

文章编号：1672-8785(2024)03-0040-09

基于多层级深度神经网络的电力设备红外图像故障识别

于晓 庄光耀

(天津理工大学电气工程与自动化学院, 天津 300384)

摘要：电力设备的故障可能导致电力系统不稳定甚至解列，对电力安全和国民经济造成巨大损失，因此迅速且准确地识别这些故障至关重要。红外图像特征在捕捉发热故障的电力设备方面表现出良好的特征表达能力。然而，在图像采集过程中，可能会发生目标重叠、遮挡以及类目标干扰等问题。因此提出了一种复杂图像故障识别算法。基于多层级深度神经网络，充分利用多层网络模块的高层次特征提取能力和多级网络模块的特征融合能力，以提高故障识别的准确性。实验结果表明，该算法在准确率和运行时间等评估指标上优于现有的Faster-RCNN、VGG16、VGG19以及传统Resnet等模型，验证了其在解决图像中目标重叠、遮挡和类目标干扰等问题上的有效性。

关键词：多层级；红外图像；特征金字塔；故障识别

中图分类号：TP18 **文献标志码：**A **DOI：**10.3969/j.issn.1672-8785.2024.03.006

Fault Recognition of Power Equipment Infrared Images Based on Multilayer Deep Neural Networks

YU Xiao, ZHUANG Guang-yao

(School of Electrical Engineering and Automation, Tianjin University of Technology, Tianjin 300384, China)

Abstract: The malfunction of power equipment may lead to instability or even disconnection of the power system, causing huge losses to power safety and the national economy. It is crucial to quickly and accurately identify these malfunctions. Infrared image features exhibit excellent feature expression ability in capturing the heating malfunctions of power equipment. However, during the image acquisition process, problems such as object overlap, occlusion and interference between categories may occur. Therefore, a complex image fault recognition algorithm based on multilayer deep neural networks is proposed in this paper, fully utilizing the high-level feature extraction capability of multilayer network modules and the feature fusion capability of multi-level network modules to improve the accuracy of fault recognition. Experimental results show that the proposed algorithm is superior to existing models such as Faster-RCNN, VGG16, VGG19 and traditional Resnet models in terms of accuracy and running time, and its effectiveness in solving problems such as target overlap, occlusion and class interference in images is verified.

Key words: multi-level; infrared image; characteristic pyramid; fault identification

收稿日期：2023-09-19

作者简介：于晓(1985-),男,山东郯城人,副教授,博士,主要研究方向为人工智能与图像处理。

E-mail: yx_tjut@163.com

0 引言

随着现代电力系统规模的不断扩大和复杂性的增加, 电力设备的多种缺陷对电网的正常运转造成影响, 严重的缺陷甚至可能导致生产生活方面的巨大损失。因此, 实现快速准确的设备缺陷检测对确保电力系统的稳定运行具有重要意义^[1]。根据电力设备的应用特点, 许多缺陷往往会导致异常发热现象^[2], 而红外图像技术可以有效地凸显电力设备的这些缺陷。

红外热像技术由于具备非接触、实时、全局的特点, 因此有全程无接触且不停电进行识别的优势。但拍摄时由于电力设备本身具有复杂性和特殊性, 在运行过程中存在多种变化, 比如环境温度的变化、照明条件的变化、拍摄角度与距离的变化等。这些都会对红外图像造成一定程度的影响, 所拍摄的电力设备红外图像存在目标重叠遮挡、类目标干扰等问题。

传统的机器学习方法在电力设备红外图像故障识别中存在一些限制。该方法主要依赖于人工先验知识来提取特征^[3], 但由于红外图像的复杂性, 这些手工设计的特征描述能力相对较弱。此外, 该方法在面对目标重叠遮挡和类目标干扰时的鲁棒性较差, 导致其准确率较低且泛化能力有限。因此, 为了实现对电力设备故障的实时准确识别, 基于深度神经网络的电力设备红外图像故障识别技术成为当前电力设备缺陷检测研究的热点^[4]。

本文针对所拍摄电力设备红外图像存在目标重叠遮挡、类目标干扰等背景复杂的问题, 提出基于多层级深度神经网络的复杂图像故障识别算法, 借鉴多层网络模块抽取高层次特征的能力和多级网络模块的特征融合能力, 增加了网络的宽度和深度, 提高了故障识别的准确率。

1 相关工作

1.1 问题分析

近年来, 电力设备红外图像故障诊断识别研究在国内外受到广泛关注, 人们也提出了一

些针对电力设备异常或故障发热的诊断方法, 比如电压降落分步法、脉冲电晕电流法、电场分布测量法、磁感应强度对比法、红外成像法等。其中, 红外图像技术作为一种非接触式、不停电、无损检测手段, 具有对电力设备进行隐蔽性缺陷检测的优势, 因此在电力行业得到了广泛应用。

但随着电网规模的扩大和电力设备的密集使用, 红外图像的拍摄存在一定的困难, 导致所拍摄的电力设备红外图像存在目标模糊、目标重叠遮挡、类目标干扰等复杂图像问题。针对此类具有复杂特征的红外图像, 传统的机器学习方法存在一系列限制, 在红外图像故障识别任务中的准确性较低, 而且泛化性能有限。

随着人工智能深度学习理论体系的发展, 各类目标检测与故障识别算法应运而生。本文提出一种基于多层级深度神经网络的复杂图像故障识别算法模型, 针对电力设备复杂红外图像实现了故障的准确识别。图 1 为存在目标模糊、目标重叠遮挡、类目标干扰等问题的复杂图像。

1.2 红外图像在电力设备故障识别中的应用

红外热成像技术是一种基于电磁波形式检测红外能量的无损技术, 主要利用电力设备的红外辐射来测量物体表面的热量分布, 从而检测并评估发热点的严重程度。

近年来, 红外热成像检测技术由于具备无创性、安全性以及相对较低的成本优势, 已被广泛应用于电气设备状态的非损伤性检查, 成为一种高效的评估方法。该技术可以及时探测电气设备中的异常热点, 有助于预防潜在的故障和事故, 并提高设备的可靠性与安全性。Wang J 等人提出了一种基于红外图像的电力设备故障诊断方法^[5]。他们采用红外图像技术来检测电力设备中的异常温度变化, 并据此进行故障诊断, 以实现对不同类型故障的准确识别。Tan X 等人提出了一种基于红外重建图像融合的超高速冲击损伤检测算法^[6]。他们通过实际超高速撞击产生的损坏标本进行红外检测

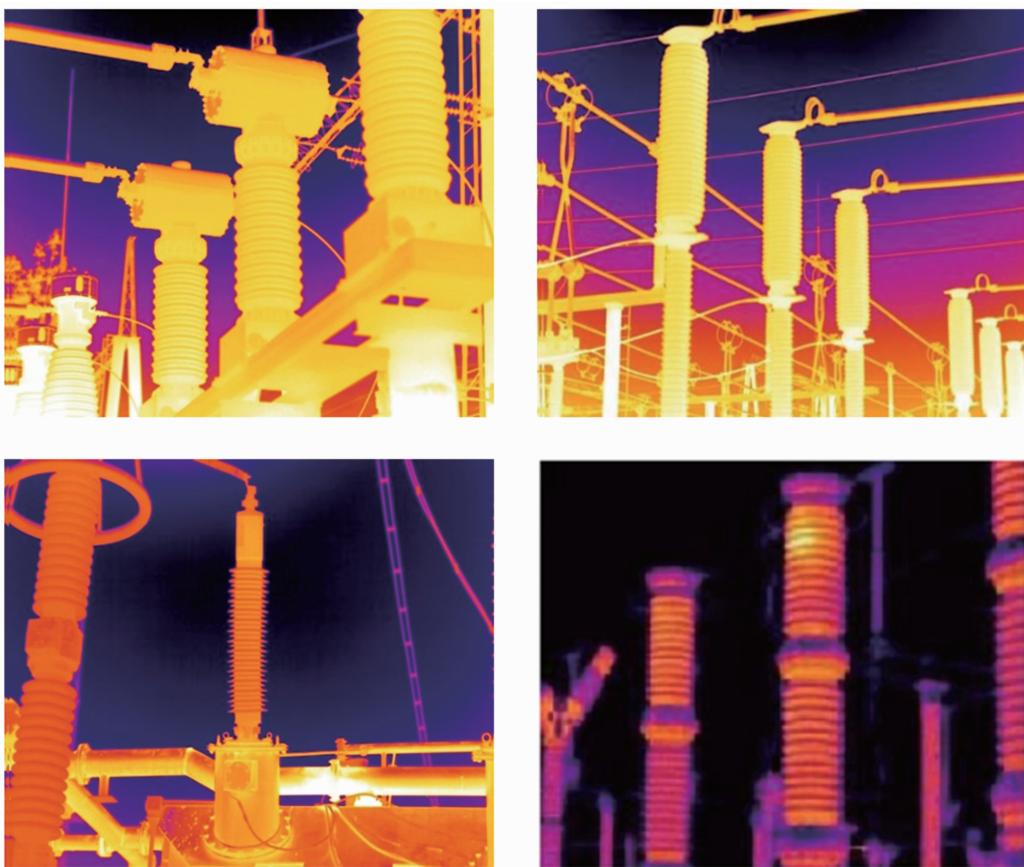


图1 电力设备复杂红外图像

实验，验证了其有效性。这一研究对于超高速冲击损伤检测领域具有重要意义，为解决此类问题提供了一种新的方法。

此外，Jiang A 等人提出了一种直接使用深度学习可见图像识别进行电力设备红外诊断的新方法^[7]。他们利用高清可见光照片样本库训练深度学习模型，然后通过深度学习模型识别新照片中的电力设备类型，并进行像素级定位。另外，他们结合可见光图像进行图像配准，使两种电力设备图像的像素一一对应，从而得到电力设备对应的温度像素。这一技术为电力设备红外诊断提供了一种新的解决方案。Wang J 提出了一种基于广义学习系统的电气设备热像图像诊断策略^[8]。该策略在电气设备状态监测与评估方面具有潜在的学术和应用价值。Huda A S N 提出了一种智能热缺陷识别系统^[9]。该系统通过分析电气设备的热图像，采集相关数据进行热状态调查，并采用预防性和预测性维修程序来实现故障诊断。Suguna

M 将红外图像转换为 HSV(色相、饱和度、亮度)图像模型^[10]，以便进行进一步的处理。特别针对有缺陷的太阳能电池板和其他电气设备的热图像，该方法表现出了更优越的特征提取能力和更高的分类精度。这些研究成果使得红外图像在电力工程领域具有重要的学术价值和应用前景，有望为电气设备状态监测与维护领域的进一步研究和发展提供有益启示。

1.3 深度学习算法在电力设备故障识别中的研究现状

深度学习网络利用卷积神经网络逐层学习图像中的特征，通过对大量图像数据迭代训练来优化损失函数的参数，进而提高检测和识别精度。例如，李洋等人将 CNN 与 Transformer 结合组成新模型进行变电站电力设备的分割，提出了一种基于编解码器结构的新型 SE-Transformer 网络^[11]。贾鑫提出了一种监督算法，使用 Softmax 损失和中心损失对红外样本图像进行特征训练。该双监督信号的分类模型

具有更高的识别准确率，并且在多种电力设备（如变压器套管）等方面均得到了成功应用^[12]。这一研究成果对于红外图像的特征提取和分类模型优化具有重要意义，并为电力设备故障诊断的自动化提供了有效的解决途径。

陈达等人针对变电站人工诊断作业量大、效率低的问题，提出了一种基于 MobileNet 的设备故障诊断方法^[13]。该方法能够对套管、电容式电压互感器、开关柜等设备的红外图像进行自动诊断，并具有设备分类的能力。这一自动诊断方法的应用有望极大地提高设备故障诊断的效率和准确性，为电力设备维护与管理提供了一种高效可行的技术方案。刘云鹏等人采用快速区域卷积神经网络算法对输变电设备的红外图片进行智能评估诊断^[14]。他们提出了一种异常发热点目标检测方法。实验结果表明，即使在复杂背景下，该模型依然具备良好的检测性能。这一研究成果为电力设备红外图像的智能评估与故障检测提供了一种高效准确的算法，为电力系统的健康运行与设备状态监测提供了有力支持。以上这些方法和算法在提

高电力设备故障诊断准确性、自动化程度以及效率方面都取得了显著的成果，对于电力工程的发展和电力设备的维护管理具有积极的推动作用。

2 基于多层级深度神经网络的复杂图像故障识别算法模型

本文提出了一种针对电力设备复杂红外图像进行故障识别的算法模型。首先，通过包含 2 个小卷积核的两层卷积传入下一卷积层中；经过一部分卷积层的特征提取，使得前三段卷积采集到的特征表达传入多层次网络模块后进行特征多层次提取与深入融合。然后下一级卷积层通过卷积、池化等方法进一步提取特征。最后的 3 层全连接层负责完成故障诊断识别任务。基于多层次深度神经网络的复杂图像故障识别算法借鉴多层网络模块抽取高层次特征的能力和多级网络模块的特征融合能力，增加了网络的宽度和深度，提高了故障识别的准确率。本文提出的基于多层次深度神经网络的复杂图像故障识别算法结构如图 2 所示。

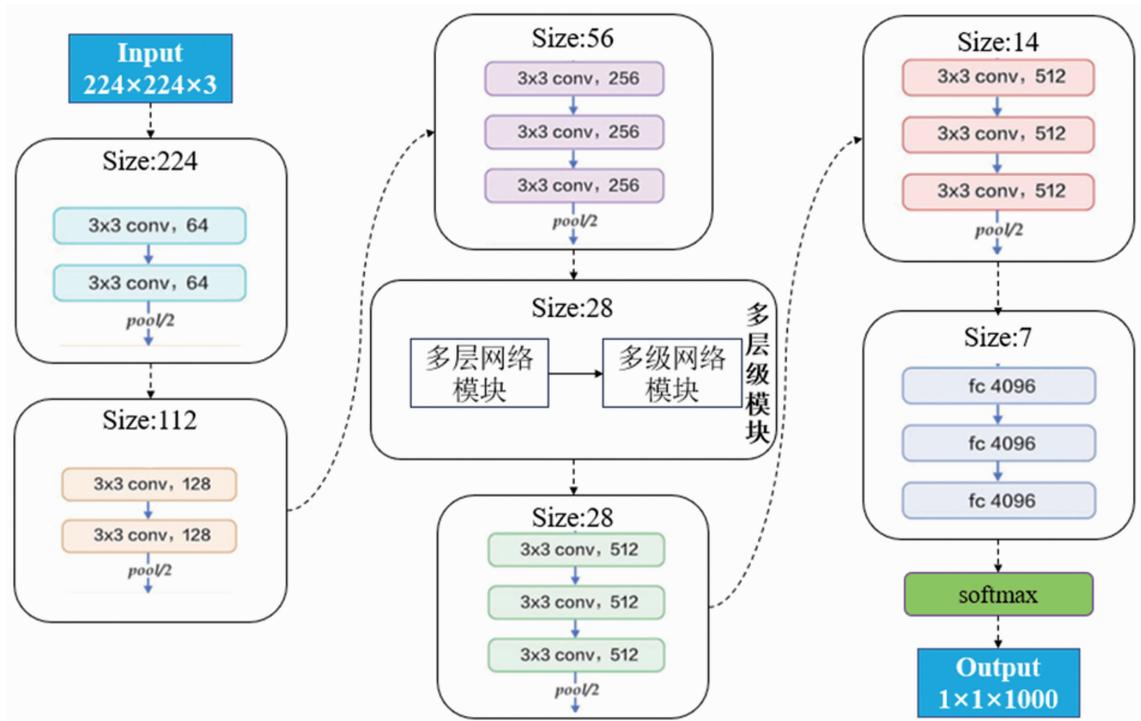


图 2 基于多层次深度神经网络的复杂图像故障识别算法结构图

2.1 多层网络模块

2017年,研究人员提出特征金字塔网络(Feature Pyramid Network, FPN),采用自上而下的结构对多尺度特征进行有效组合。该网络的目标是获得具有高分辨率和强语义信息的多层次特征,以应对多尺度物体检测和识别任务。FPN通过对顶层特征进行上采样,并与底层特征进行融合,从而实现不同分辨率特征的平滑连接,形成金字塔状的特征结构(见图3)^[15]。

图3(a)为“Channel plus”的示意图。该方法对高级特征图进行上采样,使其宽度 O_1 、高度 H_1 、通道数 C_1 与低级特征图的宽度 O_1 、高度 H_1 、通道数 C_1 相同。然后将两个特征图对应位置的值直接相加,提取到融合的特征图。计算方法如下:

$$z_{l3} = f_{l1} + f_{l2} \quad (1)$$

式中, z_{l3} 表示融合后的特征图 $l3$ 的特征向量, f_{l1} 表示高级特征图 $l1$ 的特征向量, f_{l2} 表示低级特征图 $l2$ 的特征向量。值得注意的是, $l1$ 和 $l2$ 的通道数量是相等的。

图3(b)是第二种方法的流程图。首先对高级特征图进行上采样,使其宽度、高度与低级特征图相匹配,同时将通道数减少为低级特征图的一半,得到高级特征映射 C_{l1} 。接着对卷积核为 1×1 的底层特征图进行卷积运算,将底层特征图的通道数减少为原来的一半。然后将经卷积得到的特征图与高级特征映射 C_{l1} 在通道维度上进行拼接,形成融合的特征图 C_{l3} 。这种融合过程的计算方法如下:

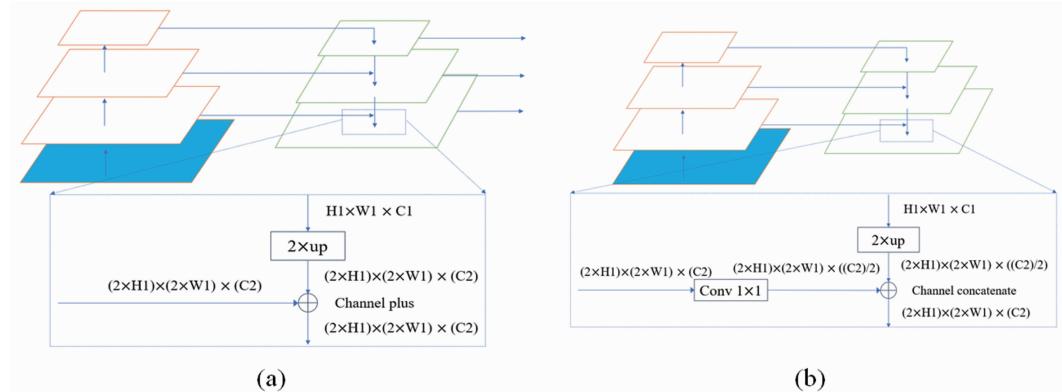


图3 FPN结构图

$$C_{l3} = C^*(C_{l1}, C_{l2}) \quad (2)$$

式中, C^* 为通道连接函数。

通过以上两种方法,将高级特征和低级特征融合在一起,构建一个更深层次的特征金字塔,从而提取多层次的特征信息^[16]。

多层网络模型在FPN的基础上,采用双向融合的思想,即对高阶特征和低阶特征构建了由顶到底和由底到顶的路线,通过上采样和下采样操作统一特征分辨率尺度,从而对两个尺度的特征进行更为丰富的表达^[17]。这在一定程度上解决了特征信息丢失的问题。多层网络模块结构如图4所示。针对前面提到的两种FPN网络,多层网络模块在特征融合表达上更具优势。首先,如果单层的特征仅与其他相同尺寸的特征进行结合,所得到的表达能力不强,那么它所呈现的特征贡献就会很小。其次,如果在高阶特征与低阶特征之间建立通道,则可融合不同尺寸间的特征,使其获得更加丰富的特征表达能力。传统的特征融合方法直接累加不同尺度的特征,忽略了不同尺度特征之间的差异;多层网络模块为了学习不同输入特征的重要性,对不同输入特征进行了区分融合,进一步提高了特征融合效率。权重公式如下:

$$Output = \sum_i \frac{\omega_i}{\epsilon + \sum_i \omega_i} \times Input \quad (3)$$

式中, ω_i 代表权重,在激活函数 $ReLU$ 的作用下 ω_i 为非负值; ϵ 为接近于0的极小值; $Input$ 表示输入的特征; $Output$ 表示加权特征融合的结果。

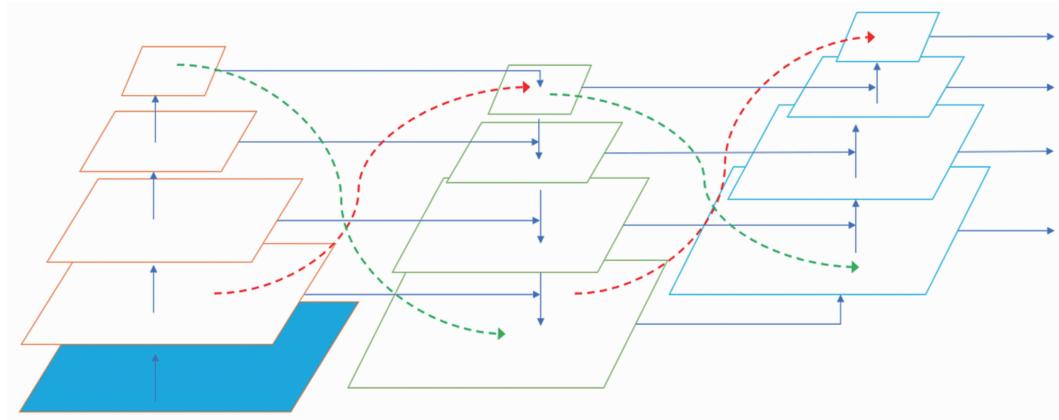


图4 多层网络模块图

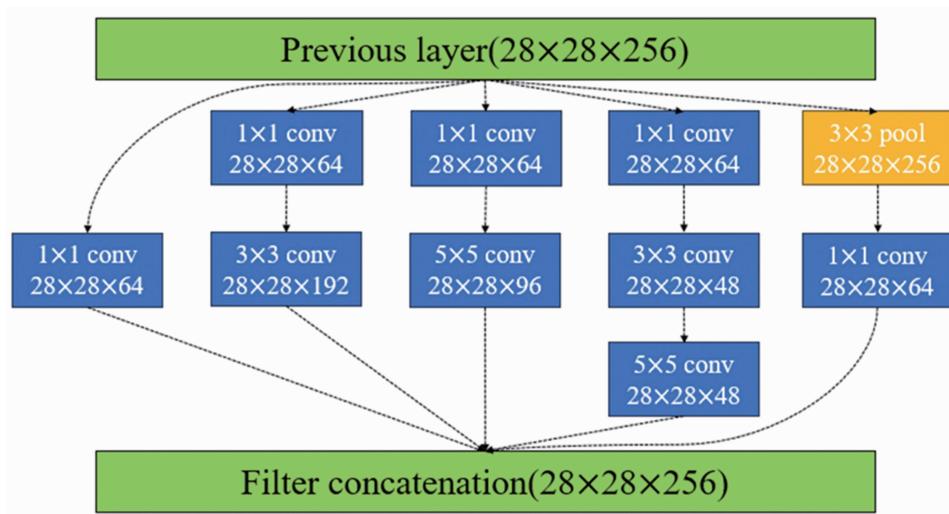


图5 多级网络模块图

2.2 多级网络模块

多级网络模块(见图5)在同一级上同时使用多种不同尺度的卷积核,从而提高网络对多层次网络模块输入特征的融合能力。通过并行地进行多尺度的卷积操作,捕捉输入数据在不同感受野下的特征表示,然后将得到的特征图进行拼接,可以获得更加丰富和多样化的特征融合能力。具体说来,先引入 1×1 卷积核,主要用于降维或升维操作,减少计算量和参数数量,同时可以提高网络的计算效率。然后分别使用 1×1 、 3×3 和 5×5 的卷积核进行卷积操作。这些卷积核具有不同大小的感受野,可以捕捉不同尺度的特征信息。在此基础上另外增加一个通道。该通道使用 3×3 和 5×5 的卷积核进行操作,使感受野更加宽广。此外,通过池化操作还可以进一步压缩特征图的空间尺

寸,从而减少计算量并提高网络的运行速度。最后,将通过不同尺度卷积得到的特征图进行拼接,实现更加丰富和多样化的特征融合。

2.3 多层级网络模块

多层级网络模块的总体结构如图6所示。借鉴多层网络模块抽取高层次特征的能力和多级网络模块的特征融合能力,形成了多层次网络模块。该模块首先采用多层次双向融合的思想(即对高阶特征和低阶特征构建由顶到底和由底到顶的路线),通过上采样和下采样操作统一特征分辨率尺度,从而对多个尺度的特征进行更为丰富的表达和提取;然后通过多层次网络使用不同感受野大小的卷积核来捕捉不同尺度的特征信息,使多层次网络模块提取的特征深入融合。

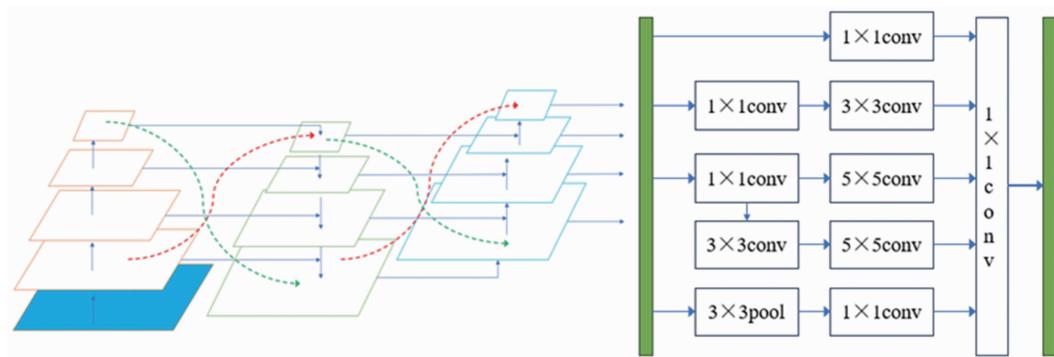


图 6 多层级网络模块结构图

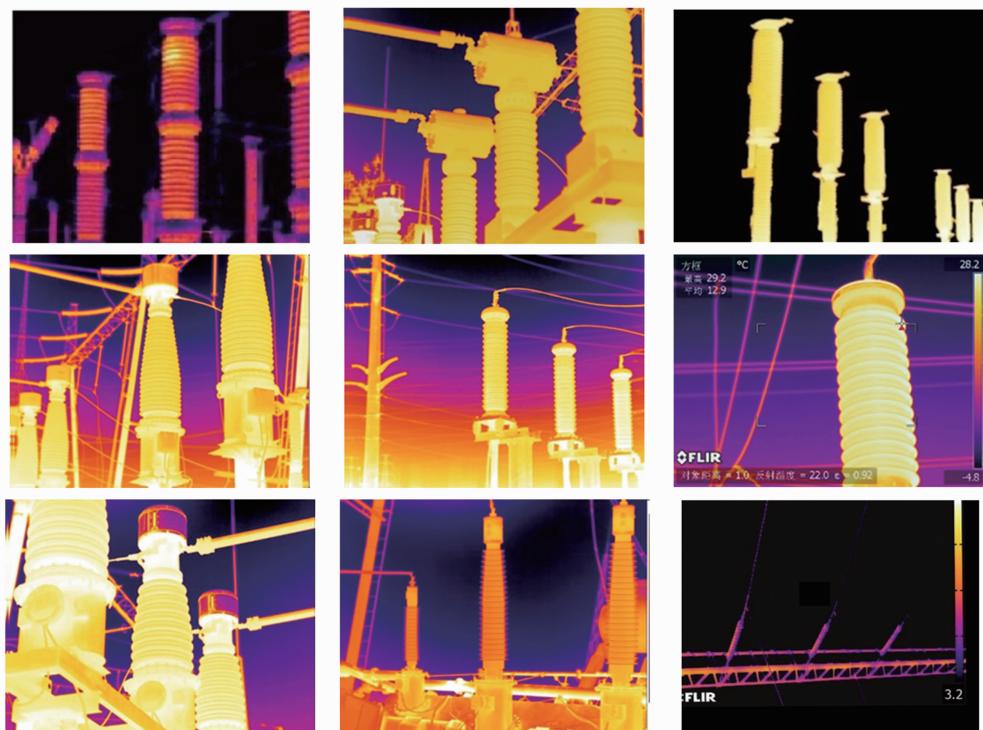


图 7 部分数据集图像

3 实验与分析

3.1 数据集

在所拍摄的电力设备红外图像数据集中，筛选出存在目标重叠遮挡、类目标干扰等问题的复杂红外图像。由于该问题的特殊性，得到大量高质量的复杂图像数据有一定的难度。因此，本文采用随机翻转、旋转和裁剪等方法对电力设备红外数据图像进行数据扩充，以增加数据集的多样性。最终得到 2000 张电力设备红外图像，并采用其中的 1800 张和 200 张分别作为训练数据和测试数据，以验证网络模型

的准确性。部分扩充后的电力设备红外图像如图 7 所示。

3.2 实验配置及环境

本文实验中的电脑配置及环境如表 1 所示。

表 1 实验配置及环境

硬件	配置
CPU	AMD Ryzen 7 5800H
GPU	NVIDIA GeForce RTX 3060
内存	16GB
固态硬盘	1024GB
软件开发环境	Pycharm、Anaconda Python3.9
操作系统	Windows10

3.3 评价指标

准确率(Precision)反映了匹配结果中正确样本的数量, 计算方法如下:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (4)$$

式中, TP 代表正确的预测值, FP 代表错误的预测值。

平均精度(AP)表示一个类别的所有准确率的平均值。AP 的数值为集合中某一类别的全部准确率之和与包含此类对象的总图像数 N_c 的比值:

$$AP = \frac{\sum \text{Precision}_c}{N_c} \quad (5)$$

然后再计算平均精度均值 mAP , 有

$$mAP = \frac{\sum_{k=0}^c AP_k}{C} \quad (6)$$

式中, C 表示总类别数。

3.4 结果分析

为测试本文提出的多层级深度神经网络的故障识别精度, 使用 Faster-RCNN、VGG16、VGG19 和传统 Resnet 模型进行对比实验(结果见表 2)。从表 2 中可以看出, 本文算法的 mAP 比 Faster-RCNN 网络提高了 8.9%, 比 VGG16 网络提高了 7.8%, 比 VGG19 网络提高了 4.1%, 比传统 Resnet 网络提高了 9.7%。实验数据表明, 本文改进的网络模型在准确率评价指标上优于 Faster-RCNN、VGG16、VGG19 和传统 Resnet 模型, 针对复杂的电力设备红外图像具有较为准确的故障识别能力。图 8 所示为用折线图表示的 mAP 变化情况。可以直观地看出, 相比于其他几种算法, 本文算法在本数据集上有不错的表现。

表 2 实验定量分析

算法模型	训练样本数量	测试样本数量	mAP
Faster-RCNN	1800	200	82.6%
VGG16	1800	200	83.7%
VGG19	1800	200	87.4%
传统 Resnet	1800	200	81.8%
本文算法	1800	200	91.5%

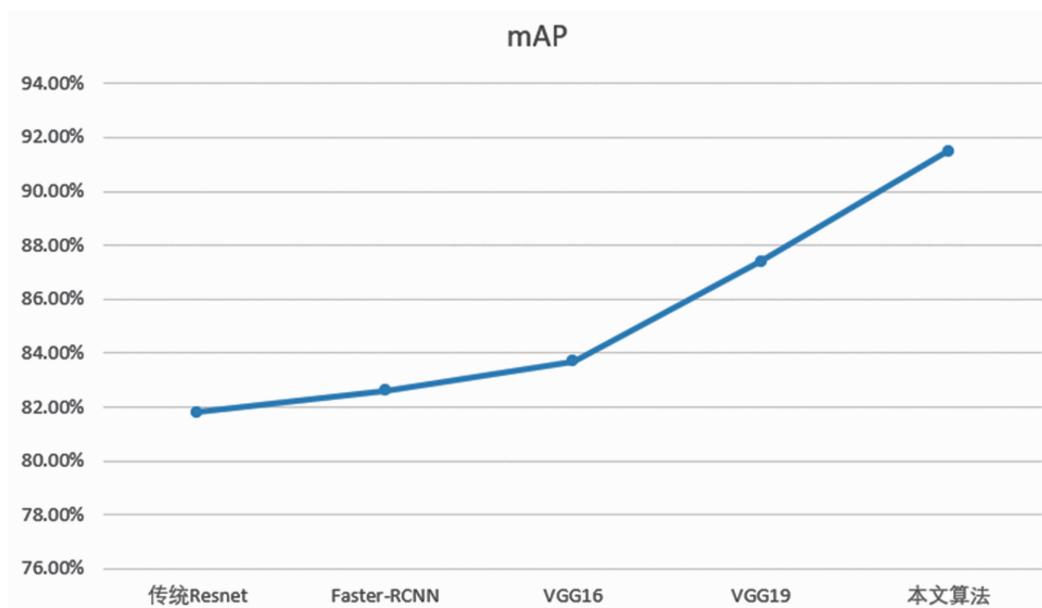


图 8 实验结果对比折线图

4 结束语

本文提出了一种基于多层级深度神经网络的复杂图像故障识别算法。该算法充分利用多层网络模块提取高层次特征的能力和多级网络模块的特征融合能力，通过增加网络的深度和宽度来提高故障识别的准确性。实验结果表明，与现有的 Faster-RCNN、VGG16、VGG19 和传统 Resnet 等模型相比，本文算法在准确率和运行时间等评估指标上表现出更佳性能，验证了其在应对图像中目标重叠遮挡和类目标干扰等方面的有效性；同时，在提高故障识别任务的速度和准确性方面也取得了显著进展。未来应继续更新数据集，考虑更多可能出现的问题，从而更全面地将理论研究与实际应用相结合，为电网的安全运行提供强有力的算法支持。

参考文献

- [1] 蔡安江, 赵飞涛, 薛晓飞. 基于共轭贝叶斯估计的多品种小批量生产控制图研究 [J]. 机械设计与制造, 2020, **41**(2): 221–224.
- [2] 陈世杰, 唐秋华. 优化神经网络用电量预测性能的多元线性回归方法 [J]. 机械设计与制造, 2019, **40**(6): 17–21.
- [3] 洪梓铭. 基于深度学习的电力设备图像识别模型构建 [J]. 信息技术, 2021, **28**(6): 58–62.
- [4] 孙丰杰, 王承民, 谢宁. 面向智能电网大数据关联规则挖掘的频繁模式网络模型 [J]. 电力自动化设备, 2018, **38**(5): 110–116.
- [5] Wang J, Wang L, Zhang S. An infrared image-based fault diagnosis method for power equipment [J]. *Infrared Physics & Technology*, 2019, **96**: 176–184.
- [6] Tan X, Huang X, Yin C, et al. Infrared detection method for hypervelocity impact based on thermal image fusion [J]. *IEEE Access*, 2021, **9**: 90510–90528.
- [7] Jiang A, Yan N, Shen B, et al. Research on infrared image recognition method of power equipment based on deep learning [C]. Beijing: 2020 IEEE International Conference on High Voltage Engineering and Application (ICHVE), 2020.
- [8] Wang J, Zhao C. Broad learning system based visual fault diagnosis for electrical equipment thermography images [C]. Xi'an: 2018 Chinese Automation Congress (CAC), 2018.
- [9] Huda A S N, Taib S. Application of infrared thermography for predictive/preventive maintenance of thermal defect in electrical equipment [J]. *Applied Thermal Engineering*, 2013, **61**(2): 220–227.
- [10] Suguna M, Roomi S M M, Sanofer I. Fault localisation of electrical equipments using thermal imaging technique [C]. Kollam: 2016 International Conference on Emerging Technological Trends (ICETT), 2016.
- [11] 李洋, 朱春山, 张建亮, 等. 基于改进 Transformer 的变电站复杂场景下电力设备分割 [J]. 太原理工大学学报, 2024, **55**(1): 57–65.
- [12] 贾鑫. 基于双监督信号卷积神经网络的电气设备红外故障识别研究 [D]. 天津: 天津理工大学, 2018.
- [13] 陈达, 唐文虎, 牛哲文. 基于深度学习的电力设备红外图像故障诊断方法 [J]. 广东电力, 2021, **34**(1): 97–105.
- [14] 刘云鹏, 裴少通, 武建华, 等. 基于深度学习的输变电设备异常发热点红外图片目标检测方法 [J]. 南方电网技术, 2019, **13**(2): 27–33.
- [15] Liu X, Li Y, Shuang F, et al. ISSD: Improved SSD for Insulator and Spacer Online Detection Based on UAV System [J]. *Sensors*, 2020, **20**(23): 6961.
- [16] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J]. *arXiv*: 1409.1556, 2014.
- [17] Jiang H, Qiu X, Chen J, et al. Insulator fault detection in aerial images based on ensemble learning with multi-level perception [J]. *IEEE Access*, 2019, **7**: 61797–61810.