第 50 卷 第 1 期：423-431 高电压技术 Vol.50, No.1: 423-431
2024 年 1 月 31 日 High Voltage Engineering January 31, 2024
**DOI**: 10.13336/j.1003-6520.hve.20222053

# 基于卷积神经网络与可视图像的类滑动放电模式识别

潘如政[1,2]，李怀宇[1,2,3]，崔 巍[4]，曾 鑫[3,5]，张 帅[3,5]，邵 涛[3,5]
（1. 河北工业大学河北省电磁场与电器可靠性重点实验室，天津 300400；2. 河北工业大学省部共建电工装备可靠性与智能化国家重点实验室，天津 300400；3. 中国科学院电工研究所等离子体科学和能源转化北京市国际科技合作基地，北京 100190；4. 空军工程大学等离子体动力学重点实验室，西安 710038；5. 中国科学院大学，北京 100049）

**摘 要**：为了提高机器学习算法对类滑动放电模式识别的准确率，提出了一种基于卷积神经网络(convolutional neural networks, CNN)与可视图像识别电晕放电、弥散放电和类滑动放电等模式的方法。通过选取气体体积流量 0~16 L/min、电极间隙 2~10 mm、脉冲频率 0.5~3 kHz 等不同条件下的类滑动放电图像构建图像库，搭建 CNN 模型并优化影响 CNN 识别性能的超参数，包括网络层数、全连接层(full connected layer, FC)神经元数、卷积核尺寸以及激活函数类型，最后比较了 CNN 与决策树(decision tree, DT)算法和随机森林(random decision forests, RF)算法的识别效果。结果表明，CNN 识别准确率为 100%，高于传统机器学习方法。此外，本文还给出了放电模式及条件参数，通过基于反向传播神经网络(back propagation neural networks, BPNN)的聚类分析算法识别弥散放电和类滑动放电，并且准确率为 100%。

**关键词**：类滑动放电；可视图像；卷积神经网络；机器学习；模式识别；参数调控

## Pattern Recognition of Microsecond Pulsed Sliding-like Discharge Based on Convolutional Neural Network and Visual Image

PAN Ruzheng[1,2], LI Huaiyu[1,2,3], CUI Wei[4], ZENG Xin[3,5], ZHANG Shuai[3,5], SHAO Tao[3,5]
(1. Key Laboratory of Electromagnetic Field and Electrical Apparatus Reliability of Hebei Province, Hebei University of Technology, Tianjin 300400, China; 2. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300400, China; 3. Beijing International S&T Cooperation Base for Plasma Science and Energy Conversion, Institute of Electrical Engineering, Chinese Academy of Sciences, Beijing 100190, China; 4. Science and Technology on Plasma Dynamics Laboratory, Air Force Engineering University, Xi'an 710038, China; 5. University of Chinese Academy of Sciences, Beijing 100049, China)

**Abstract**: In order to improve the accuracy of machine learning algorithms in recognizing sliding-like discharge patterns, this paper proposes a method based on convolutional neural network (CNN) and visual images which recognizes corona discharge, diffuse discharge, and gliding-like discharge patterns. The image library is constructed by selecting sliding-like discharge images under different conditions such as a gas flow rate of 0~16 L/min, an electrode gap of 2~10 mm, and a pulse frequency of 0.5~3 kHz. Then CNN is built, and the hyperparameters which affect the recognition performance of CNN are optimized, including the number of the network layer, the number of the neuron in the Full Connection (FC) layer, the size of the convolution kernel, and the type of the activation function. Finally, the recognition performance of CNN and Decision Tree (DT) algorithm and Random Forest algorithm (RF) algorithm is compared. The results show that the accuracy of CNN recognition is 100%, which is higher than that of the traditional machine learning method. In addition, the discharge mode and the condition parameters are given. Through the clustering analysis algorithm based on Back Propagation Neural Networks (BPNN), the diffuse discharge and sliding-like discharge are identified, and the accuracy is 100%.

**Key words**: sliding-like discharge; visual image; convolutional neural network; machine learning; pattern recognition; parameter regulation

**基金资助项目**：国家杰出青年基金(51925703)；国家自然科学基金(52077205)；中国科学院创新促进会项目(2022136)。
Project supported by National Science Fund for Distinguished Young Scholars(51925703), National Natural Science Foundation of China (52077205), Youth Innovation Promotion Association of CAS (2022136).

## 0 引言

类滑动放电是产生非平衡等离子体的有效途径之一，在环保、工业和社会生活等领域的应用广泛[1-4]。大气压类滑动放电装置在放电过程中，随着电压升高会出现 3 种放电模式，即电晕放电(corona discharge)、弥散放电(diffuse discharge)和类滑动放电(sliding-like discharge)[4-5]。电晕放电通常在不均匀电场中产生，不能击穿电极间隙的气体，放电仅在电极周围区域。放电面积小且强度较弱，在污染治理等方面应用广泛[6]。弥散放电表现为从强场处产生的放电通道相互交叠，贯穿两极，但未形成火花通道，被认为大气压均匀放电的理想放电模式，具有面积大、密度高的优点，已经成功应用在电化学、空气净化等领域[5-7]。类滑动放电是一种电极最窄间隙处产生的放电通道在气流的作用下，沿着气流方向滑动的气体放电形式，具有加热效率高和可操作性强的优点，已被广泛应用于环境保护和辅助燃烧等领域[4-7]。因此对气体放电特性的理解与模式的识别对其工业应用是十分重要的。

随着人工智能的发展，机器学习越来越多的应用在放电模式识别领域。Iwata 等采用 K 临近回归(K-nearest neighbor, KNN)[8]，逻辑回归(logistic regression, LR)[9]，决策树(decision tree, DT)[10]，随机森林(random decision forests, RF)[11]4 种机器学习算法识别电气绝缘系统局部放电(partial discharge, PD)模式，并评估了每种算法对参数的依赖性[12]。Raymond 等提出了一种基于卷积神经网络的局部放电系统，该系统在高噪声污染下，准确率比传统方法高 16.9%[13]。Lu 等使用数码相机拍摄了不同条件下的表面微放电图像，将其作为 CNN 的输入，通过放电图像的亮度预测放电模式，并研究了影响识别精度的超参数[14]。张翼等提取变压器油纸绝缘中的局部放电时频谱构建图信号，采用图卷积网络融合图信号的节点特征和拓扑结构诊断局部放电类型[15]。陈建宁等将油纸绝缘局部放电相位分布图谱进行预处理作为多通道卷积神经网络的输入，对放电进行模式识别，最终结果表明，该方法与支持向量机、反向传播神经网络等传统方向相比准确率有较大提升；与 Vgg、ResNet、DenseNet 等深度卷积神经网络相比，该方法过拟合得到改善[16]。目前对放电模式识别的研究多将放电的脉冲波形[17]、时频信号[18]、超高频电磁波[19]和声源信号[20]等数据特点作为模式识别的依据，而没有考虑放电的光学特点。放电图像包含丰富的颜色、亮度、形状等信息，对于确定放电的形貌比电磁测量更适合。将放电的光学特性结合到放电模式的诊断中，可以大大提高传统机器学习方法识别的准确率[21]。

传统的机器学习算法 DT 和 RF 适用于图像分类任务，DT 和 RF 算法本质上是在样本库的数据中总结归纳出一组分类规则，按此规则执行分类任务。但 DT 和 RF 算法需要手动提取图像特征，且样本量要求较高。CNN 是深度学习的代表算法之一，能够进行适应性计算，有一定的学习能力。CNN 在处理图像数据时，通过卷积操作自行提取图像特征，并对提取的特征进行非线性组合，得到分类输出。CNN 具有涉及的网络参数少、计算复杂度低和泛化能力强的优点[14]，更适合本文对类滑动放电模式识别的研究。

因此本文提出了一种基于卷积神经网络与可视图像的类滑动放电模式识别方法。通过选取不同气体体积流量、脉冲频率、电极间隙和电压的类滑动放电图像搭建用于 CNN 训练和验证的图像库。优化了影响 CNN 性能的网络深度、FC 神经元数、卷积核尺寸和激活函数类型等超参数。比较了 CNN 与 DT 和 RF 两种传统机器学习算法的性能。此外，给出了放电模式及条件参数，通过基于 BPNN 的聚类分析算法，使用放电条件(气体体积流量、脉冲频率、电极间隙和电压)预测放电模式，为通过参数调控放电模式提供参考。

## 1 实验部分

### 1.1 实验装置与拍摄

本文训练 CNN 模型的图像为类滑动放电图像，拍摄放电图像的实验装置如图 1 所示。电源幅值 0~30 kV，脉冲宽度 8 μs，上升沿约 0.5 μs，脉冲重复频率 1~3 kHz。电极为直径 2 mm，长度 15 cm 的钨针。空气压缩机产生压缩气体，气体体积流量由浮子流量计控制。使用 Canon EOS500D 数码相机和腾龙镜头(ModelA001)拍摄放电图像，相机拍摄方向与电极轴线方向垂直且二者保持一致，相机放置在距电极 1 m 处。有关实验的详细信息可参阅文献[5-6]。

### 1.2 建立图像库

为了提高 CNN 的泛化能力，本文选取了不同参数条件下的类滑动放电图像，具体条件见表 1。选取 3 种放电模式共 150 张图像(每种各 50 张)，其

能反映参数值范围内每种放电光学特性的变化。相机拍摄的图像为4096像素×2731像素，在训练CNN模型时速度较慢。因此使用基于Python的OpenCV (OpenCV 4.6.0)模块截取图像中央896像素×896像素的信息(该区域包含放电的全部光学信息)，将处理过的图像压缩4倍(只改变图像的尺寸而不影响图像中的信息)，得到224像素×224像素的图像，从而提高模型训练速度，并且能够保证图像的有效信息不会遗漏。

### 1.3　搭建CNN

CNN对输入数据进行卷积操作提取特征[22]，具有涉及的网络参数少、计算复杂度低和泛化能力强的优点[14]，已被广泛应用于自然语言处理[23]、语音识别[24]、图像识别[25]、对象检测[26]和医学诊断[27]等领域。

典型CNN结构包括输入层、隐含层和输出层[28]，本文搭建的CNN架构如图2所示，包含输入层、卷积层、最大池化层、完全连接层和输出层各1个。使用“RGB”三通道图像作为输入，输入层接收数据维度224×224×3，224×224表示输入为224像素×224像素的图像，维度3表示输入层3个通道分别接收图像的红色、绿色和蓝色分量。卷积层由卷积核对输入数据进行卷积操作提取图像特征，卷积核设置10个，尺寸3×3×3。池化层可以有效减小参数矩阵的尺寸，从而减少连接层中参数的数量。本文池化方式为最大池化，池化核尺寸3×3。FC神经元数为64。常用的激活函数(activation function)有sigmoid函数、tanh函数和ReLU函数[29]，本文采用ReLU函数为神经元引入非线性因素。最后采用适用于多分类问题的Softmax逻辑回归作为多分类输出层。

本文搭建神经网络的环境为Python 3.10.0，框架为Pytorch 1.12.0+cpu。

### 1.4　CNN模型训练

将样本库150个样本按照7:3的比例随机划分为训练集和验证集。使用训练损失(Loss)和准确率(A)评价CNN的识别效果。使用交叉熵损失(cross entropy loss)函数计算Loss值，Loss表示预测值与真实值之间的差距。准确率由机器学习sklearn库中内置函数accuracy_score计算，其原理见式(1)。学习率衰减方法为：使用Adam优化器[30]，训练每迭代10次，学习率将减小为之前的0.1倍。训练迭代次数设置为100。

$$A=\frac{T_{\mathrm{N}}+T_{\mathrm{P}}}{T_{\mathrm{N}}+F_{\mathrm{N}}+T_{\mathrm{P}}+F_{\mathrm{P}}} \tag{1}$$

其中各项含义见表2。

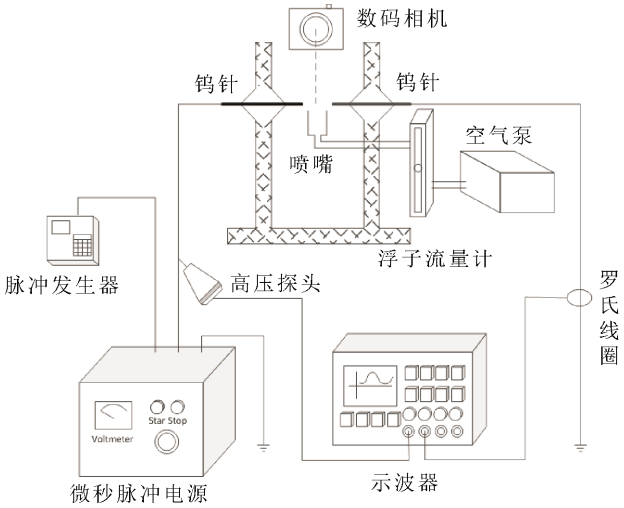



图1　实验装置示意图

Fig.1　Schematic view of the experimental set-up

表1　放电条件参数

Table 1　Condition parameters of discharge

| 参数类型 | 参数值 |
|---|---|
| 脉冲频率/kHz | 0.5、1、1.5、2、2.5、3 |
| 气体体积流量/ (L·min$^{-1}$) | 0、2、4、6、8、10、12、14、16 |
| 电极间隙/mm | 2、4、6、8、10 |

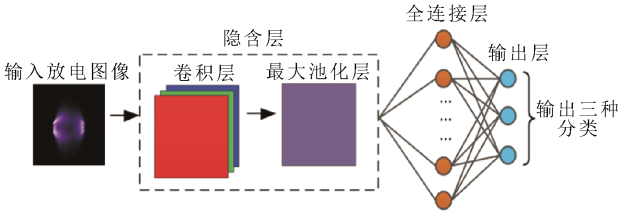



图2　CNN结构示意图

Fig.2　Structure diagram of CNN

表2　混淆矩阵

Table 2　Confusion matrix

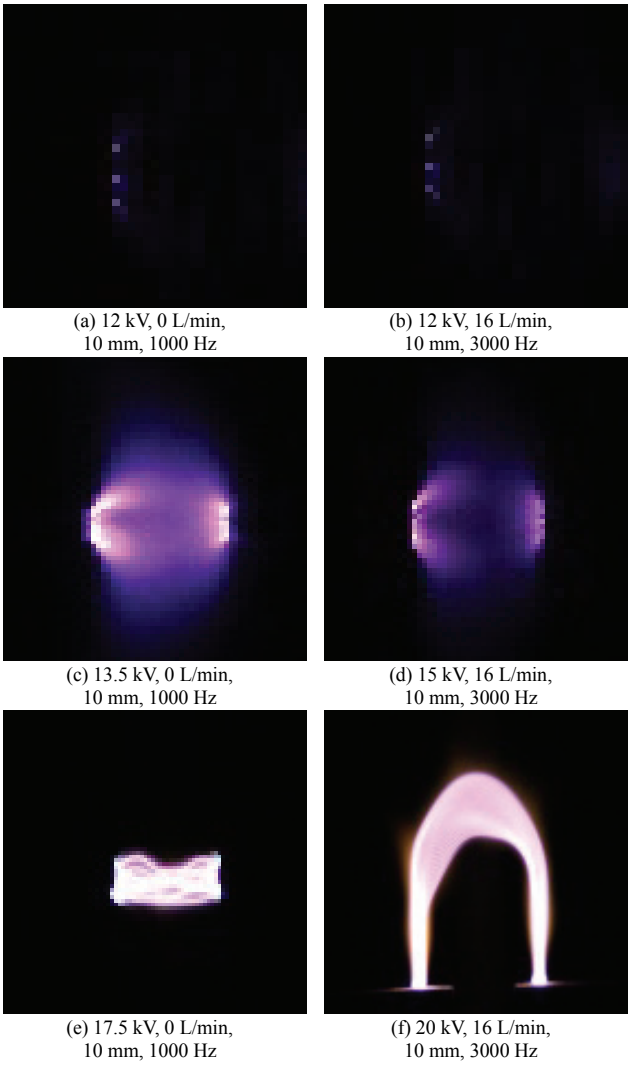
| 真实值 | 矩阵参数 | |
|---|---|---|
| | 预测值为0 | 预测值为1 |
| 0 | $T_{\mathrm{N}}$ | $F_{\mathrm{P}}$ |
| 1 | $F_{\mathrm{N}}$ | $T_{\mathrm{P}}$ |

注：$F_{\mathrm{P}}$：预测为1，预测错误，实际0；$T_{\mathrm{P}}$：预测为1，预测正确，实际1；$F_{\mathrm{N}}$：预测为0，预测错误，实际1；$T_{\mathrm{N}}$：预测为0，预测正确，实际0。

## 2 结果与讨论

### 2.1 类滑动放电模式分类

随着施加在钨针电极电压的增大，放电出现 3 种模式，即电晕放电、弥散放电和类滑动放电[5-7]。电晕放电图像如图 3(a)和 3(b)所示，电晕放电只在曲率半径很小的高压电极(阳极)附近出现，且放电发光强度较弱，脉冲频率和气体体积流量会影响电晕放电的起始电压，而不会影响电晕放电的颜色与形态[2]。电极间隙小于 6 mm 时，不会出现电晕放电，随着电压升高直接出现弥散放电。弥散放电图像如图 3(c)和 3(d)所示，高压电极端部向四周各个方向发出弥散放电，通道互相交叠，并贯穿整个气隙，并没有明显的放电细丝，此时放电表现为弥散放电模式[31-33]。脉冲频率、气体体积流量和电极间隙会影响弥散放电的起始电压，但不会影响弥散放电的颜色与形态[5-6]。类滑动放电图像如图 3(e)和 3(f)所示，针-针电极间隙发生击穿，放电通道沿气流方向随着不同的气体体积流量产生不同程度的偏移，形成彼此分散的放电通道，放电形式与常规的滑动弧放电类似，因此称之为类滑动放电[34-36]。气体体积流量和脉冲频率会对类滑动放电的起始电压和放电的形貌产生很大的影响[5-6]。



(a) 12 kV, 0 L/min, 10 mm, 1000 Hz
(b) 12 kV, 16 L/min, 10 mm, 3000 Hz
(c) 13.5 kV, 0 L/min, 10 mm, 1000 Hz
(d) 15 kV, 16 L/min, 10 mm, 3000 Hz
(e) 17.5 kV, 0 L/min, 10 mm, 1000 Hz
(f) 20 kV, 16 L/min, 10 mm, 3000 Hz

图 3 不同放电条件对应的放电图像

Fig.3 Discharge images corresponding to different discharge conditions

### 2.2 CNN 超参数优化

#### 2.2.1 网络层数优化

CNN 在卷积层通过卷积操作提取输入数据的特征，卷积层越多神经网络的特征抽象程度越高，即深层神经网络对输入数据的理解更加深入。但随着网络层数增加，容易出现过拟合问题，即神经网络只能识别图像库的图像，与图像库图像稍有不同的图像将无法识别，CNN 泛化能力降低[37]。此外，网络层数过多可能会限制 CNN 浅层网络的学习能力，降低网络的学习效率[38]。

本文搭建了 4 个不同深度的 CNN，具体结构见表 3，其卷积核尺寸为 3×3，FC 神经元数为 64，激活函数类型为 ReLU。网络深度对识别准确率的影响如图 4(a)所示，网络深度为 5 时，识别准确率为 97.83%。网络深度为 7 和 9 时，准确率为 100%。网络深度为 11 时，准确率为 82.61%。网络深度对训练损失的影响如图 4(b)所示，网络深度 7 和 9 的训练损失较低，9 层的训练损失总体上低于 7 层，约 0.08，因此适用于本文研究内容的 CNN 网络深度为 9。

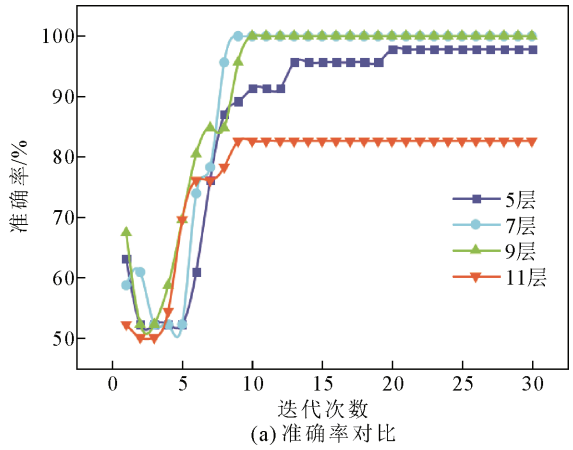
表 3 4 个不同深度的 CNN 结构

Table 3 Four CNN structure with different depths

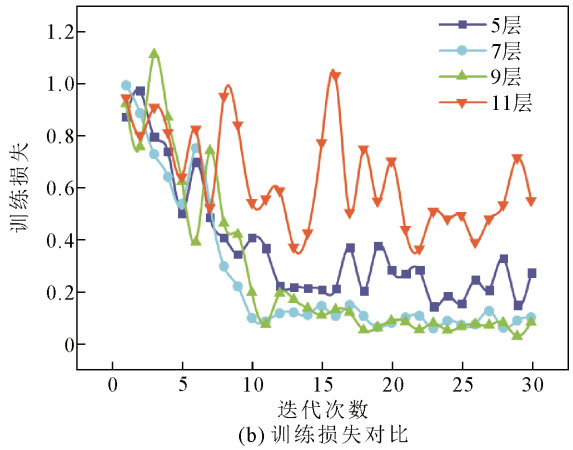
| 结构深度 | 输入层数 | 卷积层数 | 池化层数 | 全连接层数 | 输出层数 |
|---|---|---|---|---|---|
| 5 层 | 1 | 1 | 1 | 1 | 1 |
| 7 层 | 1 | 2 | 2 | 1 | 1 |
| 9 层 | 1 | 3 | 3 | 1 | 1 |
| 11 层 | 1 | 4 | 4 | 1 | 1 |

#### 2.2.2 FC 神经元数优化

全连接层每个节点都与上一层所有节点相连，能把卷积层提取的特征综合起来。FC 神经元数对 CNN 性能有很大的影响。神经元数过多，训练模型的数据增加，造成网络过度填充，导致网络训练困难。但神经元数过少会导致 CNN 不能有效捕获输入数据的特征空间，导致网络性能不达标。




(a) 准确率对比




(b) 训练损失对比

图 4　不同网络深度的 CNN 识别结果对比

Fig.4　Comparison of CNN recognition results with different network depths

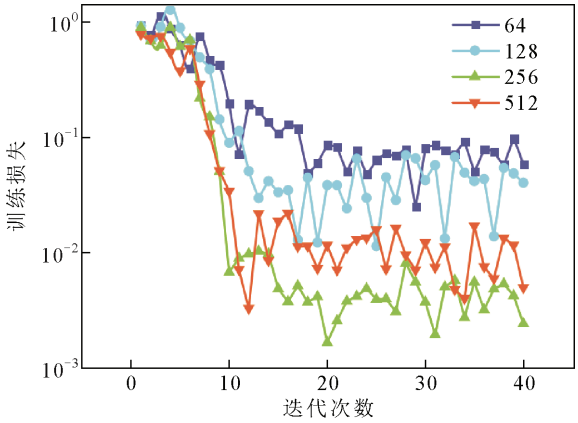



图 5　不同 FC 神经元数对训练损失的影响

Fig.5　Effect of different FC neuron numbers on training loss

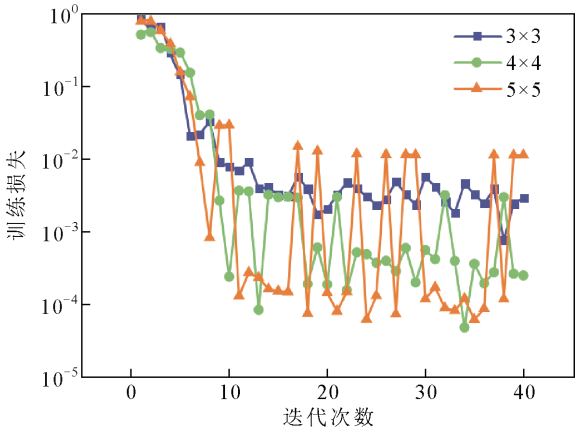



图 6　不同卷积核尺寸对训练损失的影响

Fig.6　Effect of different convolution kernel size on training loss

本节对比了不同 FC 神经元数对训练损失的影响，测试网络深度选择 9 层，卷积核尺寸 3×3，激活函数 ReLU，结果如图 5 所示。FC 神经元数为 64 时，训练损失约 0.8。随着神经元数量增加，训练损失降低，当神经元数量增加到 256 时，训练损失约 0.007。但神经元数量增加到 512 时，训练损失开始增大。因此适用于本文研究内容的 CNN 的 FC 神经元数为 256。

### 2.2.3　卷积核尺寸优化

CNN 通过卷积核提取输入数据的特征，卷积核尺寸越小，需要计算的数据量越小，其语义表达能力越强，但容易出现梯度消失、过拟合等问题[39]。卷积核尺寸越大，卷积层提取的信息越多，提取有效特征越容易，但卷积核过大会造成网络复杂性增加的问题[14]。

本节对比了不同卷积核尺寸对训练损失的影响，测试网络深度选择 9 层，FC 神经元数 256，激活函数 ReLU。结果如图 6 所示，卷积核尺寸为 3×3 时，训练损失较大，卷积核尺寸为 4×4 时，训练损失约 $8\times10^{-4}$，卷积核尺寸为 5×5 时训练损失波动较大。因此适用于本文研究内容的 CNN 卷积核尺寸为 4×4。

### 2.2.4　激活函数优化

激活函数能够引入非线性因素，提高 CNN 从数据中学习复杂函数映射的能力，对 CNN 理解复杂、非线性的函数有重要作用。不同激活函数的原理不同，各有优点与不足。针对不同的分类任务选择合适的激活函数对提高 CNN 性能有重要意义。

本节对比了不同激活函数对训练损失的影响，测试网络层数均选择 9 层，卷积核尺寸 4×4，FC 神经元数 256。结果如图 7 所示，激活函数为 sigmoid 时训练损失最高。激活函数为 tanh 时训练损失约 $5\times10^{-4}$。因此适用于本文研究内容的 CNN 的激活函数为 tanh。

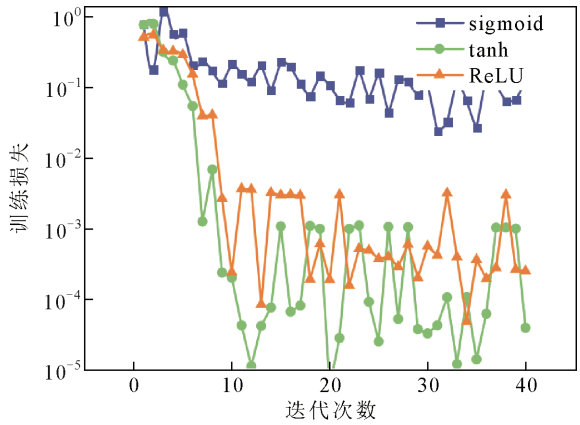



图 7 不同激活函数对训练损失的影响

Fig.7 Effect of different activation functions on training loss

## 2.3 CNN 与传统方法识别能力对比

### 2.3.1 确定 CNN 超参数

2.2 节确定了识别类滑动放电模式最佳的 CNN 超参数为：网络深度 9 层，卷积核尺寸 4×4，FC 神经元数 256，激活函数 tanh。CNN 对放电模式识别的准确率为 100 %，训练损约 $5\times10^{-4}$。

### 2.3.2 决策树算法与随机森林算法

DT 算法和 RF 算法是典型的传统机器学习算法。与 CNN 不同，DT 和 RF 算法需要人工提取输入数据的特征。图像的特征一般可以用颜色特征、纹理特征和空间关系特征等表达[39]，文献[21]的研究证明，形状特征属于高维信息，其底层信息不容易被模型捕获，而颜色特征捕获了放电状态的相关信息，作为机器学习算法的输入更有优势。因此本节选择提取放电的颜色特征，统计图像红色、绿色和蓝色分量在 0~255 像素值的点数，像素值越小表示亮度越高。结果如图 8 所示，结果表明，电晕放电各像素值点的数量最少，3 个分量差别大，表明电晕放电亮度较小，发光区域小且颜色不为白色。弥散放电的蓝色和红色分量数量水平相同，绿色分量较少，表明弥散放电发光强度较高，呈现粉色。类滑动放电图像各像素值点的数量大，各分量数值相差较小，表明类滑动放电发光强烈，呈现白色。

### 2.3.3 DT 算法和 RF 算法与 CNN 对比

为了测试 DT 算法和 RF 算法的识别效果，使用 Python 的 sklearn 库分别调用决策树算法和随机森林算法函数。决策树最大深度设置为 5，分类节点设置为 gini；随机森林最大深度设置为 3，决策树个数设置为 15，分类节点设置为 gini。

对于分类问题，在样本数量达到平衡时，模型整体的正确性可以通过准确率来判断，本文图像库 3 种放电的样本量均为 50，因此本节使用准确率作为 DT 算法和 RF 算法识别效果的评价指标。结果如图 9 所示，DT 算法识别准确率为 81.5%，RF 算法识别准确率为 96.5%，均低于 CNN 的准确率。

DT 算法和 RF 算法的训练数据为手动提取的颜色特征，提取的不同模式的颜色特征混淆，会影响

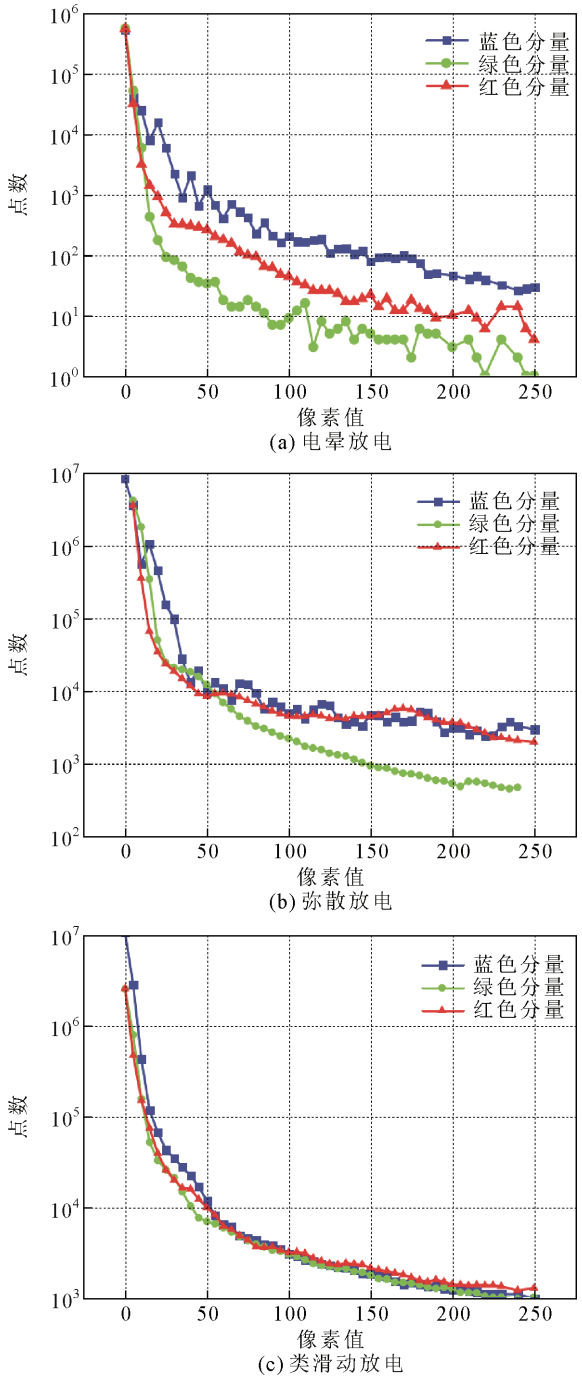



图 8 3 种放电模式的颜色特征

Fig.8 Color characteristics of the images of three discharge pattern

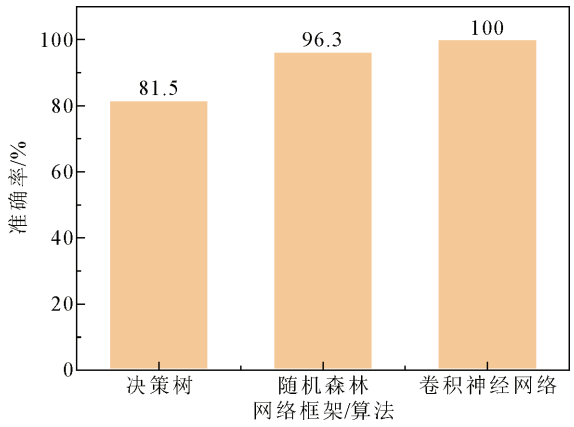



图 9　3 种方法识别准确率对比

Fig.9　Comparison of accuracy of three methods

算法的判断，导致准确率不足 100%；较小的样本量可能影响了算法产生初步规则的过程，导致准确率低于 100%。

### 2.4　参数调控

气体体积流量、脉冲频率、电极间隙和电压都会影响放电的模式，放电模式及参数三维图如图 10 所示，图中白线标注了弥散放电的起始电压和类滑动放电的击穿电压。由此可得，随着脉冲频率的增加，弥散放电的起始电压和类滑动放电的击穿电压会随之减小。随着气体体积流量的增加，弥散放电的起始电压和类滑动放电的击穿电压会随之增大。随着电极间隙增加，弥散放电的起始电压和类滑动放电的击穿电压随之增大。

在实际应用中，对弥散放电和类滑动放电的识别非常重要。由于 BPNN 采用信号正向传播和误差反向传播算法，能够通过监督学习生成一个具有泛化和容错能力的模型，具有结构简单、可操作性强的优点[40]，因此本节设计了一种基于 BPNN 的聚类分析算法，以实现通过放电参数预测放电模式。其结构如图 11 所示，输入为影响放电模式的 4 个参数(体积流量、脉冲频率、电极间隙和电压)，隐藏层为 1 层，神经元数为 20 个，输出 0 和 1 分别代表弥散放电和类滑动放电。

选取弥散放电和类滑动放电参数各 120 组，按类别以 8：2 的比例随机划分训练集和验证集，将 BPNN 训练的迭代次数设置为 800。结果如图 12 所示。BPNN 模型对验证集识别的准确率随着迭代次数的增加不断上升，在迭代 780 次时达到 100 %，随后稳定在 100 %。BPNN 的训练损失经过 800 次迭代，由 0.7 下降到 0.3。

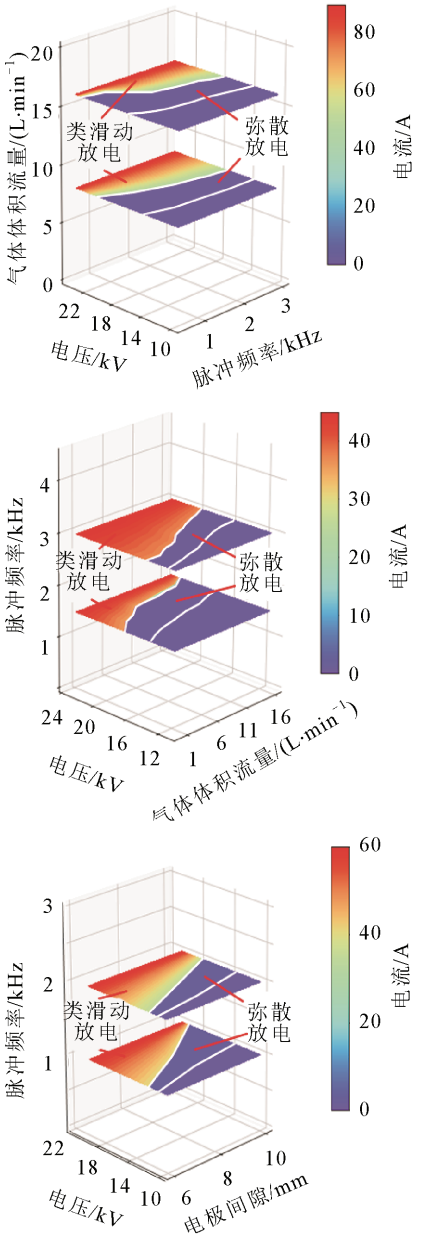



图 10　放电模式及参数三维图

Fig.10　Three dimensional figure of parameters of discharge mode

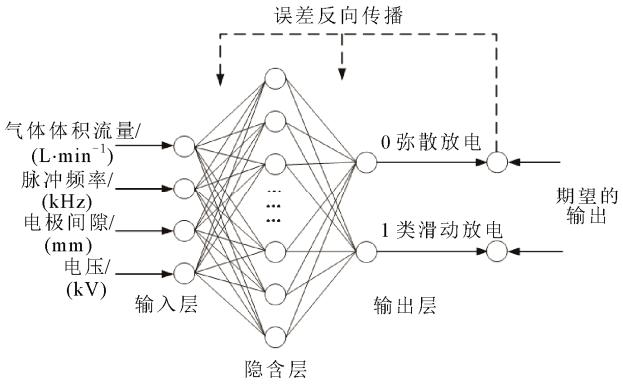



图 11　基于 BPNN 的聚类分析示意图

Fig.11　Schematic diagram of clustering analysis based on BP neural network

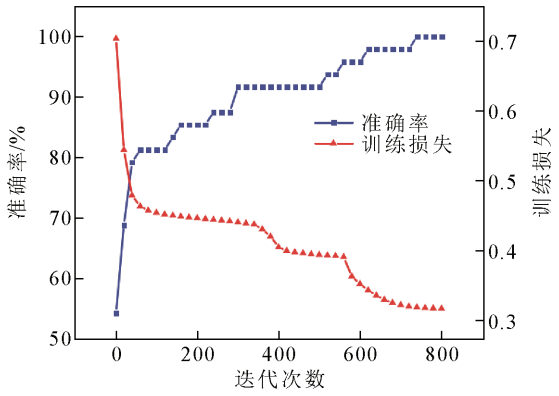



图 12 BPNN 识别结果

Fig.12 Recognition results of BPNN

## 3 结论

1）将数码相机拍摄的滑动放电图像经过预处理作为 CNN 输入，避免了传统机器学习方法繁琐的人工选择和提取图像特征的过程。

2）经过研究影响 CNN 性能的 4 个超参数，最终确定识别滑动放电模式的 CNN 其最佳超参数为：网络深度 9、FC 神经元数 256、卷积核尺寸 4×4、激活函数 tanh。

3）经过优化后的 CNN 准确率为 100 %，训练损失维持在较低水平。对于滑动放电，在小样本情况下，CNN 能提供比 DT 算法和 RF 算法更高的准确率。

4）此外本文给出了大气压滑动放电模式及条件参数。通过放电参数，可以得出放电模式过渡的电压随着电极间隙的增加而增加，随着脉冲频率的增加而减小，随着气体体积流量的增加而增加的结论。

5）最后通过基于 BPNN 的聚类分析算法能够根据放电的条件识别弥散放电和类滑动放电模式，并且准确率为 100 %。

## 参考文献 References

[1] 高 远，窦立广，李江伟，等. 低温等离子体-催化剂协同催化 $CO_2$ 转化进展[J]. 高电压技术，2022，48(4)：1607-1619.
GAO Yuan, DOU Liguang, LI Jiangwei, et al. Recent advances in catalyzing $CO_2$ conversion by synergistic low-temperature plasma and catalysts[J]. High Voltage Engineering, 2022, 48(4): 1607-1619.

[2] 满晨曦，黄邦斗，章 程，等. 不同脉冲参数下等离子体活化水活性氮特性[J]. 高电压技术，2022，48(6)：2326-2335.
MAN Chenxi, HUANG Bangdou, ZHANG Cheng, et al. Reactive nitrogen species characteristic of plasma-activated water under different pulsed parameters[J]. High Voltage Engineering, 2022, 48(6): 2326-2335.

[3] 康少芬，张 帅，陈晓晓，等. 纳秒脉冲介质阻挡放电等离子体氮还原合成氨的研究[J]. 高电压技术，2021，47(1)：368-375.
KANG Shaofen, ZHANG Shuai, CHEN Xiaoxiao, et al. Study on reduction of nitrogen to ammonia by nanosecond pulse dielectric barrier discharge plasma[J]. High Voltage Engineering, 2021, 47(1): 368-375.

[4] 邵 涛，章 程，王瑞雪，等. 大气压脉冲气体放电与等离子体应用[J]. 高电压技术，2016，42(3)：685-705.
SHAO Tao, ZHANG Cheng, WANG Ruixue, et al. Atmospheric-pressure pulsed gas discharge and pulsed plasma application[J]. High Voltage Engineering, 2016, 42(3): 685-705.

[5] 牛宗涛，章 程，王瑞雪，等. 脉冲重复频率对微秒脉冲滑动放电特性影响的实验研究[J]. 电工技术学报，2016，31(19)：191-198.
NIU Zongtao, ZHANG Cheng, WANG Ruixue, et al. Experimental study on the effect of the pulse repetition frequency on the characteristics of microsecond-pulse gliding discharges[J]. Transactions of China Electrotechnical Society, 2016, 31(19): 191-198.

[6] 牛宗涛. 微秒脉冲滑动放电模式及特性研究[D]. 郑州：郑州大学，2016.
NIU Zongtao. Experimental study on the mode and characteristics of microsecond-pulse gliding discharges[D]. Zhengzhou, China: Zhengzhou University, 2016.

[7] 牛宗涛，章 程，马云飞，等. 气流对微秒脉冲滑动放电特性的影响[J]. 物理学报，2015，64(19)：195204.
NIU Zongtao, ZHANG Cheng, MA Yunfei, et al. Effect of flow rate on the characteristics of repetitive microsecond-pulse gliding discharges[J]. Acta Physica Sinica, 2015, 64(19): 195204.

[8] HASTIE T, TIBSHIRANI R. Discriminant adaptive nearest neighbor classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1996, 18(6): 607-616.

[9] ZOU X N, HU Y, TIAN Z W, et al. Logistic regression model optimization and case analysis[C]//Proceedings of the 7th International Conference on Computer Science and Network Technology. Dalian, China: IEEE, 2019: 135-139.

[10] BRESLOW L A, AHA D W. Simplifying decision trees: a survey[J]. The Knowledge Engineering Review, 1997, 12(1): 1-40.

[11] HO T K. Random decision forests[C]//Proceedings of 3rd International Conference on Document Analysis and Recognition. Montreal, Canada: IEEE, 1995: 278-282.

[12] IWATA S, KITANI R. Phase-resolved partial discharge analysis of different types of electrode systems using machine learning classification[J]. Electrical Engineering, 2021, 103(6): 3189-3199.

[13] RAYMOND W J K, XIN C W, KIN L W, et al. Noise invariant partial discharge classification based on convolutional neural network[J]. Measurement, 2021, 177: 109220.

[14] LU C, PENG T, XIONG Z L. Operation-mode recognition of surface microdischarge based on visible image and deep learning[J]. Journal of Physics D: Applied Physics, 2022, 55(30): 305202.

[15] 张 翼，朱永利. 图信号与图卷积网络相结合的局部放电模式识别方法[J]. 中国电机工程学报，2021，41(18)：6472-6480.
ZHANG Yi, ZHU Yongli. A partial discharge pattern recognition method combining graph signal and graph convolutional network[J]. Proceedings of the CSEE, 2021, 41(18): 6472-6480.

[16] 陈健宁，周远翔，白 正，等. 基于多通道卷积神经网络的油纸绝缘局部放电模式识别方法[J]. 高电压技术，2022，48(5)：1705-1715.
CHEN Jianning, ZHOU Yuanxiang, BAI Zheng, et al. Pattern recognition method of partial discharge in oil-paper insulation based on multi-channel convolutional neural network[J]. High Voltage Engineering, 2022, 48(5): 1705-1715.

[17] 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.

[18] 宁暑光，何怡刚，程彤彤，等. 基于自适应 S 变换与截断紧致奇异值分解的局部放电源复杂染噪特征提取方法[J]. 电工技术学报，2022，37(15)：3951-3962.

NING Shuguang, HE Yigang, CHENG Tongtong, et al. Feature extraction of partial discharge source with complex noise based on adaptive S-transform and truncated compact singular value decomposition[J]. Transactions of China Electrotechnical Society, 2022, 37(15): 3951-3962.

[19] 杜劲超，陈伟根，张知先，等. 真型变压器局部放电超高频信号的传播特性[J]. 高电压技术，2020，46(6)：2185-2191.
DU Jinchao, CHEN Weigen, ZHANG Zhixian, et al. Propagation characteristics of utral high frequency signals in an actual power transformer[J]. High Voltage Engineering, 2020, 46(6): 2185-2191.

[20] 佘昌佳，郑建勇，何嘉弘，等. 时差筛选和 ABC 二次寻优的变压器局放超声定位方法[J]. 高电压技术，2021，47(8)：2820-2827.
SHE Changjia, ZHENG Jianyong, HE Jiahong, et al. Ultrasonic localization method of transformer partial discharge by time difference screening and ABC secondary optimization[J]. High Voltage Engineering, 2021, 47(8): 2820-2827.

[21] YE Q Z, YE P X, GUO Z Q, et al. A corona recognition method based on visible light color and machine learning[J]. IEEE Transactions on Plasma Science, 2020, 48(1): 31-35.

[22] GU J X, WANG Z H, JASON K, et al. Recent advances in convolutional neural networks[J]. Pattern Recognition, 2018, 77: 354-377.

[23] GIMÉNEZ M, PALANCA J, BOTTI V. Semantic-based padding in convolutional neural networks for improving the performance in natural language processing. A case of study in sentiment analysis[J]. Neurocomputing, 2020, 378: 315-323.

[24] ABDEL-HAMID O, MOHAMED A R, JIANG H, et al. Convolutional neural networks for speech recognition[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2014, 22(10): 1533-1545.

[25] YIN X, LIU X M. Multi-Task convolutional neural network for pose-invariant face recognition[J]. IEEE Transactions on Image Processing, 2018, 27(2): 964-975.

[26] ŠEVO I, AVRAMOVIĆ A. Convolutional neural network based automatic object detection on aerial images[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(5): 740-744.

[27] YANG Z L, HUANG Y F, JIANG Y R, et al. Clinical assistant diagnosis for electronic medical record based on convolutional neural network[J]. Scientific Reports, 2018, 8(1): 6329.

[28] 何　力，郑灶贤，项凤涛，等. 基于深度学习的文本分类技术研究进展[J]. 计算机工程，2021，47(2)：1-11.
HE Li, ZHENG Zaoxian, XIANG Fengtao, et al. Research progress of text classification technology based on deep learning[J]. Computer Engineering, 2021, 47(2): 1-11.

[29] 陈正博，陈左宁. 人工智能加速体系结构综述[J]. 信息工程大学学报，2020，21(2)：164-171.
CHEN Zhengbo, CHEN Zuoning. Review on artificial intelligence acceleration architecture[J]. Journal of Information Engineering University, 2020, 21(2): 164-171.

[30] KINGMA D P, BA J. Adam: a method for stochastic optimization[C]// Proceedings of the 3rd International Conference on Learning Representations. San Diego, USA, 2015: 13.

[31] 章　程，邵　涛，许家雨，等. 大气压空气中纳秒脉冲弥散放电实验研究[J]. 高电压技术，2012，38(5)：1090-1098.
ZHANG Cheng, SHAO Tao, XU Jiayu, et al. Experimental study on nanosecond-pulse diffuse discharge in atmospheric air[J]. High Voltage Engineering, 2012, 38(5): 1090-1098.

[32] SHAO T, TARASENKO V F, ZHANG C, et al. Diffuse discharge produced by repetitive nanosecond pulses in open air, nitrogen, and helium[J]. Journal of Applied Physics, 2013, 113(9): 093301.

[33] ZHANG C, SHAO T, MA H, et al. Experimental study on conduction current of positive nanosecond-pulse diffuse discharge at atmospheric pressure[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2013, 20(4): 1304-1314.

[34] ZHANG C, SHAO T, YAN P, et al. Nanosecond-pulse gliding discharges between point-to-point electrodes in open air[J]. Plasma Sources Science and Technology, 2014, 23(3): 035004.

[35] 邵　涛，孙广生，严　萍，等. 极不均匀电场下重复频率纳秒脉冲气体击穿实验研究[J]. 强激光与粒子束，2006，18(6)：1031-1036.
SHAO Tao, SUN Guangsheng, YAN Ping, et al. Experimental research of repetitively nanosecond-pulse breakdown in air under non-uniform electric field[J]. High Power Laser and Particle Beams, 2006, 18(6): 1031-1036.

[36] DALAINE V, CORMIER J M, LEFAUCHEUX P. A gliding discharge applied to $H_2S$ destruction[J]. Journal of Applied Physics, 1998, 83(5): 2435-2441.

[37] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]// Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 770-778.

[38] FUKUSHIMA K. Restoring partly occluded patterns: a neural network model[J]. Neural Networks, 2005, 18(1): 33-43.

[39] PRASAD D S, REDDY B S. Study on corona activity using an image processing approach[J]. IEEE Transactions on Industry Applications, 2017, 53(4): 4008-4014.

[40] 鲍　伟，任　超. 基于 GWO-BP 神经网络的电池 SOC 预测方法研究[J]. 计算机应用与软件，2022，39(9)：65-71.
BAO Wei, REN Chao. Research on prediction method of battery SOC based on GWO-BP Network[J]. Computer Applications and Software, 2022, 39(9): 65-71.



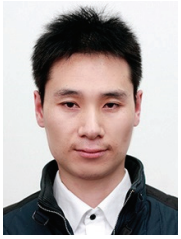
**潘如政**
1977—，男，博士，副教授，硕导
主要从事高电压技术、放电等离子体应用和电器可靠性方面的研究工作
E-mail: prz386@126.com

PAN Ruzheng
Ph.D.
Associate professor



**李怀宇**
1998—，男，硕士
主要从事高电压技术、脉冲放电方面的研究工作
E-mail: lihuaiyu@mail.iee.ac.cn

LI Huaiyu



**张　帅**(通信作者)
1988—，男，博士，副研究员，硕导
主要从事高电压技术、放电等离子体诊断和应用方面的研究工作
E-mail: zhangshuai@mail.iee.ac.cn

ZHANG Shuai
Ph.D.
Associate professor

收稿日期　2022-12-16　修回日期　2023-06-15　　编辑　曹昭君