

DOI:10.19651/j.cnki.emt.2210275

复杂环境基于 YOLACT 电缆识别与定位*

李瑾 范佳能 刘屹然
(南京航空航天大学自动化学院 南京 211100)

摘要: 日前,电力公司的电缆维护都是人工完成的。人工维护不仅工作量大、效率低,而且存在很大的安全问题。随着机器视觉的快速发展和机器人技术在各行各业的广泛应用,将机器人和视觉技术应用于电缆的自动维护已成为一种必然趋势。本文提出了一种基于 YOLACT 模型的双目电缆识别与定位方法,该方法首先利用改进的 YOLACT 网络对复杂环境下的密集电缆进行识别和分割,然后对电缆分割图像进行边缘优化与提取,最后利用得到的电缆边缘特征对双目图像中的相同目标进行匹配,从而实现复杂环境下对电缆的识别与定位。与传统的 YOLACT 模型相比,本文提出的电缆候选框相关度计算方法可以很好地解决识别密集电缆时出现的漏检和误检问题,提高了电缆识别的准确率。

关键词: 电缆检测;YOLACT;非极大值抑制;双目视觉

中图分类号: TP2 **文献标识码:** A **国家标准学科分类代码:** 510.1050

Cable identification and location based on YOLACT in complex environment

Li Jin Fan Jianeng Liu Yiran

(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211100, China)

Abstract: At present, the cable maintenance of power companies is completed manually. Manual maintenance not only has heavy workload and low efficiency, but also has serious secure issue. With the rapid development of machine vision and the wide application of robot technology in all walks of life, it has become an inevitable trend to apply these techniques to the automatic cable maintenance. This paper presents a method of binocular cable recognition and location based on the YOLACT model. Firstly, it uses the improved YOLACT network to recognize and segment dense cables in complex environments, then optimizes and extracts the edge of the cable segmentation image, and finally uses the obtained cable edge features to match the targets in the binocular image, so as to realize the recognition and location of cables in complex environments. Compared with the traditional YOLACT model, the correlation calculation method of cable candidate frame proposed in this paper can well solve the problems of missed detection and false detection when identifying dense cables, and improve the accuracy of cable identification.

Keywords: cable inspection;YOLACT;non maximum suppression;binocular vision

0 引 言

随着国家电网供电格局工程的推进,电缆线路维护工作量快速增加。为了避免人工维护电缆的隐患同时提高维护电路的效率,机器人代替人工作业的方式逐渐进入人们的视野^[1-3]。视觉是机器人感知周围环境的重要方式之一。通过视觉技术,机器人可以完成回环检测、物体抓取等复杂任务,而完成这些任务的基础则是探测出周围环境中存在的物体类别、形状和位置^[4]。当前,机器人实现全自动电缆

维护功能的关键难点是如何快速高效地识别电缆并进行精确定位。

国内外对电缆线的提取与之识别方面已经有了一定的研究成果。Saraband 等^[5]为了对电缆进行的识别和提取,提出了基于雷达反射波极化统计技术的电缆检测方法,该方法利用利雷达的反射波对空中的电缆线进行检测,但是检测精度较低。全卫国^[6]提出了一种基于自适应阈值确定的 Canny 检测算子边缘检测算法对电缆线进行检测,该方法结合自适应 Hough 变换与数学形态学结合方法提取电

收稿日期:2022-06-10

* 基金项目:南京航空航天大学校创新计划项目(xcxjh20210304)资助

电缆的线基元,有效提高了输电线检测精度。为了对电缆图像进行高质量的分割,2015 年吴华等^[7]融合了 SLIC 算法与 DBSCAN 算法改进了空间聚类分割算法以分离目标和背景。2018 年陈建等^[8]使用黑塞(Hessian)矩阵对输电线进行预处理,降低输电线的误检率和漏检率。

经典的图像分割方法应用于复杂背景时存在缺陷,且容易受到强光、天气环境影响^[9]。近年来,基于深度学习的目标检测发展迅速:2014 年在目标检测的基础上,Hariharan 等^[10]提出了“同步检测和分割目标”的模型,即 SDS,在同一年又在 SDS 模型上做了优化,提出了超柱^[11]的概念。2016 年,He 等^[12]研究了 Faster R-CNN 目标检测算法,并在此基础上提出了实例分割模型 Mask R-CNN。在 2019 年 Gong 优化了 Mask R-CNN 的模型掩码质量公式,提出了 MSR-CNN 实例分割模型,让模型分割性进一步得到提高^[13]。

在实际检测环境中,电缆线相互交错,姿态复杂。由于电缆属于弱纹理目标,采用深度学习的方式对其进行识别时,仍然会产生识别精度差、漏检误检等问题,从而影响双目对电缆定位的效果。因此,本文针对这些问题,对 YOLACT 网络进行了改进,并优化了 Canny 的边缘检测算法。利用改进后的网络对电缆进行识别分割并优化其边缘,然后通过扫描算法提取电缆中心线点集,最后通过双目匹配特征点,从而实现了对电缆的精确定位。

1 基于 YOLACT 的电缆识别

1.1 目标检测模型分析

在目标检测模型设计上,主要有两大路线:Two-stage 型的网络更加重视精度,代表作 R-FCN、Faster-RCNN 等;One-stage 型的网络更加重视提升速度,代表作 YOLO、SSD 等。在 Two-stage 模型中,通过 re-pooling 型操作(如 ROI align、ROI pooling)来将特征映射到包围框中,这种做法从逻辑上就是串行的,所以很难加速。

基于此,YOLACT 网络摒弃了隐含的特征定位步骤,将实例分割任务拆分成两个并行的子任务:一是生成一系列覆盖全图的原型 mask,二是对每个实例,预测一系列的线性组合系数。最后,在进行推理时,对每一个实例,使用其对应预测出的 mask 系数,与原型 mask 简单乘加,然后根据 bounding box 裁剪,阈值化,即得到每个实例对应的 mask。与其他网络相比,YOLACT 具有速度快、mask 质量高、普适性强等显著优势。

而配网带电作业机器人的工作需求对识别网络的速度和精度有很高的要求,基于此,本文选用 YOLACT 网络作为电缆识别网络,并在网络基础上针对电缆形态特点对网络的后处理部分进行改进,从而提高了复杂环境下对电缆的识别准确率。

1.2 YOLACT 网络分析

YOLACT 的主体结构采用全卷积网络作为特征提取

网络。残差神经网络(residual neural network)是由 He 等^[14]提出的针对深层网络梯度消失设计的网络结构。本文中采用 ResNet-101 作为 YOLACT 的主干网络生成五个不同的特征层,即图 1 中的 C1~C5。

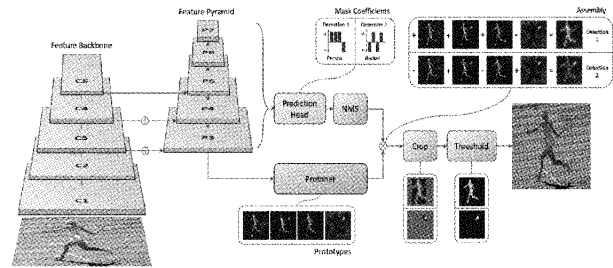


图 1 YOLACT 网络结构

将 ResNet-101 网络的第三层、第四层与第五层作为 FPN 层的输入,经过 FPN 层可以获得 P3~P7 特征图。如图 2 所示,分割原型生成网络采用 P3 特征层作为输入,经过四次卷积与两次上采样。由于该特征层有着较大的尺度,对目标分割会更加准确,并且通过特征金字塔的特征融合后也包含了丰富的深层抽象特征。检测器模块结构如图 3 所示,它在 Retina-Net 网络结构的基础上改进得到,使用 Anchor Boxes 方法^[16]去预测分类的置信度与边框。




图 2 分割原型生成网络




图 3 检测器模块

1.3 基于电缆的候选框筛选算法

YOLACT 使用非极大值抑制(non-maximum suppression, NMS)方法实现对图像目标候选框的筛选。传统非极大值抑制算法使用候选框的交并比(IOUS)来进行目标筛选,通过比较 IOU 与阈值高低实现候选框的筛选。由于电缆在图像中一般是长条状,电缆轮廓的面积相对于

候选框的面积占比小,所以同一个候选框内大概率会出现两根或者以上的电缆。如图 4 所示,采用传统算法进行电缆候选框筛选会误删除部分目标候选框,出现电缆漏检的问题。

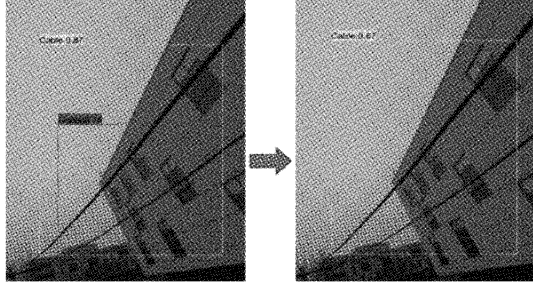


图 4 传统候选框筛选过程示例图

为此,本文基于电缆的形态特征,提出了一种针对密集电缆的候选框筛选算法。如图 5 所示,同一根电缆上的候选框对角线斜率一般接近重合,所以两个候选框上的对角线的斜率差与两个候选框之间的相关度有着较强的联系。候选框的对角线角度差范围为 $0^\circ \sim 90^\circ$,在候选框 IOU 一定的情况下,角度差为 0° 时电缆候选框的相关性较大,当角度差为 90° 时电缆候选框相关性最小。所以,本文将对角线角度差作为 IOU 权重对电缆进行重新筛选。

$$Rel(M, N) = \cos(\mu - \beta) \times IOU(M, N) \quad (1)$$

$$c_i = \begin{cases} s_i, & Rel(M, N) < N_i \\ s_i(1 - Rel(M, N)), & Rel(M, N) \geq N_i \end{cases} \quad (2)$$




图 5 候选框对角线角度差示例图




图 6 电缆定位流程

的不准确分割,因此需要对电缆边缘进行优化。传统的 Canny 算法对所有方向的边缘梯度有相同的敏感度,会检测出除电缆边缘以外的无效边缘。

本小节提出了一种自适应 Canny 算子权重的电缆边缘检测算法,来实现对电缆边缘更高精度的分割提取。该算法首先根据电缆轮廓计算出电缆的边缘趋势,然后逆向计算出 Canny 算子的权重因子,最后计算像素点的梯度并确定电缆的边缘。

式(1)中使用余弦公式将两个候选框的对角线角度差 $\mu - \beta$ 归一化到 $\cos(\mu - \beta)$,此公式将电缆候选框在图像中的斜率考虑进去,针对电缆的检测更加的合理。其中 M, N 分别表示需要计算的先验框, μ, β 分别表示两个先验框的对角线角度,为两个先验框的交并比。在置信度惩罚公式上,本文使用式(2)进行抑制惩罚。式(2)是关于相关度的线性函数,此函数并不连续,会出现梯度断层,当相关度 Rel 条件满足时,置信度 乘上一个 $1 - Rel$ 线性变小。

优化过的非极大值抑制方法具体流程如下:

- 1) 将算法预测出的 3 个候选框按照置信度从高到低排序。
- 2) 选择置信度最大的候选框。
- 3) 按照排序遍历候选框:(1)判断是否还有要遍历的候选框,若没有执行步骤(4),若有继续执行步骤(2);(2)使用式(2)计算候选框的相关度;(3)根据当前置信度与相关度,通过式(2)计算出新的置信度;(4)判断新的置信度是否大于阈值如果小于则删除候选框,否则直接回到步骤(1);
- 4) 输出剩余的候选框。

使用优化过的非极大值抑制算法可以很好地解决 YOLOACT 在识别密集电缆时存在的漏检问题。该算法经实验验证,可以提高复杂环境下电缆的识别率和准确率,本文第 3 小节对该算法进行了具体的实验分析与验证。

2 基于双目的电缆定位

2.1 电缆边缘检测算法

基于双目的电缆定位过程流程如图 6 所示。首先通过 YOLOACT 网络过滤电缆图像的复杂背景,得到电缆的轮廓图,对轮廓进行边缘检测后并提取其中心线,最后利用中心线进行极线匹配和双目关键点匹配,从而实现对电缆的定位。

如图 7 所示,电缆线的背景复杂,导致 YOLOACT 提取的轮廓精度不足,若直接利用网络所得的掩膜边缘进行中心线提取,提取到的电缆中心线会偏离。图 8 为网络分割结果示例图,从图中可以看出,电缆分割边缘会存在波形形

首先对图像进行预处理,将网络分割得到的电缆轮廓进行形态学修正,并在此基础上对修正后的图像进行膨胀,确保待检测边缘的图像可以包含电缆的完整轮廓。通过最小二乘法拟合边缘像素点对电缆进行细化处理后可以确定电缆的基本走向,并利用拟合线确定边缘梯度方向,即电缆轮廓拟合线导数方向。如图 9 所示,假设点 $A(x, y)$ 为拟合线 f 上的一点,则 B 与 C 两点的梯度方向如式(3)所示。




图 7 YOLACT 轮廓提取示例图




图 8 网络分割示例图




图 9 电缆边缘梯度示例图

$$\begin{cases} \theta_B = 90^\circ + \arctan[f'(x)] \\ \theta_C = -90^\circ + \arctan[f'(x)] \end{cases} \quad (3)$$

Canny 算法使用 S_x 与 S_y 两个算子进行卷积运算, 获取图像中的水平方向、垂直方向灰度值变化情况, 假设需要计算图像中像素点 a 的梯度, C 是以 a 为中心 3×3 的窗口, 则像素点 a 在 x 和 y 方向的梯度值 G_x 和 G_y 分别为式(4)所示。由式(4)可以确定像素点 a 的梯度和方向, 如式(5)所示, 其中, G 为梯度强度, θ 表示梯度方向。

$$\begin{cases} G_x = S_x \times C \\ G_y = S_y \times C \end{cases}, S_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix},$$

$$S_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (4)$$

$$G = \sqrt{G_x^2 + G_y^2}, \theta = \arctan\left(\frac{G_x}{G_y}\right) \quad (5)$$

根据式(5)反推出垂直算子的权重因子和水平算子的权重因子与边缘梯度向 θ 的关系如下, 其中, H 为垂直算子的权重因子, L 水平算子的权重因子。

$$H = \frac{1}{\tan(\theta) + 1}, L = \frac{\tan(\theta)}{\tan(\theta) + 1} \quad (6)$$

假设电缆拟合线点集分别为 $A_1(x_1, y_1), A_2(x_2, y_2), A_3(x_3, y_3) \dots A_n(x_n, y_n)$, 则根据式(3)与式(6)可得点集中 A_n 点两边的边缘的 Canny 垂直算子与水平算子的权重因子如式(7)所示。其中, H_n^B, L_n^B, H_n^C 与 L_n^C 分别表示线段 $A_n C_n$ 与线段 $A_n B_n$ 上垂直算子的权重因子和水平算子的权重因子。沿线段 $A_n C_n$ 与线段 $A_n B_n$ 扫描像素点并计算电缆的边缘梯度, 设 M 为 $A_n C_n$ 上的一点, 则 M 像素点 θ_c 方向的梯度强度如式(8)所示, 其中 M_d 为以像素点 M 为中心 3×3 大小的卷积核。同理可得 $A_n B_n$ 上的一点 N 的梯度强度, 如式(9)所示。根据式(8)和(9)沿拟合线遍历电缆轮廓像素点, 便可以得到图像中所需的所有像素点的梯度, 再通过双阈值检测和抑制孤立弱边缘便可以确定最终的电缆边缘。

$$\begin{cases} H_n^B = \frac{1}{\tan(+90^\circ - \arctan(f'(x))) + 1} \\ L_n^B = \frac{\tan(+90^\circ - \arctan(f'(x)))}{\tan(+90^\circ - \arctan(f'(x))) + 1} \\ H_n^C = \frac{1}{\tan(-90^\circ - \arctan(f'(x))) + 1} \\ L_n^C = \frac{\tan(+90^\circ - \arctan(f'(x)))}{\tan(-90^\circ - \arctan(f'(x))) + 1} \end{cases} \quad (7)$$

$$W_M = H_n^C \times M_d \cdot G_y + L_n^C \times M_d \cdot G_x \quad (8)$$

$$W_N = H_n^B \times N_d \cdot G_y + L_n^B \times N_d \cdot G_x \quad (9)$$

图 10 为传统 Canny 边缘检测算法与上述电缆边缘检测算法对电缆边缘检测的效果对比图, 可以看出传统的 Canny 算法在提取电缆的边缘时存在多处不连续的线段或者噪声, 无法检测出电缆真实的边缘。而本文提出对边缘的判断较为准确, 而且线段具有一定的连续性, 同时线段特征间的区分性较大, 比较符合人眼视觉的习惯。




图 10 缘检测算法对比图

2.2 电缆中心线提取

对电缆的高精度的定位依赖于对其中心线的精确提取。但电缆属于弱纹理目标,在实际应用中由于环境(如光照、背景等)变化,像素级的分割依然可能造成边缘提取像素级的误差。

为了保证双目定位的测量精度,本小节提出了一种亚像素级的电缆中心线二次函数提取算法,具体过程如下:

1)获取电缆趋势:如图 11(a)所示,可以通过电缆轮廓的最小外接矩形来判断其基本走向,左图中当红色的矩形框的长比宽大于 5 时电缆轮廓处于垂直状态,右图中当红色的矩形框的长宽比小于 0.2 即图中的时电缆轮廓处于水平状态。若外接矩形的长宽比在 0.3~3 可先进行分段处理。

2)获取中心线像素点集:如图 11(b)所示,以接近垂直状态下的电缆轮廓为例,设电缆轮廓外接矩形行像素点为 B_1 到 b_1 ,分别以 B_1 与 b_1 为起点沿着水平方向向中间扫描,扫描过程中白色像素点为背景,黑色像素点为电缆边缘,交界处即为电缆的两边边缘。沿图中的 C_1 到 C_2 方向,对外接矩形的所有行进行扫描就可以获得电缆中心线的所有点集。




图 11 电缆中心线扫描示意图

2.3 电缆三维坐标计算

电缆本身属于弱纹理目标,在对双目图像中的电缆区域进行代价计算时,由于受到左右相机自身硬件差异与拍摄环境影响,难以准确提取电缆特征,无法实现像素级的匹配,从而影响三维坐标测量精度。本小节结合了电缆的线状特征,在不对图像进行代价计算的前提下,直接通过提取的电缆中心线二次函数和水平极线约束,使用求解交点的方式匹配出左右图像中电缆的中心线点集,极大的降低了算法的复杂度。

将上节提取到的电缆中心线经过最小二乘拟合后可以得到其二次函数方程,设左右相机的电缆中心线二次函数分别为:

$$\begin{cases} y_l = a_{l0} + a_{l1}x + a_{l2}x^2 \\ y_r = a_{r0} + a_{r1}x + a_{r2}x^2 \end{cases} \quad (10)$$

若已知左相机图中电缆中心线上的任意一点 P 坐标为 (x_p, y_p) , 设其对应右相机图中 Q 的坐标为 (x_q, y_q) , 则 $y_p = y_q$ 。像素点 Q 点的横坐标可以由水平极线函数

与右图电缆中心二次函数的交点得到,公式如式(11)所示。得到 P 和 Q 的二维坐标后,根据双目定位原理,由式(12)便可以求得电缆中心线上一点坐标,其中 f 为双目相机的焦距, b 为两相机之间光心的距离。遍历中心线的点集就可以得到整根电缆线的三维坐标,从而实现对电缆的精确定位。第 3 小节对本文使用的定位算法进行了精度验证。

$$\begin{cases} y_p = y_q \\ y_q = a_{r0} + a_{r1}x_q + a_{r2}x_q^2 \end{cases} \quad (11)$$

$$X = \frac{x_p b}{x_p - x_q}, Y = \frac{y_p b}{x_p - x_q}, Z = \frac{f b}{x_p - x_q} \quad (12)$$

3 实 验

3.1 电缆识别实验

本文选用 COCO 格式的数据集作为 YOLACT 的训练集来进行网络训练,利用 labelme 图像标注工具对采集到的电缆样本进行标注后进行训练。其中电缆采集环境包括房屋背景、天空背景、道路背景等一共 2 000 多张机器人工作环境,示例图如图 12 所示。




图 12 电缆样本示例图

为了验证第 2 小节中提出的基于候选框的电缆筛选算法的有效性,从电缆样本中选取了 100 张电缆测试图片,其中包含了各 50 张密集电缆图像和非密集电缆图像。采用原网络和改进后的网络分别对其进行识别分割,其中优化过的 YOLACT 算法选取式(2)作为 NMS 中的惩罚公式,并将置信度阈值设置为 0.5,测试结果数据如表 1 所示。从表中看出,原网络与改进后的网络对非密集电缆的识别率差别不大,但改进后的网络对密集电缆图像的识别率要明显高于原网络。

图 13 为识别结果对比图,其中图 13(a)和(b)为优化前的网络识别结果,图 13(c)和(d)为优化后的网络识别结果。从图中可以看出,第 3 小节中提出的基于电缆的候选框筛选算法很好地解决了复杂环境下对密集电缆的漏检问题。

3.2 电缆定位实验

在电缆定位实验中,主要测试系统测量出的电缆三维坐标的精度和稳定性。机器人机械臂的工作范围在 0.8~1 m,

表 1 网络识别结果对比

电缆图像	目标检测算法	召回率/%	准确率/%	平均像素准确率/%	FPS
非密集	原 YOLACT	75.1	77.2	73.2	33.1
	优化后 YOLACT	75.1	77.8	73.1	32.6
密集	原 YOLACT	71.2	74.2	72.6	33.2
	优化后 YOLACT	76.3	77.3	73.1	32.4

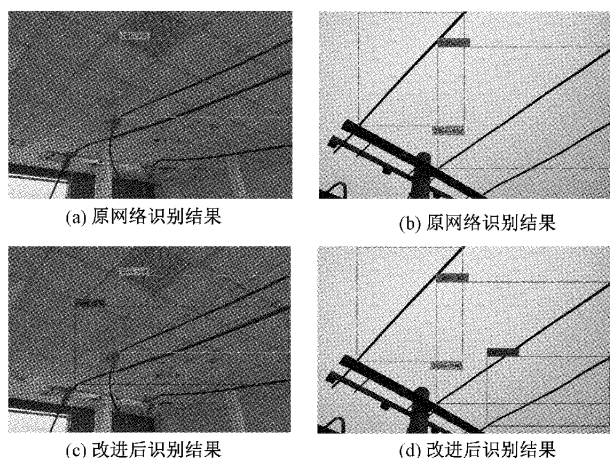


图 13 网络优化前后检测对比图

为了检测定位系统是否满足机器人的作业要求,本实验将电缆线放置在双目相机前 0.8~1 m 的不同位置进行测试。

实验通过机械手指点的方式来验证系统的测量精度。将电缆识别定位系统测量到的坐标发送给机械手进行指点操作,结果如表 2 所示,表中距离为机械手与对应电缆角点的欧式距离误差,单位为 mm。

表 2 机械手指点欧式距离误差

编号	1	2	3	4	5	6	7	8
距离/mm	2.1	2.6	3.1	2.7	0.7	2.7	1.8	2.3

在验证了电缆三维坐标的测量精度后,还需要对测量的稳定性进行测试。利用系统测量出的电缆三维点集绘制电缆的三维姿态并与实际电缆姿态进行对比,结果如图 14 所示。其中,图 14(a)和(b)为存在颜色与电缆相似的背景环境,图 14(c)和(d)的测试环境为逆光环境。从三维测量结果可以看出,在不同环境下本系统的三维建模姿态结果与电缆实际姿态均基本一致。为了验证系统测量坐标的稳定性,在静态情况下对上述两种环境进行测试,记录相同位置下一分钟内电缆中点坐标的变化情况,结果如图 15 所示。从图中可以看出,在两种不同环境下电缆中点坐标均没有出现因为背景与环境的影响而出现较大的跳动。

根据测量结果计算出坐标值波动的平均值、均方差与最大值,结果如表 3、4 所示。从表 3、4 可以看出,在不同环

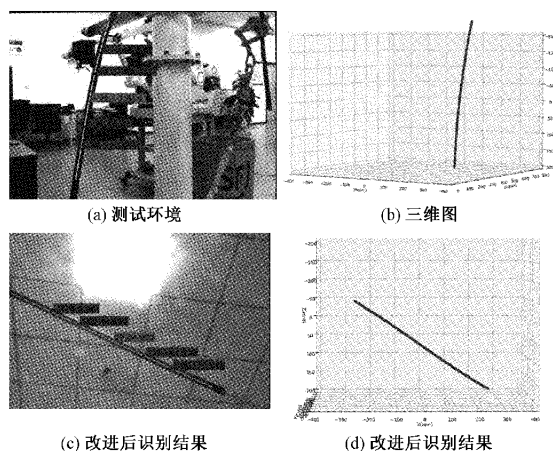


图 14 电缆三维测量结果图

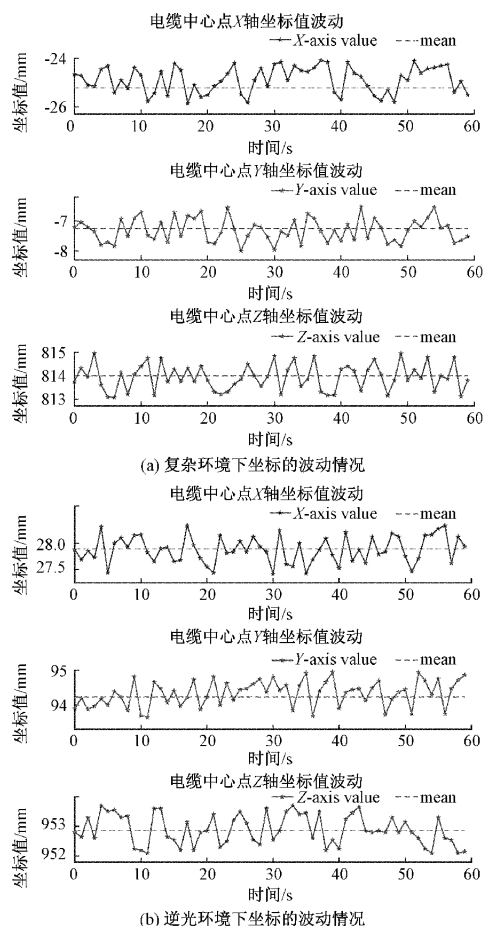


图 15 不同环境坐标波动情况

境与距离下,本系统测量出的电缆三维轴向坐标的最大波动不超过 2 mm,均方差不超过 0.5 mm,测量结果稳定性较好,可以满足机械手指点的稳定性要求。

表 3 复杂环境下坐标量化结果

坐标轴	均值/mm	均方差/mm	最大波动值/mm
X	-25.32	0.42	1.83
Y	-7.25	0.32	1.52
Z	813.92	0.53	1.96

表 4 逆光环境下坐标量化结果

坐标轴	均值/mm	均方差/mm	最大波动值/mm
X	27.91	0.49	1.95
Y	94.23	0.42	1.43
Z	952.86	0.39	1.37

4 结 论

为了在复杂环境下识别和分割出图像中的电缆目标并获得其三维坐标,本文对实例分割 YOLACT 算法进行了研究与改进,并提出了一种自适应的电缆边缘检测算法来改善网络分割效果,最后利用双目视觉的方式实现对电缆的精确定位。本文首先介绍了分割网络中的主干前端的特征提取模块、特征金字塔模块、分割原型掩膜生成模块。然后,基于配置的网络参数完成了电缆样本数据集的训练并对实验结果进行分析。实验结果表明,使用现有 YOLACT 算法检测时,会出现密集电缆漏检的问题。针对该问题,本文建立了新的电缆候选框相关度计算方法,优化了非极大值抑制算法,并将两者相结合,提出了一种针对电缆的 YOLACT 改进算法,并通过实验方式选取优化后算法的最佳参数。实验证明,该算法更有效地保留了正确的电缆候选框,提高了在电缆检测上的召回率与准确率。不仅如此,本文提出的电缆边缘优化算法可以更好的提取电缆轮廓,在电缆的定位实验中可以发现,利用优化后的边缘可以提取到更为准确的电缆中心线点集,从而实现对电缆的精确定位。

参考文献

- [1] 焦红. 直升机巡检输电线路图像中防振锤的识别定位[D]. 大连:大连海事大学,2011.
- [2] 王芳,崔丹丹,李林. 基于深度学习的采摘机器人目标识别定位算法[J]. 电子测量技术,2021,44(20):162-167.

- [3] 李实,刘波,韩刚,等. 电力系统配电网带电作业机器人[J]. 自动化博览,2018(3):68-70.
- [4] 彭秋辰,宋亦旭. 基于 Mask R-CNN 的物体识别和定位[J]. 清华大学学报(自然科学版),2019,59(2):135-141.
- [5] SARABANDI K, PARK M. Extraction of power line maps from millimeter-wave polarimetric SAR images[J]. IEEE Transactions on Antennas and Propagation, 2000, 48(12): 1802-1809.
- [6] 全卫国. 基于航拍图像的输电线路识别与状态检测方法研究[D]. 保定:华北电力大学,2011.
- [7] 吴华,卢君妥,柳长安,等. 巡检图像的改进密度空间聚类分割算法[J]. 华中科技大学学报(自然科学版),2015,43(S1):473-476.
- [8] 陈建,沈潇军,姚一杨,等. 基于航拍图像的输电线检测方法[J]. 计算机工程与设计,2018,39(4):1155-1160.
- [9] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553):436.
- [10] HARIHARAN B, ARBELÁEZ P, GIRSHICK R, et al. Simultaneous detection and segmentation[C]. European Conference on Computer Vision, Zurich, Switzerland, 2014: 297-312.
- [11] HARIHARAN B, ARBELÁEZ P, GIRSHICK R, et al. Hypercolumns for object segmentation and fine-grained localization[C]. IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2015: 447-456.
- [12] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-cnn[C]. IEEE International Conference on Computer Vision. Piscataway, NJ: IEEE, 2017: 2961-2969.
- [13] HUANG Z, HUANG L, GONG Y, et al. Mask scoring R-CNN[C]. IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2019: 6409-6418.
- [14] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Los Alamitos: IEEE Computer Society Press, 2016: 770-778.

作者简介

李瑾,硕士研究生,主要研究方向为测试计量技术与仪器,机器视觉等。

E-mail:811347272@qq.com