

# 基于卷积神经网络的 GIS 绝缘缺陷检测方法

## GIS Insulation Defect Detection Method Based on Convolutional Neural Network

黄吕轩

Lvxuan Huang

安徽送变电工程有限公司 中国·安徽 合肥 230000

Anhui Power Transmission and Transformation Engineering Co., Ltd., Hefei, Anhui, 230000, China

**摘要:** 本研究探讨了一种创新的 GIS (气体绝缘金属封闭开关设备) 绝缘缺陷检测方法, 采用了卷积神经网络 (CNN) 技术。

**Abstract:** This study explores an innovative insulation defect detection method for GIS (Gas Insulated Metal Enclosed Switchgear), using convolutional neural network (CNN) technology.

**关键词:** 卷积神经网络 (CNN); 绝缘缺陷检测; 模型设计; 图像增强

**Keywords:** convolutional neural network (CNN); insulation defect detection; model design; image enhancement

**DOI:** 10.12346/peti.v6i1.9075

## 1 图像分割法

### 1.1 原理

图像分割法, 作为一种精细的图像处理技术, 在 GIS 绝缘缺陷检测中扮演着至关重要的角色 (图 1)。它基于卷积神经网络, 通过大量训练数据来学习并识别绝缘图像中的缺陷特征, 进而实现像素级的分割。

卷积神经网络通过一系列的卷积层、激活函数和池化层, 逐层提取图像的特征。这些特征可能包括颜色、纹理、形状等, 它们对于区分缺陷区域和正常区域至关重要。随着网络层数的加深, 提取到的特征也会从低级的像素强度, 逐渐抽象为高级的语义信息。在得到高级特征后, 网络会进行上采样操作, 将特征图恢复到与原图相同的尺寸。在这个过程中, 网络会利用之前提取的特征, 对每一个像素进行分类, 判断它属于缺陷区域还是正常区域。这样, 我们就得到了一个与原图大小相同的分割图, 其中的每个像素都被标记为缺陷或正常。

FCM 算法原理如下:

通常情况下  $X=\{X1(i, j), X2(i, j), \dots, Xn(i, j)\}$  来描述, 通过迭代实现目标函数的最小值。另外, 像素点的隶属度用  $u_{ij}$  表示, 表示点源  $x_j$  是第  $i$  类的概率, 具体表达

式如下:

$$J_{(u,v)} = \sum_i^c \sum_j^n u_{ij}^m d^2(x_k, v_i)$$

其中, 约束条件如下:

$$\sum_{i=1}^c u_{ij} = 1, \forall i$$

$$0 < \sum_{i=1}^c u_{ij} < n, \forall c$$

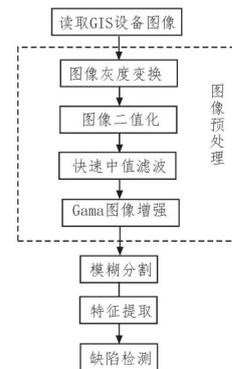


图 1 GIS 设备缺陷检测流程图

**【作者简介】** 黄吕轩 (1984-), 男, 中国江苏淮安人, 本科, 高级工程师, 从事高压试验及高压设备故障分析诊断研究。

在上面列式中，对每个变量进行分别求偏导，当目标函数为最小值的时候，通过联立方程，计算出聚类中心  $v_i$  和隶属度  $u_{ij}$ ，具体列式如下：

$$u_{ij} = \frac{1}{\sum_k [d^2(x_j, v_i) / d^2(x_j, v_k)]^{\frac{2}{m-1}}}$$

$$v_i = \frac{\sum_{j=1}^n u_{ij}^m x_j}{\sum_{j=1}^n u_{ij}^m}, \forall i, j$$

其中， $i=1, 2, 3, \dots$ ;  $j=1, 2, 3, \dots, n$ ;  $c=1, 2, 3, \dots, n$ 。

## 1.2 优势

**精确性：**图像分割法可以实现像素级别的分割，这意味着它能够精确定位和勾勒出缺陷的轮廓和位置。相比其他方法，它提供了更高的检测精度。

**自动化程度：**基于卷积神经网络的图像分割法能够自主学习并提取绝缘图像中的特征，无需手动设计和选择特征。这大大减少了人工干预，并提高了检测的自动化程度。

**扩展性：**一旦模型训练完成，它可以很容易地应用于其他类似的绝缘缺陷检测任务。这意味着该方法具有很好的扩展性，能够适应不同的检测需求。

**对复杂缺陷的有效处理：**对于传统方法难以处理的复杂、细微的绝缘缺陷，图像分割法能够利用深度学习模型强大的表征能力，更准确地识别和分割这些缺陷。

## 2 特征识别法

### 2.1 原理

特征识别法是一种基于卷积神经网络的 GIS 绝缘缺陷检测方法，其核心思想是通过提取 GIS 绝缘图像的特征，并利用卷积神经网络学习和识别这些特征来实现缺陷检测。这种方法在 GIS 绝缘缺陷检测中具有独特的优势，并且在实际应用中取得了良好的效果。

首先，特征提取是特征识别法的关键步骤之一。在 GIS 绝缘图像中，绝缘缺陷通常表现为特定的纹理、形状或色彩等特征<sup>[1]</sup>。通过利用图像处理技术，我们可以提取出这些特征，为后续的缺陷检测提供重要的信息。例如，常用的特征提取方法包括灰度共生矩阵、小波变换、SIFT 等，它们可以从不同的角度描述图像的特征。其次，卷积神经网络在特征识别法中发挥了重要作用。卷积神经网络具有强大的学习能力，可以通过训练学习到绝缘缺陷的特征表示。在训练过程中，网络通过逐层卷积、池化和非线性变换等操作，从原始图像中提取出一系列的特征图。这些特征图能够逐层抽象地表示图像的特征，并在后续的全连接层中进行分类或回归操作。最后，特征识别法的关键在于提取到的特征是否能够有效表示绝缘缺陷。这要求我们在特征提取的过程中要选择适当的特征提取方法，并考虑到绝缘缺陷的多样性和复杂性。通过合理地设计卷积神经网络的结构和参数，我们可以使得网络能够学习到更加鲁棒和有区分度的特征表示，从而

提高缺陷检测的准确性。

卷积层通过卷积操作对输入图像进行特征提取，可得：

$$(f * g)(t) = \sum_{a=1}^k f(a)g(t-a)$$

其中： $f$ 是输入图像的像素值； $g$ 是卷积核（也称为滤波器）的权重； $t$ 是输出图像中的位置； $k$ 是卷积核的大小。卷积层的输出计算通过在整个输入图像上滑动卷积核，并在每个位置执行卷积操作。

池化层用于减小特征图的空间维度，同时保留关键信息。常用的池化操作是最大池化（Max Pooling）和平均池化（Average Pooling）最大池化的公式如下：

$$\text{MaxPooling}(x, size) = \max(x_{i:i+size, j:j+size})$$

其中： $x$ 是输入图像或特征图； $size$ 是池化窗口的大小。平均池化的公式如下：

$$\text{AvgPooling}(x, size) = \frac{1}{size^2} \sum_i \sum_j x_{i:i+size, j:j+size}$$

池化层通过在输入图像上滑动池化窗口，并在每个窗口上应用相应的池化操作，生成池化后的输出。

### 2.2 优势

**有效性：**通过提取图像中的关键特征，特征识别法能够更准确地表示绝缘缺陷。这使得该方法能够迅速定位并识别出绝缘图像中的缺陷区域。

**灵活性：**特征识别法可以灵活选择不同的特征提取方法，根据不同的绝缘缺陷类型和场景进行调整。这种灵活性使得该方法能够适应各种复杂的绝缘缺陷检测任务。

**对噪声和干扰的鲁棒性：**通过特征提取和卷积神经网络的学习过程，特征识别法能够对图像中的噪声和干扰进行一定程度的抑制。这使得该方法在实际应用中对于图像质量的变化具有一定的鲁棒性。

## 3 深度学习分类法

### 3.1 原理

深度学习分类法在应用过程中，需要通过大量的训练数据来训练卷积神经网络模型。训练过程中，网络通过反向传播算法优化网络参数，以最小化预测结果与实际标签之间的差距。这个过程中，网络能够学习到从原始图像到缺陷类别的映射关系。在训练完成后，我们可以使用训练好的模型来对新的 GIS 绝缘图像进行分类。分类过程中，输入图像经过卷积层的特征提取，全连接层根据提取的特征生成最终分类结果。这个结果是基于网络在训练过程中学到的知识，能够准确地反映出输入图像的缺陷类型<sup>[2]</sup>。除了训练过程中的参数优化，深度学习分类法还需要关注一些其他的技术细节。例如，为了防止过拟合，我们通常会在训练过程中引入一些正则化技术，如 Dropout、L2 正则化等。此外，为了提高模型的泛化能力，我们也会使用数据增强技术，如对训练图像进行随机裁剪、旋转等。

深度学习分类法的训练过程通常涉及最小化预测结果与实际标签之间的差距，这可以通过定义损失函数来实现。常见的交叉熵损失函数（Cross-Entropy Loss）可以表示为：

$$J(\theta) = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(p_{i,c})$$

其中： $\theta$  表示模型的参数； $N$  是训练样本的数量； $C$  是类别的数量。 $y_{i,c}$  是样本  $i$  属于类别  $c$  的实际标签（0 或 1）； $p_{i,c}$  是模型预测样本  $i$  属于类别  $c$  的概率。

### 3.2 优势

自动特征提取：深度学习分类法利用卷积神经网络自动提取图像的特征，而无需手动设计和选择特征。这使得该方法能够适应各种复杂的绝缘缺陷，并减少人工干预和专家经验的依赖。

适应大规模数据集：深度学习分类法可以处理大规模的数据集，并利用 GPU 等计算资源加快训练速度。这使得该方法能够充分利用现有的数据资源，提高训练效率和模型性能。

端到端的训练：深度学习分类法通过端到端的训练方式，可以同时优化特征提取和分类器，使得整个模型能够更好地适应绝缘缺陷检测任务。这种训练方式简化了模型设计的流程，并提高了模型的泛化能力。

## 4 目标检测法

### 4.1 原理

目标检测法在 GIS 绝缘缺陷检测中是一种非常有效的方法。这种方法将绝缘缺陷视为特定目标，采用目标检测算法，如 YOLO（You Only Look Once）和 SSD（Single Shot Detector）等，在 GIS 绝缘图像中进行检测。与前面介绍的方法相比，目标检测法具有同时实现绝缘缺陷定位和分类的能力，因此在实际应用中具有很高的价值。目标检测法基于深度学习的技术，它利用神经网络对图像进行多阶段的处理。在处理过程中，目标检测算法通过卷积层提取图像的特征，并生成一系列候选区域（Bounding Boxes），这些区域可能包含绝缘缺陷。然后，算法对每个候选区域进行分类和回归操作，以确定是否存在绝缘缺陷，并精确确定其位置<sup>[3]</sup>。对于 YOLO 算法而言，它将目标检测任务看作一个回归问题，将图像划分为  $S \times S$  的网格，每个网格预测  $B$  个边界框和这些框的置信度，以及  $C$  个类别的条件概率。这种方式使得 YOLO 算法具有较高的检测速度，因为它只需要一次前向传播就可以得到所有的预测结果。而 SSD 算法则采用了多尺度的特征图来进行目标检测。它通过不同卷积层的输出，构建了不同尺度的特征图，然后在这些特征图上同时进行预测。这样的设计使得 SSD 算法能够检测到不同大小的绝缘缺陷，提高了检测的准确性。

YOLO 将目标检测任务视为一个回归问题，它在图像上

划分成  $S \times S$  的网格，每个网格预测  $B$  个边界框和这些框的置信度，以及  $C$  个类别的条件概率。

$$\text{Detection} = P(\text{Object}) \times \text{IoU}(\text{predicted box, ground truth})$$

$P(\text{Object})$  是对象存在的概率； $\text{IoU}(\text{Predicted Box, Ground Truth})$  是预测边界框与实际边界框的交并比。

SSD 算法的损失函数由定位损失（Localization Loss）和置信度损失（Confidence Loss）两部分组成。

$$L(x, c, l, g) = \frac{1}{N} (L_{\text{conf}}(x, c) + \alpha L_{\text{loc}}(x, l, g))$$

其中： $L_{\text{conf}}$  是置信度损失函数； $L_{\text{loc}}$  是定位损失函数； $x$  是预测的类别概率； $c$  是真实类别标签； $l$  是预测的边界框坐标； $g$  是真实的边界框坐标； $\alpha$  是平衡两个损失项的权重； $N$  是匹配的正样本数量。

### 4.2 优势

同时实现定位和分类：目标检测法不仅能够识别出绝缘缺陷的存在，还能准确地定位缺陷的位置，并对其进行分类。这种同时定位和分类的能力使得目标检测法在实际应用中更为实用和高效。

处理复杂背景：由于目标检测法基于深度学习技术，它具有较强的抗干扰能力，能够有效地处理复杂背景下的绝缘缺陷检测任务。这对于实际应用中的 GIS 绝缘图像来说尤为重要，因为图像背景往往复杂多变。

对多种缺陷类型的处理：目标检测法通过训练可以识别多种类型的绝缘缺陷，而不仅仅局限于某一种特定的缺陷。这使得该方法在实际应用中能够更全面地检测 GIS 绝缘图像的缺陷。

## 5. 结语

基于卷积神经网络的 GIS 绝缘缺陷检测方法在电力系统中扮演着日益重要的角色。论文详细介绍了四种主要的检测方法，即图像分割法、特征识别法、深度学习分类法以及目标检测法，这四种方法各有优势，但在实际应用中，选择何种方法应根据具体需求、数据规模、计算资源等因素综合考虑。未来，随着技术的不断进步和创新，我们相信基于卷积神经网络的 GIS 绝缘缺陷检测方法将更加成熟和完善，为电力系统的安全稳定运行提供更加坚实的技术支撑。

### 参考文献

- [1] 张昊,刘薇.电力设备缺陷诊断中深度学习的应用进展[J].电力系统及其自动化学报,2020,32(5):1-10.
- [2] 李峰,王建国,赵雷.基于图像处理的GIS缺陷识别研究[J].电力设备管理,2019,8(3):45-53.
- [3] 陈明,黄勇,王伟.卷积神经网络在电力设备故障诊断中的应用研究[J].电工电气,2018,30(2):112-118.