

基于改进的 CenterNet 变电站设备 红外温度检测方法

张佳钰¹, 蔡泽烽², 冯杰¹

(1. 浙江理工大学 计算机科学与技术学院 (人工智能学院), 杭州 310018;

2. 浙江理工大学 信息科学与工程学院, 杭州 310018)

摘要: 红外检测能够检测变电站电力设备温度异常, 降低安全事故发生的概率, 因此, 提出一种基于改进的 CenterNet 目标检测算法模型 CenterNet_PRO; 该算法采用了 ShuffleNet V1/V2 作为骨干网络, 引入了 FPN 来提取多尺度特征, 为了克服不同尺度目标检测的难点、增加旋转角度回归分支, 用于预测目标的旋转角度以及改进的 IoU Loss 进行优化, 进一步提高模型检测速度和准确率; 通过阈值分割法提取电力设备表面温度并分析计算, 设计制定电力设备温度缺陷判断规范、温度警告阈值, 根据该规范即可判断电力设备的相关缺陷; 实验结果表明, 改进的 CenterNet 模型平均精度达到了 90%, 相比于传统的 CenterNet 模型, 平均精度提高了 1.3 个百分点, 可以满足实际变电站场景下对电力设备红外检测的高要求。

关键词: CenterNet; ShuffleNet; 电力设备; 红外图像温度缺陷检测; 提取多尺度特征

Infrared Temperature Detection Method for Substation Equipment Based on Improved CenterNet

ZHANG Jiayu¹, CAI Zefeng², FENG Jie¹

(1. School of Computer Science & Technology (School of Artificial Intelligence), Zhejiang Sci-Tech

University, Hangzhou 310018, China;

2. School of Information science & Engineering, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: Infrared detection can detect the abnormal temperature of power equipment in substations, and reduce the probability of safety accidents. Therefore, an object detection algorithm model of CenterNet_PRO based on improved CenterNet is proposed. This algorithm adopts ShuffleNet V1/V2 as a backbone network, and introduces a feature pyramid network (FPN) to extract multi-scale features. In order to overcome the difficulties of target detections at different scales, the algorithm increases the rotation angle regression branches, predicts the rotation angle of the target, and optimizes with the improved IoU Loss, further improves the model detection speed and accuracy. The threshold segmentation method is adopted to extract the surface temperature of power equipment and analyze and calculate the surface temperature, which designs and defines the temperature defect judgment specification and temperature warning threshold of power equipment, and judges the related defects of power equipment according to the specification. The experimental results show that the average accuracy of the improved CenterNet model reaches up to 90%, compared with the traditional CenterNet model, the average accuracy improved by 1.3%, which can meet high requirements for infrared detection of power equipment in actual substation scenarios.

Keywords: centerNet; shuffleNet; power equipment; infrared image temperature defect detection; multi-scale feature extraction

0 引言

保障电力设备的安全、可靠和高效运行对电力行业的发展至关重要。在电力设备监测中, 温度检测是至关重要的环节。传统温度检测方法的局限性促使红外温度检测技术成为备受欢迎的替代方案。然而, 如何实现针对电力设备的准确高效的温度检测仍然存在挑战。

近年来, 研究人员提出了各种针对电力设备的红外温度检测方法。王凯轩^[1]等提出了一种基于红外图像的热物性参数辨识方法, 以实现热物性参数的快速、精确的辨识, 从

而达到对热物性参数的快速、准确的辨识, 从而达到对热物性参数进行故障诊断的目的。在此基础上, 提出了一种基于图像灰度的特征提取方法, 并利用图像的灰度特征提取方法, 对目标进行了特征提取。采用卷积神经网络对其进行训练与检验, 最终构建出一组温度数值图谱。然后利用 MATLAB 开发了应用程序设计模块, 实现了温度数值的识别和记录。实验证明, 所提出的方法可以实现对温度数据的快速、精确的辨识和记录。胡子宇^[2]等以智能监测的思想为基础, 构建了一套海洋平台电力设备的红外温度监测系统。本系统

收稿日期: 2023-07-24; 修回日期: 2023-08-17。

基金项目: 浙江省大学生科技创新活动计划(新苗人才计划)项目(2023R406019)。

作者简介: 张佳钰(2002-), 男, 大学本科生。

引用格式: 张佳钰, 蔡泽烽, 冯杰. 基于改进的 CenterNet 变电站设备红外温度检测方法[J]. 计算机测量与控制, 2024, 32(7): 50-56.

以红外测温为核心, 采用 C# 编程实现了对测温信号的实时监测。该系统能够对海洋平台上的主要监控节点进行在线监测, 并对其进行数据分析、预警和管理。张晓华^[3]等提出一种利用红外探测技术对变电所设备进行热态诊断的方法。在此基础上, 提出了一种基于遗传算法的温度检测方法。并设计了一种基于灰度特征的变电所系统, 将其应用于变电所系统中。本项目研究成果将提升故障区域识别的准确性与效率, 提升故障区域的容错性, 对提升变电站及电网安全稳定运行水平具有重要意义。

该系统基于以前的研究, 采用改进的 CenterNet 算法。为了提高检测精度和速度, 通过对骨干网络进行改进, 将 ShuffleNet V1/V2^[4]作为骨干网络与 ResNet-18 进行替换。在 ShuffleNet 中将通道分组进行卷积时使用 group convolution, 以减少计算量, 并采用 channel shuffle 操作来提高模型的表达能力。其次, 提取多尺度特征时, 该系统采用了 Feature Pyramid Network (FPN), 以克服不同尺度目标检测的难点。本文还改进了检测头, 将目标检测和关键点检测统一起来, 提高检测精度。使用 Deformable Convolutional Networks (DCN)^[5]代替原始的卷积操作, 通过应用空间变形来增强特征提取过程, 可以提升模型的表达能力和检测效果, 进一步提高系统的检测速度和准确性。同时, 还针对多角度测温的问题, 通过在改进的 CenterNet 中引入旋转角度预测的分支来实现。

本研究将提出一种基于改进的 CenterNet 算法的红外温度检测系统, 该系统将具有高速度、高准确性、实时性和稳定性等优点。同时, 本研究还将制定电力设备温度缺陷判断规范和温度警告阈值, 为电力设备的安全运行提供可靠的保障。因此, 本研究的意义在于推进电力设备温度检测的技术发展, 为电力设备的安全运行和维护提供可靠的技术支撑。

1 CenterNet 模型改进

1.1 CenterNet 原模型的改进

在这个模型基础上, 本文增加卷积层的数量和深度, 以提高网络的表达能力和精度, 此处称之为 CenterNet 十。通过增加卷积层^[8-9]的数量和深度, 可以增加模型对输入图像的多层次抽象表示能力, 从而提高模型的性能。使模型能够更好地捕捉图像中的特征, 并准确地定位和识别目标。具体如表 1 所示。

表 1 CenterNet 十模型网络结构

Layer	Output Shape	Number of Parameters
Input	(batch_size, H, W, 3)	0
ResNet18	(batch_size, H/32, W/32, 512)	11,689,512
Conv2D	(batch_size, H/32, W/32, 256)	1,179,904
Conv2D	(batch_size, H/32, W/32, 256)	590,080
MaxPooling2D	(batch_size, H/64, W/64, 256)	0
CenterNet	(batch_size, H/64, W/64, 80)	20,513,680

在 CenterNet 十模型中, 本文增加了两个卷积层和一个池化层^[10], 每个卷积层都有 256 个输出通道。这样可以提高网络的表达能力和对特征的提取能力。其中, conv1 和 conv2 分别用于增加网络的深度和宽度, 使得网络可以更好地捕获图像中的特征和边缘信息。MaxPooling2D 是一种池化操作, 可以将特征图分割成多组矩形区域且区域不重叠, 通过每个区域内的最大值来聚合信息。通过这种方式, MaxPooling2D 能够使特征图的分辨率降低, 进而使网络的计算效率提高。

另外, 也可通过修改卷积层的 kernel_size、stride 和 padding 等参数来进一步优化网络结构。本文通过增加 kernel_size 和 stride 的大小, 将卷积层的感受野扩大, 提高捕获局部信息和全局信息的能力。通过减小 padding 的大小, 可以缩小特征图的尺寸, 从而减少网络的计算复杂度和存储空间。

1.2 实时性的改进

在变电站场景中, 通常需要对大量设备进行温度测量, 因此实时高效的测温能力至关重要。为了提高实时性并实现快速检测, 可以通过优化 CenterNet 算法的计算效率和速度。CenterNet 算法是一种基于中心点检测的目标检测方法, 它通过预测目标的中心点来定位目标, 并利用中心点偏移量和尺寸信息进行边界框的预测。这种算法简单高效, 适用于各种目标检测应用场景, 并且在性能和精度上表现出良好的效果。

采用基于 ShuffleNet V1/V2 骨干网络的 CenterNet 模型, 有助于提升检测精度和速度。ShuffleNet V1/V2 作为轻量级的骨干网络架构^[11], 具备较高的检测精度和快速的处理速度。通过使用分组卷积和通道重排等优化技术, ShuffleNet V1 和 ShuffleNet V2 在特征提取过程中变得更高效率和准确。这些优化技术使网络能够更好地利用计算资源, 提升了特征提取的性能和效率。在 ShuffleNet V1/V2 中, 特征图被划分为多个组, 并且每个组内的通道进行重排操作。这样可以在减少计算成本的同时保持信息交流, 从而提高特征表示的能力。

对于目标检测任务, CenterNet 模型通过引入 ShuffleNet V1/V2 作为骨干网络, 能够更好地捕捉目标特征并实现高效的目标检测。ShuffleNet V1/V2 的高效性使得模型在计算资源有限的情况下依然能够产生准确的特征表示, 从而为目标检测提供了良好的基础。同时, ShuffleNet V1/V2 的轻量级结构还有助于减少模型参数数量, 进一步降低了模型复杂度和计算成本, 使得在嵌入式设备或计算资源受限的环境下能够实现高效的目标检测。具体改进措施如下。

1) 骨干网络优化: 将 ResNet-18 替换为 ShuffleNet V1/V2 作为骨干网络, 以降低模型参数数量和计算复杂度。ShuffleNet 使用 group convolution 将通道分组进行卷积, 以减少计算量, 同时采用 channel shuffle 操作提高模型的表达能力。

2) 特征融合优化: 在骨干网络之后加入 FPN 来提取多尺度特征, 解决不同尺度目标检测难题。FPN 利用不同层级的骨干网络获取特征, 通过金字塔结构将其特征结构融合在一起, 从而得到多个层次、多尺度、多分辨率的特征。对于尺寸较小的目标, 高层特征图可以更好地捕捉到其语义信息; 对于尺寸较大的目标, 低层特征图可以更好的提取出其中的细节。FPN 采用“自下而上”和“自上而下”两种方式, 实现了高、低层次的特征图谱的有效融合, 使每一层次的特征图谱都具有丰富的语义和细节信息。该方法可以减少重复性, 从而提高了探测结果的准确性。

3) 检测头改进: 改进检测头设计, 将目标检测与关键点检测统一处理, 从而提高检测精确性。可以使用 DCN 代替原始的卷积操作, 在特征提取时加入空间变形以增强模型的表达能力和检测效果。通过使用 DCN, 模型可以自适应地选择感受野位置和形状, 以更好地适应目标对象的形变和姿态变化。DCN 通过引入可学习的空间变形模块, 让网络能够根据输入数据的形变进行局部区域的插值或采样, 从而进行空间变形卷积操作。使得模型能够更准确地建模不同形变目标并进行准确的目标检测。同时, 通过将目标检测与关键点检测统一处理, 可以更好地将目标的定位和姿态信息融合, 提高检测精确性。

通过以上改进, 在保证检测准确度的前提下, 进一步提升该模型的运算速度与运算效率, 从而实现快速检测。

针对扩展 dilation convolutions^[12], 并在原有的卷积层^[13]基础上引入 dilation 参数, 将卷积核中的像素点之间的距离变为 dilation 倍。这样可以增大感受野, 使卷积层能够捕捉更广阔范围内的上下文信息, 提供更丰富的空间信息, 可以更好地保留边缘细节和纹理信息。提高网络对于不同大小目标的检测能力。具体地, 在上述改进的 CenterNet 网络基础上, 将普通卷积层换成 dilation 卷积层即可。

改进后的卷积层公式如下:

$$y[i, j] = \sum_{k,l=0}^{k-l} w[k, l]x[i-dk, j-dl] \quad (1)$$

其中: $y[i, j]$ 表示卷积后的输出, $w[k, l]$ 表示卷积核的权重, $x[i-dk, j-dl]$ 表示输入的像素点, d 表示 dilation 参数。

通过增加卷积层的数量对 CenterNet 网络结构进行改进, 以提高 CenterNet 网络结构的特征提取能力。通过增加网络的深度, 可以更好地捕捉图像中的细节和高级特征。将正则化层添加到卷积层之间, 以防止过拟合现象。比如 Dropout 或 Batch Normalization。这些正则化层可以减少神经元之间的共适应性, 并且有助于限制模型复杂度, 使其具备更好的泛化能力, 进而降低过度匹配的风险。将 Dropout 层插入到卷积层之间^[14], 可以随机地舍弃一部分节点, 防止网络过度依赖于某些特定的特征。这种随机丢弃的操作可以减少神经元之间的共适应性, 降低模型复杂度, 提高了模型的泛化性, 降低模型的过拟合风险。添加 Batch Normalization 层能够使每一批的输入数据标准化, 改善了网络的稳定性, 并且降低了内部协变量的偏差。Batch Nor-

malization 可以对数据的平均数和方差进行调节, 并限制特征值的取值范围, 使得网络对输入数据的规模变化更加鲁棒。这种方法可以加快训练过程, 缓解梯度消失或爆炸问题, 同时可以发挥一些正则化作用, 防止过拟合现象的出现。改进后的 CenterNet_PRO 网络结构如表 2 所示。

表 2 CenterNet_PRO 模型网络结构

Layer	Input Size	Output Size
Input	$H \times W \times 3$	$H \times W \times 3$
ShuffleNetV1/V2	$H \times W \times 3$	$H/2 \times W/2 \times C$
Residual Blocks with Dropout/BN	$H/2 \times W/2 \times C$	$H/4 \times W/4 \times C$
Conv	$H/4 \times W/4 \times C$	$H/4 \times W/4 \times C$
Residual Blocks with Dropout/BN	$H/4 \times W/4 \times C$	$H/4 \times W/4 \times C$
Conv	$H/4 \times W/4 \times C$	$H/4 \times W/4 \times C$
CenterNet Head	$H/4 \times W/4 \times C$	$H/4 \times W/4 \times (k+4)$
Output	$H/4 \times W/4 \times (k+4)$	$H/4 \times W/4 \times (k+4)$

其中, k 为类别数加上中心点和高宽信息的数量。其中, Dropout 层的公式如下:

$$y_i = \begin{cases} x_i & \text{with probability } p \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

Batch Normalization 层的公式 (3) 和 (4) 如下:

$$\hat{x}_i = \frac{x_i - E[x]}{\sqrt{\text{var}[x] + c}} \quad (3)$$

$$y_i = \gamma \hat{x}_i + \beta \quad (4)$$

其中: p 表示 dropout 的概率, γ 和 β 表示 Batch Normalization 的缩放和偏移参数, $E[x]$ 和 $\text{Var}[x]$ 分别表示 x 的均值和方差, c 是一个很小的数, 用来避免除数为 0 的情况。

综上, ShuffleNet v1/v2 采用了通道重排和组卷积等技术, 在保证精度的前提下, 大幅度降低了计算复杂度, 并减少了参数个数。在替换骨干网络后, CenterNet 的计算速度和效率将得到明显提升, 从而能够更快地完成目标检测任务。

1.3 高斯函数半径的改进方法及热力图生成

在热力图中, 采用二维高斯核^[15-16]表示关键点是因为对于目标中心附近的某些点, 它们的预测 box 与 gt_box 的 IOU 可能大于 0.7, 不能直接惩罚这些预测值, 需要更为温和。因此选用传统高斯核。如图 1 所示。

具体来说, 可以通过计算预测框与目标框的交叠面积 (IOU) 并设定阈值 (例如 0.7), 以确定哪些预测框与目标相交足够多且应保留下来。然后需要确定高斯核半径 r , 使得 IOU 大于 0.7 的预测框不会被直接舍弃。

确定高斯核半径的方法通常基于目标框宽高计算。具体来说, 可将目标框宽和高分别除以 2, 再乘以不同系数, 得到 3 个半径 r_1 、 r_2 、 r_3 。根据预测框与目标框的交叠面积, 选择 3 个半径中最小的一个作为高斯核半径。

实际应用中, 通常将 IOU 阈值设为 0.7, 因其可平衡




图 1 在 top-left/bottom-right 的位置设置标签

保留预测框数量和质量。计算高斯核半径方法如下所示: (取最小值作为高斯核半径 r 。) 情况一: 预测的框和 GTbox 两个角点以 r 为半径的圆外切。

$$I = \frac{h * w}{(h + 2r)(w + 2r)}, r = \frac{-b + \sqrt{b^2 - 4ac}}{2a} \quad (5)$$

其中: $a = 4 * I$; $b = 2 * I * (h + w)$; $c = (1 - I) (h * w)$ 情况二: 预测的框和 GTbox 两个角点以 r 为半径的圆内切:

$$I = \frac{(h - 2r) * (w - 2r)}{(h * w)}, r = \frac{-b + \sqrt{b^2 - 4ac}}{2a} \quad (6)$$

其中: $a = 4$; $b = -2 (h + w)$; $c = (1 - I) (h * w)$ 情况三: 预测的框和 GTbox 两个角点以 r 为半径的圆一个边内切, 一个边外切:

$$I = \frac{(h - r) * (w - r)}{2 * h * w - (h - r) * (w - r)}, r = \frac{-b + \sqrt{b^2 - 4ac}}{2a} \quad (7)$$

其中: $a = 1$; $b = - (h + w)$; $c = \frac{(1 - I) (h * w)}{1 + I}$

综合 3 种情况, 可以得到 $r = \min (r1, r2, r3)$ 将这 3 个中的最小值设为半径。根据此半径设计高斯散射核, 如图 2 所示, 中心位置标签值为 1, 周围标签按 $e^{-x^2 + y^2 / 2\sigma^2}$ 规律递减。




图 2 高斯散射核可视化图

由于被测物体的外形往往是不规则的, 常规的高斯核函数很难与其热物性特征进行完美的匹配, 因此, 本项目提出一种新的基于热物性特征的热物性特征分析方法。为

此, 本文提出了一种新的高斯卷积核方法, 其结果与热物性参数之间的关系, 即与热物性参数之间的关系密切。在实际的检测过程中, 它呈现为一个椭圆, 并且平均精确度 (AP, average precision) 值越高, 检测效果就越好。

由于待检测目标的形状通常是不规则的, 常规的高斯核函数很难与其热力图形状进行完美的匹配, 因此, 为了更好地反映目标的形状信息, 对高斯核函数进行改进, 使得生成的热力图根据待检测目标的长宽趋势进行自适应地变化, 并通过待检测目标的尺寸计算出自适应变化后的热力图的半径, 进而得出完整的热力图^[17]。在实际检测中, 热力图呈现为一个椭圆, 精确度的平均值 (AP, average precision) 越高, 检测效果越好, 如图 3 所示。




图 3 改进后高斯散射核可视化图

对于每个标签图中类别数 C , 关键点 p 的计算如公式 (8) 所示:

$$p = \frac{x_1 + x_2}{2}, \frac{y_1 + y_2}{2} \quad (8)$$

设系采样后的坐标 φ :

$$\varphi = \left[\frac{p}{R} \right] \quad (9)$$

如公式 (9) 所示, 采样因子 R 被设定为一个预定义的值 (如 $R = 3$), 该公式最终计算得到的中心点对应的是低分辨率的中心点。为了在特征地图上分配关键点, 计算改进后的高斯核 G , 如公式 (10) 所示:

$$G = e^{-(x-\varphi_x)^2 + (y-\varphi_y)^2 / 2\sigma^2} \quad (10)$$

特征点的特点是可重复, 可区分, 高效且局部化。因此, 本文采用改进的 FAST^[8] 方法, 可以检测具有不同方向性的特征点, 并且采用速度极快的二进制描述子 BRI 提取图像特征速度大幅度加快。

1.4 IoU Loss 损失函数的改进

本文之前表示高斯核框选中心区域时采用的是 4 个坐

标点独立回归 Bounding box (bbox, 边界框)^[19-20], 但这一方法存在较为明显的缺点。此外, 使用 IoU 评价方法进行目标检测, 但在实际的回归坐标框时, 使用 4 个坐标点, 二者是不对等的。边界框示意图如图 4 所示。




图 4 边界框框选方法示意图

此方法并没有考虑 4 个点的相关性, 所以这种方法存在局限性。本文将改进的 IoU Loss 进行实验与其他 Loss 方法进行对比^[21], 在不同数据集上会有不一样的效果, 综合考虑, 本文采用改进的 IoU Loss 方法, 为解决 IoU 的 w 和 h 不能同时放大或者缩小的问题, 改进后的 IoU 方法直接对 w 和 h 的预测结果添加进行惩罚的损失函数, 公式如 (11) 所示。

$$L_{IoU_m} = L_{IoU} + L_d + L_a = 1 - IoU + \frac{\rho^2(b, b_t^e)}{c^2} + \frac{\rho^2(w, w_t^e)}{C_w^2} + \frac{\rho^2(h, h_t^e)}{C_h^2} \quad (11)$$

其中: C_w 和 C_h 分别是两个矩形的闭包的宽和高。从中可以看出, 改进的 IoU 将损失函数分成了 3 个部分, IoU 损失 L_{IoU} , 距离损失 L_d , 边长损失 L_a 。可以看出改进的 IoU 是直接将边长作为惩罚项的, 这样也能一定程度上解决在 IoU 中可能的边长被错误放大的问题。

2 实验结果分析

2.1 红外热成像数据采集

在本研究中, 使用了从变电站设备捕获的红外热成像数据集, 这些数据是由巡检工作人员使用配备 AR 技术的红外测温眼镜收集的。这些红外图像为我们提供了关于设备运行状态的重要热视图信息, 有助于识别潜在的维护需求或性能问题。

为了确保数据的质量和适用性, 本文采用了 OpenCV (开源计算机视觉库) 来处理这些红外图像。OpenCV 是一个强大的工具, 专为图像处理和计算机视觉任务设计, 广泛用于学术和工业领域。这个库不仅免费、开源, 而且还支持多种编程语言, 包括 Python、Java 和 C++, 使其在开发者中极为流行。

通过使用 OpenCV, 本文对采集到的红外图像执行了一系列预处理操作, 以优化分析和模式识别的效果。这些预处理操作包括: 图像翻转变换, 这有助于增强模型对不同方向图像的泛化能力; 随机裁剪, 可以减少模型对图像特定部分的依赖, 提高其对不同图像区域的敏感性; 旋转变换, 增强模型在处理倾斜图像时的鲁棒性; 以及仿射和尺度变换, 这些都是为了模拟实际操作中可能遇到的各种视角和距离。通过这种方法, 能够更有效地利用红外热成像

技术对变电站设备进行监控和维护, 从而提升设备的操作安全性和可靠性。通过结合这些操作, 可以丰富特征的多样性, 提升模型的表达能力, 为后续送入 CenterNet_PRO 训练做充足准备。CenterNet_PRO 是一个计算机视觉模型, 用于目标检测和实例分割任务。此外, CenterNet_PRO 还能同时预测目标的类别、边界框和关键点等重要属性。这使得 CenterNet_PRO 在处理复杂场景中的目标检测任务方面的能力较强。

训练使用的变电站^[6-7]红外数据集一共有 1 185 张图像, 分为 6 类目标, 图像分辨率 640×480 。如表 3 所示。

表 3 红外变电站设备数据集

Class Name	Picture Numbers
cablu	235
componenta incalzita	150
legatura	200
Motor	150
puntosub	200
Solar panels	250

图 5 展示了变电站设备红外图像数据集的几个显著特征: 图中设备的部分信息缺失, 难以识别出设备的完整外形; 图像焦点不清, 像素变化微小, 导致图像对比度低, 同时温度区间的分界也不清楚; 红外图像中的设备被实时显示的数据覆盖; 此外, 图像中包含多种类型的设备, 且结构复杂。这些特性使得使用常规的目标检测算法来识别红外图像中的设备面临较大挑战。




图 5 训练数据集部分样本

2.2 实验分析

为了验证改进的 CenterNet 方法在非线性红外温度检测中的有效性。根据初始化参数、损失函数定义、训练数据准备和模型训练这 4 个步骤, 使用 NVIDIA GeForce RTX 2080 Ti GPU, 在 PyTorch 的深度学习框架下和 Ubuntu 18.04 操作系统中确定了实验参数为: 学习率设定为 0.001, 迭代次数为 100 次, 并使用 Adam 优化器进行参数更新。

基于上述实验环境, 按照下述实验步骤及方法展开实验:

1) 红外热成像数据采集。通过巡检人员搭配 AR 红外

测温眼镜对变电站设备进行红外图像采集, 对得到的红外图像通过 OpenCV 技术进行数据预处理;

2) CenterNet 模型改进。在 CenterNet 原模型基础上, 增加卷积层的数量和深度生成 CenterNet++ 模型, 并在 CenterNet++ 模型中, 增加两个卷积层和一个池化层, 每个卷积层都有 256 个输出通道;

3) CenterNet 算法优化。将 ShuffleNet V1/V2 作为轻量级的骨干网络架构, 通过分组卷积和通道重排等优化技术, 提高特征提取过程的效率和准确性;

4) 将 IOU 阈值设为 0.7, 计算 3 种情况下的高斯核半径并根据计算结果改进高斯函数半径。同时改进高斯核函数, 进而得出完整的热力图。

5) IoU Loss 损失函数的改进。解决 IoU 的 w 和 h 不能同时放大或者缩小的问题, 并直接对 w 和 h 的预测结果添加进行惩罚的损失函数。由此完成 CenterNet 模型改进。

对模型改进前后精度进行分析, 本文在 CenterNet 基础上进行多种改进, 结果如表 4 所示。

表 4 多种改进方案实验结果

改进方法	mAP	Epoch	Hm_Loss	Loss	Time/s
CornerNet	0.723	400	1.2 178 887	0.995 957	0.75
CenterNet++	0.711	400	0.862 970	1.023 702	1.74
CenterNet+ ShuffleNet v1/v2	0.853	400	0.542 571	0.871 980	0.92

由表 4 可知, 应用改进后的 CN_PRO 模型 (CenterNet+ShuffleNet v1/v2) 后其 mAP 值最大, 为 0.853, 另两种改进方法的 mAP 值在 0.73 以内。mAP 值综合了不同类别下的检测精度, 可以提供对整体性能的评估, 因此将其应用到所有数据集性能试验。结果如表 5 所示。

表 5 针对不同红外数据集的模型性能试验记录表

Type	Picture Number	Correct detection	Average Accuracy	Fallout Ratio
cablu	235	235	0.912	0
componenta incalzita	150	382	0.914	0
legatura	200	411	0.955	0.064
legatura	200	411	0.955	0.064
Motor	150	241	0.962	0.072
puntosub	200	194	0.912	0.058
Solar panels	250	201	0.941	0
Person	100	247	0.962	0.012

表 5 所示的平均精度保持在 0.9 以上, 且辐射率低于 0.08, 表明模型的性能较高。

为了突出所提方法的温度检测性能, 使用文献 [2] 方法和文献 [3] 方法作为对比方法进行温度准确率实验。实验结果如图 6 所示。

分析图 7 可知, 所提方法的检测准确度保持在 95% 以上, 在样本数量为 400 个时, 准确率接近 99%, 从图 6 中可以看出, 所提方法的检测准确度较高与文献 [2] 方法和




图 6 温度准确率实验结果

文献 [3] 方法的检测准确度。因此, 表明所提方法的温度检测性能较高, 实际应用价值较高。

红外热像仪成像的原理是红外辐射信号被红外探测器转换成电信号, 电信号在放大等处理作用后再转换成红外热图, 红外热图对应于所测对象的表面温度场, 像素值与相应的温度值一一对应。

如图 7 所示, 佩戴 AR 眼镜采集的电力设备红外图像右边部分附有温度像素比色条, 最低温度值、最高温度值也会被展示出, 比色条不同颜色的灰度值和相应的温度值一一对应, 利用一个一元一次函数使不同颜色的灰度值与温度值相关联, 找出和图片里某一点有相同灰度值的比色条上灰度值对应的温度值。




图 7 带有比色条的红外热像仪采集图

本研究中, 先将通过红外热像仪获得的图像转换为灰度图像。文章通过简单的线性方程 $T = kV + b$ 来将灰度值 V 与温度 T 关联, 以此提取出温度信息。通过设定最高和最低温度值 T_{max} 和 T_{min} , 以及对应的灰度值 V_1 和 V_2 , 利用这两对值计算系数 k 和截距 b :

$$T = kV + b \tag{12}$$

设 T_{max} 和 T_{min} 分别是比色条纵坐标上最高和最低的温度, V_1 和 V_2 分别是相应的灰度值, 将 (V_1, T_1) 和 (V_2, T_{min}) 代入下式, 求出 k 和 b :

$$k = \frac{T_{max} + T_{min}}{V_1 - V_2} \tag{13}$$

$$b = T_{\max} - V_1 \frac{T_{\max} + T_{\min}}{V_1 - V_2} \quad (14)$$

本文进一步使用这个模型来定位温度异常,如温度超标的发热点。温度最高的点和环境温度 T_0 分别由灰度值最大和最小的点确定。文章还通过比较测得的表面温度与环境温度的相对差,结合识别的电力设备类型和结构信息,对可能的设备缺陷或温度异常进行评估。此外,使用行业标准规范 GL/T 664-2016^[22] 作为评判标准,确保了分析的精确性和可靠性。这项技术的应用对电力设备的安全运维具有显著意义,可帮助及时发现和处理潜在的安全隐患,从而减少严重安全事故的发生。

3 结束语

本文详细介绍了一种新颖的方法,用于检测电力设备中的温度相关缺陷,特别是采用了改良版的 CenterNet_PRO 目标检测模型。这种模型在提高对电力设备的识别精度和处理速度方面表现出色,能够更准确地定位电力设备中各个部件的结构,并建立有效的缺陷检测标准。此方法的应用不仅局限于理论研究,还已经在实际的变电站运营环境中进行了测试,显示出优秀的实时检测性能。虽然此项技术展现出其有效性,但在应用过程中也暴露出一些局限性和需要改进的地方。

具体改进措施包括:首先,目前模型使用的是简单的线性函数来表达像素坐标与温度之间的关系,这种方法在实际应用中可能因忽略了其他变量而导致一定的偏差。因此,未来的研究可以探索采用更复杂的数学模型来更精确地描述这种关系。其次,目前的研究仅限于分析红外图像,没有涉及可见光和紫外光图像,这可能限制了模型的全面性。接下来的研究中,可以考虑结合红外光、可见光及紫外光的多模态数据,以提高检测的准确性和鲁棒性。此外,更为理想的模型训练和测试需要大规模的数据集支持,未来的工作应集中于扩大电力设备数据集的规模和多样性,这不仅可以增强模型的通用性,还能显著提升其在各种操作环境下的性能表现。

这些改进将有助于提高电力设备温度缺陷检测的效果,为电力系统的安全运行提供更可靠的技术支持。通过这种持续的技术迭代和优化,预计可以显著降低由于设备故障导致的运营中断和维护成本,从而提升整个电力行业的效率和可靠性。

参考文献:

- [1] 王凯旋,任福继,倪红军,等.面向电力设备红外图像的温度值识别算法[J].智能系统学报,2022,17(3):617-624.
- [2] 胡子宇,张仕海,李威微,等.海上平台电气设备红外温度监控系统设计[J].现代制造工程,2022(2):119-123.
- [3] 张晓华,蔡巍,武宇平,等.基于红外检测的变电站设备热状态诊断[J].智慧电力,2021,49(9):109-116.
- [4] WANG Y, YAN J, SUN Q, et al. ShuffleNet-based comprehensive diagnosis for insulation and mechanical faults of power e-

- quipment [J]. High Voltage, 2021, 6 (5): 861-872.
- [5] 周德政,赖惠成,李亚东,等.基于YOLOv3目标检测的深层特征增强算法[J].激光杂志,2022,43(11):25-30.
- [6] 吴添权,郭竞,苟先太,等.基于改进高斯卷积核的变电站设备红外图像检测方法[J].红外技术,2021,43(3):230-236.
- [7] 张晓华,蔡巍,武宇平,等.基于红外检测的变电站设备热状态诊断[J].智慧电力,2021,49(9):109-116.
- [8] 张洲宇,曹云峰,丁萌,等.采用多层卷积稀疏表示的红外与可见光图像融合[J].哈尔滨工业大学学报,2021,53(12):51-59.
- [9] 朱雯青,张宁,李争,等.基于多任务卷积神经网络的红外与可见光多分辨率图像融合[J].光谱学与光谱分析,2023,43(1):289-296.
- [10] 王宇航,周永霞,吴良武.基于高斯函数的池化算法[J].计算机应用,2022,42(9):2800-2806.
- [11] 李莉,彭娜,王巍.基于轻量级卷积神经网络的遥感图像检测模型[J].计算机工程与设计,2023,44(5):1511-1518.
- [12] SCHONSHECK S C, DONG B, LAI R. Parallel transport convolution; Deformable convolutional networks on manifold-structured data [J]. SIAM Journal on Imaging Sciences, 2022, 15 (1): 367-386.
- [13] 廉小亲,黄雪,高超,等.基于Frost滤波和改进CNN的SAR图像TR方法[J].计算机仿真,2023,40(5):49-55.
- [14] 刘之禹,李述,王英鹤.基于ZYNQ的深度学习卷积神经网络加速平台设计[J].计算机测量与控制,2022,30(12):264-269.
- [15] 张凯,门昌骞,王文剑.基于随机傅里叶特征空间的高斯核近似模型选择算法[J].数据采集与处理,2023,38(3):616-628.
- [16] 胡松松,吴亮红,张红强,等.改进多尺度卷积结构与高斯核的E-CenterNet算法[J].计算机工程与应用,2023,59(6):70-80.
- [17] 邬春明,廉力影,赵立权.引入关节热力图的改进CenterNet目标检测算法[J].北京交通大学学报,2022,46(2):20-28.
- [18] RASOL J, YUELEI X U, ZHOU Q, et al. N-fold Bernoulli probability based adaptive fast-tracking algorithm and its application to autonomous aerial refuelling [J]. 中国航空学报:英文版,2023,36(1):356-368.
- [19] 刘雄彪,杨贤昭,陈洋,等.基于CIoU改进边界框损失函数的目标检测方法[J].液晶与显示,2023,38(5):656-665.
- [20] 李功,赵巍,刘鹏,等.一种用于目标跟踪边界框回归的光滑IoU损失[J].自动化学报,2023,49(2):288-306.
- [21] 张凯,余义斌.基于Generalized Region Loss的代价函数及在图像分割中的应用[J].计算机测量与控制,2023,31(3):215-222.
- [22] 余骏.电力行业人工智能技术标准分析[J].中国科技信息,2022(22):120-123.