

深度学习在电力设备缺陷检测中的应用

张扬

山东电工电气集团新能源科技有限公司, 中国·山东 济南 250100

摘要: 随着电力系统的不断扩展和智能化水平的提升, 确保电力设备的稳定和可靠运行已成为确保电力供应的关键。电力设备缺陷检测, 作为预防故障和保障电力系统安全的重要环节, 其传统检测方法在效率、准确性和实时性方面的局限性越来越明显。利用深度学习技术的强项——自动特征提取和复杂模式识别, 为电力设备缺陷检测领域带来了新的解决方案。论文深入分析了深度学习在电力设备缺陷检测中的应用, 详细探讨了其关键技术、算法模型、实际应用案例、所面临的挑战以及未来的发展方向, 目的是促进电力设备缺陷检测技术的发展, 提高电力系统的运行可靠性, 提供理论和实践上的参考。

关键词: 深度学习; 电力设备; 缺陷检测; 卷积神经网络; 目标检测

Application of Deep Learning in Defect Detection of Power Equipment

Yang Zhang

Shandong Electric Group New Energy Technology Co., Ltd., Jinan, Shandong, 250100, China

Abstract: With the continuous expansion of the power system and the improvement of intelligence level, ensuring the stable and reliable operation of power equipment has become the key to ensuring power supply. The detection of defects in power equipment, as an important part of preventing faults and ensuring the safety of the power system, has increasingly obvious limitations in terms of efficiency, accuracy, and real-time performance compared to traditional detection methods. Utilizing the strengths of deep learning technology - automatic feature extraction and complex pattern recognition - has brought new solutions to the field of power equipment defect detection. The paper deeply analyzes the application of deep learning in power equipment defect detection, and explores in detail its key technologies, algorithm models, practical application cases, challenges faced, and future development directions. The purpose is to promote the development of power equipment defect detection technology, improve the operational reliability of the power system, and provide theoretical and practical references.

Keywords: deep learning; power equipment; defect detection; convolutional neural network; target detection

0 前言

电力作为现代社会经济发展与民生保障的核心能源, 其稳定供应直接关系到社会的深度学习作为人工智能领域的核心技术, 凭借其强大的自动特征提取能力和复杂模式识别能力, 能够从海量数据中自动学习和挖掘潜在的特征模式, 无需人工手动设计特征。将深度学习应用于电力设备缺陷检测领域, 能够有效克服传统检测方法的弊端, 实现对电力设备缺陷的快速、准确、智能化检测, 及时发现设备潜在故障隐患, 为电力设备的运维管理提供科学依据, 对于保障电力系统的安全稳定运行、提高电力供应质量具有重要的现实意义。

1 深度学习基础理论与技术

1.1 深度学习概述

深度学习是基于人工神经网络的机器学习技术, 它通过多层神经网络自动学习数据中的模式和特征。与传统方法相比, 深度学习能自动提取特征, 减少对专家知识的依赖, 适应复杂数据和任务。

深度学习模型由输入层、隐藏层和输出层组成, 通过数据变换处理得到预测结果。训练时, 调整参数以最小化误差, 常用方法包括随机梯度下降及其变种, 以优化模型性能。

1.2 卷积神经网络 (CNN) 原理与结构

卷积神经网络 (CNN) 是深度学习中广泛使用的模型, 尤其适合处理图像和视频数据。它通过组合卷积层、池化层和全连接层自动提取特征。

CNN 的核心是卷积层, 使用卷积核在数据上滑动提取局部特征。卷积核参数如大小、数量和步长影响特征提取效果。池化层紧随其后, 通过下采样减少特征图分辨率和计算量, 增强模型鲁棒性。池化方式包括最大池化和平均池化。全连接层将特征图扁平化后连接输出层, 用于分类或回归。

以经典的 LeNet-5 模型为例, 其结构如图 1 所示。

该模型输入为 32×32 的图像, 经过两次卷积和池化操作后, 再通过两个全连接层, 最终输出分类结果。这种结构能够有效地识别手写数字等简单图像。随着深度学习的发展, 涌现出了许多更复杂、性能更强大的 CNN 模型, 如 AlexNet、VGG、ResNet 等, 这些模型在图像识别、目标检

测等领域取得了优异的成绩。




图 1 LeNet-5 模型结构示意图

1.3 循环神经网络 (RNN) 及其变体

循环神经网络主要用于处理具有序列特征的数据，如时间序列数据、自然语言等。与前馈神经网络不同，RNN 在处理序列数据时，能够记住之前时间步的信息，并将其融入当前时间步的计算中，从而对序列中的长期依赖关系进行建模。

RNN 的基本单元是循环单元，其结构如图 2 所示。

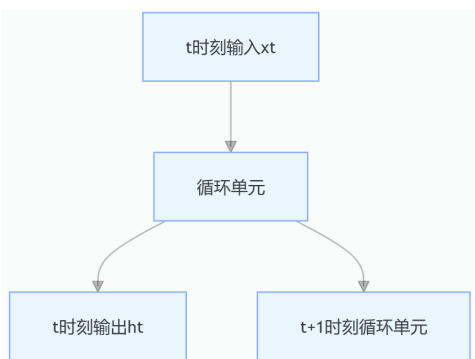


图 2 RNN 循环单元结构示意图

在每个时间步，循环单元接收当前输入 x_t 和上一时刻的隐藏状态 h_{t-1} ，通过非线性变换得到当前时刻的隐藏状态

h_t ，即： $h_t = \sigma(W_{xh}x_t + W_{hh}h_{t-1} + b_h)$ 。其中， σ 为激活函数，常用的有 sigmoid、tanh 等； W_{xh} 和 W_{hh} 分别为输入权重矩阵和隐藏层权重矩阵； b_h 为偏置向量。

然而，传统 RNN 在处理长序列数据时存在梯度消失和梯度爆炸问题，导致其对长期依赖关系的建模能力有限。为解决这些问题，研究者提出了长短期记忆网络 (LSTM) 和门控循环单元 (GRU) 等变体。

LSTM 通过引入输入门、遗忘门和输出门，能够有效地控制信息的流入、流出和记忆，从而更好地处理长序列数据。其结构如图 3 所示。

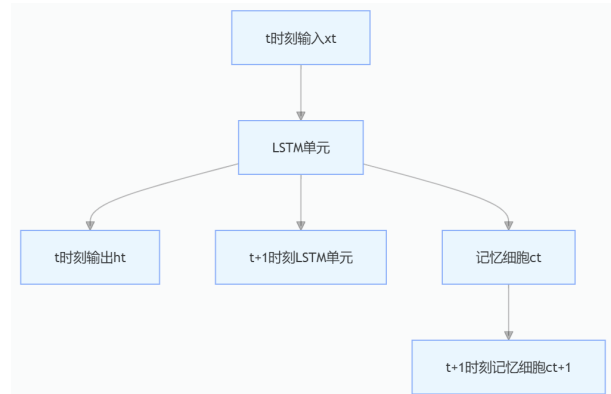


图 3 LSTM 单元结构示意图

GRU 则是在 LSTM 的基础上进行了简化，通过更新门和重置门来控制信息的流动，在保持较好性能的同时，减少了计算量。这些 RNN 变体在电力设备缺陷检测中，可用于分析设备运行状态的时间序列数据，预测设备缺陷的发展趋势。

1.4 生成对抗网络 (GAN) 简介

生成对抗网络由生成器和判别器组成，通过两者之间的对抗训练，使生成器能够生成逼真的数据样本。在电力设备缺陷检测中，GAN 可用于数据增强，解决样本数量不足的问题。

生成器的作用是根据随机噪声生成数据样本，判别器则负责判断输入的数据样本是真实数据还是生成器生成的虚假数据。在训练过程中，生成器和判别器相互博弈，不断优化自身的参数，使得生成器生成的数据越来越接近真实数据，判别器越来越难以区分真实数据和生成数据。其训练过程可表示为： $\min_G \max_D J(D,G) = E_{x \sim p_{data}(x)}[\log D(x)] + E_{z \sim p_z(z)}[\log(1 - D(G(z)))]$ 。其中， G 为生成器， D 为判别器， $p_{data}(x)$ 为真实数据分布， $p_z(z)$ 为噪声分布。通过这种对抗训练方式，GAN 能够生成多样化的电力设备缺陷样本，扩充训练数据集，提高深度学习模型的泛化能力。例如，在绝缘子缺陷检测中，利用 GAN 生成不同类型、不同程度的绝缘子缺陷图像，丰富训练数据的多样性，有助于训练出更具鲁棒性的检测模型。

2 电力设备常见缺陷类型及特征分析

2.1 输电线路缺陷

绝缘子是输电线路中关键的绝缘部件，常见缺陷包括

污秽和破损。污秽绝缘子表面吸附灰尘、盐分等，形成导电通道，降低绝缘性能，增加闪烁风险。图像上表现为颜色变深、污渍斑块。破损绝缘子如瓷体开裂、掉块、伞裙损坏，会破坏绝缘结构和机械强度，图像上可见裂纹、缺口或伞裙缺失。

输电线路导线易出现断股和磨损缺陷。断股是导线受风力、冰雪荷载、机械振动和短路电流冲击等作用，导致股线断裂，降低承载能力和导电性能。图像上表现为不连续的断裂点，断口金属光泽异常。磨损主要由导线与悬挂金具摩擦、舞动等造成，表面变细、出现划痕，减少使用寿命。

2.2 变电设备缺陷

变压器是变电设备的核心，主要缺陷包括绕组变形和过热。绕组变形可能由短路电流、运输振动或长期过载引起，间接判断方法包括测量短路阻抗和绕组电感等电气参数。变压器过热可能由绕组短路、铁芯过热或分接开关接触不良引起，红外热像仪能显示过热部位。

断路器是电力系统关键控制和保护设备，主要问题包括触头磨损和接触不良。磨损由电弧侵蚀和机械摩擦引起，接触不良可能由氧化、污垢或压力不足引起。红外图像中，磨损表现为表面不平整和磨损坑洼，接触不良导致的过热表现为触头部位温度异常升高。

互感器在运行中可能面临绝缘老化和故障问题。绝缘老化由电气应力、热应力和化学腐蚀等因素引起，可能导致绝缘击穿。互感器也可能出现绕组短路或开路故障。基于图像的检测可观察外观异常，但对早期绝缘老化的检测敏感度低，需结合电气试验和局部放电检测。

2.3 配电设备缺陷

配电设备运行状态影响用户用电质量和安全。

配电箱外壳易腐蚀损坏，长期户外暴露导致防护性能下降，增加故障概率。损坏可能由外力或安装不当引起。

配电线路可能短路或断路，影响供电安全。短路可能引发火灾和设备损坏，断路导致停电。地下电缆的缺陷检测难度大，需专业设备。

开关设备操作故障影响供电，需实时监测操作过程。图像检测可观察触头动作和指示灯状态，但内部故障需综合诊断。

3 基于深度学习的电力设备缺陷检测方法

3.1 基于卷积神经网络的电力设备缺陷检测

3.1.1 目标检测算法

在电力设备缺陷检测中，目标检测算法用于定位并识别图像中存在的缺陷。基于卷积神经网络的目标检测算法主要分为两类：一类是基于区域提议的两阶段目标检测算法，如 R-CNN (Regions with CNN features) 系列；另一类是单阶段目标检测算法，如 YOLO (You Only Look Once) 系列和 SSD (Single Shot MultiBox Detector)。

R-CNN 是早期将深度学习用于目标检测的算法，通过选择性搜索生成候选区域，再用卷积网络提取特征和分类，但计算量大且速度慢。Fast R-CNN 和 Faster R-CNN 通过共享特征和引入 RPN 改进了这些缺点，提高了速度和精度。

YOLO 算法将目标检测视为回归问题，直接预测类别和位置，检测速度快，适合实时应用，但小目标检测和精度不足。YOLOv4 和 YOLOv5 通过改进网络和训练方法，在保持速度的同时提升了精度。

SSD 算法结合了 YOLO 的回归思想和 Faster R-CNN 的多尺度特征图检测方法，在不同尺度的特征图上进行目标检测，能够更好地检测不同大小的目标。通过对不同算法的实验对比 (见表 1)，可以看出不同算法在检测精度和速度上各有优劣，在实际应用中需要根据具体需求进行选择。

表 1 不同目标检测算法性能对比

算法	平均精度均值 (mAP)	检测速度 (FPS)
Faster R-CNN	85.6%	15
YOLOv5	83.2%	50
SSD	80.5%	30

3.1.2 图像分类算法

图像分类算法在电力设备缺陷检测中主要用于判断图像中的电力设备是否存在缺陷以及缺陷的类型。常见的基于卷积神经网络的图像分类算法有 AlexNet、VGG、ResNet 等。

AlexNet 是首个在图像分类上表现突出的深度卷积神经网络，利用 ReLU 和 Dropout 技术改善了梯度问题，提升了训练效率和泛化性。VGG 通过增加卷积层深度，学习更复杂的图像特征，但深度增加也带来了梯度问题。ResNet 通过残差连接解决了梯度问题，简化了深层网络训练，增强了性能。

在电力设备缺陷检测中，选择合适的图像分类算法对提高准确性至关重要。以变压器缺陷检测为例，使用 AlexNet、VGG16 和 ResNet50 进行训练和测试。结果表明，ResNet50 在准确率和召回率上表现最优，其残差结构更有效地学习了缺陷特征 (见图 4)。

3.2 基于循环神经网络的电力设备缺陷检测

3.2.1 时间序列数据分析

电力设备在运行过程中会产生大量的时间序列数据，如电压、电流、温度等参数的变化。基于循环神经网络 (RNN) 及其变体 (如 LSTM、GRU) 的方法可以有效地处理这些时间序列数据，分析设备运行状态的变化趋势，预测设备缺陷的发生。

以变压器油温数据为例，监测一段时间的油温，形成时间序列。RNN 能学习油温变化规律，预警异常升高或波动。LSTM 和 GRU 的门控机制更擅长处理长序列数据的长期依赖，预测油温异常变化效果更佳。训练 LSTM 模型预测未来油温变化 (见图 5)，模型能拟合油温趋势，异常时预测值与实际值偏差增大，预警潜在过热缺陷。

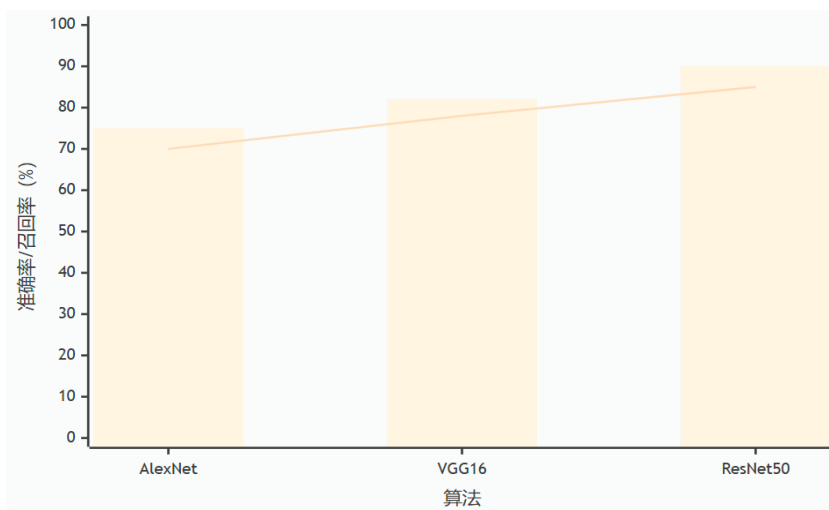


图 4 不同图像分类算法在变压器缺陷检测中的性能对比 (柱状图为准确率, 折线图为召回率)




图 5 基于 LSTM 的变压器油温预测 (蓝色线为实际油温, 橙色线为预测油温)

3.2.2 设备状态预测

循环神经网络不仅分析电力设备运行参数, 还能结合传感器数据和维护记录预测设备状态。构建多输入 RNN 模型, 输入包括电气参数和设备运行、维护信息, 输出设备健康评估。例如, 断路器模型利用操作次数、电流变化和触头温度等数据, 预测故障概率, 支持预防性维护。

3.3 深度学习模型的训练与优化

3.3.1 数据增强技术

在电力设备缺陷检测中, 由于获取大量带有标注的缺陷图像数据较为困难, 数据增强技术成为提高模型性能的重要手段。数据增强通过对原始数据进行变换, 如旋转、翻转、缩放、裁剪、添加噪声等操作, 生成新的样本, 扩充训练数据集的规模, 增加数据的多样性, 从而提高模型的泛化能力。

以绝缘子缺陷图像为例, 对原始图像进行水平翻转随

机裁剪和添加高斯噪声等数据增强操作后, 得到了不同的图像样本, 这些样本在模型训练过程中能够让模型学习到更多的特征变化, 从而提高对不同角度、不同背景下绝缘子缺陷的识别能力 (见图 6)。

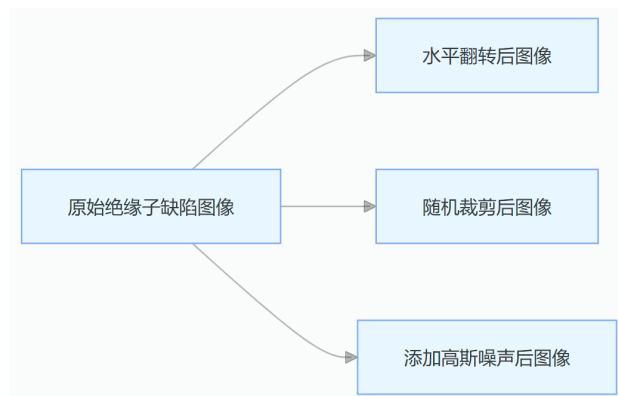


图 6 绝缘子缺陷图像的数据增强示例

3.3.2 模型训练优化方法

在深度学习模型训练过程中，选择合适的优化方法可以加快模型的收敛速度，提高模型的性能。除了常见的随机梯度下降（SGD）算法外，Adagrad、Adadelta、Adam 等自适应学习率优化算法在电力设备缺陷检测模型训练中也得到了广泛应用。

Adam 算法结合了 Adagrad 和 RMSProp 算法的优点，能够自适应地调整每个参数的学习率，在训练过程中表现出较好的稳定性和收敛速度。通过对基于 YOLOv5 的输电线路缺陷检测模型分别使用 SGD 和 Adam 算法进行训练（见图 7），可以发现使用 Adam 算法的模型在训练初期损失下降更快，且最终能够达到更低的损失值，从而获得更好的检测精度。

此外，还可以通过调整网络结构参数、增加训练数据量、使用预训练模型等方法进一步优化模型性能。例如，在基于 ResNet 的电力设备图像分类模型中，适当增加网络的深度和宽度，同时使用在大规模图像数据集上预训练的模型作为初始化，能够显著提高模型在电力设备缺陷检测任务中的准确率。

4 深度学习在电力设备缺陷检测中的应用案例

一家电力企业在其输电线路的巡检工程中采纳了深度学习驱动的缺陷识别技术。该技术通过无人机搭载的高分辨率摄像头对输电线路进行拍摄，从而收集了众多图像资料。这些图像资料经过详细标注后，形成了一个包含多种缺陷类型的数据集，例如输电线路的断股、绝缘子的污秽以及线路上的异物悬挂等。利用 YOLOv5 目标检测算法对这些输电线路图像进行训练和识别，该技术在实际应用中展现出了优异的性能。

在某次巡检作业中，无人机所采集的图像资料经过 YOLOv5 模型的分析处理，准确地识别出了一处绝缘子的破损缺陷（见图 8）。该模型不仅精确地确定了缺陷的具体位置，还成功辨识了缺陷的种类。与传统的人工巡检手段相比，基于深度学习的缺陷检测技术显著提升了巡检的效率，能够在较短的时间内检查更广泛的输电线路区域。此外，通过对检测结果的分析统计，电力企业能够更精确地了解输电线路的运行状况，从而合理规划维护作业，有效减少了线路故障的可能性。

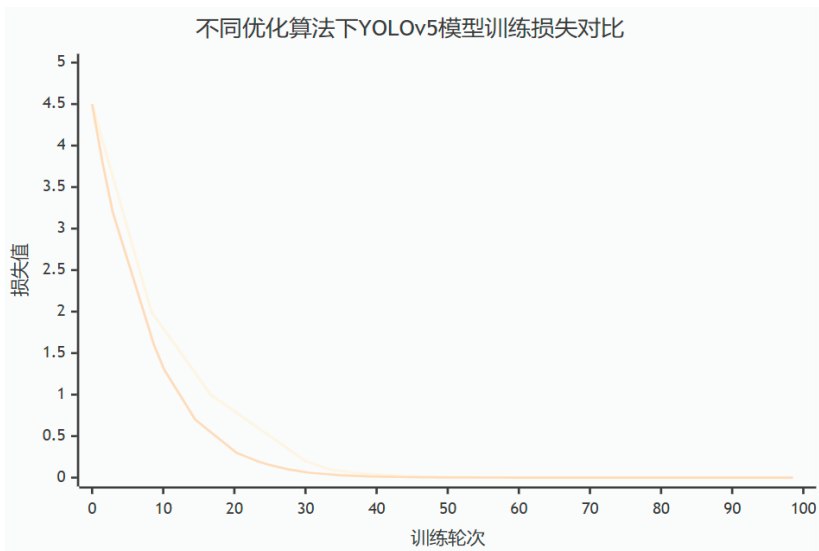


图 7 SGD 和 Adam 算法下 YOLOv5 模型训练损失对比（蓝色线为 SGD，橙色线为 Adam）




图 8 基于 YOLOv5 的输电线路绝缘子破损缺陷检测示例

参考文献：

[1] 胡维昊.人工智能与电气应用[M].北京:科学出版社,2021.

[2] 上海交通大学物理与天文学院太阳能研究所.基于深度学习的光伏组件多类型缺陷自动检测及其在实际生产线中的应用[J].光伏研究及应用进展,2021(29):471-484.

[3] 发明一种基于深度学习的电力设备缺陷检测识别方法与流程 [P].X技术,2024.

[4] 基于深度学习的电网绝缘子缺陷检测方法研究 [D].豆丁网,2025.