

[变电设备]

基于深度学习的变电设备缺陷图像识别与分类技术

文/刘乾

国网江苏省电力有限公司淮安市洪泽区供电分公司

提出一种基于深度学习的变电设备缺陷图像识别与分类技术。对变电设备缺陷图像进行了预处理和数据增强，采用多种卷积神经网络模型进行模型训练和优化。通过交叉熵损失函数和Adam优化器，构建精确度较高的图像分类模型。实验结果表明，基于深度学习的图像识别方法在变电设备缺陷分类任务中表现出较高的准确率和鲁棒性，有助于提升电力设备故障诊断的自动化程度和准确性。

随着电力系统的快速发展和变电设备运行复杂性的增加，变电设备的健康状态对电网的安全性和稳定性起着至关重要的作用。由于长时间运行及环境条件的影响，变电设备常会出现各种缺陷，如绝缘损伤、表面裂纹、腐蚀和异物附着等^[1]。这些缺陷如果得不到及时检测和处理，会导致设备故障，甚至引发严重的电力系统事故。因此，如何快速、准确地识别和分类变电设备的缺陷图像成为当前研究的重点^[2-3]。

本文旨在基于深度学习技术，探讨变电设备缺陷图像识别与分类的关键方法与实现路径。首先研究如何利用深度学习模型实现缺陷特征检测和边缘信息提取，从而实现缺陷的精准识别；然后深入探讨缺陷特征匹配与分类技术，建立高效的缺陷图像分类模型；最后，通过实验研究验证所提方法的有效性，为变电设备智能化运维提供技术支持。

基于深度学习的变电设备缺陷图像识别

1. 缺陷特征检测

基于深度学习的缺陷特征检测，通过构建卷积神经网络模型，利用网络的多层结构提取图像的多尺度和深层语义信息，实现对缺陷区域的准确定位

与描述。

深度学习模型的核心在于卷积操作，通过卷积核在图像上滑动，实现局部感受野的信息提取。卷积操作的数学表示为

$$y_{ij}^k = \sigma \left(\sum_{m=0}^{M-1} \sum_{n=0}^{N-1} x_{(i+m)(j+n)} \cdot w_{mn}^k + b^k \right) \quad (1)$$

式中， x 为输入图像像素值； w 为卷积核； b 为偏置； σ 为激活函数； y_{ij}^k 为第 k 个卷积核在位置 (i,j) 处的输出特征值。

通过多层卷积叠加，模型能够逐步提取图像的低层次特征（如边缘、纹理）和高层次特征（如形状、结构）。

变电设备缺陷的表现形式多样，包括细小裂纹、较大面积的腐蚀等，需要模型具备多尺度特征提取能力。为此，采用基于特征金字塔网络的结构，将不同层次的特征图进行融合

$$F_{\text{out}}^l = \text{Upsample}(F_{\text{out}}^{l+1}) + F_{\text{in}}^l \quad (2)$$

式中， F_{in}^l 和 F_{out}^l 分别为第 l 层的输入特征图和输出特征图； $\text{Upsample}(\cdot)$ 表示特征上采样操作。

通过多层特征融合，网络能够在不同分辨率上捕捉缺陷的局部细节和全局结构^[4]。

缺陷特征的检测离不开缺陷区域的精准定位。

基于区域提议网络的检测框生成，生成候选区域，其损失函数由分类损失和回归损失组成

$$L = L_{\text{cls}} + \lambda L_{\text{reg}} \quad (3)$$

式中， L_{cls} 为分类损失（如交叉熵）； L_{reg} 为边框回归损失； λ 为损失权重。通过优化损失函数，模型能够生成准确的缺陷区域提议。

为提升模型的鲁棒性，需要引入数据增强技术，如旋转、裁剪及亮度调整等。同时，通过 L2 正则化防止模型过拟合，其正则化项为

$$L_{\text{reg}} = \frac{\lambda}{2} \sum_{i=1}^n \|w_i\|^2 \quad (4)$$

式中， w_i 为模型权重参数； λ 为正则化强度。

2. 边缘检测约束

边缘是图像中强度变化最大的区域，是识别变电设备缺陷的重要特征之一。通过边缘检测，可以突出图像中缺陷的轮廓和形状，减少不必要的背景干扰。基于深度学习的边缘检测约束方法结合传统边缘检测算法的直观性与深度神经网络的强大特征提取能力，为缺陷识别提供更准确和鲁棒的输入^[5]。

传统的边缘检测方法，Sobel算子的核心是通过卷积计算图像在x和y方向上的梯度

$$G_x = \sum_{i=0}^2 \sum_{j=0}^2 w_{ij}^x \cdot I_{(m+i)(n+j)} \quad (5)$$

$$G_y = \sum_{i=0}^2 \sum_{j=0}^2 w_{ij}^y \cdot I_{(m+i)(n+j)}$$

式中， w^x 和 w^y 分别为 Sobel 核权重矩阵； I 为输入图像； G_x 和 G_y 分别为x和y方向的梯度。

图像的梯度幅值可表示为

$$G = \sqrt{G_x^2 + G_y^2} \quad (6)$$

虽然传统方法计算简单，但在处理复杂场景如噪声干扰或多重边缘时，检测效果有限。

深度学习结合边缘检测约束，通过构建特定的损失函数引导模型聚焦于边缘信息。基于全卷积网络的边缘检测网络，采用像素级预测输出边缘概率图。边缘损失函数通常由二分类交叉熵损失构成

$$L_{\text{edge}} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (7)$$

式中， y_i 为边缘标签； p_i 为模型预测的边缘概率； N 为像素总数。

通过优化此损失函数，网络能够更准确地学习到边缘特征。

为将边缘信息与高层次特征相结合，在深度学习中引入边缘约束模块。将边缘检测结果作为辅助监督信号，与主任务（如缺陷检测）的损失函数共同优化

$$L = L_{\text{main}} + \alpha L_{\text{edge}} \quad (8)$$

式中， L_{main} 为主任任务的损失； L_{edge} 为边缘检测损失； α 为平衡权重。

边缘信息的引入使模型在提取全局特征的同时能够关注局部细节。

边缘检测的性能对图像质量高度敏感。为提升边缘检测的鲁棒性，引入基于对比学习的边缘优化方法，通过最大化真实边缘与背景区域特征之间的对比度，进一步强化模型对细微缺陷边缘的敏感性。

基于深度学习的变电设备缺陷图像分类

1. 缺陷特征匹配

缺陷特征匹配是基于深度学习的变电设备缺陷图像分类的关键环节，其目的是将提取到的缺陷特征与已有的缺陷类别模板进行对比，以实现缺陷的精准分类。深度学习方法通过特征提取网络生成高维特征向量，并结合特征相似性度量方法，完成缺陷特征的高效匹配。

(1) 特征向量生成

深度学习网络通过多层卷积神经网络（CNN）提取输入图像的特征，并将其转换为高维特征向量表示。假设输入图像为 X ，网络通过一系列卷积、池化和全连接层生成特征向量

$$f_x = f_\theta(X) \quad (9)$$

式中， f_θ 为网络的参数化映射函数； $f_x \in \mathbb{R}^d$ 为 d 维特征向量。

网络提取的特征向量能够表征缺陷的纹理、形状、颜色等重要信息，表面裂纹的线性特征或腐蚀的斑点特征均可被编码为特定的高维表示。

(2) 特征相似性度量

特征匹配的核心是计算目标特征与已知类别特征之间的相似性，对于输入图像 f_x 和类别模板特征 f_T ，欧氏距离表示为

$$D_E(f_x, f_T) = \sqrt{\sum_{i=1}^d (f_x[i] - f_T[i])^2} \quad (10)$$

较小的 D_E 表示两者特征更接近，匹配度更高^[6]。

通过计算两个向量的夹角余弦值来评估相似性，余弦相似度计算公式为

$$S_{\cos}(f_X, f_T) = \frac{f_X \cdot f_T}{\|f_X\| \|f_T\|} \quad (11)$$

式中， $S_{\cos}$ 的值范围为 $[-1, 1]$ ，越接近1表示相似度越高^[7]。

通过训练度量学习模型优化特征匹配的准确性。

为提升特征匹配的效率和准确性，结合注意力机制优化特征表示。通过构建注意力模块，模型能够聚焦于缺陷区域的显著特征，减少背景噪声干扰。注意力权重的计算公式为

$$\alpha_i = \frac{\exp(e_i)}{\sum_{j=1}^n \exp(e_j)}, \quad e_i = w^T f_X[i] \quad (12)$$

式中， α_i 为特征通道的注意力权重； w 为权重参数。

基于深度学习的缺陷特征匹配通过高效特征提取与相似性度量实现精准分类，为后续的变电设备智能诊断提供坚实支持^[8]。

2. 变电设备缺陷图像分类

利用深层神经网络（Deep Neural Network, DNN）对提取的缺陷特征进行类别判定。深度学习通过端到端的训练方法，能够自动学习图像的特征表示，并利用分类层对特征进行精准分类。

深度学习模型以卷积神经网络为核心。其基本结构包括卷积层、池化层、全连接层和分类层。在分类任务中，经过卷积和池化的特征映射 F 通过全连接层转换为特征向量 z

$$z = \sigma(W \cdot \text{flatten}(F) + b) \quad (13)$$

式中， W 为权重矩阵； b 为偏置向量； σ 为激活函数。最终，分类层利用 Softmax 函数将特征向量映射为每种缺陷类别的概率

$$P(y=k|z) = \frac{\exp(w_k^T z + b_k)}{\sum_{j=1}^K \exp(w_j^T z + b_j)} \quad (14)$$

式中， k 为缺陷类别总数； w_k 和 b_k 为类别 k 的权重和偏置。

分类模型的训练以最小化交叉熵损失函数为目标，该损失函数衡量模型预测与真实类别之间的差异

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{ik} \log P(y=k|z_i) \quad (15)$$

式中， N 为训练样本数； y_{ik} 为样本 i 的真实标签； $P(y=k|Z_i)$ 为模型预测概率。

通过反向传播和优化算法更新网络参数

$$\theta_{t+1} = \theta_t - \eta \nabla_{\theta} L \quad (16)$$

式中， θ 为网络参数； η 为学习率； $\nabla_{\theta} L$ 为损失函数的梯度。

利用预训练模型提取通用特征并进行微调，减少训练时间并提高分类精度。通过旋转、缩放、翻转和噪声添加等方式生成多样化的训练样本，提高模型对缺陷特征的鲁棒性。同时学习缺陷分类和其他相关任务（如缺陷位置检测）的模型共享特征表示，提高分类性能。

实验研究

为验证基于深度学习的变电设备缺陷图像识别与分类技术的实际应用效果，设定对比实验，与传统的人工检测技术进行实验对比。本实验所使用的数据集包含不同类型变电设备的缺陷图像，如变压器的腐蚀、裂纹和电缆的破损等。数据集包含两部分内容。

1) 缺陷图像。每张图像的分辨率为 256×256 像素，包含不同类别的缺陷。

2) 标签信息。每张图像都标注了缺陷类型（如裂纹、腐蚀和电缆损伤等）。

数据集的总规模为5 000张图像，其中70%用于训练，15%用于验证，15%用于测试。

为了提高模型的泛化能力，采用了数据增强技术，如旋转、翻转、缩放和裁剪等。这样不仅增加了训练样本的多样性，还能有效减少过拟合现象。

得到的缺陷图像识别准确率实验结果如图1所示。




图1 缺陷图像识别准确率

使用深度学习模型进行训练后，变电设备缺陷图像识别的准确率最高达到了97.5%。相比之下，传统方法的准确率最高为92.3%，显示出深度学习模型在特征提取和识别上的优势。

缺陷图像分类准确率如图2所示。




图2 缺陷图像分类准确率

可以看到，本文方法在所有缺陷类别（如裂纹、腐蚀及损坏电缆等）上的表现均优于传统方法。

通过对比不同模型的性能，可以得出结论：深度学习模型在变电设备缺陷检测中具有较强的优势，能够有效地提升缺陷识别的准确性和自动化水平。

结束语

本文通过基于深度学习的变电设备缺陷图像识别与分类技术，提出了一种高效的自动化缺陷检测与分类方法。通过引入卷积神经网络（CNN）模型，结合多种优化策略和数据增强技术，实现了变电设备缺陷图像的精准分类，并在实验中取得了较为优异的性能。实验结果表明，基于深度学习的缺陷识别系统能够有效识别变电设备中的常见缺陷类型，具有较高的准确率和较强的鲁棒性。

然而，变电设备缺陷图像受光照、角度等因素的影响较大，可能导致图像质量不佳，影响模型的

识别能力。其次，在处理复杂的缺陷场景时，深度学习模型可能会出现过拟合的现象，需要更多的训练数据和正则化手段来解决。未来，进一步优化网络结构，结合多模态传感数据，以及引入在线学习和迁移学习等方法，将有助于提升模型在实际应用中的适应性和准确性。EA

（收稿日期：2025-05-07）

参考文献

- [1] 齐冬莲, 韩译锋, 周自强, 等. 基于视频图像的输变电设备外部缺陷检测技术及其应用现状[J]. 电子与信息学报, 2022, 44(11): 3709-3720.
- [2] 李雅峰. 基于深度学习与点云数据的3D检测系统应用研究[J]. 微型电脑应用, 2024, 40(2): 62-65.
- [3] 李明轩, 李峰, 颜培培, 等. 计及等效负荷密度的变电站设备故障缺陷识别仿真[J]. 微型电脑应用, 2024, 40(5): 120-123.
- [4] 付晶, 谈家英, 周立玮, 等. 输电线路无人机巡检图像缺陷智能识别方法分析[J]. 高电压技术, 2023, 49(S1): 103-110.
- [5] 李瑛, 耿军伟, 赵留学, 等. 基于ChineseBERT和多特征协同网络的电力设备缺陷文本分类模型[J]. 微型电脑应用, 2024, 40(2): 106-109.
- [6] 裴少通, 杨家骏, 马子儒, 等. 基于深度学习的输变电设备紫外放电光斑分割方法[J]. 科学技术与工程, 2022, 22(33): 14759-14766.
- [7] 谢静, 杜耀文, 刘志坚, 等. 基于轻量化改进型YOLOv5s的可见光绝缘子缺陷检测算法[J]. 电网技术, 2023, 47(12): 5273-5282.
- [8] 贾骏, 杨强, 付慧, 等. 基于电力设备大数据的预训练语言模型构建和文本语义分析[J]. 中国电机工程学报, 2023, 43(3): 1027-1036.