

DOI: 10.19783/j.cnki.pspc.201012

基于 RetinaNet 的变压器图像小部件智能识别方法

万吉林¹, 吴国强², 管敏渊², 吴凯^{2,3}, 高奥², 施康明^{2,3}, 王慧芳¹

(1. 浙江大学电气工程学院, 浙江 杭州 310027; 2. 国网浙江省电力有限公司湖州供电公司, 浙江 湖州 313000; 3. 湖州电力设计院有限公司, 浙江 湖州 313000)

摘要: 变电站巡检图像中变压器小部件的自动识别是利用变压器图像进行变压器外观异常缺陷识别的基础。为了提高变压器小部件的识别准确性, 提出了一种基于 RetinaNet 的变压器小部件识别方法。首先, 对图像目标检测网络 RetinaNet 进行改进, 加入分辨率更高的融合特征图, 以解决变压器小部件包含的像素信息过少的问题。然后, 提出一种基于位置关联性的变压器小部件概率修正方法, 利用识别难度相对较小的大部件位置与相应的小部件之间的位置关联信息, 对小部件检测框的预测概率进行修正, 以避免其他外形相似部件对目标部件识别的干扰。最后, 通过实际变电站巡检图像对变压器小部件识别方法进行实验验证。结果表明, 所提出的变压器小部件识别方法在变压器三类小部件的识别准确率以及整体识别准确率上, 都具有比较显著的优势。

关键词: 目标检测; 变压器; 巡检图像; 部件识别; RetinaNet

Intelligent recognition method for transformer small components based on RetinaNet

WAN Jilin¹, WU Guoqiang², GUAN Minyuan², WU Kai^{2,3}, GAO Ao², SHI Kangming^{2,3}, WANG Huifang¹

(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China; 2. Huzhou Power Supply Company, State Grid Zhejiang Electric Power Company Limited, Huzhou 313000, China; 3. Huzhou Electric Power Design Institute Company Limited, Huzhou 313000, China)

Abstract: Automatic recognition of transformer small components in substation inspection images is the basis of recognizing transformer exterior defects by transformer images. To improve the recognition accuracy, a recognition method based on RetinaNet is proposed. First, the object detection network RetinaNet is improved, and the fusion feature map with higher resolution is added to solve the problem that transformer small components contain too little pixel information. Then, a probability correction method for the components based on location correlation is proposed. This can modify the probability of small component detection boxes according to the location correlation between large components and corresponding small components. This avoids the interference of other similar components to the target component recognition. Finally, the proposed recognition method is verified by the actual substation inspection images, and the result shows that the method has significant advantages both in the recognition accuracy of three types of transformer small components and the overall recognition accuracy.

This work is supported by the National Youth Science Foundation of China (No. 62001416) and the Science and Technology Project of State Grid Zhejiang Electric Power Co., Ltd. (No. 2019-HUZJTKJ-09).

Key words: object detection; transformer; inspection image; component recognition; RetinaNet

0 引言

变电站巡检机器人的应用和普及, 为变压器的

定期巡检和图像采集提供了便利^[1-2]。在此基础上, 一些研究对基于图像的变压器外观异常缺陷自动识别进行了探索^[3-4]。其中, 对变压器图像中的各类部件进行自动识别定位是实现变压器各种外观异常缺陷识别的前提^[3]。相比于体积较大的变压器部件(如储油柜等), 变压器小部件在图像中包含的像素信息

基金项目: 国家青年科学基金项目资助(62001416); 国网浙江省电力有限公司科技项目资助(2019-HUZJTKJ-09)

十分有限, 要实现准确识别的难度更大。但是变压器的很多小部件往往反映了与变压器运行状态相关的关键信息, 例如油标管的油位可以反映储油柜的油位是否正常, 呼吸器的硅胶颜色可以反映其受潮情况等。因此对变压器的各类小部件进行自动识别, 既是变压器巡检图像目标检测的难点, 也是实现变压器缺陷自动识别的重点。

对于变电站巡检图像中电力设备和部件的自动识别问题, 传统的研究方法大都基于人工设计的图像特征进行识别。例如: 文献[5]基于变压器图像各个像素点的颜色特征, 对变压器的呼吸器进行识别, 进而判断是否存在呼吸器硅胶受潮变色的缺陷; 文献[6]采用 SIFT 方法^[7]提取图像局部的梯度特征, 借助模板图像实现了对变压器套管的自动识别; 文献[8]在 SIFT 特征的基础上, 又加入了图像的稀疏编码特征, 通过联合特征对变电站图像的变压器、变电柜等设备进行了识别。然而人工设计的图像特征抽象程度不足, 泛化能力普遍较弱, 识别准确性不稳定, 难以适应于复杂的变电站场景。

近年来随着深度学习理论的不完善, 深度学习神经网络方法已经在设备故障诊断、故障分类以及状态监测识别等电力领域得到了较为广泛的应用^[9-12]。基于深度学习神经网络的变压器图像部件识别也是其中的一个研究热点。文献[13]采用深度卷积神经网络 AlexNet^[14]对电力设备图像进行特征提取, 再通过随机森林模型对变压器、断路器等设备图像进行了分类, 但未能具体识别出图像中电力设备的位置; 文献[15]采用了深度学习目标检测模型 SSD^[16], 在提取变电站图像深层特征的基础上, 实现了对变压器的识别定位; 进一步地, 文献[17]基于卷积神经网络设计了 TSENet 网络, 可以在对多种变电站设备进行分类的同时, 对各类设备的位置进行识别。相比于人工设计的图像特征, 采用深度学习神经网络对图像特征进行深层次的自动提取, 提高了模型的泛化能力。然而上述方法识别的对象都是变电站的电力设备, 而非电力设备上的具体部件, 既未能解决小部件包含像素信息过少的问题, 也未考虑同一设备上各个部件之间的位置存在关联性的特点, 在应用于变压器小部件识别时, 其准确率会受到较大的影响。

为此, 本文采用改进的 RetinaNet 目标检测网络对变压器图像中多种尺度的部件进行识别, 再通过与小部件相关的大部件位置关联信息, 修正小部件的识别概率, 从而利用较易识别的大部件信息辅助进行小部件的位置识别, 以获得更为准确的变压器小部件识别结果。

1 基于改进 RetinaNet 的变压器多尺度部件识别

1.1 RetinaNet 的目标检测原理

RetinaNet 是一个单阶段目标检测网络, 由一个基础网络和两个子网络构成^[18]。由于在分类时采用了 Focal Loss 损失函数, 解决了类别不平衡问题, 并对特征进行了有效融合, RetinaNet 的目标检测准确率不仅高于 SSD、YOLO 等单阶段网络, 还高于双阶段的 Faster R-CNN 网络^[16,18-20]。

RetinaNet 的网络结构如图 1 所示。当待识别图像输入 RetinaNet 网络时, 首先由基础网络中的 ResNet-101 网络^[21]对图像进行特征提取, 并通过 ResNet-101 网络 5 个不同层次的残差模块输出不同分辨率的特征图, 按照输出的顺序将特征图依次记为 C_1 、 C_2 、 C_3 、 C_4 和 C_5 。然后, 通过基础网络中的特征金字塔网络(FPN)^[22]对特征图进行特征融合, 形成分别与 C_3 、 C_4 和 C_5 分辨率相同的融合特征图 P_3 、 P_4 和 P_5 。在此基础上, 采用 3×3 的卷积核, 对 P_5 进行步长为 2 的卷积运算, 得到特征图 P_6 ; 再采用 3×3 的卷积核, 对 P_6 进行步长为 2 的卷积运算, 并经过修正线性单元(ReLU)的非线性化处理, 得到特征图 P_7 。

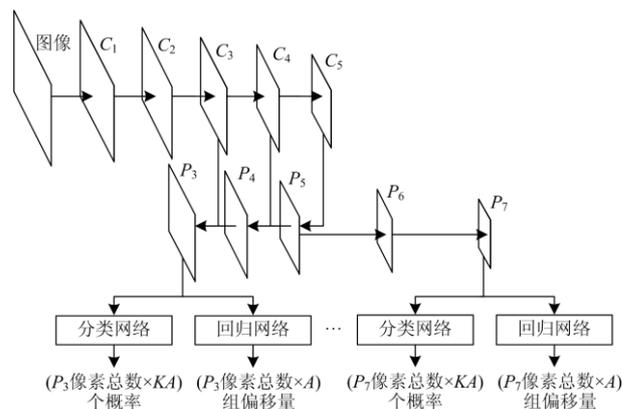


图 1 RetinaNet 网络结构

Fig. 1 RetinaNet network structure

特征融合完成后, 对每一个融合特征图 P_3 、 P_4 、 P_5 、 P_6 和 P_7 , 分别以每个像素点为中心设定 A 个预选框(称为 anchor)。然后, 采用两个子网络, 即分类网络和回归网络进行类别和位置的预测。分类网络采用全卷积网络(FCN)结构^[23], 通过对融合特征图进行一系列的卷积运算, 得到每个 anchor 包含第 k 类目标物体的概率($k = 1, 2, \dots, K$, K 为待识别目标物体的类别数); 同理, 回归网络也采用 FCN 结构, 通过对融合特征图进行一系列的卷积运算, 得到每个 anchor 与包含目标物体的真实区域(称为

ground-truth box)的一组偏移量。最后，通过取每个 anchor 的 K 个概率的最大值，以及利用 anchor 与 ground-truth box 的偏移量对 anchor 进行坐标变换，可以得到每个 anchor 包含的目标类别和精确的坐标位置。

1.2 变压器多尺度部件识别方法

本文所采用图像中变压器的型号为 SSZ10-180000/220，如图 2 所示，其中矩形框表示对应部件的位置。选择图 2 中 3 类尺寸较小的部件，即油标管、瓦斯继电器和呼吸器，对变压器小部件的识别方法进行说明。同时，为了利用部件之间的位置关联信息，进一步修正小部件的识别结果，还需要同时识别与 3 类小部件有比较明确的位置关联性的大部件位置。就变压器的设计而言，一般油标管布置在储油柜附近用以反应其油位的变化；瓦斯继电器安装在储油柜、油箱附近，反应是否存在变压器内部故障使油分解产生气体或造成油流涌动；而呼吸器一般安装在距离地面较近的位置，方便工作人员更换其中的填充物(减少填充物暴露在空气的时间可以有效提高呼吸器使用寿命)，所以呼吸器往往和体积较大、位置同样较低(降低重心)的散热器组相邻布置。因此本文选择储油柜和散热器组 2 类大部件辅助相应小部件的识别，RetinaNet 的目标物体类别数 $K=5$ 。

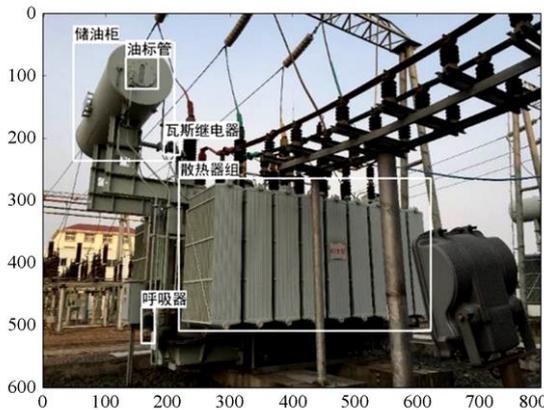


图 2 变压器图像示例

Fig. 2 Sample of transformer images

同时，由于变压器小部件所包含的像素信息更少，识别难度相对更大，需要在特征提取和融合时尽可能保留更多的像素信息。因此，将图 1 所示的 RetinaNet 结构改进为图 3 所示的网络结构。

改进的 RetinaNet 网络结构在采用基础网络对变压器图像进行特征提取和融合时，加入特征图 C_2 的特征，并与特征图 P_3 进行融合，生成比 P_3 分辨

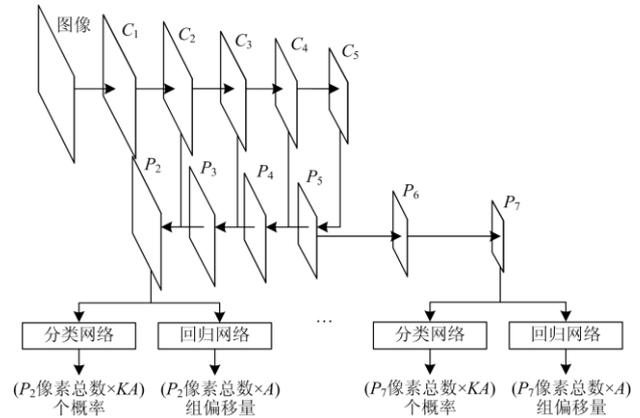


图 3 改进的 RetinaNet 网络结构

Fig. 3 Improved RetinaNet network structure

率更高的融合特征图 P_2 。具体方法是：采用 1×1 的卷积核对 C_2 进行卷积运算，生成与 C_2 分辨率相同的特征图 C'_2 ；同时，通过最近邻上采样方法提高 P_3 的分辨率，生成与 C'_2 分辨率相同的特征图 P'_3 ；最后将特征图 C'_2 和 P'_3 相同位置的像素值相加，得到融合特征图 P_2 。相比于 P_3 到 P_7 ，生成融合特征图 P_2 所进行的卷积运算次数更少，虽然特征的抽象程度较低，但保留了更多像素信息，有利于提高小部件识别的准确率。

2 基于位置关联性的变压器小部件概率修正

2.1 变压器部件的位置关联性分析

按照图 2 所示的变压器型式，可以对变压器各类部件之间的位置关联性进行分析，以获得更多关于小部件位置的先验知识。

在图像目标检测中，通常用类似图 2 中的矩形检测框来表示目标物体的位置，每个检测框的位置和大小由 4 个坐标 x 、 y 、 w 和 h 进行表示，其中 (x, y) 表示检测框中心的坐标(以图像左下角为直角坐标系原点)， w 和 h 分别表示检测框的宽度和高度。小部件和大部件之间固定的位置关系，可以通过它们检测框的坐标进行表达：若小部件紧贴在大部件表面使得小部件的检测框整体位于大部件的检测框内，考虑到大部件的尺寸远大于小部件，则小部件的上下左右界限必然包含在大部件检测框内；若小部件未完全包含在大部件内部而是在大部件附近相邻区域，同样考虑到其关联大部件的尺寸远大于小部件自身，可以选取关联大部件的宽高尺寸作为参照值建立位置关联方程或不等式。位置关联性设计的核心思想是尽量简化筛选逻辑，同时保留足够的裕度，使得当图像数据的采集位置和角度发生变化时，小部件和大部件的位置关联性仍然可以保持一

致。下面分别对油标管、瓦斯继电器、呼吸器三个小部件及其关联大部件的位置关联性进行分析。

对于油标管, 与其位置相关的大部件为储油柜。由于油标管整体位于储油柜侧面, 所以油标管的检测框整体位于储油柜的检测框内, 故有

$$\begin{cases} x_{\text{油}} - \frac{1}{2}w_{\text{油}} > x_{\text{储}} - \frac{1}{2}w_{\text{储}} \\ x_{\text{油}} + \frac{1}{2}w_{\text{油}} < x_{\text{储}} + \frac{1}{2}w_{\text{储}} \\ y_{\text{油}} - \frac{1}{2}h_{\text{油}} > y_{\text{储}} - \frac{1}{2}h_{\text{储}} \\ y_{\text{油}} + \frac{1}{2}h_{\text{油}} < y_{\text{储}} + \frac{1}{2}h_{\text{储}} \end{cases} \quad (1)$$

式中: $x_{\text{油}}$ 、 $y_{\text{油}}$ 、 $w_{\text{油}}$ 和 $h_{\text{油}}$ 分别表示油标管检测框的 4 个坐标; $x_{\text{储}}$ 、 $y_{\text{储}}$ 、 $w_{\text{储}}$ 和 $h_{\text{储}}$ 分别表示储油柜检测框的 4 个坐标。

对于瓦斯继电器, 与其位置相关的大部件也是储油柜。从图 2 可以看出, 瓦斯继电器的实际空间位置在储油柜的下方, 因此瓦斯继电器的检测框中心在储油柜的检测框中心的下方, 但两者在竖直和水平方向上相距不大, 竖直距离不会超过储油柜高度的 2 倍, 水平距离不会超过储油柜宽度的 2 倍。同时, 随着拍摄角度的变化, 两者在图像中的左右相对位置也会变化, 但瓦斯继电器检测框在图像中的宽度和高度始终小于储油柜检测框的宽度和高度, 故有

$$\begin{cases} y_{\text{瓦}} < y_{\text{储}} \\ y_{\text{储}} - y_{\text{瓦}} < 2h_{\text{储}} \\ |x_{\text{储}} - x_{\text{瓦}}| < 2w_{\text{储}} \\ w_{\text{瓦}} < w_{\text{储}} \\ h_{\text{瓦}} < h_{\text{储}} \end{cases} \quad (2)$$

式中, $x_{\text{瓦}}$ 、 $y_{\text{瓦}}$ 、 $w_{\text{瓦}}$ 和 $h_{\text{瓦}}$ 分别表示瓦斯继电器检测框的 4 个坐标。

与呼吸器位置相关的大部件是散热器组。由于在变压器的两侧均有散热器组, 所以呼吸器和散热器组的左右关系也不固定。但是, 无论哪一侧的散热器组, 在空间位置上都位于呼吸器的上方, 且两者的竖直距离不会超过散热器组的高度。同时, 散热器组的宽度和高度都大于呼吸器。因此, 两者的位置关系可以表示为

$$\begin{cases} y_{\text{呼}} < y_{\text{散}} \\ y_{\text{散}} - y_{\text{呼}} < h_{\text{散}} \\ w_{\text{呼}} < w_{\text{散}} \\ h_{\text{呼}} < h_{\text{散}} \end{cases} \quad (3)$$

式中: $y_{\text{呼}}$ 表示呼吸器检测框中心的纵坐标; $w_{\text{呼}}$ 和 $h_{\text{呼}}$ 分别表示呼吸器检测框的宽和高; $y_{\text{散}}$ 表示散热器组检测框中心的纵坐标; $w_{\text{散}}$ 和 $h_{\text{散}}$ 分别表示散热器组检测框的宽和高。

此外, 对于外观与图 2 差异较大的其他型号的变压器, 依然可以按照上述思路进行小部件和大部件的位置关联性设计: 即首先根据变压器的外观构造为每个小部件关联合理的大部件, 然后以该大部件的宽高尺寸为参照值, 建立两者的位置关联方程或不等式。

2.2 变压器小部件概率修正方法

RetinaNet 在对变压器图像进行识别后, 会生成带有部件类别名称和概率的检测框, 代表将检测框内的区域以一定的置信概率预测为某一类部件。利用置信概率, 可以对检测框进行初步筛选, 即设定概率阈值 p_1 , 将概率小于 p_1 的检测框剔除, 以保留较大可能包含目标部件(包括大部件和小部件)的检测框, 如图 4 所示。

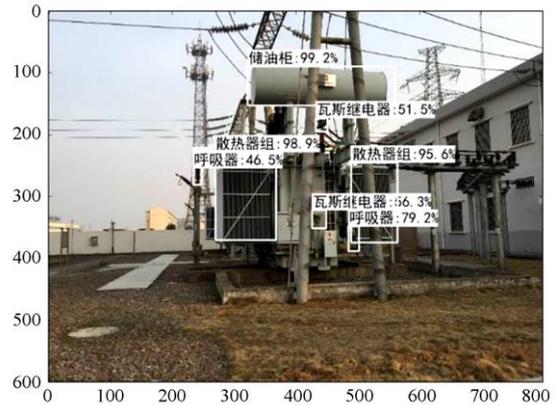


图 4 初步筛选后的图像识别结果

Fig. 4 Recognition results after preliminary screening

但是, 初步的概率筛选难以剔除所有误识别的小部件检测框, 同时由于小部件占据的像素少, 只依靠其本身的像素信息难以保证识别准确性, 在图像中存在较多相似外形部件的干扰时, 容易出现错误检测框概率反而高于正确检测框概率的情况, 例如图 4 的瓦斯继电器。因此, 需要利用相关大部件的位置关联信息, 对小部件检测框的概率进行修正。

以油标管为例, 对小部件的概率修正方法进行说明。对经过初步筛选后的每一个油标管检测框, 按照以下步骤进行概率修正:

1) 记油标管检测框的概率为 $p_{\text{油}}$;

2) 在所有初步筛选后的储油柜检测框中, 选择与油标管检测框的位置关系符合式(1)的储油柜检

测框，并取其中概率最大的储油柜检测框，记其概率为 $p_{\text{储}}$ ；如果找不到与油标管检测框的位置关系符合式(1)的储油柜检测框，则令 $p_{\text{储}}$ 等于 0；

3) 设定权重值 λ ，按照式(4)计算油标管检测框修正后的概率。

$$p'_{\text{油}} = \lambda \cdot p_{\text{油}} + (1 - \lambda) \cdot p_{\text{储}} \quad (4)$$

与油标管类似，可以分别计算瓦斯继电器和呼吸器检测框的修正概率，相关的大部件应分别选择储油柜和散热器组。

求出每一个小部件的修正概率后，再设定概率阈值 p_2 ，对小部件检测框进行再次筛选，即剔除修正概率小于 p_2 的小部件检测框。

最后，对于每一类小部件，如果经过再次筛选后仍有多个小部件检测框，就取其中修正概率最高的一个检测框作为该类小部件最终的检测结果；如果再次筛选后剩下一个小部件检测框，就将其作为该类小部件最终的检测结果；如果再次筛选后该类小部件没有相应的检测框，就判断图像中没有出现该类小部件，未出现的原因可能是在一定的拍摄角度下，该类小部件被变压器的其他部位遮挡。

3 变压器小部件识别实验

3.1 实验数据与模型

选取某变电站的 10 000 张变压器巡检图像作为实验数据集，每张图像图像的分辨率为 1920×1080，同时为了减少网络的计算复杂度，在保证图像清晰度的基础上对图像进行了裁剪、缩放等预处理。处理后的图像的宽度为 800 像素点，高度为 600 像素点。随机将实验图像中的 8 000 张图像划分为训练集，剩余 2 000 张图像作为测试集。对于每张训练图像，均标注出变压器的油标管、瓦斯继电器、呼吸器等 3 类小部件以及储油柜、散热器组等 2 类大部件的真实检测框；对于每张测试图像，只需标注出变压器的油标管、瓦斯继电器、呼吸器等 3 类小部件的真实检测框，用于验证变压器小部件识别的效果。实验平台 CPU 为 Core i7-9700K，GPU 为单核 GEFORCE GTX 1080Ti。

为了与 RetinaNet 网络的变压器小部件识别效果进行对比，选择图像目标检测中经典的单阶段网络 SSD 和双阶段网络 Faster R-CNN 分别进行变压器小部件的识别。同时，选择原始的 RetinaNet 网络(简称“原始 RetinaNet”)和加入 P_2 层的 RetinaNet 网络(简称“RetinaNet+ P_2 ”)，与本文方法(简称“RetinaNet+ P_2 +修正”)进行对比。其中，通过网络搜索方法进行参数寻优，本文的方法在小部件概率

修正时概率阈值 p_1 和 p_2 分别设定为 40% 和 60%，权重值 λ 设定为 0.6；各种对照模型则在利用目标检测网络识别小部件后以 60% 的概率阈值筛选小部件检测框，并取每类小部件概率值最高的检测框作为该类小部件最终的检测结果。另外，根据文献[18]，将 RetinaNet 在每个像素点的 anchor 数量 A 设定为 9。

统计变压器小部件识别的准确率时，如果预测检测框和真实检测框的交集和并集面积之比大于 0.5，就认为预测检测框正确地定位了小部件。对于每一类小部件，将该类小部件识别正确的图像数量占所有测试图像数量的比例作为该类小部件的识别准确率，分别记油标管、瓦斯继电器和呼吸器的识别准确率为 η_1 、 η_2 和 η_3 。同时，将 3 类小部件均识别正确的图像数量占所有测试图像数量的比例作为变压器小部件识别的整体准确率，记为 η 。

3.2 实验结果与分析

用 8 000 张训练图像分别对本文方法和各种对照模型的目标检测网络进行训练后，再用 2 000 张测试图像分别测试本文方法和各种对照模型的变压器小部件识别准确率，实验结果如表 1 所示。

表 1 变压器小部件识别结果

Table 1 Recognition results of small transformer components

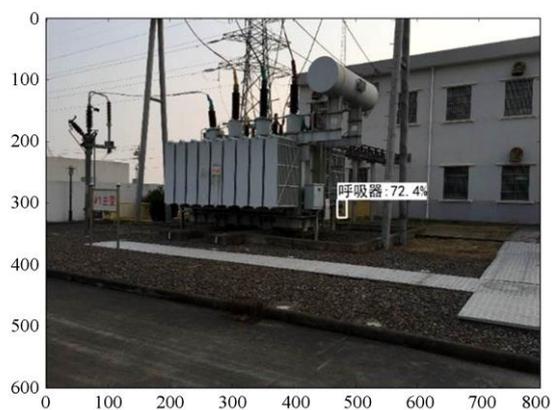
识别方法	$\eta_1/\%$	$\eta_2/\%$	$\eta_3/\%$	$\eta/\%$
SSD	76.55	72.40	79.65	44.05
Faster R-CNN	80.80	76.15	82.10	50.10
原始 RetinaNet	83.75	80.20	84.90	56.85
RetinaNet+ P_2	87.75	86.70	89.15	67.30
RetinaNet+ P_2 +修正	95.05	93.35	96.10	85.45

从表 1 可以看出，本文提出的“RetinaNet+ P_2 +修正”的识别方法在各类小部件的识别结果以及整体识别结果上都取得了最高的准确率。表 1 中三种基于 RetinaNet 的识别方法在各类小部件识别准确率以及整体识别准确率上，均高于 SSD 和 Faster R-CNN 模型，这表明 RetinaNet 所采用的特征融合方法和 Focal Loss 损失函数，能有效提高小部件识别的准确率。

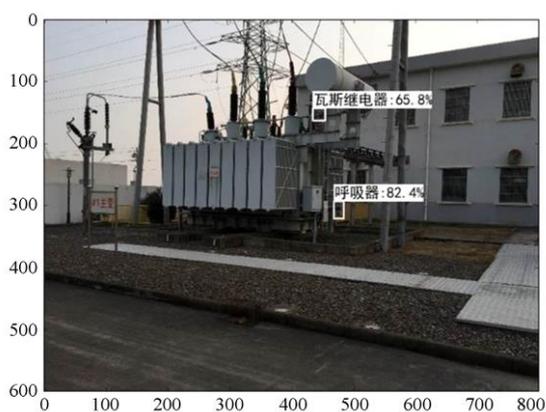
从表 1 中“RetinaNet+ P_2 ”与“原始 RetinaNet”的对比可以看出，在原始的 RetinaNet 网络基础上增加融合特征图 P_2 ，可以通过引入分辨率更高的特征图 C_2 ，保留更多的像素信息，并融入包含深层语义特征的特征图 P_3 ，从而提高对变压器小部件的识别效果。改进的 RetinaNet 对变压器小部件的平均识别准确率提高了 4.9%，并且同时将三者识别正确的整体准确率提高了 10.45%。这表明了浅层特征图丰富的空间分辨率信息在识别小部件中具有巨大优势。当然由于引入了更多的特征图，网络的计算复

杂度会有所增加。不过变压器巡检图像识别的核心在于如何提高对各类小部件的识别准确率, 对实时性要求并不高(实验条件下改进的 RetinaNet 平均图像识别时间约为 0.1 s/张, 远少于图像的采集时间, 这种情况下进一步降低模型的运行时间的实际应用价值有限)。此外为了尽量减少计算复杂度, 本文在保证图像清晰度的前提下对初始图像进行了缩放等预处理操作。与减小输入图像尺寸节省的计算量相比, 增加融合特征图 P_2 的开销可以被忽略, 因而这个代价是值得的。

以图 5 为例, 图 5(a)和图 5(b)分别为“原始 RetinaNet”和“RetinaNet+ P_2 ”对同一张变压器图像的识别结果。



(a) “原始 RetinaNet” 的图像识别结果



(b) “RetinaNet+ P_2 ” 的图像识别结果

图 5 “原始 RetinaNet” 和 “RetinaNet+ P_2 ” 结果对比

Fig. 5 Result comparison of original RetinaNet and RetinaNet+ P_2

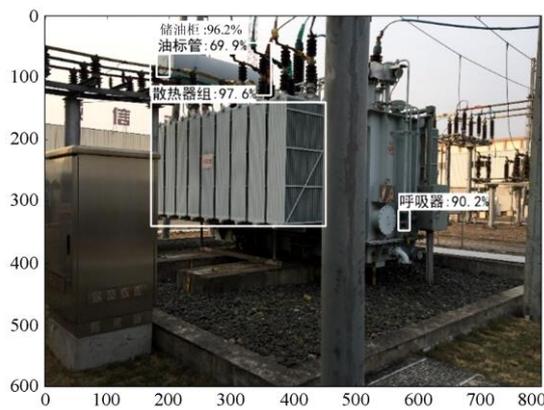
图 5 的变压器图像中存在瓦斯继电器和呼吸器, 但在图 5(a)中, “原始 RetinaNet” 只识别到呼吸器, 未能识别到瓦斯继电器, 而在图 5(b)中, “RetinaNet+ P_2 ” 可以同时识别到瓦斯继电器和呼吸器。RetinaNet 的 ResNet-101 网络经过卷积运算

对图像特征的多次提取, 所生成的特征图 C_1 、 C_2 、 C_3 、 C_4 和 C_5 的分辨率分别只有变压器图像的 1/4、1/16、1/64、1/256 和 1/1024。由于在图 5 的变压器图像中, 瓦斯继电器大约只占据 16×16 的像素区域, 因此在特征图 C_2 中与瓦斯继电器相关的约有 $4 \times 4 = 16$ 个像素, 但在特征图 C_3 中与瓦斯继电器相关的只有约 $2 \times 2 = 4$ 个像素, 故加入与 C_2 分辨率相同的特征图 P_2 , 相对于“原始 RetinaNet”只采用与 C_3 分辨率相同的 P_3 以及分辨率更低的 P_4 到 P_7 , 可以保留更多的像素信息, 对于提升本身尺寸较小的部件识别准确性, 具有较为明显的作用。

从表 1 中“RetinaNet+ P_2 ”和“RetinaNet+ P_2 +修正”的对比可以看出, 利用识别难度较小的大部件位置信息, 对小部件检测框的概率进行修正, 可以有效避免与小部件外形相似的部件干扰, 从而较为显著地提高变压器小部件的识别准确率。以图 6 为例, 图 6(a)和图 6(b)分别为“RetinaNet+ P_2 ”和“RetinaNet+ P_2 +修正”对同一张变压器图像的识别结果。



(a) “RetinaNet+ P_2 ” 的图像识别结果



(b) “RetinaNet+ P_2 +修正” 的图像识别结果

图 6 “RetinaNet+ P_2 ” 和 “RetinaNet+ P_2 +修正” 结果对比

Fig. 6 Result comparison of RetinaNet+ P_2 and RetinaNet+ P_2 +modification

图 6 的变压器图像中存在油标管和呼吸器,但在图 6(a)中,“RetinaNet+ P_2 ”只正确识别了呼吸器的位置,油标管的位置识别出现了错误,而在图 6(b)中,“RetinaNet+ P_2 +修正”利用大部件的识别结果对小部件概率进行修正,从而正确识别出了油标管和呼吸器的位置。由于在图 6 的变压器图像中,油标管被 A 相导线部分遮挡,而呼吸器左边存在一个与油标管外形相似的圆盖,因此在图 6(a)中,“RetinaNet+ P_2 ”预测出圆盖处的检测框概率高于油标管处的检测框概率,最终误将圆盖处的检测框作为油标管的识别结果。相反,在图 6(b)中,“RetinaNet+ P_2 +修正”即使在修正前圆盖处的检测框概率高于油标管处的检测框概率,但是在小部件概率修正时,油标管处检测框与储油柜检测框的位置关系符合式(1),且储油柜检测框的概率 $p_{\text{储}}$ 达到了 96.2%,根据式(4),修正后油标管处检测框概率 $p'_{\text{油}}$ 会比修正前概率 $p_{\text{油}}$ 更高;而圆盖处检测框不存在与其位置关系符合式(1)的储油柜检测框,概率修正时会令 $p_{\text{储}}$ 为 0,根据式(4),修正后圆盖处检测框概率 $p'_{\text{油}}$ 会比修正前概率 $p_{\text{油}}$ 更低,最终使得在概率修正后,圆盖处的检测框概率低于油标管处的检测框概率,因而能够保留油标管处的检测框作为正确的油标管识别结果。

4 结语

本文针对变电站巡检图像的目标检测问题,提出一种变压器图像的小部件识别方法,有效地提高了变压器小部件的识别准确率。该方法具有以下的特点:

1) 针对变压器小部件像素信息有限的问题,在目标检测网络 RetinaNet 中加入了分辨率更高的融合特征图 P_2 ,保留了更多的小部件像素信息,降低了模型对小部件的识别难度;

2) 借助识别难度较小的大部件位置信息,利用变压器各类小部件与相应大部件之间的位置相关关系,对小部件概率进行修正,进一步提高了变压器小部件的识别准确率。

对大部件的高识别准确率是应用本文方法的一个前提条件,即本文方法只能使得对小部件的识别准确率不断逼近大部件的识别准确率。如果能够进一步利用变压器的各个大部件或大部件组(包括大部件与关联到该大部件的所有小部件)的位置关联性,理论上可以更加有效地提高变压器巡检图像的部件整体识别准确率。此外,若能找到类似的位置关联性特征,本文提出的利用关联大部件修正小部件的检测概率以提高小部件的识别准确率的思想方

法同样适用于其他电力图像部件的识别。

参考文献

- [1] 李军锋,何双伯,冯伟夏,等. 基于改进 CNN 的增强现实变压器图像识别技术[J]. 现代电子技术, 2018, 41(7): 29-32.
LI Junfeng, HE Shuangbo, FENG Weixia, et al. Improved CNN based transformer image recognition technology in augmented reality environment[J]. Modern Electronics Technique, 2018, 41(7): 29-32.
- [2] 马承志,王宇雷,杨玺,等. 用于变电站自主巡视机器人的图像传输系统研究[J]. 电力系统保护与控制, 2014, 42(18): 105-109.
MA Chengzhi, WANG Yulei, YANG Xi, et al. Research on image transmission system for substation autonomous patrol robot[J]. Power System Protection and Control, 2014, 42(18): 105-109.
- [3] LIU Z Q, WANG H F. Automatic detection of transformer components in inspection images based on improved faster R-CNN[J]. Energies, 2018, 11: 3496-3513.
- [4] 吴曦,姚楠,许建刚. 基于改进神经网络算法的变电站变压器裂纹图像识别[J]. 现代电子技术, 2017, 40(13): 66-69.
WU Xi, YAO Nan, XU Jiangang. Substation transformer crack image recognition based on improved neural network algorithm[J]. Modern Electronics Technique, 2017, 40(13): 66-69.
- [5] HU Y, WEI S, GAO P, et al. Automatic detection of transformer respirator based on image processing[C] // Chinese Automation Congress, October 20-22, 2017, Jinan, China: 511-515.
- [6] ZHOU Q, ZHAO Z. Substation equipment image recognition based on SIFT feature matching[C]// International Congress on Image and Signal Processing, October 16-18, 2012, Chongqing, China: 1344-1347.
- [7] LOWE D G. Distinctive image features from scale-invariant key points[J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [8] 楚瀛,李帅奇. 基于联合特征的变电站设备图像识别[J]. 电力科学与技术学报, 2018, 33(1): 102-107.
CHU Ying, LI Shuaiqi. Image recognition of substation equipment based on joint feature[J]. Journal of Electric Power Science and Technology, 2018, 33(1): 102-107.
- [9] 吴迪,汤小兵,李鹏,等. 基于深度神经网络的变电站

- 继电保护装置状态监测技术[J]. 电力系统保护与控制, 2020, 48(5): 81-85.
- WU Di, TANG Xiaobing, LI Peng, et al. State monitoring technology of substation relay protection device based on deep neural network[J]. Power System Protection and Control, 2020, 48(5): 81-85.
- [10] 丁石川, 厉雪衣, 杭俊, 等. 深度学习理论及其在电机故障诊断中的研究现状与展望[J]. 电力系统保护与控制, 2020, 48(8): 172-187.
- DING Shichuan, LI Xueyi, HANG Jun, et al. Deep learning theory and its application to fault diagnosis of an electric machine[J]. Power System Protection and Control, 2020, 48(8): 172-187.
- [11] 汪颖, 孙建风, 肖先勇, 等. 基于优化卷积神经网络的电缆早期故障分类识别[J]. 电力系统保护与控制, 2020, 48(7): 10-18.
- WANG Ying, SUN Jianfeng, XIAO Xianyong, et al. Cable incipient fault classification and identification based on optimized convolution neural network[J]. Power System Protection and Control, 2020, 48(7): 10-18.
- [12] 刘子英, 张靖, 邓芳明. 基于 BP 神经网络的高压隔离开关分合闸监测识别[J]. 电力系统保护与控制, 2020, 48(5): 134-140.
- LIU Ziyang, ZHANG Jing, DENG Fangming. Monitoring and identification of state of opening or closing[J]. Power System Protection and Control, 2020, 48(5): 134-140.
- [13] 李军锋, 王钦若, 李敏. 结合深度学习和随机森林的电力设备图像识别[J]. 高电压技术, 2017, 43(11): 3705-3711.
- LI Junfeng, WANG Qinruo, LI Min. Electric equipment image recognition based on deep learning and random forest[J]. High Voltage Engineering, 2017, 43(11): 3705-3711.
- [14] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C] // Neural Information Processing Systems, 2012, Granada, Spain: 1097-1105.
- [15] 位一鸣, 童力, 罗麟, 等. 基于卷积神经网络的主变压器外观缺陷检测方法[J]. 浙江电力, 2019, 38(4): 61-68.
- WEI Yiming, TONG Li, LUO Lin, et al. An exterior defects detecting method of main trans-former based on convolutional neural networks[J]. Zhejiang Electric Power, 2019, 38(4): 61-68.
- [16] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot MultiBox detector[C] // European Conference on Computer Vision, 2016, Amsteram, Netherlands: 21-37.
- [17] 王祎瑞. 基于深度卷积神经网络的变电站设备识别[D]. 沈阳: 沈阳农业大学, 2018.
- WANG Yirui. Substation equipment recognition based on deep convolution neural network[D]. Shenyang: Shenyang Agricultural University, 2018.
- [18] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.
- [19] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C] // IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, USA: 779-788.
- [20] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [21] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C] // IEEE Conference on Computer Vision and Pattern Recognition, 2016, Las Vegas, USA: 770-778.
- [22] LIN T Y, DOLLAR P, GIRSHICK R. Feature pyramid networks for object detection[C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017, Honolulu, USA: 936-944.
- [23] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.

收稿日期: 2020-08-18; 修回日期: 2020-10-25

作者简介:

万吉林(1995—), 男, 硕士研究生, 研究方向为智能电网数据挖掘、电力图像处理、机器视觉; E-mail: 2025819879@qq.com

王慧芳(1974—), 女, 通信作者, 博士, 副教授, 研究方向为电网状态检修、继电保护与控制。E-mail: huifangwang@zju.edu.cn

(编辑 姜新丽)