

基于 EAST 的二次回路端子编号检测方法

王兴媛¹, 王春雨¹, 李志², 赵进全²

(1. 中国电力科学研究院有限公司, 北京 100192; 2. 西安交通大学电气工程学院, 陕西 西安 710049)

摘要:二次回路现场检验是关口电能计量装置现场检验中的重要环节,但过往检验时寻找待检二次回路端子的方法较为繁琐。为了优化寻找待检端子流程,提出一种基于 EAST 的端子编号检测方法。该方法首先建立训练数据集,训练 EAST 模型;使用已训练模型对端子排图像进行文本检测,输出端子编号区域的大小位置信息;然后,对区域坐标使用 DBSCAN 聚类,区分可能存在的多列端子,由线性回归计算每列端子倾斜角度;最后,结合倾斜角度与区域平均宽高,得到矫正后端子编号区域检测结果。实例验证表明,本方法能够准确检测图像中端子编号,提高了端子的分辨检测效率,为后续开展二次回路检验工作奠定基础。

关键词:现场检验;二次回路;场景文本检测;EAST;DBSCAN 聚类;线性回归

DOI:10.19781/j.issn.1673-9140.2022.05.024 中图分类号:TM645.2 文章编号:1673-9140(2022)05-0215-07

Detection method of terminal number of secondary circuit based on EAST

WANG Xingyuan¹, WANG Chunyu¹, LI Zhi², ZHAO Jinqun²

(1. China Electric Power Research Institute, Beijing 100192, China; 2. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: The field inspection of the secondary circuit is an important step in the field inspection of the gateway electrical energy metering device. However, the method of finding a secondary circuit terminal to be tested was rather complicated in the past. In order to optimize the process of finding terminals to be tested, this paper proposes a terminal number detection method based on EAST. In this method, the training dataset is first established, and the EAST model is trained. The trained model is used to detect the text in the terminal block image and outputs the size and position information of the terminal number region. Then, the region coordinates were clustered by DBSCAN clustering to distinguish possible multi-column terminals, and the tilt angle of each column terminal was calculated by linear regression. Finally, combined with the tilt angle and the average width and height of the region, the corrected detection results of the terminal number region are obtained. Examples show that this method can accurately detect the terminal number in the image and effectively improve the efficiency of terminal detection, which lays a foundation for the subsequent secondary circuit inspection work.

Key words: field inspection; secondary circuit; scene text detection; EAST; DBSCAN clustering; linear regression

关口电能计量装置是安装在关口用于电能核算的设备,包括电能表、互感器及其二次回路等^[1]。按相关标准,二次回路需周期性进行现场检验^[2-3]。现场检验过程中寻找特定的端子主要依赖人工比对设计图纸,流程繁琐、耗时长,且存在错检的可能。因此,优化寻找待检端子的流程,促进检验的智能化和自动化,是现场检验的研究热点和重要的发展方向。一种可行的基于计算机视觉的优化流程方法为基于图像识别技术识别端子编号,通过识别结果查询数据库,依据查询结果标注待检端子。文献[4]提出了一种端子排标签智能识别方法,该方法首先对图像进行文本检测,然后进行光学字符识别,其使用语言模型纠正错误的文本识别结果,但对于文本检测部分缺少措施保证准确率;文献[5]提出了一种基于联合训练模型的端子排接线标签文本识别方法,该方法包括字符定位网络和识别网络。定位网络的训练过程使用残差卷积神经网络,通过识别网络的梯度误差反向传播实现权重更新。该方法采用的端到端训练方式有利于提升系统整体性能,但存在贡献度分配问题,难以评价每个模块的性能,从而优化存在瓶颈的模块。

相对于场景文本检测,数字文本识别方法较为成熟,国内外如百度、有道、谷歌等公司都提供相关开放 api。但这些开放 api 主要应用于扫描文档识别,识别现实场景中的文本时需要先确定文本所在区域,否则识别效果较差。因此,为了利用成熟技术,本文提出了一种基于 EAST 的互感器二次回路端子编号检测方法。该方法首先搭建 EAST 模型并进行训练,使用模型检测端子排图像得到端子编号区域的坐标;然后对模型检测结果进行矫正,采用局部离群因子(local outlier factor, LOF)算法,对编号区域坐标进行离群点检测,筛选出异常的检测结果;其次使用基于空间密度的聚类算法(density-based spatial clustering of application with noise, DBSCAN),对筛选后的编号区域坐标进行聚类,区分出可能存在的多列端子,分别对每列端子的坐标进行线性回归,求得图像中端子排的倾斜角度;最后结合倾斜角度与编号区域的平均宽高,输出矫正后的端子编号区域检测结果。通过对多张不同尺寸与种类的端子排图像检测并矫正,在端子大小接

近且排布具有规律的前提下,本文方法能够准确检测端子编号区域,提高了端子的分辨检测效率。

1 场景文本检测的 EAST 方法

基于计算机视觉的优化流程如图 1 所示,其中的识别端子排图像包括场景文本检测与文本识别 2 个环节。

场景文本检测可以分为传统检测方法和基于深度学习的检测方法。传统检测方法主要有基于连通域分析和基于滑动检测窗等方法。深度学习方法通过训练多层的神经网络,能以任意精度逼近任意的连续函数,主要有基于区域建议和基于图像分割等方法^[6]。EAST(An Efficient and Accurate Scene Text Detector)方法属于基于图像分割的方法。该方法工作流程只包含 2 步:首先利用一个全卷积神经网络输出图像各点的得分图与位置大小信息;然后对置信度满足阈值条件的点进行局部感知非最大抑制(Locality-Aware NMS)得到文本区域检测结果^[7]。EAST 方法无须人工设计特征,减少了复杂的候选聚合、单词分割等步骤,具有检测效率高(Efficient)和准确度高(Accurate)的优点。

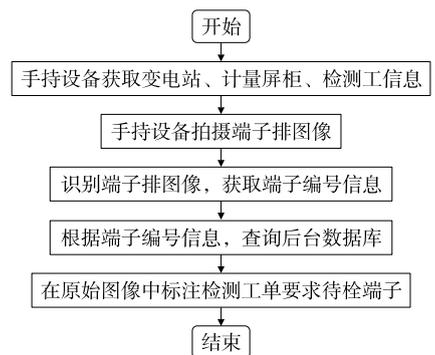


图 1 优化的寻找端子流程

Figure 1 Optimized process of finding terminals

EAST 网络结构如图 2 所示,主要由特征提取、特征合并与模型输出三部分组成。

特征提取部分采用一个在 ImageNet 数据集上训练的卷积网络,从该卷积网络中提取出多尺度的特征图,满足不同大小文本区域的检测需要;特征合并环节中,小尺度特征图采样与大尺度拼接。其中 1×1 卷积核减少通道数及计算量, 3×3 卷积核融合特征图信息;模型输出分为 1 通道的得分图信

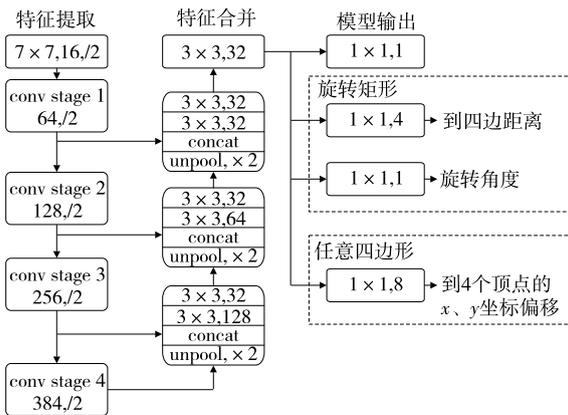


图 2 EAST 网络结构

Figure 2 Network architecture of EAST

息和 n 通道的几何图形位置形状信息。

EAST 方法的损失函数为

$$L = L_s + \lambda_g L_g \quad (1)$$

式中 L_s 为得分图损失函数; L_g 为几何图形的损失函数; λ_g 为反映 L_g 损失函数重要程度的常数。

对得分图大于阈值的几何图形输出结果进行 Locality-Aware NMS 计算。相较于标准 NMS 方法,在最好情况下,Locality-Aware NMS 能将复杂度从 $O(n^2)$ 降为 $O(n)$ 。其假定邻近像素输出的几何图形高度相关,先逐行以得分图为权重,合并像素的几何图形输出结果;对合并后结果进行标准 NMS 操作,舍弃得分较低的检测区域,输出检测结果。

2 EAST 网络模型训练

2.1 训练数据集建立

有监督深度学习的方法需要标注数据的真值标签,建立用于训练的数据集。如图 3 所示,每张端子排图像一般包含多达几十个端子,单个端子尺寸较小,标注时需要给出每个端子编号区域的位置大小信息,标注工作较为繁重。为了节约标注工作所需时间,训练时采用两部分数据集。

第 1 部分为公开的数据集。包括 ICPR 2018 网络图像数据集的数字部分、COCO-TEXT V2.0 数据集的数字部分以及来自于 Google 街景门牌号的 SVDH 数据集,共约 9 000 张。其中 SVDH 数据集的标注格式为标注数字的每一位,需要将其转化为标注整体数字的形式,如图 4 所示。

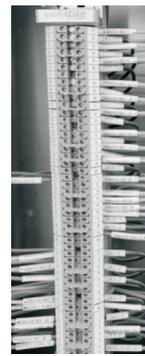
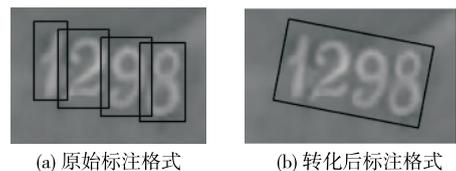


图 3 端子排

Figure 3 Terminal block



(a) 原始标注格式

(b) 转化后标注格式

图 4 SVDH 数据集标注转化前、后对比

Figure 4 Comparison of SVDH dataset annotation before and after transformation

第 2 部分为手工标注数据。首先使用 roLabelImage 软件标注一张端子排图像;然后在该图像任意位置以随机的高度和宽度生成一个矩形裁切区域,根据标注信息检查该区域内是否包括端子编号。若包括则按该区域裁切原始图像的一个拷贝,并根据裁切区域的位置及大小更新标注信息。反复执行该过程扩充训练数据。本文选择 9 张原始标注图像,对较清晰的 2 张图像进行 3 000 次随机裁切,对较模糊的 7 张图像进行 1 000 次随机裁切,共产生 3 018 张符合要求的图像。

2.2 训练流程

先采用第 1 部分数据集训练, $batch_size=8$, 训练集与验证集比例为 9 : 1, 初始学习率为 10^{-4} , 梯度优化算法为 Adam。Adam 优化算法在传统的梯度下降法中加入一、二阶动量,并考虑历史训练轮次的影响,是一种自适应学习率方法^[8]。当验证集上的损失 val_loss 在一定训练次数内没有改进时停止训练,最终得到模型的 $val_loss=0.376$ 。

将该模型作为预训练模型,使用第 2 部分数据集加载并调优。由于是在已收敛模型上继续训练,因此将 $batch_size$ 减小为 2,期望跳出可能的局部

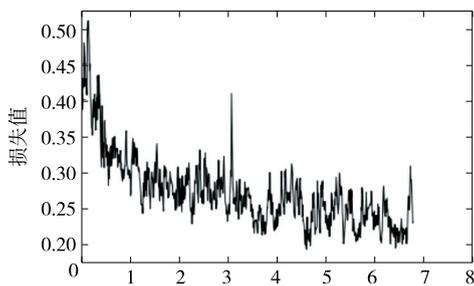
最优点,每个 epoch 迭代 1 358 次。此外,令学习率随训练进行而指数增加,寻找 val_loss 转折点作为最优初始学习率^[9],结果如表 1 所示。相对于较大的学习率,较小的学习率对参数更新作用也较小。因此,可以认为表 1 中 5 个 epoch 的初始训练条件接近。而当学习率等于 10^{-4} 时, val_loss 最小,说明该学习率下能够有较好的收敛速度,同时损失函数值不至于过大。最终确定初始学习率为 10^{-4} ,其余参数保持不变。

训练过程中设置减小学习率的回调函数,将 val_loss 作为监测对象,一定训练阶段内 val_loss 未减小时就减小学习率,即使对于 Adam 自适应学习率该措施也能取得一定效果^[10],训练结果如图 5 所示。

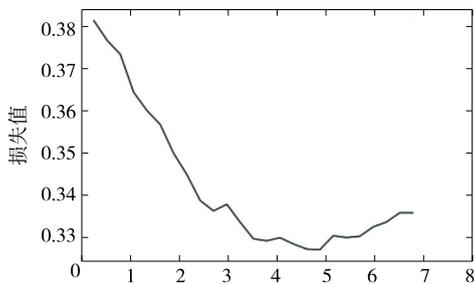
表 1 学习率及对应 val_loss

Table 1 Learning rate and corresponding val_loss

epoch 序号	学习率	val_loss
1	10^{-6}	0.700
2	10^{-5}	0.477
3	10^{-4}	0.368
4	10^{-3}	0.446
5	10^{-2}	1.032



(a) 训练集损失值变化曲线



(b) 验证集损失值变化曲线

图 5 EAST 模型训练结果

Figure 5 Training results of EAST model

其中,图 5(a)为在训练集上的损失值变化曲线,而图 5(b)为验证集上损失值变化曲线。随着训

练进行,经过约 48 000 次迭代 val_loss 取得最小值。此后 val_loss 不再下降且出现回升,这可能是由于训练的过拟合导致的。过拟合指模型在训练集上表现良好,但面对未知数据表现较差。选择 val_loss 最小时的模型作为最终模型,此时 val_loss=0.314。

3 基于 DBSCAN 聚类和线性回归的矫正方法

由于过拟合导致最终的 EAST 模型检测结果依然存在偏差。消除过拟合的有效方法之一是增加训练数据,但增加训练数据带来了标注图像的难度。若对已有检测结果进行矫正,则无须标注新的图像。为此,提出 2 个前提条件:

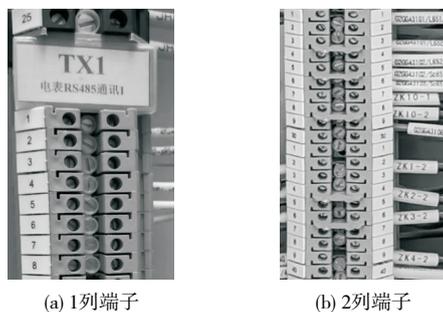
1) 一张端子排图像中每列端子基本在一条直线上,且每个端子编号区域大小相近;

2) 现有模型的检测结果整体较为准确,仅存在少数检测错误区域。

在 2 个前提条件下,选择使用聚类和线性回归方法对模型的输出结果(端子编号区域的左上、右上、左下、右下 4 点坐标)进行矫正。基于减少运算量和消除误差的考虑,聚类和线性回归中处理的数据为区域的中心坐标,即四点坐标的均值。

3.1 DBSCAN 聚类

聚类是一种无监督的数据挖掘分析技术,能够将数据中具有相似特性的对象分类。选择合适的算法是聚类的关键。根据端子排种类不同,一般单张端子排图像可能包含 1 列或 2 列端子,如图 6 所示。目前常用的 K-Means 聚类算法简单快速,但由于需要预先指定聚类数难以应用在本情景^[11]。



(a) 1列端子

(b) 2列端子

图 6 不同种类的端子排

Figure 6 Different types of terminal blocks

DBSCAN 聚类算法将聚类簇定义为密度可达的点集合,基于空间密度聚类无需给定聚类数,适合本文研究场景^[12]。为了说明该算法,考虑所有数据点的集合 D ,给定 2 个关键参数邻域半径 r 和最少点数目 P_{\min} ,补充相关概念如下。

1)密度。点 p 的密度为 $N_\epsilon(p)$ 内属于 D 的点的个数,记为 $\rho_\epsilon(p)$,其中 $N_\epsilon(p)$ 表示 p 的半径为 ϵ 的邻域。

2)核心点。若 $p \in D$ 且 $\rho_r(p) > P_{\min}$,则称 p 为核心点。

3)密度直接可达。给定 D 中 2 点 p, q ,若 p 为核心点且 $q \in N_r(p)$,则称 q 从 p 密度直接可达。

4)密度可达。给定点序列 $p_i (i = 1, 2 \dots, n)$, $p_1 = p, p_n = q$,若 p_{i+1} 从 p_i 密度直接可达,则称 q 从 p 密度可达。

5)密度相连。给定 D 中 3 点 p, q, o ,若 p 和 q 都从 o 密度可达,则称 p, q 密度相连。

DBSCAN 聚类算法从一个核心点出发,寻找全部密度相连的点形成一个聚类簇。较大的 P_{\min} 和较小的 r 要求更高的点密度以形成一个簇。结合实际情况(每个聚类簇中点的个数应为每列端子个数;两列端子分布在图像两侧,中间间隔一定距离)并考虑一定裕度,本文选 r 为 0.4 倍的 x 坐标最大与最小值之差, P_{\min} 选为 0.3 倍的数据点数。由于图像中端子数量较多,在宽度方向上不同列的端子分隔较为明显,高度方向上则差异较小。因此仅对端子编号区域的 x 坐标进行 DBSCAN 聚类。

LOF 方法通过比较一个点和其邻域点的密度来判断该点是否为异常点,能够定量给出离群得分。使用 DBSCAN 算法聚类前,先对 x 坐标使用基于 LOF 的离群点检测以排除可能存在的检测错误的区域。

3.2 线性回归与检测结果矫正

DBSCAN 聚类结果可能为一类或两类,其中每类代表 1 列端子,2 种聚类结果分别对应图 5 中 2 种端子排。分别对每类中所有区域中心的 x, y 坐标线性回归,得到回归直线的斜率;当存在 2 列端子时,它们几乎是平行的,因此将各条回归直线的斜率求平均值作为最终的斜率 k_f ,最终的倾斜角度确

定为 $\alpha_f = \arctan k_f$ 。

区域的宽高 w, h 取 2 条对边长度的平均值。基于所有端子编号区域大小相近这个前提,计算所有区域的平均宽高 $w_{\text{avg}}, h_{\text{avg}}$ 作为矫正后区域的统一宽高,区域中心坐标保持不变,结合端子的倾斜角度 α_f 得到矫正后区域。

4 端子编号区域检测及矫正实例

选取一张端子排图像,使用已训练的 EAST 模型检测端子编号区域,并对检测结果进行矫正。原始端子排图像及检测结果如图 7 所示,有 3 个检测错误的编号区域,分别在右方 2、4、10 号编号的左侧;编号区域的形状不是矩形,存在一定的扭曲。错误或扭曲的检测区域会影响图像裁切,给文本识别带来困难。

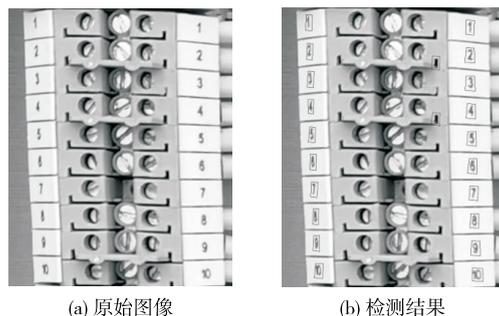


图 7 原始图像与 EAST 模型检测结果

Figure 7 Original image and EAST model detecting results

区域中心坐标及 LOF 得分如表 2 所示。坐标格式为以图像左上顶点作为坐标原点,向右为 x 轴正方向,向下为 y 轴正方向;LOF 得分绝对值接近 1,说明该点与周围点密度相近,越大于 1 说明该点可能是离群点。参照多组数据,将 LOF 得分绝对值大于平均值且绝对值大于 1.6 的点设为离群点。

检测编号区域中心坐标散点及经过 LOF 离群点检测后的散点如图 8 所示。

将 LOF 检测后的结果使用 DBSCAN 聚类,聚类后分别对每类的区域中心坐标线性回归。聚类及线性回归结果如图 9 所示。第 1 类区域中心坐标的回归直线为 $y = 25.659 5x - 1 729.387 1$,第 2 类为 $y = 31.694 5x - 15 341.903 6$ 。

表 2 区域中心坐标及 LOF 得分

Table 2 Region center coordinates and LOF scores

区域中心坐标/ (x,y)	LOF 得分	区域中心坐标/ (x,y)	LOF 得分
(71.05, 40.48)	-1.019 3	(82.08, 405.69)	-0.859 8
(488.97, 52.84)	-0.972 6	(495.71, 415.97)	-0.972 6
(73.06, 116.40)	-0.980 8	(84.60, 477.74)	-0.948 6
(488.99, 125.66)	-0.972 2	(498.76, 487.28)	-0.921 5
(400.08, 145.61)	-7.632 6	(88.63, 548.33)	-1.115 9
(75.32, 189.18)	-0.974 0	(500.82, 559.33)	-1.106 3
(489.84, 199.60)	-0.972 2	(90.74, 618.60)	-1.151 8
(76.04, 260.51)	-0.987 9	(503.35, 631.35)	-1.179 3
(491.68, 272.13)	-1.016 4	(96.714, 690.38)	-1.403 5
(400.37, 292.95)	-7.619 6	(508.48, 700.55)	-1.411 8
(79.20, 334.06)	-0.995 6	(418.25, 727.02)	-6.8621 3
(493.49, 344.06)	-1.059 8		

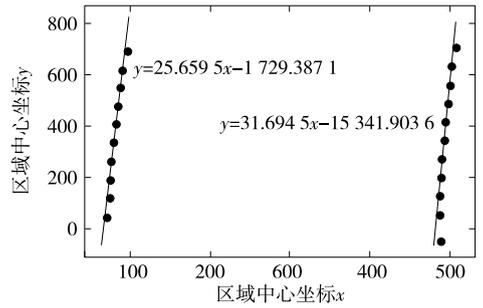


图 9 聚类及线性回归结果

Figure 9 Clustering and linear regression result



图 10 矫正后检测结果

Figure 10 Detecting result after correction

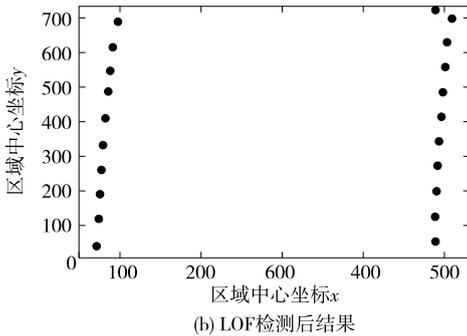
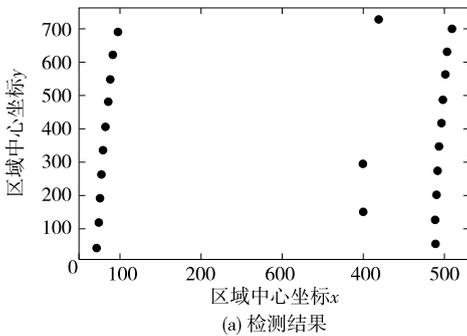


图 8 LOF 检测前后的区域中心坐标检测结果

Figure 8 Detecting results of region center coordinates before and after LOF detection

2 条直线的平均斜率 $k_f=28.677 0$, 编号区域倾斜角 $\alpha_f=88.002 8^\circ$ 。对编号区域进行矫正, 结果如图 10 所示。与图 7 相比, 去除了 3 个检测错误的区域, 所有区域形状为统一的矩形。

多张端子排图像矫正前、后的结果如图 11 所示, 图 11(b) 中去除图 11(a) 右侧接线上的错误检测区域; 图 11(d) 中去除图 11(c) 左侧和右侧接线上的错误检测区域; 图 11(f) 中去除图 11(e) 左方 3 号编

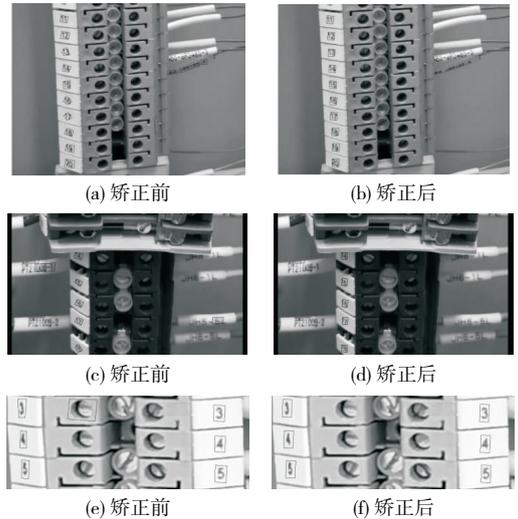


图 11 矫正前、后端子排图像检测结果

Figure 11 Detecting results of terminal block images before and after correction

号右侧的错误检测区域; 图 11(a)、11(c) 中部分不规则的检测区域矫正为矩形。由图 11 可知, 对于单列端子或多列端子以及不同尺寸的图像, 本文的矫正方法均有很好的效果。

对 35 张图片进行测试, 端子检测总耗时约 38 s, 检测数据矫正总耗时约 0.4 s, 参考过往研究, 端子检测速度还有很大优化空间。此外, 当端子平面与成像平面夹角较大时, 由于透视效应, 图片中

的端子扭曲也较为严重,这为检测带来了困难。

EAST 算法检测端子时,将图片按比例调整至固定尺寸。因此,当拍摄的端子排较长时,原始图片尺寸一般也较大。调整后图片压缩情况很严重,单个端子的尺寸很小,可能会影响识别。一种解决的方法是裁切原始图片,对每张裁切的图片调整尺寸并检测,但这也消耗更多时间。

5 结语

精准的文本检测是实现场景文本识别的基础。本文基于 EAST 方法对互感器二次回路端子编号区域检测,使用 DBSCAN 聚类 and 分类线性回归对端子数字编号的检测结果进行矫正,通过实例对比验证了矫正方法用于该情景下的实用性。结论如下:

1) 基于深度学习的 EAST 方法能够应对复杂的环境,检测出端子排图像中的端子编号区域。但训练数据不足可能会导致过拟合,从而影响模型性能,导致检测结果存在误差;

2) 采用 DBSCAN 聚类和线性回归能够较好地排除错误的检测结果,将各区域形状矫正为统一的矩形,无须增加训练数据和计算资源,可作为文本检测网络的辅助手段。

LOF 离群点检测和 DBSCAN 聚类对参数较为敏感。结合实际情况调优参数可能对矫正效果有改善,是潜在的改进方向。EAST 算法检测耗时较长,尤其是其 Locality-Aware NMS 部分。因此,检测算法的优化也是后续应当开展的工作。用户界面软件可以提供检测结果的纠错功能。单个端子检测区域较小,分辨较为困难,结合端子编号识别,通过识别结果进行人工纠错更为可行。

参考文献:

[1] 卢树峰.关口电能计量装置的现状分析与思考[J].电测与仪表,2005,42(8):21-23+8.
LU Shufeng.The analysis and thoughts of present situation for measurement devices in gateway[J].Electrical Measurement & Instrumentation,2005,42(8):21-23+8.

[2] DL/T 448—2016.电能计量装置技术管理规程[S].

[3] DL/T 1664—2016.电能计量装置现场检验规程[S].

[4] 周健,李岩,张克声.变电站二次系统设备屏柜线套标签智能识别系统[J].机械与电子,2018,36(11):67-70.
ZHOU Jian,LI Yan,ZHANG Kesheng.Intelligent iden-

tification system for equipment screen cabinet line label of substation secondary system[J].Machinery&Electronics,2018,36(11):67-70.

- [5] 王磊,黄力,张礼波,等.基于联合训练方法的变电站屏柜接线故障诊断技术[J].供用电,2020,37(5):85-90.
WANG Lei,HUANG Li,ZHANG Libo,et al.Substation panel cabinet wiring fault diagnosis technology based on joint training method[J].Distribution&Utilization,2020,37(5):85-90.
- [6] 王润民,桑农,丁丁,等.自然场景图像中的文本检测综述[J].自动化学报,2018,44(12):2113-2141.
WANG Runmin,SANG Nong,DING Ding,et al.Text detection in natural scene image:a survey[J].Acta Automatica Sinica,2018,44(12):2113-2141.
- [7] ZHOU X Y,CONG Y,WEN H,et al.EAST:an efficient and accurate scene text detector[C]//IEEE Conference on CVPR,Honolulu,United States,2017.
- [8] 谭敏戈,蒋勃,王建渊,等.基于双向长短期记忆深度学习模型的短期风功率预测方法研究[J].电网与清洁能源,2020,36(6):85-91.
TAN Minge,JIANG Bo,WANG Jianyuan,et al.Research on short-term wind power prediction method based on deep learning model with bidirectional long short-term memory[J].Power System and Clean Energy,2020,36(6):85-91.
- [9] Leslie Smith.Cyclical learning rates for training neural networks[C]//IEEE Winter Conference on Applications of Computer Vision,New York,USA,2017.
- [10] Ilya Loshchilov, Frank Hutter.Decoupled weight decay regularization[C]//ICLR 2019 Conference,New Orleans,USA,2019.
- [11] 方鑫,殷俊,蒋苏,等.基于等距 K-means 和 apriori 算法的配电网故障规律挖掘方法[J].智慧电力,2020,48(10):99-104+125.
FANG Xin,YIN Jun,JIANG Su,et al.Data mining algorithm for fault rules of distribution network based on combination of isometric K-means and apriori algorithm[J].Smart Power,2020,48(10):99-104+125.
- [12] 赵振兵,张帅,蒋炜,等.基于 DBSCAN-FPN 的输电线路螺栓缺销检测方法[J].中国电力,2021,54(3):45-54.
ZHAO Zhenbing,ZHANG Shuai,JIANG Wei,et al.Detection method for bolts with missing pins on transmission lines based on DBSCAN-FPN[J].Electric Power,2021,54(3):45-54.