

基于 Faster RCNN 的红外热图像热斑缺陷检测研究^①



郭梦浩, 徐红伟

(中国计量大学 机电工程学院, 杭州 310018)

通讯作者: 郭梦浩, E-mail: gmh19970518@163.com

摘要: 光伏组件在日常运行中不可避免会产生各种缺陷, 热斑缺陷就是其中一种. 现有的研究主要针对光伏组件在生产工艺流程中出现的缺陷, 对日常运行中光伏组件产生的缺陷检测算法研究很少并且存在泛化能力差、准确率不足等问题. 本文在原始 Faster RCNN 的基础上, 结合图像预处理、迁移学习、改进特征提取网络模型以及改进锚框选区方案, 得到热斑缺陷检测模型. 实验证明, 使用本文模型在自制的测试集上平均检测准确率可达 97.34%, 相比原始 Faster RCNN 提高了 4.51%.

关键词: 光伏组件; 热斑缺陷; Faster RCNN

引用格式: 郭梦浩, 徐红伟. 基于 Faster RCNN 的红外热图像热斑缺陷检测研究. 计算机系统应用, 2019, 28(11): 265-270. <http://www.c-s-a.org.cn/1003-3254/7137.html>

Hot Spot Defect Detection Based on Infrared Thermal Image and Faster RCNN

GUO Meng-Hao, XU Hong-Wei

(College of Mechanical and Electrical Engineering, China Jiliang University, Hangzhou 310018, China)

Abstract: Photovoltaic modules inevitably produce various defects in daily operation, and hot spot defects are one of them. The existing research mainly focuses on the defects of photovoltaic modules in the production process, and there is few research on the defect detection algorithms generated by PV modules in daily operation, and there are problems such as poor generalization ability and insufficient accuracy. Based on the original faster RCNN, this study combines image preprocessing, migration learning, improved feature extraction network model, and improved anchor frame selection scheme to obtain hot spot defect detection model. Experiments show that the average detection accuracy of the self-made test set using this model is 97.34%, which is 4.51% higher than the original faster RCNN.

Key words: photovoltaic module; hot spot defects; faster RCNN

可持续发展是二十一世纪的一个重要命题, 核心思想是经济发展与资源、生态环境协调一致, 其中最重要就是寻找一种环保干净型能源系统. 太阳能不仅清洁无污染, 而且来源广泛, 成为新能源发展的宠儿^[1]. 但是光伏组件由于其工作特性长期裸晒在自然环境下, 环境比较恶劣. 在户外, 不仅要遭受风吹雨打, 而且表面容易沾染沙尘与飞禽粪便等异物. 面对以上这些情

况, 如果不能及时对光伏组件进行有效的日常维护, 就会使光伏组件产生各种各样的故障, 热斑就是其中一种典型故障.

热斑问题不仅影响光伏组件的发电效益, 严重时甚至可引发火灾, 因此实现对热斑的实时定位检测对光伏电站的维护工作有着重要应用价值. 王培珍等^[2]发现光伏组件会在不同的状态下存在明显的温差, 针

① 收稿时间: 2019-04-07; 修改时间: 2019-05-08; 采用时间: 2019-05-13; csa 在线出版时间: 2019-11-06

对这一特性提出基于红外图像分析的故障检测方法。王亚丽^[3]提出一种改进传统 OSTU 算法来自动识别最优分割阈值的方法对光伏组件上产生的缺陷进行检测定位与分类。王宪宝^[4]提出以深度置信网络为基础,通过学习大量样本,得到训练样本与无缺陷模板之间的映射关系,从而实现样本的缺陷检测。车曦^[5]提出对光伏电池片状态进行分类编码,再结合图像的预处理与神经网络实现对热斑缺陷的变化趋势做出预测。这些方法虽然取得了一定的检测成果,但这些研究多数是针对光伏组件的制作工艺中发生的缺陷,对实际运行维护的缺陷检测研究较少,并且存在泛化能力差、准确率不足等问题。

由于深度学习相关技术的快速突破,使得越来越多的科研人员在图像分类、目标识别、图像分割和检测等问题上采用深度学习的方法解决,并且取得了不错的效果。本文所研究的热斑缺陷检测即可看作是一个物体检测问题。目前主流的深度学习的目标检测算法包括两类:一类是基于区域的目标检测算法如 Fast RCNN^[6]、Faster RCNN^[7]与 RFCN 等,其特点是检测精度高,但速度相对较慢;另一类是将检测问题转变为回归问题求解如 YOLO^[8],其特点是虽提高了网络的检测效率,但是目标定位的准确率有所降低。而热斑缺陷检测问题对其检测模型的准确率有较高的要求,选用 Faster RCNN 模型比较符合实际需求。但是已有实验证明 Faster RCNN 对中大型的目标具有良好的检测效果,但对小目标的检测效果不佳^[9],如果直接套用原始的 Faster RCNN 模型,可能会造成小型的热斑缺陷的漏检。综上所述,本文采用 Faster RCNN 为基础模型,在此基础上结合图像预处理、迁移学习、改进特征提取网络模型以及改进锚框选区方案,得到了热斑缺陷检测模型。

1 Faster RCNN 简介

Faster RCNN 是在 RCNN、Fast RCNN 研究的基础上提出的,主要改进是在 Fast RCNN 上引入了 RPN。用 RPN 来提取候选框可以消除使用选择性搜索而导致的分离问题。Faster RCNN 先通过特征提取网络获得图片的特征图,然后通过 RPN 网络提取候选框,最后 Fast RCNN 根据 RPN 网络提供的候选框实现目标检测。并且 RPN 网络和 Fast RCNN 通过交替训练实现参数贡献,使得目标检测更加高效。

1.1 RPN 网络

RPN 网络的作用是类似目标检测网络中的选择性搜索,是 Faster RCNN 的核心。RPN 网络使用的滑动窗口机制,并且可以实现多个候选区的同时预测。每个滑动窗口在滑动后,随后会产生一个短特征向量;紧接着将产生的短特征向量输入到全连接层中进行位置和类别的判断。RPN 网络结构如图 1 所示,图中右侧为 RPN 网络的 k 个锚框,由于待测目标的尺寸、高宽比的差异,需要设定多种形态的锚框;左侧图中可以看出每个待测区域将会产生 k 个预测候选区域;RPN 网络的输出层是一个多任务模型,一是通过 SOFTMAX 来区分候选框属于前景类或背景类,二是通过边界回归预测候选框的偏移量,降低定位的误差。

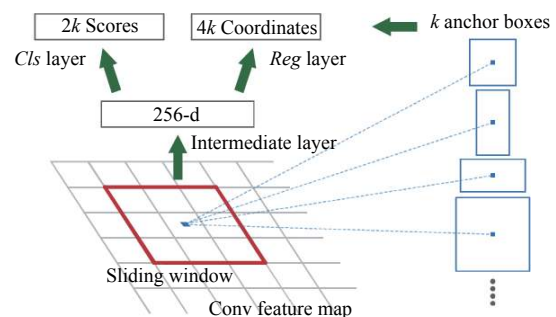


图 1 RPN 网络结构

1.2 区域建议网络的损失函数

RPN 网络在训练时,获得候选窗口太多,因此需要对候选窗口进行筛选,依据如下:

- (1) 将超过输入原始图像的候选窗口筛掉;
- (2) 通过非极大值抑制,设置重叠区域高于 0.7 的窗口标定为前景区,低于 0.3 的窗口标定为背景。

RPN 网络的整体损失函数定义为公式:

$$L(\{p_i\}|\{p_i^*\}) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (1)$$

式中, i 为最小批次种锚框的索引, p_i 为锚框所属目标的预测概率, t_i 代表预测候选框的坐标, t_i^* 为真实候选框坐标, L_{cls} 为分类结果对数损失, L_{reg} 为回归损失, R 为鲁棒损失函数,定义式为:

$$L_{\text{reg}}(t_i, t_i^*) = R(t_i - t_i^*) \quad (2)$$

$p_i^* L_{\text{reg}}$ 表示当 $p_i^* = 1$ 时才有回归损失,分类层和回归层的输出分别由 $\{t_i\}$ 和 $\{t_i^*\}$ 组成, $\{p_i\}$ 和 $\{t_i\}$ 分别对 N_{cls} 和 N_{reg} 以及 λ 进行归一化。获取回归过程的坐标的公式如下:

$$t_x = (x - x_a) / w_a, t_y = (y - y_a) / h_a \quad (3)$$

$$t_w = \log(w / w_a), t_h = \log(h / h_a) \quad (4)$$

$$t_x^* = (x^* - x_a) / w, t_y^* = (y^* - y_a) / h_a \quad (5)$$

$$t_w^* = \log(w^* / w_a), t_h^* = \log(h^* / h_a) \quad (6)$$

2 热斑缺陷检测模型设计

综上所述,为填补目前对光伏组件实际中产生缺陷检测算法的空白,解决不同大小、不同形状的热斑缺陷提取困难的问题.本文提出在原始 Faster RCNN 的基础上结合图像预处理、迁移学习、改进特征提取网络模型以及改进锚框选区方案,得到热斑缺陷检测模型.本文热斑检测系统框架图以及热斑缺陷检测模型框架图分别如图 2、图 3 所示.

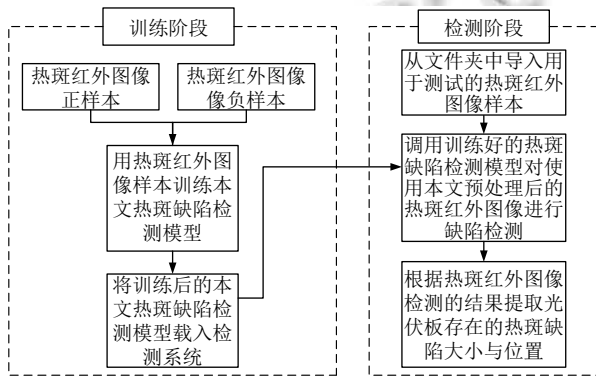


图 2 热斑缺陷检测模型框架图




图 3 热斑缺陷检测模型框架图

2.1 图像预处理

热像仪使用时受自身干扰与所测时自然环境影响,不可避免的会使所采集的红外热图像存在低对比、高噪声等问题.而样本的好坏决定了后续实验的效果,为了避免样本集对本文模型检测效果的影响,因此对采集到的红外热图像进行预处理操作尤为重要.

所采集的红外热图像对比度较低,本文选用直方图均衡化的方法.另外采集的红外热图像包含由自身设备导致的高斯噪声以及光伏组件表面异物形成的椒

盐噪声与微小斑点.对于这种情况下的复杂噪声问题,仅通过单个滤波器难以有效的滤除噪声.综上所述,为了降低噪声对实验的影响,本文采用的图像预处理流程具体如图 4 所示.第一步,使用直方图均衡化,用以获得合适对比度的红外热图像;第二步,对第一步获得的图片先进行一次方形结构闭运算,在进行一次方形结构开运算,用来滤除椒盐噪声和微小斑点;第三步,对得到的图片使用高斯滤波,完成图像预处理.




图 4 图像预处理流程图

2.2 锚框方案调整

由于热斑缺陷的形成受建筑物遮荫、树叶、鸟粪以及积尘等多种自然因素影响,导致热斑缺陷的尺寸差异较大,其长宽比更加多样化.原始的 Faster RCNN 包含 9 种锚框,其长宽比为 0.5, 1, 2, 尺寸为 8, 16, 32.如果使用原始 Faster RCNN 的锚框,原始图像在经过池化后,所有特征图各点对应得到的感受野尺寸为 16×16.使用最小尺度映射的锚框尺寸都达到 128,而实际中存在一些较小的热斑缺陷,在检测过程中不可避免会出现定位偏差,进而造成误检.因此,根据热斑缺陷尺寸差异较大、长宽比更加多样化的特点调整原始 RPN 网络的锚框尺寸和比率.调整后锚框的种类共有 16 种,将锚框尺寸改成 2、4、8、16,有助于增强对小型热斑缺陷的检测;长宽比额外增加 4 的比例,有助于提高对鸟粪引起的长条状热斑缺陷的检测.实验证明本文调整后的锚框可以提高检测精度,锚框选择方案对比如表 1 所示.

表 1 锚框选择方案

锚框	选择方案
原始长宽比	[0.5, 1, 2]
原始尺寸	[8, 16, 32]
调整长宽比	[0.5, 1, 2, 4]
调整尺寸	[2, 4, 8, 16]

2.3 改进特征提取网络模型

在深度学习算法中,用 CNN 网络作为整个模型的特征提取网络.这是至关重要的一步.特征网络提取的特征将直接影响最终的特征提取结果,从而对目标检测效果造成影响.一般来说,特征提取网络的层数越深其获得的特征效果更高,但是网络选择过深会加大训

练过程的难度. 本文选用 VGG16 网络作为特征提取网络的基础网络. VGG16 网络的深度适中, 并且使用了多层小卷积. 多层小卷积核的叠加在保证感受野大小

不变的情况下引入了更多的非线性映射. 这样不仅提高了整个网络的学习能力, 并且有效的减少了对网络参数的计算量. VGG16 网络结构图如图 5 所示.

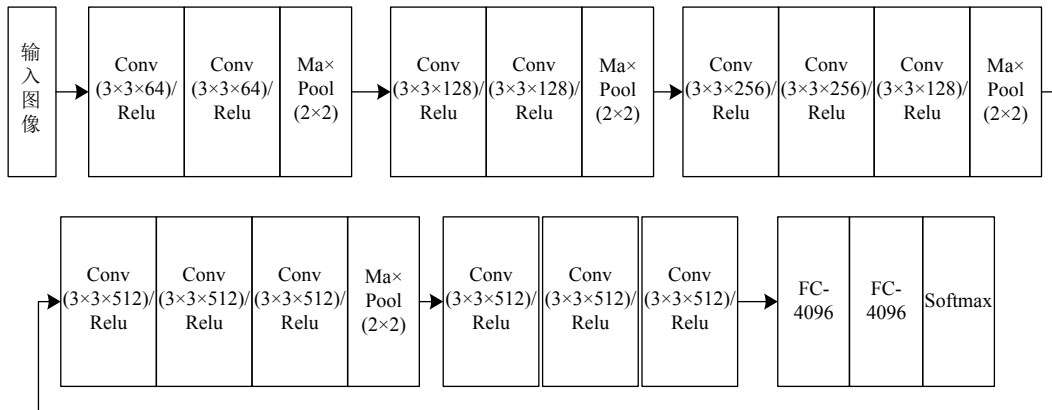


图 5 VGG16 网络结构

根据本文的研究对象的复杂度与实际需要的时效性, 在保证深层网络在高层特征抽象上的优势, 又要减少网络模型的复杂度. 文中涉及的热斑缺陷检测问题暂只是一个二分类问题, 且不属于复杂的物体检测问题. 直接使用 VGG16 模型略显大材小用, 也会造成额外的计算量或产生过拟合问题. 由于全连接层的参数量占整个 VGG16 网络参数量的一大部分, 故本文将 VGG 模型中的后两层全连接层剔除, 用一层包含 1024 个神经元的全连接层进行替代, 其他部分不变. 此外, 本文选用迁移学习的方法避免过拟合问题, 本文的改进后特征提取网络没有选择随机参数初始化的方式, 而是选择在 Image Net 数据库上获取模型的初始化参数, 最后在训练过程中对其进行微调.

3 实验分析

在户外, 使用热像仪采集大量含有不同尺寸和不同形状的热斑缺陷的大量红外热图像, 以形成图像数据集, 并加入样本标签; 然后将获得的数据集在本文热斑缺陷检测模型上进行训练; 最后在测试集上进行测试, 观察本文热斑缺陷模型平均检测准确率、平均漏检率与平均误检率. 另外还对比了 Faster RCNN、去除预处理的本文模型以及本文模型对热斑缺陷检测在平均检测准确率、平均检测时间与平均加速比上的差别.

3.1 实验系统组成

本文实验系统由 Ti25 红外热像仪与计算机构成, 实验对象为我校太阳能光伏示范工程中的光伏组件, 如图 6 所示. Ti25 红外热像仪是一款手持式的外热像

仪, 可拍摄可见光图像或红外热图像, 检测灵敏度高、测温精准, 满足实验需求. Ti25 在实验过程中主要用于红外热图像的采集、读取温度数据. 须注意的是由于热像仪自身在拍摄过程中会引起自反射, 在采集数据集时视角应尽可能接近光伏组件法向量, 另外热像仪应保持在与光伏组件法向量成 $0^{\circ}\sim 40^{\circ}$ 的夹角.



图 6 光伏组件与热像仪

在进行热斑缺陷采集的过程中, 采集到的自然状态下光伏组件产生的热斑缺陷样本不足, 另人为模拟热斑缺陷实现对样本集的扩充. 自然热斑和模拟热斑的热斑均包含不同尺寸、不同的形状. 如图 7 所示: 分别为自然热斑与模拟热斑缺陷图像.




图 7 自然热斑与模拟热斑

3.2 样本集制作

为了使样本保持多样性和训练出来的热斑缺陷检测模型的鲁棒性更强, 在多种自然条件情况下进行数据的采集. 之后 LABELING 对采集到的红外热图像

中的热斑大小和位置信息进行标注, 标签名称 Hot spot, 用做本文热斑缺陷检测模型的训练与测试. 采集的红外热图像共有 1167 张, 选取其中 1000 张原始图像随机进行镜像翻转、旋转和颜色光照变换等操作将

数据集扩增至 3000 张图像, 部分样本集示例如图 8 所示. 剩余的 167 张红外热图像用作模型的测试与评估, 测试样本中一张图片包含 1 至 3 个热斑缺陷, 其中自然热斑缺陷数量为 115 个, 模拟热斑缺陷为 108 个.

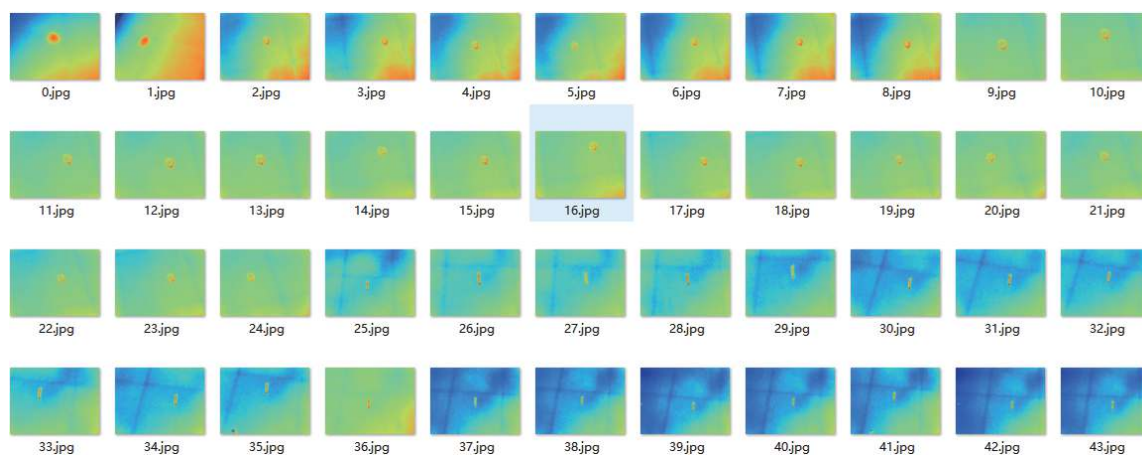


图 8 部分样本集

3.3 实验软件与硬件

实验软件与硬件如表 2 所示. 本文使用 Python 作为编程语言, 使用 Tensorflow 搭建模型框架, 使用 GPU 加速, 开发工具为 SPYDER.

表 2 硬件环境与软件环境

硬件环境	软件环境
处理器: Intel Core i7-8700	Windows10
内存: 8 GB	CUDA8.0+CuDNN5.1
GPU: NVIDIA GTX1070ti(8 GB)	Python+TensorFlow+OPENCV

3.4 模型训练方式与参数设定

本文模型采用交替式训练, 其过程涉及四个阶段:

第一阶段: 特征提取层初始化参数使用在 Image Net 上训练的 VGG16 模型参数. 随后对 RPN 网络进行训练, 获取候选框, 通过随机梯度下降法迭代 30 000 次. 学习率大小设置为 0.0001, 动量设置为 0.9, 权重衰减设置 0.0005.

第二阶段: 先用原始 VGG16 对 Fast RCNN 进行初始化, 然后使用第一阶段获取的候选框和 Ground Truth 共同训练 Fast RCNN. 同样随机梯度下降法, 迭代次数为 10 000 次, 学习率的大小设置为 0.001, 动量设置为 0.9, 权重衰减设置为 0.0005.

第三阶段: 利用第二阶段获得的 Fast RCNN 网络参数初始化网络模型, 并且保持特征提取层参数不变,

然后再次训练 RPN 网络, 进一步调整 RPN 网络的参数. 同样使用随机梯度下降法, 迭代次数为 20 000 次, 学习率的大小设置为 0.0001, 动量设置为 0.9, 权重衰减设置为 0.005.

第四步: 使用第三阶段调整后的 RPN 网络获取的候选框和 Ground Truth 对 Fast RCNN 网络进行第二次训练. 同样采用随机梯度下降法, 迭代次数为 10 000 次, 学习率的大小设置为 0.001, 动量设置为 0.9, 权重衰减设置为 0.005.

3.5 热斑缺陷检测实验结果分析

在测试过程中, 使用本文的热斑缺陷检测模型在 167 张测试图片上进行测试, 其中自然热斑缺陷数量为 115 个, 模拟热斑缺陷为 108 个. 对模拟热斑、自然热斑的实际数量、正确检测个数、漏检个数、误检个数统计结果如表 3 所示. 可以看出, 对模拟热斑的检测效果相对自然热斑的检测效果要好, 模拟热斑的漏检个数为 2, 误检个数为 0; 自然热斑的漏检个数为 4, 漏检个数为 2.

本文热斑缺陷检测模型在测试集上的测试统计比率表 4 所示. 可以看出本文热斑缺陷检测模型在测试集上的平均准确率、平均漏检率、平均误检率分别达到了 97.34%、2.67%、0.87%, 该实验说明, 使用深度学习对光伏组件的热斑缺陷检测是可行的, 并从本文测试集上获得了良好的效果.

表3 本文热斑检测模型测试结果统计

对象	实际数量	正确检测	漏检	误检
模拟热斑	108	106	2	0
自然热斑	115	111	4	2
总数	223	217	6	2

表4 本文热斑检测模型测试比率统计 (%)

对象	准确率	漏检率	误检率
模拟热斑	98.15	1.85	0
自然热斑	96.52	3.48	1.74
平均	97.34	2.67	0.87

另外,分别对原始 Faster RCNN、去除预处理的本文模型与本文热斑缺陷检测模型在测试集上进行测试,计算三者平均检测准确率、平均检测时间与平均加速比。3种模型对比结果如表5所示。

表5 算法对比结果统计

检测方法	平均检测准确率 (%)	平均检测时间 (s)	平均加速比
Faster RCNN	92.83	0.09	5.12
去除预处理的本文模型	96.27	0.12	6.68
本文模型	97.34	0.17	6.31

通过表5可以看出,去除图像预处理的本文模型在测试集上的平均检测准确率为96.27%,相比原始 Faster RCNN 模型提高了3.44%。由于本文的热斑缺陷检测模型加入了图像预处理,相比去除预处理的本文模型的检测准确率进一步提升了1.07%,最终在测试集上的检测准确率达到97.34%。可以看出对红外热图像进行预处理是提高热斑缺陷检测准确率的重要性。由于本文的热斑缺陷检测模型是通过离线学习训练得到的,对实际中的检测时间没有影响,故本文只统计了3种模型的平均加速比,由表5可以看出使用GPU加速可以有效降低模型的检测时间,提高系统的检测效率。另外,从平均检测时间与平均加速比两方面看,本文的热斑缺陷检测模型虽然尽管不是最优,但对实际检测影响较小,可以忽略。

本文热斑缺陷检测模型测试效果示例如图9所示。

4 结论与展望

本文模型是结合图像预处理、改进特征提取网络模型以及调整锚框选区方案的在原始的 Faster RCNN 模型上进行了略微的优化。然后将自己制作的红外热图像数据集在本文模型上训练,提取出热斑缺陷。实验

证明,本文模型在测试集上的平均检测准确率可达97.34%,效果良好。但是本文所涉及到的光伏组件缺陷只是针对热斑缺陷,实际运维中光伏组件还会产生其它类型的缺陷,这是接下来研究的重点问题。




图9 本文热斑缺陷检测模型测试效果示例

参考文献

- 马宁. 太阳能光伏发电概述及发展前景. 智能建筑电气技术, 2011, 5(2): 25-28. [doi: 10.3969/j.issn.1729-1275.2011.02.007]
- 王培珍, 郑诗程. 基于红外图像的太阳能光伏阵列故障分析. 太阳能学报, 2010, 31(2): 197-202.
- 王亚丽. 基于红外热成像的太阳能板缺陷检测[硕士学位论文]. 杭州: 中国计量学院, 2015.
- 王宪保, 李洁, 姚明海, 等. 基于深度学习的太阳能电池片表面缺陷检测方法. 模式识别与人工智能, 2014, 27(6): 517-523. [doi: 10.3969/j.issn.1003-6059.2014.06.006]
- 车曦. 基于红外图像识别的光伏组件热斑故障检测方法研究[硕士学位论文]. 重庆: 重庆大学, 2015.
- Girshick R. Fast R-CNN. Proceedings of 2015 IEEE International Conference on Computer Vision. Santiago, Chile. 2015. 1440-1448.
- Ren SQ, He KM, Girshick R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149. [doi: 10.1109/TPAMI.2016.2577031]
- 徐守坤, 王雅如, 顾玉宛, 等. 基于改进 FasterRCNN 的安全帽佩戴检测研究. 计算机应用研究, 2020, 37(3). http://www.aocmag.com/article/02-2020-03-059.html.
- Shrivastava A, Gupta A, Girshick R. Training region-based object detectors with online hard example mining. Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA. 2016. 761-769.