

基于深度学习的高效电力部件识别

欧家祥¹, 史文彬², 张俊玮¹, 丁超¹

(1. 贵州电网有限责任公司电力科学研究院, 贵州 贵阳 550002; 2. 上海电力学院, 上海 200090)

摘要:传统的图像识别方法,不能有效检测出电力部件的具体位置,同时在干扰物较多的场景下识别准确率较低。本文针对以上问题提出一种基于 MASK LSTM-CNN 模型的电力部件巡检图像识别方法。结合已有的 Mask R-CNN 方法,利用长短期记忆神经网络,通过络融合上下文信息来构建 MASK LSTM-CNN 模型,然后结合电力部件的具体特征进一步利用优化算法来优化模型的参数,使设计的模型能够在干扰信息较多的现场环境下依然可以准确识别电力部件,成功解决了已有方法中存在的电力部件在被遮挡情况下识别率较低的问题,大大改善了部件识别的精度。结合实际采集的电力部件巡检图像数据集对提出的模型进行大量测试验证,实验结果表明提出的 MASK LSTM-CNN 模型相比于 R-FCN、Faster R-CNN 等模型检测效果更优,平均识别准确率提高 9%~12% 左右,有效解决了干扰信息较多的电力场景中的部件识别问题。

关键词:电力部件识别;模型;识别率;图像识别

文章编号:2096-4633(2018)09-0001-08 中图分类号:TM93 文献标志码:B

随着信息技术的迅速发展,智能的电力部件检测受到各大电网公司的广泛关注^[1]。传统的检测方法需要人眼长期工作,不能够实现持续监测和识别,系统的可靠性较差。对电力系统来说,停电意味着经济效益的下降^[2]。为了保持设备良好的运行状况,减少停电带来的损失,不断提高供电可靠性,加入机器视觉的电力部件检测能够很好的解决这些问题^[3]。

与传统的图像识别相比,电力现场工况图像背景复杂、小部件密度高,并且有较高的时效性要求^[4]。传统的电力部件识别算法主要采用人工设计的特征如 SIFT (scale invariant feature transform)^[5]、边缘检测符^[6]、HOG (histogram of oriented gradients)^[7]等,不能很好地适用于电力部件,采用的分割算法主要基于外围轮廓骨架^[8]、自适应阈值等进行图像分割^[9]。这些方法在设计原则上往往是基于特定类别来实现的,其准确率低,不具有可扩展性;而且方法结构松散,缺少对低层特征进行综合利用进而达到全局最优识别的目的。

针对以上问题,本文研究了深度学习在电力部件识别中的应用,基于 Mask R-CNN 提出了 MASK LSTM-CNN 通过 LSTM 神经网络在分类与回归层中融入上下文特征,大大增加目标识别的抗干扰性,提高了电力部件识别的精确度。本文首先介绍了 Faster-RCNN^[9~10]、R-FCN^[11] 和 MASK LSTM-CNN

3 种算法的结构与原理,通过实验对比了 Mask R-CNN^[12] 与改进后的 MASK LSTM-CNN 的性能,然后针对电力部件识别问题分析了 Faster-RCNN、R-FCN 和 MASK LSTM-CNN 三种算法的效果和性能,最后结合实验结果对带电作业机器人巡检图像电力部件识别提出了展望。

1 经典电力部件识别定位方法

1.1 基于 Faster-RCNN 方法的电力部件识别定位

继 R-CNN 和 Fast-RCNN^[13]之后,为了进一步减少检测网络的运行时间,Faster-RCNN 被学者提了出来。这是一种通过区域建议网络 (region proposal network, RPN) 来生成建议区域 (region proposals) 的识别方法。RPN 的出现替代了之前选择性搜索^[14]和边缘盒 (edge boxes)^[15]等方法,它和检测网络共享全图的卷积特征,使得区域建议检测花费更少的时间。Faster-RCNN 神经网络的结构如图 1 所示。

Faster R-CNN 通过设计提取候选区域的网络 RPN,代替了效率较低的选择性搜索,使得整个模型的检测速度大幅提高,但只能判断目标的大致区域位置,不能精装的识别电力部件的具体位置,且在电力部件在被遮挡情况下识别率较低,不能满足电力部件识别的现场需求。

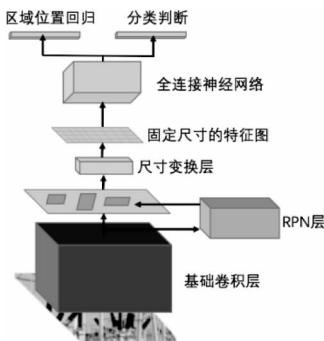


图 1 Faster-RCNN 模型结构图

Fig. 1 Structure diagram of Faster-RCNN model

1.2 基于 R-FCN 方法的电力部件识别定位

基于区域的全卷积网络^[16]的目标检测分为两个步骤,先定位目标,再进行目标具体类别的分类。R-FCN 模型目标检测框图如图 2 所示,首先利用基础卷积网络生成特征映射图,并利用区域建议网络(region proposal networks, RPN)^[17]对生成的特征映射图进行全图的前后景目标搜索和筛选,以确定目标框;在此基础上,利用分类网络对目标框进行分类识别。

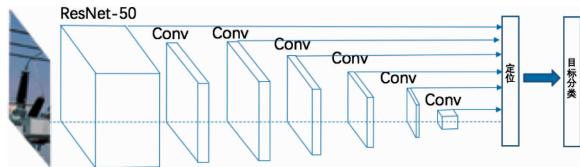


图 2 R-FCN 模型结构图

Fig. 2 Structure diagram of R-FCN model

R-FCN 通过位置敏感评分图把目标的位置信息融合进尺寸变换层,解决了 Faster-RCNN 网络 ROI pooling 层不具备平移不变性的问题,提高了目标检测和分类准确度,并提高了模型的运行效率。但 R-FCN 模型仍不能检测出目标的具体位置,并且对干扰物较多的电力部件场景不具备较好的鲁棒性。

2 基于 MASK LSTM-CNN 的电力部件识别

尽管 Faster-RCNN 和 R-FCN 方法提高了部件识别模型的处理速度和精度,但不能细化出电力部件的具体轮廓,带电作业机器人不能通过这类方法准确识别部件方位。并且这两种方法在电力部件有遮挡物的情况下,识别率不理想,不能满足复杂的现场工业环境。本文结合 Mask-RCNN 构建一种高效的 MASK LSTM-CNN 模型,可以有效降低遮挡物对识目标的影响。

2.1 电力部件识别的神经网络模型

本文提出 MASK LSTM-CNN 模型主要由四部分构成:预训练 CNN 模型、RPN 网络、RoIAlign 层、检测网络层与 Mask 层,模型的具体结构如图 3 所示。该模型在 box 识别之前通过 LSTM 关联了特征区域的附近信息,用来降低遮挡物对识目标的影响,通过对区域之间依赖关系的学习,进而提高了电力部件识别的准确度。

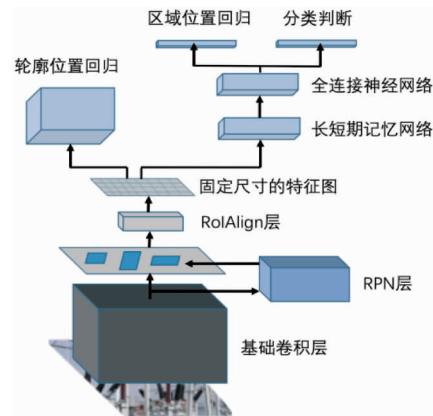


图 3 MASK LSTM-CNN 模型结构图

Fig. 3 Structure diagram of Mask LSTM-CNN model

2.1.1 预训练 CNN 模型

本文设计的模型中,CNN 模型是提出的 MASK LSTM-CNN 模型的基础,受已有方法的启发我们利用 ResNeXt 进行设计,同时结合 coco2017 图像分类任务中的训练数据进行预训练,最后通过实际采集的电力部件巡检数据构建的数据来完善,最终构建一个完整的 CNN 模型。该 CNN 模型作为本文提出方法的基础,它提供了后续 RPN 网络和检测网络都需要的特征图^[18]。特征图是 CNN 模型中的最后一个卷积层,该层包含多个通道。特征图为输入图像的深层卷积特征,同类物体的深层特征十分接近;而不同类物体的深层特征差异很大,即在特征图上物体具有很好的可分性。

2.1.2 RPN 层

电力部件图像经过前面的 CNN 网络生成了一个多通道的特征图,RPN 网络通过在这些特征图上应用滑动窗口,使用 anchor 机制对特征图进行目标区域判定和分类,最后使用反向传播算法对区域提议网络进行调优。

具体的形式是在输出层利用多个卷积核进行卷积操作,获得一个三个维度的张量;将该张量作为两个独立卷积层的输入,从而将特征映射图里的信息

转换为候选区域的位置信息和其为前景的概率信息。如图 4 所示,图中红色区域即为搜索区域,图中只画出了部分搜索的目标框。

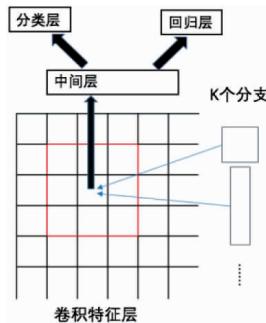


图 4 RPN 层原理图

Fig. 4 Schematic diagram of RPN layer

RPN 默认用 9 个搜索框来搜索一块区域长宽比为 1:1, 1:2, 2:1。相对于原始的输入图片, RPN 网络会得到约两万个搜索框。在实际应用时,一些超出图片边界的搜索框会被剔除;同时,对于同一目标重叠覆盖的搜索框,采用非极大值抑制 (non-maximum suppression, NMS)^[19] 方法来处理,以达到去除重叠搜索框的目的。上述策略可显著提高候选目标框的搜索效率。

RPN 在基础卷积网络的输出层上完成候选区域的搜索,为后续的目标检测网络提供了候选区,提高了整个模型的效率。

$$\frac{\partial L}{\partial x_i} = \sum_r \sum_j [d(i, i * (r, j)) < 1] (1 - k) (1 - w) \frac{\partial l}{\partial y_{rj}}$$

上式中, d 表示两点之间的距离, Δh 和 Δw 表示 x_i 与 $x_i * (r, j)$ 横纵坐标的差值, 这里作为双线性内插的系数乘以原始的梯度。

RoIAlign 层解决特征图与原始图像上的特征图不对准问题,通过更严格的定位度量指标获得更好的度量结果,相对提高了后期掩码的精度。

2.1.4 检测网络层与 Mask 层

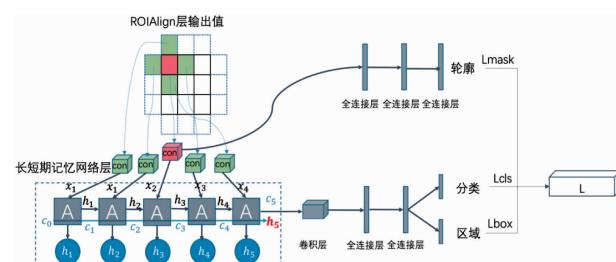


图 6 分类网络和区域位置网络结构图

Fig. 6 Structure diagram of classification network and regional location network

2.1.3 RoIAlign 层

RoIAlign 优化了像素偏差的问题, 使用双线性内插法获得坐标为浮点数的像素点上的图像数值,从而将整个特征聚集过程转化为一个连续的操作。首先遍历每一个候选区域,保持浮点数边界不做量化,将候选区域分割成 $k * k$ 个单元, 每个单元的边界也不做量化, 在每个单元中, 计算固定的四个坐标位置, 用双线性内插法计算出这四个位置的值, 然后进行最大池化操作, 具体过程如图 5 所示。

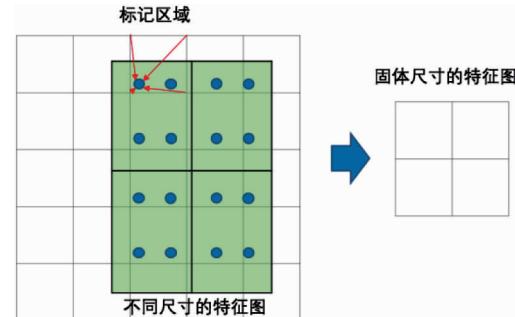


图 5 双线性插值法示意图

Fig. 5 Schematic diagram of bilinear interpolation

在 RoIAlign 层的反向传播中, $xi * (r, j)$ 是一个浮点数的坐标位置(前向传播时计算出来的采样点), 在池化前的特征图中, 每一个与 $xi * (r, j)$ 横纵坐标均小于 1 的点都应该接受与此对应的点 y_{rj} 回传的梯度, RoIAlign 层的反向传播公式如下。

$$\frac{\partial L}{\partial y_{rj}} = \begin{cases} 1 & \text{if } xi * (r, j) < 1 \\ 0 & \text{otherwise} \end{cases} (1 - k) (1 - w) \frac{\partial l}{\partial y_{rj}} \quad (1)$$

根据步骤 2.1.3 生成的区域提议结果是作为检测网络与 Mask 层的输入, 其中检测网络由分类网络和区域位置网络构成, 具体结构如图 6 所示。

2.1.5 检测网络层

检测网络利用卷积网络预对每个特征区域以及该区域上下左右的区域进行卷积提取高维特征向量作为长短期记忆网络层的输入^[20], 记忆单元与各种门的连接状态如图 6 蓝色区域所示。图中 x_t 表示不同区域的输入, h_t 分别表示 t 区域的输出结果, 其中 sigmoid 函数对输入信息进行变换, 逐点相乘, 忘记门 (forget gate) 用于控制从存储状态丢弃或继续保存前一区域的信息 h_t ; 输入门则用于确定需要更新的信息; 整个单元通过忘记门和输入门更新存储状态 c_t ; 输出门 (output gate) 则用于确定存储状态 c_t 中哪些信息用于输出。通过 5 个输入 x_t 和每个隐藏输出 h_t , 最后得出总的输出 h_5 。其中隐藏层 A 的具体结构如

图 7 所示。当序列的第 t 块区域输入到网络中时, LSTM 隐藏层的输入包括网络的当前输入 x_t , 上一时刻的隐藏层输出向量 h_{t-1} , 以及隐藏层状态 c_{t-1} 。隐藏层的任务是计算并输出向量 h_t , 并更新状态得到 c_t , 为此隐藏层加入了遗忘门 f_t 、输入门 i_t 以及输出门 o_t 。遗忘门 f_t 决定状态 c_t 中的哪些信息被丢弃, 输入门 i_t 决定由 x_t 和 h_{t-1} 得到的更新信息中有哪些能够用于状态 c_t 的更新, 经过遗忘门和输出门, 状态 c_t 的更新完成。长短期记忆网络层中加入隐藏层状态的目的是使其对隐藏层的输出 h_t 产生影响, 因此输出门 o_t 用于决定状态 c_t 中的如何作用到 h_t 的计算中。

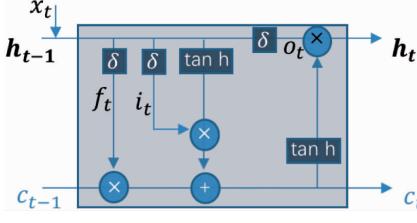


图 7 隐藏层结构示意图

Fig. 7 Structure schematic diagram of hidden layer

上图 7 中, δ 表示 sigmod 激活函数, 3 个新加门以及隐藏层输出 h_t 和状态更新 c_t 的计算表达式如下:

$$f_t = \delta(W_f[x_t, h_{t-1}] + b_f) \quad (2)$$

$$i_t = \delta(W_i[x_t, h_{t-1}] + b_i) \quad (3)$$

$$o_t = \delta(W_o[x_t, h_{t-1}] + b_o) \quad (4)$$

$$c_t = \tanh(W_c[x_t, h_{t-1}] + b_c) + f_t c_{t-1} \quad (5)$$

$$h_t = o_t \tanh(c_t) \quad (6)$$

最后输出 h_5 连接两层全连接层输出 $k+1$ 维数组 p 和 $4*k$ 维数组 t , 数组 p 表示属于 k 类和背景的概率。对每个目标区域输出离散型概率分布:

$$p = (p_0, p_1, \dots, p_k) \quad (7)$$

p 由 $k+1$ 类的全连接层利用 softmax 计算出。数组 t 表示分别属于 k 类时, 应该平移缩放的参数:

$$tk = (tk_x, tk_y, tk_w, tk_h) \quad (8)$$

k 表示类别的索引, tk_x , tk_y 是相对于 object proposal 尺度不变的平移, tk_w , tk_h 是对空间中相对于对象区域的高与宽。分类层的损失函数 L_{cls} 是由真实分类 u 对应的概率决定:

$$L_{cls}(p, u) = -\log p_u \quad (9)$$

区域判别层的检测框定位损失函数 L_{box} 是通过比较真实分类对应的预测平移缩放参数 tu 和真实平移缩放参数 v 的差得来的。其中 v :

$$v = (v_x, v_y, v_w, v_h) \quad (10)$$

$$L_{box}(tu, v) = \sum_{i=1}^4 smooth_{L_1}(tu_i - v_i) \quad (11)$$

其中, $smooth_{L_1}$ 损失函数:

$$smooth_{L_1}(X) = \begin{cases} 0.5x^2 & \text{if } |x| < 1 \\ |x| - 0.5 & \text{otherwise} \end{cases} \quad (12)$$

由最后一层全卷积层可预测:① 候选区域框属于每个类别的概率, 即得分;② 目标对象外围框的更合适的位置, 用它相对于候选区域框的 2 个平移和 2 个放缩共 4 个参数表示。

轮廓识别层对于每个特征区域有 $K * m^2$ 个维度的输出。 K 个(类别数)分辨率 $m * m$ 的二值 mask。本文对每个区域的像素点进行了判断, 并且定义 Lmask 为平均二值交叉熵损失。对于一个属于第 k 个类别的 ROI, Lmask 仅仅考虑第 k 个 Mask(其他的掩模输入不会贡献到损失函数中)。这样的定义会允许对每个类别都会生成掩模, 并且不会有类间竞争。通过逐像素的 Sigmoid 计算得到 Mask 层的损失函数:

$$Lmask(Cl_{-k}) = \text{Sigmoid}(Cl_{-k}) \quad (13)$$

总的损失函数: 损失函数为分类误差 + 检测误差 + 分割误差。

$$L = L_{cls} + L_{box} + L_{mask} \quad (14)$$

最后通过预先标记的信息利用反向传播算法对该网络进行微调。

3 结果与分析

带电作业机器人拍摄影像具有分辨率较高、包含目标大小缩放较快的特点, 拍摄影像的角度具有多样性和一定随机性。本文识别 3 类型电力部件—电力变压器、隔离开关和断路器。

3.1 训练集和测试集构建

本次试验, 对于电力变压器、隔离开关和断路器的每一类部件, 均使用 1 200 张训练样本, 共 3 600 张样本构成训练集; 每类 400 张测试影像, 共 1 200 张影像构成测试集。对训练集中每张图片里电力部件标记其外围框; 而对测试集, 要标出每张图片里出现的所有电力部件。

测试时, 当识别出的外围框与标记的外围框重叠面积达到标记外围框的 80% 以上时, 视为一次成功识别。本次试验中, 用正确率、召回率和有效面积占有率来评判识别的准确性, 其中正确率 AP(average precision):

$$AP = n_{cp} / n_{ca} \quad (15)$$

n_{cp} 为目标类别标记正确的外围框个数, n_{ca} 为所有标记出的外围框个数; 召回率为 Recall

$$Recall = n_{bp} / n_{ba} \quad (16)$$

n_{bp} 是目标类别标记正确的外围框个数, n_{ba} 是所有标准的外围框个数。有效面积占有率 EAO (effective area occupancy) :

$$EAO = (m_p \&& m_a) / m_p \quad (17)$$

其中 m_p 是模型预测出的面积, m_a 是目标区域的实际面积。

由于本次试验识别的类别仅有 3 种类型, 因此分别对每一类电力部件识别的平均精确度 mAP (mean average precision)、平均召回率 mRecall (mean recall) 和平均有效面积占有率 mEAO (mean effective area occupancy) 做统计。

3.2 实验结果

本文使用同样的基础卷积网络以及性能参数对比了 Mask R-CNN 与 MASK LSTM-CNN 两种模型的性能。

在 1200 的普通样本中测试了两种模型的正确率和召回率, 如图 8 所示, MASK LSTM-CNN 在断路器、隔离开关和变压器的分类准确率上都略高于 Mask R-CNN, 为了进一步测试 MASK LSTM-CNN 的改进优势, 本文准备了 600 个电力部件带遮挡物的特殊样本进一部测试, 如图 9 所示, MASK LSTM-CNN 在特殊样本上相对 Mask R-CNN 有了较为明显的优势。在遮挡物较多的情况下, 两种模型的目标识别结果如图 10 所示, 蓝色标记为样本的实际分割结

果, 红色标记为 Mask R-CNN 模型的分割结果, 绿色标记为 MASK LSTM-CNN 模型的分割结果, 从图中可以看出 MASK LSTM-CNN 分割的精确度要优于 Mask R-CNN, Mask R-CNN 把更多的干扰背景识别为目标的一部分。本文提出的方法在全连接判断层之前融合了长短期记忆网络。这个方法通过中间状态保存上下区域的图片信息, 并把这个状态作为输入影响下一区域的判断, 增强了模型对区域信息判断的依据, 有效地解决了模型训练过程中模型因梯度消失导致对干扰因素识别能力下降的问题。

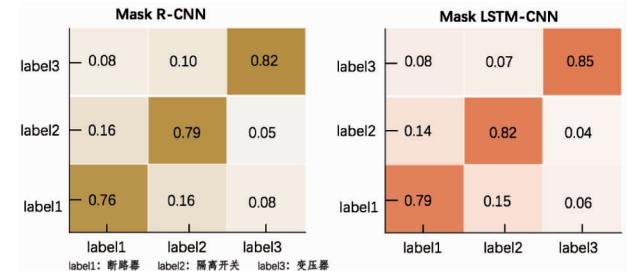


图 8 普通样本下三种分类结果对比

Fig. 8 Three classification results based on normal samples

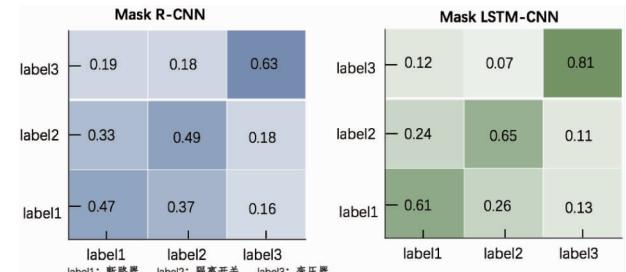


图 9 特殊样本下三种分类结果对比

Fig. 9 Comparison of three classification results under special samples



图 10 Mask R-CNN 模型与 MASK LSTM-CNN 模型识别效果对比

(蓝色代表样本实际值, 红色代表 Mask R-CNN, 绿色代表 MASK LSTM-CNN)

Fig. 10 Comparison of recognition effect between Mask R-CNN model and MASK LSTM-CNN model (blue represents the actual value of samples, red represents Mask R-CNN, green represents MASK LSTM-CNN)

基于正常样本和特殊样本, 本文做了进一步实验统计, 计算出了在不同样本下, 两种模型的平均精确度 (mAP)、平均召回率 ($mRecall$)、平均有效面积占有率 ($mEAO$), 实验统计结果如表 1 所示, MASK LSTM-CNN 模型在普通样本上的识别效果相对优

Mask R-CNN 模型, 在带遮挡物的特殊样本上, 模型的识别准确度有明显提升, MASK LSTM-CNN 模型的 mAP 超过 Mask R-CNN 16%, $mRecall$ 超过 11%, $mEAO$ 超过 Mask R-CNN 15%。

表 1 两种模型识别效果的平均精确度、平均召回率、均有效面积占有率对比

Tab. 1 Comparison of recognition effects between the two models such as mAP, mRecall and mEOA

MODEL	<i>mAP</i>	<i>mRecall</i>	<i>mEOA</i>
Mask R-CNN(正常)	0.793	0.82	0.83
MASK LSTM-CNN(特殊)	0.833	0.85	0.91
Mask R-CNN(正常)	0.532	0.67	0.64
MASK LSTM-CNN(特殊)	0.694	0.78	0.79

电力现场一般错中复杂,电力部件目标前具有较多的遮挡物,MASK LSTM-CNN 在这种任务上较为有效,这得益于 MASK LSTM-CNN 在目标识别之前凭借长短期记忆网络关联了特征区域的关联信息,通过附近区域的图片信息辅助判断障碍物的存在性,加强了神经网络的判断依据,进一步提高了分类的准确性,而 Mask 层的判断是依赖分类的结果,分类的结果决定以何种类别对目标生成掩模,所以分类层准确度的提高直接关系了轮廓掩模,所以分类层准确度的提高直接关系了轮廓

识别层的精确度。

本文接着使用 VGG、ResNet、ResNeXt 等不同的基础卷积框架作为、RCNN 的基础网络,对比了不同基础卷积框架对拥有相同性能参数的 Faster-RCNN、RFCN、MASK LSTM-CNN 三种模型精度的影响,并通过分类结果和区域选择的平均准确率均值(*mAP*)具体表现出来。

从表 2 可以看出 Mask-RCNN 与 RFCN 的召回率几乎相等,都优于 Faster-RCNN。

表 2 三种模型的召回率对比

Tab. 2 Comparison of the recall rate of three models

	Faster-RCNN	R-FCN	MASK LSTM-CNN
<i>mRecal</i>	0.74	0.84	0.85

本文进一步对比了三种算法基于相同基础卷积网络处理每张图片所需要的时间,从表 3 中可以看出,R-

FCN 模型处理速度最快,MASK LSTM-CNN 要明显慢于其他两种算法,但也在可接受的范围之内。

表 3 三种模型识别图片所需的时间

Tab. 3 Time required for identify pictures of three models

	Faster-RCNN	R-FCN	MASK LSTM-CNN
处理每张图片所需的时间	300 ms	180 ms	800 ms

MASK LSTM-CNN 在 *mAP* 与召回率都优于 Faster-RCNN 与 R-FCN,处理每张图片的时间要比其他两种模型慢,但 MASK LSTM-CNN 能细化出部件的详细轮廓,更有利于带电作业机器人判定部件各个轮廓的位置以及配件的详情,对目标遮挡有比较好的适应。这些优势得益于 Mask-RCNN 模型中 ROIAlign 层对提取的特征和输入之间进行校准,以及使用矩阵对每一个特征区域进行预测而不是使用向量去进行预测,降低了空间信息的损失。本文提出的方法使用长短期记忆网络关联了附近 ROI 的

中的特征,这种方式增强了对带有遮挡物目标识别的鲁棒性,解决了模型对遮挡物信息判断学习过程中的梯度消失问题。

从下面实验结果中,如图 11 和图 12 所示,可以看出三种模型的识别效果。红色标注代表 MASK LSTM-CNN,黄色标注代表 R-FCN,蓝色标注代表 Faster-RCNN,其中 Faster-RCNN 标注框目标类别标记正确的外围框个数少于实际外围框个数,MASK LSTM-CNN 与 R-FCN 相对较为准确,并且 MASK LSTM-CNN 能够细化出了部件的具体轮廓。



图 11 不同模型下断路器识别效果对比(蓝色代表 Faster-RCNN,黄色代表 R-FCN,红色代表 MASK LSTM-CNN)

Fig. 11 Comparison of circuit breaker recognition effect under different models(blue represents Faster-RCNN, yellow represents R-FCN, red represents MASK LSTM-CNN)



图 12 不同模型下变压器识别效果对比(蓝色代表 Faster-RCNN,黄色代表 R-FCN,红色代表 MASK LSTM-CNN)

Fig. 12 Comparison of transformer identification results under different models(blue represents Faster-RCNN, yellow represents R-FCN, and red represents MASK LSTM-CNN)

4 结语

本文在总结分析当前较为先进的图像识别方法的基础上,验证了利用 MASK LSTM-CNN 算法对电力小部件识别的准确性和效率。实验表明,利用 MASK LSTM-CNN 模型可以实时地对电力部件进行目标检测和定位,为电力检测中的部件定位、检修奠定良好的基础^[21~23]。

此外,根据深度学习的特点,构建更大的样本库可能进一步提高准确率。下一步的工作是构建更精细的识别类别,包括有各种电力部件的故障图像类型,这样不但可以实现目标部件的分类,还可实现部件的故障诊断。

参考文献:

- [1] 张浩,王玮,徐丽杰,等. 图像识别技术在电力设备监测中的应用[J]. 电力系统保护与控制,2010,38(06):88~91.
ZHANG Hao, WANG Wei, XU Lijie, et al. Application of image recognition technology in electrical equipment on-line monitoring [J]. power system protection and control,2010,38(6):88~91.
- [2] 李天友,赵会茹,欧大昌,等. 短时停电及其经济损失的估算[J]. 电力系统自动化,2012,36(20):59~62.
LI Tianyou, ZHAO Huiru, OU Dachang, et al. Short interruption and its cost appraisal[J]. Automation of Electric Power Systems, 2012,36(20):59~62.
- [3] 陈昕然. 基于机器视觉的电力仪表自动检定系统研究[D]. 哈尔滨工业大学,2015.
- [4] 张吉生,张波,于烨. 基于大数据架构的变电设备运行质量智能评价[J]. 电力大数据,2017,20(09):37~41.
ZHANG Jisheng, ZHANG Bo, YU Ye. Intelligent evaluation of substation equipment operation quality based on big data structure [J]. Power Systems and Big Data,2017,20(09):37~41.
- [5] APOSTOLOS P.PSYLLOS,CHRISTOS NIKOLAOS E ANAGNOSTOPOULOS, ELEFTHERIOS KAYAFAS, et al. Vehicle logo recognition using a SIFT-Based enhanced matching scheme[J]. IEEE Transactions on Intelligent Transportation Systems,2010,11(02):322~328.
- [6] 余金栋,张宪民. 用于线纹显微图像的边缘检测算法[J]. 光学精密工程,2015,23(1):271~281.
- [7] YU Jindong, ZHANG Xianmin. Edge detection algorithm for lines on microscopic image[J]. Optics & Precision Engineering,2015, 23(01):271~281.
- [8] PEIYIN CHEN, CHIENCHUAN HUANG, CHIHUAN LIEN, et al. An efficient hardware implementation of HOG feature extraction for human detection [J]. IEEE Transactions on Intelligent Transportation Systems,2014,15(02):656~662.
- [9] 谢邦旺,王加俊. 一种基于轮廓的图像检索算法[J]. 中国图象图形学报,2008,13(07):1367~1373.
XIE Bangwang, WANG Jiajun. A contour-based image retrieval algorithm[J]. Journal of Image and Graphics,2008,13(07):1367~1373.
- [10] 魏巍,申铉京,千庆姬. 工业检测图像灰度波动变换自适应阈值分割算法[J]. 自动化学报,2011,37(8):944~953.
WEI Wei, SHEN Yunjing, QIAN Qingji. An adaptive thresholding algorithm based on grayscale wave transformation for industrial inspection images[J]. Acta Automatica Sinica,2011,37(08):944~953.
- [11] 王林,张鹤鹤. Faster R-CNN 模型在车辆检测中的应用[J]. 计算机应用,2018,38(3):666~670.
WANG Lin, ZHANG Hehe. Application of Wang Lin, Zhang Hehe. Application of Faster R-CNN model in vehicle detection [J]. Journal of computer applications,2018,38(03):666~670.
- [12] 徐逸之,姚晓婧,李祥,等. 基于全卷积网络的高分辨率遥感影像目标检测[J]. 测绘通报,2018(01):77~82.
XU Yizhi, YAO Xiaowei, LI Xiang, et al. Object detection in high resolution remote sensing images based on fully convolution networks[J]. Bulletin of Surveying and Mapping,2018(01):77~82.
- [13] XI YANG, XINBO GAO, BIN SONG, et al. ASI aurora search: an attempt of intelligent image processing for circular fisheye lens [J]. Optics Express,2018,26(07):7985~8000.
- [14] 曹诗雨,刘跃虎,李辛昭. 基于 Fast R-CNN 的车辆目标检测 [J]. 中国图象图形学报,2017,22(05):671~677.
CAO Shiyu, LIU Yuehu, LI Xinzao. Vehicle detection method based on fast R-CNN[J]. Journal of Image and Graphics,2017, 22(05):671~677.
- [15] 吴素雯,战荫伟. 基于选择性搜索和卷积神经网络的人脸检测[J]. 计算机应用研究,2017,34(09):2854~2857+2876.
WU Suwen, ZHAN Yinwei. Face detection based on selective search and Gabor optimizing convolutional neural network [J].

- Application Research of Computers, 2017, 34(09): 2854 – 2857.
- [15] 申瑞杰, 张军朝, 郝敬滨. 基于边缘盒与低秩背景的图像显著区域检测算法 [J]. 计算机科学, 2017, 44(12): 298 – 303.
SHEN Ruijie, ZHANG Junchao, HAO Jingbin. Research on image salient regions detection combing edge boxes and low-rank background [J]. Computer Science, 2017, 44(12): 298 – 303.
- [16] 罗斌, 邹伟, 汤进, 等. 复杂环境下基于角点回归的全卷积神经网络的车牌定位 [J]. 数据采集与处理, 2016, 31(01): 65 – 72.
LUO Bin, GAO Wei, TANG Jin, et al. Learning corner regression-based fully convolutional network for license plate localization in complex scene [J]. Journal of Data Acquisition & Processing, 2016, 31(01): 65 – 72.
- [17] 彭刚, 杨诗琪, 黄心汉, 等. 改进的基于区域卷积神经网络的微操作系统目标检测方法 [J]. 模式识别与人工智能, 2018, 31(02): 142 – 149.
PENG Gang, YANG Shiqi, HUANG Xinhuan, et al. Improved object detection method of micro-operating system based on region convolutional neural network [J]. Pattern Recognition and Artificial Intelligence, 2018, 31(02): 142 – 149.
- [18] JEAN KOH, MINSOO SUK, SUCHENDRA, M. BHANDARKAR. A multilayer self-organizing feature map for range image segmentation [J]. Neural Networks, 1995, 8(01): 67 – 86.
- [19] 汤鹏杰, 谭云兰, 李金忠. 融合图像场景及物体先验知识的图像描述生成模型 [J]. 中国图象图形学报, 2017, 22(09): 1251 – 1260.
TANG PENGJIE, TAN YUNLAN, LI JINZHONG. Image description based on the fusion of scene and object category prior knowledge [J]. Journal of Image and Graphics, 2017, 22(09): 1251 – 1260.
- [20] 毛勇华, 桂小林, 李前, 等. 深度学习应用技术研究 [J]. 计算机应用研究, 2016, 33(11): 3201 – 3205.
MAO Yonghua, GUI Xiaolin, LI Qian, et al. Study on application technology of deep learning [J]. Application Research of Computers, 2016, 33(11): 3201 – 3205.
- [21] 邹成伍, 吴剑芳, 吕凡凡, 等. 基于图像识别的数字多用表自动化检定系统关键技术及实现 [J]. 浙江电力, 2017, 36(04): 14 – 17.
ZOU Chengwu, WU Jianfang, LYU Jifan, et al. Key techniques and implementation of automatic calibration system for digital multimeter based on image recognition [J]. Zhejiang Electric Power, 2017, 36(04): 14 – 17.
- [22] 杨涛, 黄军凯. 基于深度学习的变压器故障诊断方法研究 [J]. 电力大数据, 2018, 20(06): 23 – 30.
YANG Tao, HUANG Junkai, et al. Diagnosis method of power transformer fault based on deep learning [J]. Power systems and big data, 2018, 20(06): 23 – 30.
- [23] 杨伟旗, 关鑫, 汪洋, 等. 基于动态边缘的 OCR 算法在航检影像切分中的应用 [J]. 内蒙古电力技术, 2017, 35(06): 16 – 20.
YANG Weiqi, GUAN Xin, WANG Yang, et al. Application of OCR algorithm based on dynamic edge in the aeronaautical detecting videos [J]. Inner Mongolia Electric Power, 2017, 35(06): 16 – 20.

收稿日期: 2018-07-22

作者简介:



欧家祥(1979),男,硕士,高级工程师。主要从事电能计量和配网节能方面的工作。

(本文责任编辑:范斌)

Recognition of efficient electrical components based on deep learning

OU Jiaxiang¹, SHI Wenbin², ZHANG Junwei¹, DING Chao¹

(1. Electric Power Research Institute of Guizhou Power Grid Co., Ltd., Guiyang 550002 Guizhou, China;

2. Shanghai University of Electric power, Shanghai 200090, China)

Abstract: The traditional image recognition method cannot effectively detect the specific position of the power component, and the recognition accuracy is low in the scene with many interferences. In view of the above problems, this paper proposes a method based on MASK LSTM-CNN model for power component inspection image recognition. Combining with the existing Mask R-CNN method, the MASK LSTM-CNN model is constructed by using the long-short-term memory neural network, and the context information is constructed by the fusion of the context information. Then, the optimization algorithm is used to optimize the parameters of the model by combining the specific characteristics of the power components. The model can accurately identify the power components in the field environment with more interference information, and successfully solves the problem that the power components existing in the existing methods have low recognition rate under the occlusion condition, and greatly improves the accuracy of component recognition. Combined with the actual collected power component inspection image dataset, a large number of tests are carried out on the proposed model. The experimental results show that the proposed MASK LSTM-CNN model is better than R-FCN and faster R-CNN. The recognition accuracy rate is improved by 9% - 12%, which effectively solves the component identification problem in the power field with more interference information.

Key words: power component identification; model; recognition rate; image identification