

基于关键点的输电线路防振锤滑移视觉检测

刘又维^{1*}, 樊绍胜¹, 唐立军², 冯勇², 李浩涛²

¹长沙理工大学电气与信息工程学院, 湖南 长沙 410114;

²云南电网有限责任公司电力科学研究院, 云南 昆明 650217

摘要 提出一种基于关键点训练学习的防振锤滑移检测方法。首先利用改进 SSD 模型对防振锤进行识别、定位; 再选择防振锤关键点, 训练 MobileNetV3 网络, 通过上一级定位结果设定输入区域, 从而实现关键点的检测; 最后依据线路图像特征, 制定相应判别规则。当档距内悬挂 $m(m \geq 2)$ 个防振锤时, 利用关键点几何约束关系实现判别; 当档距内悬挂单防振锤时, 采用 EPnP 算法估计相机在多个角度的位姿, 通过位姿与线夹关键点像素坐标间的关系求解最邻近点的世界坐标, 判断最邻近点与防振锤间的距离是否在阈值范围内。实验结果表明, 所提方法能对滑移异常进行有效识别, 为输电线路异常检测提供了新思路。

关键词 机器视觉; 关键点检测; 异常检测; 位姿估计

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP57.201502

Visual Detection of Stockbridge Damper Slip on Power Transmission Lines Based on Key Points

Liu Youwei^{1*}, Fan Shaosheng¹, Tang Lijun², Feng Yong², Li Haotao²

¹School of Electrical & Information Engineering, Changsha University of Science & Technology, Changsha, Hunan 410114, China;

²Electric Power Research Institute, Yunnan Power Grid Co., Ltd., Kunming, Yunnan 650217, China

Abstract This study proposes a method for detecting slipping of stockbridge dampers based on key point training and learning. First, an improved SSD model is used to identify and locate the stockbridge damper. Thereafter, the key points of the stockbridge damper are selected, the MobileNetV3 network is trained, and the input area is set by the upper positioning results of the stockbridge damper to realize the detection of key points. Finally, discrimination rules are formulated according to the characteristics of line images. For $m(m \geq 2)$ stockbridge dampers, the geometric constraint relationship among the key points is used to realize determination. For a single stockbridge damper, the EPnP algorithm is used to estimate the multiangle pose of the camera. Moreover, the spatial coordinates of the nearest points are obtained from the relationship between the pose and the pixel coordinates of the key point of the damp to determine whether the distance between the nearest points and the stockbridge damper is within the threshold range. The experimental results show that the proposed method can effectively identify slip faults and provide new ideas for detecting defects in transmission lines.

Key words machine vision; key point detection; defect detection; pose estimation

OCIS codes 150.1135; 100.4996; 110.2970

1 引言

输电线路巡检对国民用电安全至关重要。输电线路被风力掀起时会发生振动, 长期振动将导致导线材料周期性弯折, 形成机械应力, 最终造成线路故

障。防振锤是一种用于降低振动的关键金具, 通过产生与导线不同步的反作用力来吸收振动能量, 减弱振幅^[1]。输电导线一般由多股金属丝缠绕铁芯制成, 在实际应用中, 导线在受力作用下常发生蠕变现象^[2], 导致其横截面直径减小, 长度增加。横截面的

收稿日期: 2020-01-19; 修回日期: 2020-02-12; 录用日期: 2020-02-24

* E-mail: erwill@qq.com

缩小必然造成防振锤夹板握力不足,出现松动,在自重、风力等因素的影响下,防振锤常从安装位置滑动至导线弧垂最低处。所以,滑移现象是防振锤最常出现的异常情况,防振效果受到极大影响^[3]。

目前在电力巡检中对异常情况的判定主要通过肉眼完成。随着科学技术的发展,巡检方式日渐多样,如无人机巡检和机器人巡检可通过搭载的摄像头向后台监控设备反馈线路图像信息,这为计算机视觉技术在电力系统智能巡检领域创造了更多可能。在图像处理算法方面,一般基于边缘、形状、颜色等特征判别输电线路金具的种类和锈蚀情况。陈晓娟等^[4]通过随机 Hough 变换检测圆弧,再加以半径、圆心坐标等约束条件,实现输电线路防振锤检测。谭磊等^[5]通过 Otsu 自适应阈值算法提取图片边缘,获得了边缘中的几何图形基元,再加以结构约束,实现了导线、绝缘子、防振锤的检测。在一定情况下上述方式能达到识别的目的,但在光照强度大、噪声干扰强、外界环境复杂等情况下难以获得理想结果。在机器学习方面,研究人员基于大量样本训练分类器,实现了复杂背景中线路金具的有效识别。金立军等^[6]使用拓展的类 Haar 特征对防振锤进行描述,输入级联 AdaBoost 进行识别。唐宏伟等^[7]使用小波变换提取图像边缘,设计了一种基于粒子群优化的小波神经网络,该网络将输电线路障碍物分为防振锤、悬垂线夹、耐张线夹 3 类。以上方法都实现了输电线路防振锤的识别,但在异常检测领域没有对其进行后续研究。

本文主要面向输电线路防振锤滑移异常检测,首先通过改进的 SSD 网络对图像中的防振锤进行识别与定位;依据识别结果,确定 MobileNetV3 模型的输入区域,实现防振锤关键点检测;基于线路图像特征,制定两种判断规则。1) 当档距内悬挂 $m(m \geq 2)$ 个防振锤时,利用关键点几何约束关系实现异常判别。2) 当档距内悬挂单防振锤时,采用 EPnP 算法估计相机在多个角度的位姿,再检测图中的线夹关键点,通过位姿与线夹关键点像素坐标间的关系求解最邻近点的世界坐标,计算最邻近点与防振锤间的距离,从而完成滑移异常判别。

2 算法介绍

2.1 基于改进 SSD 的防振锤识别定位

SSD 算法是现今应用最广泛的目标检测算法之一,具有多尺度、高精度、快速等优点^[8]。SSD 网络由基础网络和辅助网络两部分组成,基础网络一般为去掉最后分类层的高精度模型,辅助网络为

尺寸不断缩小的金字塔式卷积结构。利用不同特征层可实现目标的多尺度预测,低层用于小目标检测,高层用于大目标检测。

SSD 网络特征图的每个像素点上有 k 个宽高比不同的默认框。当特征图尺寸为 $w \times h \times s$,类别数为 c 时, $c \times k$ 个卷积核用于标签分类, $4 \times k$ 个卷积核用于默认框偏移量回归,共得 $(4+c) \times k \times w \times h$ 个预测值。通过非极大值抑制(NMS)筛选得到最终输出类别和预测框信息。

默认框的预设宽高比在特征层 conv7, conv8_2, conv9_2 中为 $\{1, 2, 3, 1/2, 1/3\}$, 在 conv4_3, conv10_2, conv11_2 为 $\{1, 2, 1/2\}$ 。防振锤具有型号标准,依据尺寸特征选择宽高比替换原始预设,可提高模型检测效果^[9],优化后的默认框宽高比为 $\{1, 5/2, 10/3, 2/5, 3/10\}$ 与 $\{1, 5/2, 2/5\}$ 。

SSD 网络是一种具有较高精度的 one-stage 网络,与 two-stage 网络相比,检测速度大幅提升,但受参数总量和计算量限制,仍不满足移动端部署、实时检测等需求。其基础网络主要用于特征提取,占据了大部分存储与运行时间,one-stage 模型优化特征提取方式可以极大提高识别精度,但对 SSD 模型精度提升效果不明显^[10]。轻量网络 MobileNetV3 由深度可分离卷积、倒残差结构等模块构成,具有占用存储小、运行速度快的特点。因此,本文去除池化层,用预测层部分的 MobileNetV3 替换原基础网络 VGG-16。所提方法在不损失精度的同时,缩小网络体量、提高速度,降低了对硬件设备性能的要求。

2.2 基于 MobileNetV3 的关键点检测

MobileNetV3 是谷歌发布的新一代轻量级神经网络,改进了已有的深度可分离卷积、倒残差结构和 SE(Squeeze-and-Excitation)模块,具有更快的速度和更高的识别精度^[11-13]。

假设一组输入特征图的尺寸为 $D_F \times D_F \times M$,输出特征图的尺寸为 $D_G \times D_G \times N$,其中 M 和 N 均为特征图的通道数。深度可分离卷积实质上是深度卷积与逐点卷积的组合,可有效减少参数计算量。其总计算量与标准卷积相比减少了

$$\frac{D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F}{D_K \times D_K \times M \times N \times D_F \times D_F} = \frac{1}{N} + \frac{1}{D_K^2}, \quad (1)$$

式中: $D_K \times D_K$ 为深度卷积的卷积核尺寸。MobileNetV3 在原线性瓶颈倒残差结构的 3×3 深度卷积后加入了轻量级通道注意力模块 SE,缓解了

非线性激活函数在低维度下发生的信息丢失,同时通过调整通道关系增强了特征提取性能,提高了网络精度。

倒残差结构在浅层、深层网络中使用了不同的激活函数,浅层为 ReLU,深层为 h-swish。h-swish 是一种基于 swish 改进的非线性激活函数,表达式为

$$\text{h-swish}[x] = x \frac{\text{ReLU}(x+3)}{6}, \quad (2)$$

式中: x 为输入特征值。其利用 $\text{ReLU}(x+3)/6$ 逼近 Sigmoid 函数,在深层网络有更好的表现,消除了量化精度的损失,参数量少且应用成本降低,具有更好的平台适配性。

选择 4 个防振锤关键点,用全连接层代替 MobileNetV3 网络最后的 2 个 1×1 卷积层,将检测点与真实点间方均误差(MSE)的和作为损失函数^[14],实现回归定位,最终输出 8 个坐标值,为后续防振锤异常检测打下基础。

2.3 基于 EPnP 算法的相机位姿估计

PnP(perspective- n -point)问题是指:使用内参数已知的相机拍摄图像,获得 n 个特征点成像后的像素坐标,根据特征点的像素坐标与已知的世界坐标,求取相机的位姿。EPnP 算法是 PnP 问题常用的解析法,能进行精准、高效的位姿估计^[15]。

存在 n 个特征点 $p_i (i=1, 2, \dots, n)$,特征点在世界坐标系中表示为 $p_i^s = [x_i^s, y_i^s, z_i^s]^T$,在相机坐标系中表示为 $p_i^c = [x_i^c, y_i^c, z_i^c]^T$,在成像后的像素坐标系中表示为 $p_i^u = [u_i, v_i]^T$ 。相机成像过程中坐标系关系如图 1 所示,其中 f 为相机焦距, t 为平移向量, R 为旋转矩阵。投影模型可表述为

$$\omega_i \begin{bmatrix} p_i^u \\ 1 \end{bmatrix} = \mathbf{K} p_i^c, \quad (3)$$

$$\mathbf{K} = \begin{bmatrix} f_x & 0 & u_0 \\ 0 & f_y & v_0 \\ 0 & 0 & 1 \end{bmatrix}, \quad (4)$$

式中: ω_i 为投影深度; \mathbf{K} 为相机内参矩阵; f_x, f_y, u_0, v_0 均为相机内部参数。

依据 EPnP 算法,在世界坐标系中,任意 4 个虚拟控制点 $c_j (j=1, 2, 3, 4)$ 可以线性描述一个真实特征点 p_i 。由于欧氏变换下线性关系不发生改变,在相机坐标系下 p_i 可表示为

$$p_i^c = \sum_{j=1}^4 \alpha_{ij} c_j^c, \quad (5)$$




图 1 成像过程坐标系关系示意图

Fig. 1 Relationship schematic of coordinate system in imaging process

式中:转换系数 $\sum_{j=1}^4 \alpha_{ij} = 1$ 。设相机坐标系下的虚拟控制点坐标 $c_j^c = [u_j^c, v_j^c, w_j^c]^T$,将(5)式代入(3)式,则有

$$\omega_i \begin{bmatrix} u_i \\ v_i \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & u_0 \\ 0 & f_y & v_0 \\ 0 & 0 & 1 \end{bmatrix} \sum_{j=1}^4 \alpha_{ij} \begin{bmatrix} u_j^c \\ v_j^c \\ w_j^c \end{bmatrix}. \quad (6)$$

将(6)式展开整理,可得

$$\sum_{j=1}^4 \alpha_{ij} f_x u_j^c + \alpha_{ij} (u_0 - u_i) w_j^c = 0, \quad (7)$$

$$\sum_{j=1}^4 \alpha_{ij} f_y v_j^c + \alpha_{ij} (v_0 - v_i) w_j^c = 0. \quad (8)$$

同理,由 n 个特征点可形成 $2n$ 个线性方程。已知虚拟控制点间的距离,可求得坐标 c_j^c ,将其代入(5)式解得坐标 p_i^c ,进一步计算可得相机坐标系与世界坐标系之间的 R, t ,实现相机位姿的估计。

3 防振锤滑移异常检测

3.1 关键点的选择

输电线路防振锤由夹板、钢绞线、2 个具有一定质量的锤头组成,其防振能力与安装方案和工作频率有关。目前工程中,防振锤的安装距离与个数依据输电现场的导地线规格、风速等因素设计。对于悬垂线夹,安装距离一般指防振锤夹板中心与线夹中心线间的距离,对于耐张线夹,安装距离指防振锤夹板中心与线夹挂点中心间的距离^[16]。

根据安装规则和结构特点,选择 4 个关键点,分别为防振锤夹板上中心点、夹板下中心点及左、右锤头端点,具体如图 2 所示。

3.2 多防振锤检测方法

设档距内悬挂 $m (m \geq 2)$ 个防振锤,发生滑移时,防振锤间距离缩小,甚至出现碰撞,如图 3 所示,




图2 防振锤关键点示意图

Fig. 2 Schematic of key points of stockbridge damper

所以可通过几何约束关系进行异常判定。

经过级联卷积神经网络可获得 m 个防振锤预测框和 $4 \times m$ 个关键点坐标,将左锤头端点坐标记为 $P_{mL}(x_{mL}, y_{mL})$,右锤头端点坐标记为 $P_{mR}(x_{mR}, y_{mR})$ 。当相邻锤体间的距离小于锤体平均长度时,则认为该区域出现滑移异常,具体数学表达式为

$$|P_{mL}P_{(m+1)R}| < \frac{|P_{mL}P_{mR}| + |P_{(m+1)L}P_{(m+1)R}|}{2} \quad (9)$$



图3 防振锤滑移示意图

Fig. 3 Schematic of stockbridge damper slip

3.3 单防振锤检测方法

当档距内仅悬挂一个防振锤时,不可通过几何约束完成判别,需从防振锤与线夹间的标准安装距离 S 入手。首先,将模型输出的防振锤关键点作为 EPnP 算法的控制点,估计相机相对于防振锤的位姿;然后,在线夹上选定 1 个关键点,使用同样的方法获得其关键点坐标;通过不同位姿的图像,推算线夹的世界坐标值,再计算防振锤与线夹间的实际距离 S_n 。设置滑动阈值 T ,当 $|S_n - S| \leq T$,判定没有发生滑移,若 $|S_n - S| > T$,则判定防振锤发生了滑移。

在 EPnP 算法中,各控制点的像素坐标由 MobileNetV3 网络输出,世界坐标由依据防振锤型号建立的坐标系获得。以左锤头端点为原点, y 轴平行于连接锤头的钢绞线,向右为正, z 轴平行于夹板中心线,向上为正, x 轴垂直于 y 轴和 z 轴,向外为正。以 FR-2 防振锤为例,图 4 为其垂直截面图,具体尺寸如表 1 所示,对应可得夹板上中心点世界坐标为 $(0, 190, 105)$,夹板下中心点坐标为 $(0, 190, -12)$,左锤头端点坐标为 $(0, 0, 0)$,右锤头端点坐标为 $(0, 429, 0)$ 。

表 1 FR-2 防振锤的主要尺寸

Table 1 Main sizes of FR-2 stockbridge damper

Parameter	damper					
	A	L	L_1	L_2	H_1	H_2
Value	50	429	190	239	105	12




图4 防振锤尺寸示意图

Fig. 4 Diagram of stockbridge damper size

将四个控制点的像素坐标与世界坐标一一对应输入到 EPnP 算法后,得到世界坐标系与相机坐标系间的旋转矩阵 R 与平移向量 t 。旋转矩阵体现坐标系间的变换方式,平移向量描述相机坐标系下世界原点 O_s 的相对坐标。

世界坐标系下相机位姿通过旋转欧拉角获得。欧拉角 θ 基于旋转矩阵求出,具体公式为

$$\theta_x = \arctan2(r_{32}, r_{33}), \quad (10)$$

$$\theta_y = \arctan2(-r_{31}, \sqrt{r_{32}^2 + r_{33}^2}), \quad (11)$$

$$\theta_z = \arctan2(r_{21}, r_{11}), \quad (12)$$

式中: r_{32} 为旋转矩阵第三行第二列对应的值,其余同理; $\arctan2(x, y)$ 表示当 $|x| > |y|$ 时采用 $\arctan(y/x)$ 计算,反之,采用 $\arctan(x/y)$ 计算。

将原始相机坐标系绕 z 轴、 y 轴、 x 轴顺序依次旋转 θ_z 、 θ_y 、 θ_x ,即可与世界坐标系完全平行。相机原点 O_c 在旋转过程中不发生改变,但两坐标原点间的向量 $d_{O_c O_s}$ 会随之改变。因此,为保证向量方向不变,应再将方向向量绕同轴反向旋转 $-\theta$ 。三次正向旋转与反向旋转后,相机位姿推测完成。

选定线夹关键点 P ,点 P 像素坐标已知,世界坐标未知。由相机位姿与成像图片可确定一条由相机原点指向线夹关键点的直线 $O_{c1}P_1^{cl}$, $O_{c1}P_1^{cl}$ 所在位置即为关键点映射到世界坐标系的所有解。对 $O_{c1}P_1^{cl}$ 进行三次正向旋转三次反向旋转后,获得坐标转换后的 P_1^{cl} ,记为 $P^{cl'}_1$ 。世界坐标系中 P_1^s 的坐标值即为 $P^{cl'}_1$ 与相机原点 O_{c1}^s 的坐标和。

每张图像可确定唯一射线 $O_{c1}P_1^s$,通过两条射线求解交点可确定线夹关键点的世界坐标。但在实际计算中,受估计误差影响,射线往往难以相交,一般选择两条射线间的最邻近点坐标进行替代。图 5

为线夹关键点 P 的计算示意图,防振锤与线夹间的实际距离 S_n 即为防振锤夹板上中心点 P_T 与线夹关键点 P 间的距离。




图5 线夹关键点 P 计算示意图

Fig. 5 Schematic of calculating clamp key point P

4 实验结果与分析

4.1 数据集与评价指标

本研究基于 Linux Ubuntu 16.04 系统, Pytorch 平台, TITAN X 显卡, 12G 显存。数据集来源于无人机线路巡检和实验室模拟线路。共收集了 3964 张图片, 针对不同场景样本分布不均问题, 采用水平翻转、顺时针旋转 60° 、逆时针旋转 60° 等方式对数量较少的场景样本进行数据扩充, 增强模型的泛化能力。针对无人机巡检图片易受光照、阴影影响问题, 采用自适应直方图均衡化调整局部亮

表2 防振锤识别结果统计

Table 2 Statistics of recognition results of stockbridge damper

Network	New default box	$P_{accuracy}/\%$	$R_{recall}/\%$	Running time /ms
Original SSD (1)	×	88.90	85.70	98
Original SSD (2)	✓	89.01	86.23	98
SSD-InceptionV2	✓	89.36	89.06	54
SSD-MobileNetV3	✓	91.86	88.86	37

4.3 故障判别结果

采集两种情况下的线路图片, 分别进行实验。

1) 档距内悬挂 $m(m \geq 2)$ 个防振锤

利用预训练模型迁移学习, 设置动量参数为 0.9, 权重衰减为 0.0001, 前 30000 次迭代的学习率为 0.001, 后 30000 次迭代的学习率为 0.0001。

训练完成的 MobileNetV3 网络可以实现对防振锤关键点的检测, 但只能基于单目标图片。为实现多目标的检测, 首先利用 SSD 网络对图像中的防振锤目标进行定位, 再根据检测框位置设定目标区域, 并将其作为关键点检测网络的输入, 最后将关键点输出结果映射到原图。该方法提高了关键点检测精度, 图 6 为级联网络检测结果示意图。

拍摄两防振锤相触、防振锤间距离小于平均长

度, 以获得更多的图像细节, 减少光照、阴影影响。最终获得 6856 张图片, 随机选取 4800 张作为训练集, 2056 张作为测试集。

采用目前常用的精确率 $P_{accuracy}$ 和召回率 R_{recall} 作为目标检测评价指标, 分别定义为

$$P_{accuracy} = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (13)$$

$$R_{recall} = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (14)$$

式中: N_{TP} 为检测结果中正确的个数; N_{FP} 为检测结果中错误的个数; N_{FN} 为检测错误的正样本个数。规定: 当检测框与数据集标定框的交并比 (IOU) 大于等于 0.7 时, 认为是正确检测结果。

4.2 防振锤识别结果

首先利用 ImageNet 数据对基础网络 MobileNetV3-large 进行预训练, 得到的 top-1 准确度为 70.3%。然后将最后分类层以外的所有参数迁移学习至改进 SSD 网络中, 设置动量参数为 0.9, 权值衰减为 0.0005, 初始学习率为 0.005, 衰减因子为 0.95, 每迭代 10000 次进行一次衰减。

使用原 SSD 网络与改进 SSD 网络对测试集样本进行检测, 实验结果如表 2 所示。改进 SSD 网络的性能较原 SSD 网络有所提高, 其中 SSD-MobileNetV3 检测速度为原 SSD 网络的 2.65 倍。

度、防振锤间距离大于平均长度三种情况的实验室模拟线路图像各 30 张。检测得到 67 处疑似滑移, 其中 7 处为误判, 这是因为受拍摄角度影响, 若两防振锤相隔距离不够大, 则锤头关键点间的距离 $|P_{mL}P_{(m+1)R}|$ 不能准确描述防振锤的间隔。当相机光心与两防振锤中心连线所形成的夹角大于 35° 时, 可忽略成像图片角度影响, 此时能对异常进行有效检测。

2) 档距内悬挂单防振锤

通过张正友标定法获得相机的内、外参数, 将防振锤关键点的坐标一一映射, 利用 EPnP 算法估计相机位姿。以耐张线夹为例, 选择线夹挂点中心作为关键点 P , 如图 7 所示。关键点 P 检测方法 with 防振锤关键点相同, 其像素坐标已知, 世界坐标未知。




图 6 级联网络检测结果。(a)多防振锤;(b)单防振锤
Fig. 6 Detection results of cascade network. (a) Multiple stockbridge dampers; (b) single stockbridge damper




图 7 耐张线夹关键点示意图

Fig. 7 Schematic of key point of tension clamp

实验中设置实际安装距离为 1 m, 相机从右侧至左侧拍摄视频影像, 画面中包含防振锤与线夹整体, 当拍摄越趋于正视时, 相机偏角越小。在视频中每 3 帧提取一张图片, 共获得 128 张图片。将图片按顺序两两分组, 依次编号, 共计 64 组, 计算每组的最邻近点坐标, 获得其与夹板上中心间的距离。图 8 为距离偏差曲线, 可知, 随着相机偏角的减小, 计算误差也在减小, 并存在一段偏差保持在 6 cm 以内的

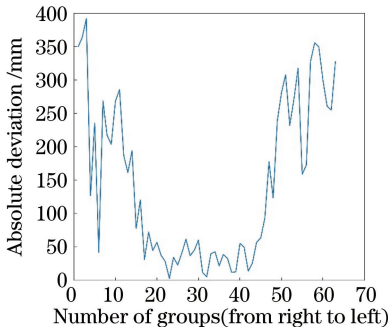


图 8 距离偏差曲线

Fig. 8 Curve of distance deviation

稳定区域。在判断时, 应对不同角度图像设定相应权重, 求取加权平均值, 获得最小误差, 从而实现异常检测。

5 结 论

提出一种输电线路防振锤的异常检测方法。首先对 SSD 基础网络进行改进, 在保证精度的同时提高了速度; 然后利用轻量化网络 MobileNetV3 实现防振锤关键点检测; 再利用输出的关键点坐标, 设计防振锤滑移异常检测方案。当档距内悬挂 $m (m \geq 2)$ 个防振锤时, 利用两个防振锤锤头关键点间的距离 $|P_{mL}P_{(m+1)R}|$ 进行判断; 当档距内悬挂单防振锤时, 则基于 EPnP 算法估计相机位姿, 得到最邻近点坐标与夹板上中心间的计算距离, 判断其偏差是否超过阈值。在算法方面, 还可增加分类器种类和多角度训练集对左锤头、右锤头、夹板等部件单独识别后, 再检测关键点, 进一步提高位姿估计算法的精度。

参 考 文 献

[1] Wang F, Wang Y, Zhou R, et al. Experiments on aeolian vibration of large span overhead transmission lines[J]. Journal of Chongqing University, 2018, 41(1): 42-50.
汪峰, 王宇, 周蕊, 等. 架空输电线路大跨越导线微风振动试验[J]. 重庆大学学报, 2018, 41(1): 42-50.

[2] Xia H X, Xia D S. Analysis of damper clamp slippage and preventive measures[J]. Electric Power Construction, 2008, 29(8): 108-109.
夏泓轩, 夏德森. 防振锤线夹滑移分析及预防措施[J]. 电力建设, 2008, 29(8): 108-109.

[3] Ma L T, Zheng S H, Zhu Y K, et al. Fracture analysis of overhead transmission line dampers in the eastern region of Inner Mongolia [J]. Northeast Electric Power Technology, 2018, 39(4): 4-7, 10.
马龙涛, 郑树会, 祝永坤, 等. 蒙东地区架空输电线路防振锤断裂破坏原因分析[J]. 东北电力技术, 2018, 39(4): 4-7, 10.

[4] Chen X J, Wu Y S, Zhao L. Identification of OPGW vibration damper based on random Hough transformation [J]. Heilongjiang Electric Power, 2010, 32(1): 1-2, 5.
陈晓娟, 吴英石, 赵亮. 基于随机 Hough 变换的 OPGW 防震锤识别[J]. 黑龙江电力, 2010, 32(1): 1-2, 5.

- [5] Tan L, Wang Y N, Shen C S. Vision based obstacle detection and recognition algorithm for transmission line deicing robot [J]. Chinese Journal of Scientific Instrument, 2011, 32(11): 2564-2571.
谭磊, 王耀南, 沈春生. 输电线路除冰机器人障碍视觉检测识别算法[J]. 仪器仪表学报, 2011, 32(11): 2564-2571.
- [6] Jin L J, Yan S J, Liu Y. Vibration damper recognition based on Haar-like features and cascade AdaBoost classifier [J]. Journal of System Simulation, 2012, 24(9): 1806-1809.
金立军, 闫书佳, 刘源. 基于类 Haar 特征与级联 AdaBoost 算法的防震锤识别[J]. 系统仿真学报, 2012, 24(9): 1806-1809.
- [7] Tang H W, Sun W, Zhang W Y, et al. Wavelet neural network method based on particle swarm optimization for obstacle recognition of power line deicing robot[J]. Journal of Mechanical Engineering, 2017, 53(13): 55-63.
唐宏伟, 孙炜, 张文洋, 等. 电力线除冰机器人基于粒子群优化的小波神经网络障碍物识别方法[J]. 机械工程学报, 2017, 53(13): 55-63.
- [8] Chen L L, Zhang Z D, Peng L. Real-time detection based on improved single shot MultiBox detector[J]. Laser & Optoelectronics Progress, 2019, 56(1): 011002.
陈立里, 张正道, 彭力. 基于改进 SSD 的实时检测方法[J]. 激光与光电子学进展, 2019, 56(1): 011002.
- [9] Liu X P, Li Y Q, Liu L, et al. Improved YOLOV3 target recognition algorithm with embedded SENet structure[J]. Computer Engineering, 2019, 45(11): 243-248.
刘学平, 李珂乾, 刘励, 等. 嵌入 SENet 结构的改进 YOLOV3 目标识别算法[J]. 计算机工程, 2019, 45(11): 243-248.
- [10] Howard A G, Zhu M L, Chen B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[EB/OL]. (2017-04-17)[2020-01-18]. <https://arxiv.org/abs/1704.04861>.
- [11] Huang J, Rathod V, Sun C, et al. Speed/accuracy trade-offs for modern convolutional object detectors [EB/OL]. (2017-04-25)[2020-01-18]. <https://arxiv.org/abs/1611.10012>.
- [12] Sandler M, Howard A, Zhu M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[EB/OL]. (2019-03-21)[2020-01-18]. <https://arxiv.org/abs/1801.04381>.
- [13] Howard A, Sandler M, Chu G, et al. Searching for MobileNetV3[EB/OL]. (2019-11-20)[2020-01-18]. <https://arxiv.org/abs/1905.02244>.
- [14] Zhu K, Tao P, Fu Z L, et al. Ultrasound image fixed point measurement based on landmark detection method [J]. Journal of Harbin Institute of Technology, 2018, 50(11): 67-73.
朱锴, 陶攀, 付忠良, 等. 利用关键点检测算法的超声图像定点测量[J]. 哈尔滨工业大学学报, 2018, 50(11): 67-73.
- [15] Chen P, Wang C X. IEPnP: an iterative camera pose estimation algorithm based on EPnP[J]. Acta Optica Sinica, 2018, 38(4): 0411001.
陈鹏, 王晨骁. IEPnP: 一种基于 EPnP 的相机姿态迭代估计算法[J]. 光学学报, 2018, 38(4): 0411001.
- [16] Li G Z. Graphical method for calculating the installation distance of earthquake vibration hammer [J]. High Voltage Technology, 1980, (2): 53-60.
李桂中. 导线线防振锤安装距离计算的图解法[J]. 高电压技术, 1980(2): 53-60.