neocognitron visual recognition [J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2017, 47(12): 3386-3396.
- [15] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998,86(11):2278-2324.
- [16] DONG C, LOY C C, HE K, et al. Image super-resolution using deep convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295-307.
- [17] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016:2818-2826.
- [18] ELFWING S, UCHIBE E, DOYA K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning [J/OL].(2017-12-12)[2018-01-11]. https://doi.org/10.1016/j. neunet.2017.12.012.
- [19] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks [C] // European Conference on Computer vision. Cham, Switzerland: Springer, 2014:818-833.

作者简介:



杨 帆(1995—),男,陕西西安人,硕 士研究生,主要研究方向为电力设备状态 监测与故障诊断、新能源功率预测等;

彭小圣(1983—),男,湖北随州人,博 士,IEEE 会员,通信作者,主要研究方向为 电力系统大数据理论与应用、电力系统主

设备状态监测与故障诊断、局部放电信号提取与模式识别、 新能源功率预测等(E-mail;xiaoshengpeng@hust.edu.cn)。

Partial discharge pattern recognition of high-voltage cables based on convolutional neural network

YANG Fan¹, WANG Ganjun², PENG Xiaosheng¹, WEN Jinyu¹, CHEN Qingjiang², YANG Guangyao¹, LI Zhaohui¹ (1. State Key Laboratory of Advanced Electromagnetic Engineering and Technology, School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;

2. Zhongshan Power Supply Bureau of Guangdong Power Grid Corporation, Zhongshan 528400, China)

Abstract: The recognition of PD (Partial Discharge) caused by different types of defects in high-voltage cables is difficult, especially the recognition of PD caused by cable insulation defects with high similarity. The CNN (Convolutional Neural Network)-based PD pattern recognition method for high-voltage cables is presented. The influences of different network layers, activation functions and pooling methods of CNN on recognition effect are studied. The proposed method is also compared with SVM (Support Vector Machine) and BPNN (Back Propagation Neural Network) method, and the results show that the overall recognition accuracy of CNN is respectively 3.71% and 4.06% higher than that of SVM and BPNN. Furthermore, it is proved that the cable insulation defects with high similarity can be effectively recognized by CNN.

Key words: high-voltage cables; partial discharge; convolutional neural network; pattern recognition; deep learning