第 50 卷 第 11 期：5034-5046 高电压技术 Vol.50, No.11: 5034-5046
2024 年 11 月 30 日 High Voltage Engineering November 30, 2024
DOI: 10.13336/j.1003-6520.hve.20231408

适应于户外场景下低成像质量的指针式表计读数智能识别方法

刘 萌[1]，王 波[1]，罗 鹏[1]，马富齐[2]，张迎晨[1]，王雷雄[1]
（1. 武汉大学电气与自动化学院，武汉 430072；2. 西安理工大学电气工程学院，西安 710054）

摘 要：由于户外场景下智能巡视表计设备采集图像时会受光照条件影响，设备采集图像质量较低，因而难以实现表计的准确读数。为此，该文首先提出一种户外场景下巡视表计的方法。该方法分为表盘检测与读数检测两部分，通过训练表盘特征高效检测模型进行表盘检测后，将检测到的候选框图像进行预处理以及基于轮廓检测的二值图重构，然后在上述二值图中依次进行起始刻度线检测、指针检测，最后使用角度法获得表计读数。经实验验证，该文方法可以克服户外场景下表计图像存在的图像模糊、反光以及存在阳光阴影等低成像质量的影响，在 5 种常见光照场景下的表盘目标平均误检率与平均漏检率分别为 1.005%与 0.505%，单张图像检测平均耗时 28.1 ms，读数检测准确率为 93.91%，对于复杂光照场景下的变电站指针式表计读数具有适用性与有效性。
关键词：表计读数识别；目标检测；概率霍夫变换；轮廓检测；深度学习；指针式仪表

Intelligent Recognition Method for Pointer-type Meter Reading Adapted to Low Image Quality in Outdoor Environments

LIU Meng[1], WANG Bo[1], LUO Peng[1], MA Fuqi[2], ZHANG Yingchen[1], WANG Leixiong[1]
(1. School of Electrical and Automation, Wuhan University, Wuhan 430072, China;
2. School of Electrical Engineering, Xi'an University of Technology, Xi'an 710054, China)

Abstract: Due to the influence of lighting conditions on image acquisition by intelligent inspection meter devices in outdoor settings, the quality of captured images is often low, making it difficult to accurately read the meter. To address this issue, this paper introduces a method for outdoor inspection meter reading. The method comprises dial detection and reading detection components. After dials are efficiently detected by using a trained feature detection model, the detected candidate box images undergo preprocessing and binary image reconstruction based on contour detection. Subsequently, the scale line detection and pointer detection are performed in the reconstructed binary image, followed by obtaining meter readings using an angular method. Experimental verification demonstrates that the proposed method mitigates the effects of image blurring, glare, sunlight shadows, and other factors affect the image quality in outdoor scenarios. The average false detection rate and average miss detection rate for dial targets under five common lighting conditions are 1.005% and 0.505%, respectively. The average time for single image detection is 28.1 ms with a reading detection accuracy of 93.91%. This method proves to be applicable and effective for accurate reading of pointer-type meters at substations under complex lighting conditions.
Key words: meter reading identification; object detection; probabilistic Hough transform; contour detection; deep learning; pointer instrument

0 引言

指针式表计具有结构简单、抗电磁干扰能力强以及反应迅速等优点，在变电站中仍然存在广泛的应用。然而，指针式表计的输出结果并非数字信号，不能实现数字化采集表计测量数据，需要依靠人工收集表计测量数据，工作任务繁杂且效率低[1-2]。为实现智能化准确采集表计读数，实时监测、收集表计数据，减轻运维人员巡视任务，近年来通过无人机、摄像头、巡检机器人智能化巡视表计读数的应用日益增多[3-4]。通过此类巡视设备获取表计读数依

基金资助项目：国家重点研发计划 (2021YFB2401300)；云南省科技厅科技专项 (202202AD080004)。
Project supported by National Key R&D Program of China (2021YFB2401300), Science and Technology Department Project of Yunnan Province (202202AD080004).

赖于监控过程高质量的图像获取。而变电站中较大一部分的指针式仪表处于户外，在此类场景下巡视表计设备在采集图像时会受到复杂的光照条件干扰，如晴天时阳光照射带来的阴影、反光以及阴天时光线较暗等问题。此类干扰可能会导致指针、刻度线的误提取甚至无法获取读数。因此，通过图像处理技术克服户外场景下上述干扰因素影响，实现指针式仪表读数的准确检测具有重要意义[5]。

指针式表计读数过程可分为表盘检测、读数检测两个部分。目前在表盘、读数检测上已有较丰富的研究，其检测方法可分为传统图像处理方法与深度学习方法两大类[6-8]。

在传统图像处理方面，文献[9]通过尺度不变特征变换(scale invariant feature transform，SIFT)算法提取角点以进行表盘区域的匹配，而户外场景下的表盘图像与匹配模板在 SIFT 角点特征上将会有较大出入，从而出现误匹配、无匹配目标等状况；文献[10]基于二进制鲁棒不变尺度特征(binary robust invariant scalable keypoints，BRISK)、fast retina keypoint，FREAK)特征检测技术与快速直线检测(line segment detector，LSD)算提出一种 SF_6 压力指针式仪表的定位、读数方法，该方法对倾斜、模糊的表盘图像有一定适应性，但缺点是需在光线较强的场合下应用，对表计的图像质量要求较高；文献[11]通过空间变换将圆弧形分布刻度线转换为水平分布，再利用剪影法获取仪表读数。该方法在不同光照条件有较好的识别效果，但整体步骤较繁琐，且户外光照强度并非均匀分布，在此条件下空间变换后将会出现多条直线难以准确读数；文献[12]使用二维码记录了待识别的仪表信息，且通过其进行辅助校正，该方法需要配备额外辅助设备，暂时难以推广。

近年来，深度学习的方法在表计检测领域也有所应用。文献[13]采用 YOLOv5 模型检测仪表后基于霍夫变换的思想进行读数，但该方法仅适用于固定相机、表盘位置的情景，同时在户外诸多干扰条件下将会出现指针误检测，鲁棒性较差；文献[14]提出一种基于 Faster R-CNN 和 U-Net 的目标检测技术的指针式仪表识别方法，该方法运用 Faster R-CNN 实现表盘定位并采取 U-Net 提取指针，该方法在光线条件良好环境下读数准确度较高，但对于图像质量较低，出现反光情况，U-Net 难以分割出指针的轮廓，在光照条件复杂的环境中难以适用。

综上所述，目前关于仪表读数检测的研究多在理想光照条件场景下讨论，对原始图像质量要求较高，仍缺少一种能够适用于恶劣光照条件的表计读数检测方法。为此，本文提出了一种户外开关柜场景下指针式表计读数识别算法。通过文中提出的表盘特征高效检测模型检测出表盘后，根据不同光照条件下的图像特征，采用轮廓提取与概率霍夫变换等传统图像处理技术，弱化非指针特征、准确提取出刻度线与指针位置，从而提升低图像质量下表计读数检测的准确性。

1　适应于户外场景下低成像质量的指针式表计读数检测框架

1.1　读数检测场景特点与方案分析

本文提出的方法旨在解决户外场景下表计图像质量较低的读数检测问题。考虑到文中涉及待检测场景中图像特点，根据不同的光照条件将文中难以检测读数的图像分为 4 类：图像中存在阳光阴影、图像较模糊、图像轻微反光以及图像整体光照条件较暗。

根据以上场景的特点，本文引入深度学习与传统图像处理技术相结合的方法。其中深度学习方法主要应用于表盘检测，其原因在于训练完成的深度学习网络模型在各个场景下的应用具有较强的兼容性、迁移性与鲁棒性，在图像质量较低的情况依旧能较好地实现表盘定位；而在读数检测方面，由于大量场景下的表计指针具有明显的直线特征，概率霍夫变换能根据直线特征迅速检测到指针，其检测过程具有很强的可解释性和操作性，因此概率霍夫变换在读数检测方面仍然有着其不可替代的作用。

1.2　读数检测框架搭建

根据以上分析，文中搭建的适应于户外场景下低成像质量的指针式表计读数检测框架如图 1 所示。该读数检测框架分为表盘、读数检测单元。首先将文中场景图像输入到表盘特征检测网络中检测相应的仪表候选框图像，然后对其进行图像预处理以及基于轮廓检测的二值图重构。最后根据检测到的起始刻度线、指针位置信息采用角度法进行读数计算。

2　表盘特征高效检测模型

户外场景下复杂的光照条件使得表盘的图像呈现不同的特点。比如在光线强烈时出现的反光现

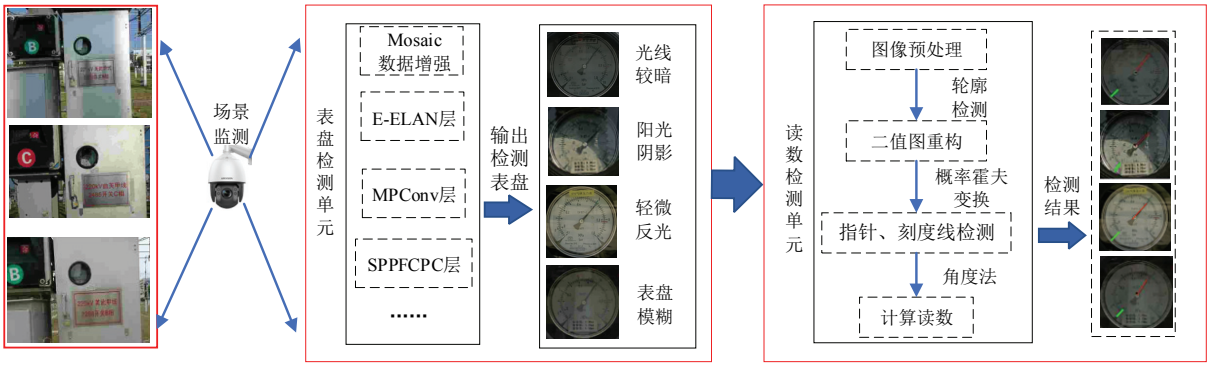


图 1 适应于户外场景下低成像质量的指针式表计读数检测框架

Fig.1 Reading detection framework of pointer meter suitable for low imaging quality in outdoor scene

象，反光条件下表盘图像会出现局部模糊不清从而丧失某些表盘特征，现有的深度学习模型也很难辨识出表盘目标。为此，本文根据应用场景图像像素高、被检测目标小、检测环境复杂的特点在 YOLOv7 算法[15-16]骨干网络处引入有效通道注意力机制(efficient channel attention for deep convolutional neural networks，ECA-Net)[17]，同时采用 CARAFE (content-aware reassembly of features)算子[18]增强头部网络对表盘特征感知能力并使之轻量化，保证文中模型在恶劣光照条件下对表盘的检测精度的同时提升检测速度，更适用于计算性能与存储空间有限的边缘设备。

2.1 引入注意力机制的骨干网络

考虑到文中待检测表盘图像区域在整个场景图像中占比很小，图像中的无效特征较多。为增强网络对表盘特征的提取能力，文中选择在骨干网络末端引入 ECA 注意力机制。具体引入过程见图 2。通过对骨干网络末端输出进行平均池化以获得[1,1,C]维度的聚合特征层，再使用大小为 k 的卷积核进行 1 维卷积以激励(excitation)网络生成特征通道权重，权重生成的具体流程如式(1)所示。

$$\omega=\sigma(C_{1\times1}(P(x))) \tag{1}$$

式中：ω 为生成的特征权重；$C_{1\times1}$(*)表示一维卷积；σ(*)表示归一化 Sigmoid 函数；P(*)表示平均池化；x 表示骨干网络末端输入。

需要说明的是：卷积核大小 k 通过通道维度 C 的映射自适应确定，具体计算关系 Ψ 如式(2)所示。

$$k=\left|\frac{\log_2(C)}{\lambda}+\frac{b}{\lambda}\right|_{\text{odd}} \tag{2}$$

式中：odd 表示取奇数；λ 和 b 用于改变通道数和卷积核大小之间的比例，文中分别取 2 和 1。

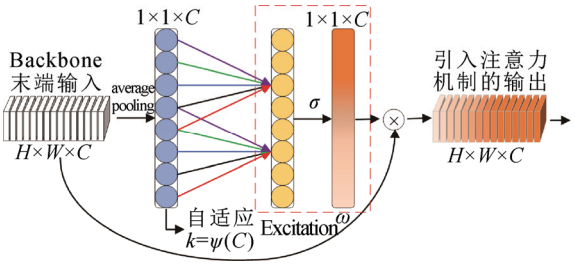


图 2 骨干网络引入的 ECA 注意力机制

Fig.2 ECA attention mechanism introduced by backbone network

最后将生成的各个通道权重映射到骨干网络末端输入，实现局部跨通道信息交互。ECA 模块为模型获得通道注意力机制后，模型将自适应给定通道权重，从而弱化图像背景中无效特征，针对性快速提取表盘特征，实现更高精度、更快速度的表盘检测。

2.2 增强感知能力的轻量化头部网络

文中设备采集的图像像素较高，为增强模型对含有表盘特征图像信息内容的感知处理能力并提升模型的检测速度和精度，在头部网络引入轻量级 CARAFE 算子[18]，并在头部网络中增加轻量化的 SPPFCSPC 结构。

头部网络引入的 CARAFE 上采样主要分为上采样核预测与内容感知重组 2 个模块。上采样核预测模块中生成重组内核具体实现过程包括卷积压缩、内容编码及归一化 3 个步骤(如图 3 所示)：首先使用 1 个 1 维卷积核将输入为 $H\times W\times C$ 特征图通道数压缩至 $H\times W\times C_m$；然后在此基础上使用一个 $k_{\text{encoder}}\times k_{\text{encoder}}$ 的卷积核对内容进行编码并生成 $\sigma H\times\sigma W\times k_{\text{up}}^2$ 上采样内核(k_{encoder} 为编码器卷积核尺寸；σ 为上采样率；k_{up} 为重组内核的尺寸)；最后使

用 Softmax 函数将上采样核进行归一化。内容感知模块使用图 3 中维度为 $k_{up}\times k_{up}$ 上采样内核与原特征图对应位置图块做点积，从而得到上采样的输出值(文中 $k_{encoder}$ 和 k_{up} 取 3，σ 取 2)。

CARAFE 算子计算开销很小，且其可以根据图像中不同位置的内容信息生成重组内核并重组图像特征，拥有着更大感受野与更强感知能力，使得模型更敏锐地检测到表盘特征信息。

此外，为增强模型的轻量化特性，在头部网络中增加轻量化的 SPPFCSPC 结构。SPPFCSPC 结构实际上是对 SPPCSPC 结构的优化(如图 4 所示)，相较于 SPPCSPC 结构，SPPFCSPC 通过将 SPPCSPC 层中空间金字塔池化结构(SPP)的 3 个不同尺度 Maxpool 层进行串接，并取卷积后输出的特征图与 3 个 Maxpool 层输出的特征图进行聚合。如此，网络可获得表盘图像不同维度的感受野，增强模型对不同光照条件下表盘的特征的学习能力，同时也大幅减少模型的参数与运算量，提升模型计算与检测速度，能更迅速地检测出文中表盘特征。

经过以上改进，本文提出的表盘特征高效检测模型网络整体结构如图 5 所示。由于本文模型引入了注意力机制的主干网络与改进的轻量化头部网络，使得模型能很好地适用于文中图像像素高、被检测目标小、检测环境复杂的应用场景。

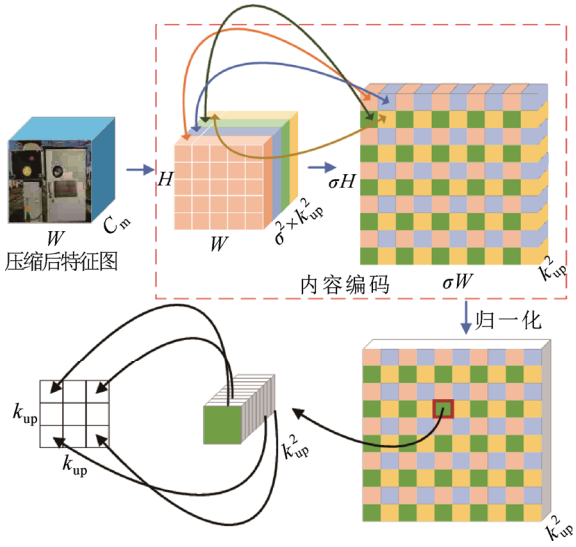


图 3　CARAFE 上采样核预测模块

Fig.3　Up-sampling kernel prediction module

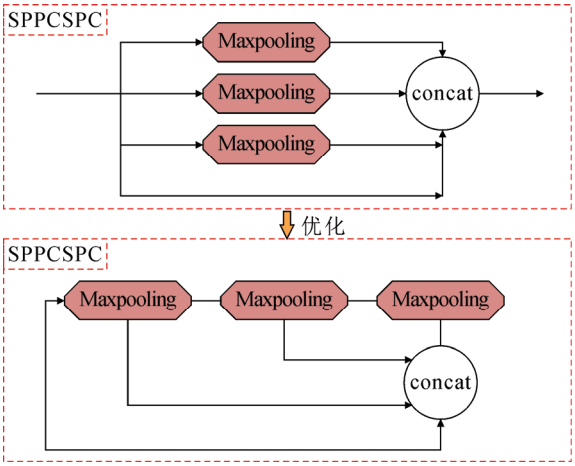


图 4　SPPFCSPC 中对 SPP 结构的优化过程

Fig.4　Optimization process of SPP structure in SPPFCSPC

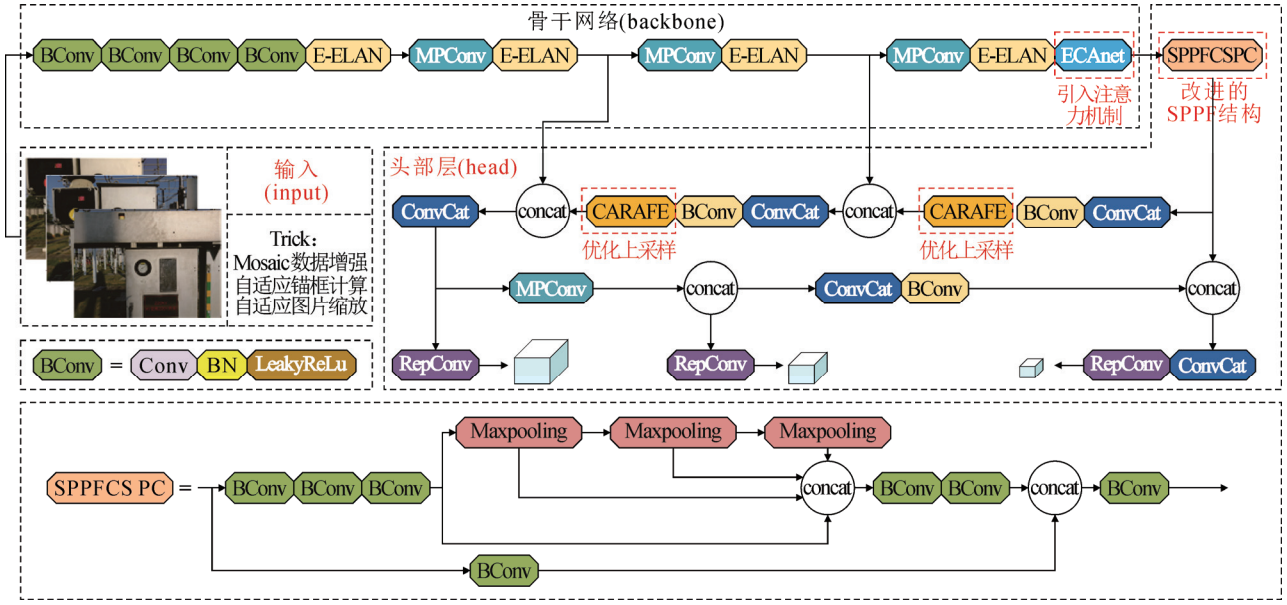


图 5　表盘特征高效检测模型网络结构

Fig.5　Network structure of efficient detection model for dial features

3 表计读数检测

通过巡视设备将待检测图像输入到训练完成的表盘特征高效检测网络模型后，模型会输出检测到的表盘候选框图像，此时根据表盘图像进行读数检测即可获得表计示数。然而由于表计处于户外，表计图像质量将受到诸多因素干扰。针对图像存在的阳光阴影、轻微反光等问题，本文提出了一种基于轮廓检测与概率霍夫变换的指针读数识别方案。

3.1 图像预处理

为提高图像可读性，最大程度简化数据信息，减少运算量，需进行必要的图像预处理流程，以保证后续仪表识读的准确性。本文图像预处理步骤包括图像色阶变换、灰度化、高斯滤波、均值滤波等，下面将阐述文中预处理的具体过程。

色阶变换通过调整表计图像的 RGB 通道值以进行色阶调节，当表盘区域存在阳光阴影时，指针与刻度线在表盘中较难辨认，而这种处理使得表计的指针、刻度线与表盘其他区域对比更明显，明显改善此类场景下指针、起始刻度线难以提取的问题(处理效果见图 6)；均值滤波用于消除表盘图像中非表盘特征的噪声，使图像整体变得平滑；高斯滤波是为图像中的表盘保持更多的原始细节；灰度化则是为了减少图像处理的计算量，提高图像处理效率。

经过上述处理后，最后再将图像转化为二值图。二值图根据图像中的像素值按照一定阈值重新分配新的像素值，从而将仪表图像转化成黑白二值图。二值图可去除仪表盘的一部分由于光线不均匀产生的过暗、过亮区域的影响；此外，由于仪表的二值图只存在黑白两种像素，为后续算法在指针轮廓提取上带来了便利。

3.2 二值图重构

读数检测中最重要的内容是检测指针的位置信息。如果可将仪表的指针区域部分图像与表盘中其他图像噪声分离，指针检测的准确度会大大提升。为实现指针轮廓的提取，文中采用的轮廓提取算法为 Suzuki 算法[19]。其算法原理过程如下。

假设输入的二值图像 $F=\{f(i,j)|i,j=1,2,\cdots,n\}$，其中$(i,j)$为图像中第 i 行第 j 列的像素点，$f(i,j)$为像素点(i,j)处的像素值。T_{NBD} 为轮廓提取扫描过程找到的新边界编号(T_{NBD} 初始值设定为 1)，T_{LNBD} 为扫描过程保存的上一个边界编号。图片从左到右扫描，按照以下两种规律区分：(1)若像素点(i,j)处像素值为 1 且左侧像素点像素值为 0 时，称该像素点为外轮廓起始点，如图 7(a)；(2)若像素值不为 0 的像素点(i,j) 其右侧像素点$(i,j+1)$处像素值为 0 时，称该像素点为孔轮廓起始点，如图 7(b)。

该算法选择像素值不为 0 的点为指定开始点(starting point)，每次扫描新的一行将 T_{LNBD} 的值重置为 1。

在起始点进行扫描时分别进行以下步骤。

步骤 1：判断起始点(i,j)的轮廓点类型

1）当(i,j)是外轮廓点时，$T_{\mathrm{NBD}}=T_{\mathrm{NBD}}+1$，同时将左边$(i,j-1)$点记作$(i_2,j_2)$；

2）当(i,j)是孔轮廓点时，$T_{\mathrm{NBD}}=T_{\mathrm{NBD}}+1$，将右边一点$(i,j+1)$记作$(i_2,j_2)$，$T_{\mathrm{LNBD}}=f(i_3,j_3)$。

步骤 2：在起始点周围寻找边界

1）首先从(i_2,j_2)点起顺时针寻找第 1 个非 0 像素点记作(i_1,j_1)。如果没有找到非 0 像素点，取$f(i,j)=-T_{\mathrm{NBD}}$，并执行 4）；

2）将(i_1,j_1)点记作(i_2,j_2)，以及(i,j)点记作(i_3,j_3)；

3）以像素点(i_2,j_2)为起点围绕(i_3,j_3)按照逆时针顺序扫描，找到的第一个非 0 像素点记作(i_4,j_4)；

4）根据(i_3,j_3+1)像素点的值确定$f(i_3,j_3)$，当其为 0 时，$f(i_3,j_3)=-T_{\mathrm{NBD}}$，当其为 1 时，$f(i_3,j_3)=T_{\mathrm{NBD}}$ 。否则不改变$f(i_3,j_3)$；

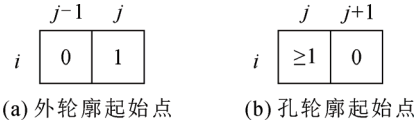
5）如果在上述步骤 3）寻找非 0 像素点时回到起始点，将(i,j)点记作(i_4,j_4)，(i_1,j_1)点记作(i_3,j_3)，并执行步骤 3，否则将(i_3,j_3)记作(i_2,j_2)，将(i_4,j_4)点记作(i_3,j_3)并且回到 3）。

步骤 3：如果$f(i,j)=1$，令 $T_{\mathrm{LNBD}}=|f(i,j)|$并从$(i,j+1)$点处开始扫描，扫描停止的条件是直到扫描到图片的最右下角。



图 6 色阶变换处理前后表盘对比图

Fig.6 Comparison chart of dial before and after color gradation conversion processing



(a) 外轮廓起始点 (b) 孔轮廓起始点

图 7 外轮廓起始点与孔轮廓起始点

Fig.7 Starting points of outer contour and hole contour

具体的扫描过程见图 8，当扫描停止后，根据整个过程中各像素点(i,j)标注的与 T_{NBD} 相关的 $f(i,j)$ 值，可得到相应的轮廓边界序号与轮廓类型。

通过 Suzuki 算法对表盘上指针、刻度线、数字、符号、阴影边界线等各个轮廓特征进行提取后，可根据各个轮廓的特点进行筛选，以保留最关键的指针轮廓进行二值图重构。

具体重构方案如图 9 所示，将检测到的存在阳光阴影的表盘图像预处理为二值图后，首先通过 Suzuki 算法提取表盘的轮廓信息，其中红色边缘轮廓线即表盘中的轮廓信息。此时在其基础上运用 minAreaRect 函数获得各个轮廓框的长、宽以及方框的中心点位置，提取效果如图 9 绿色方框所示。为保证方框位置均处于表盘中心的一定圆区域范围内，此时再界定轮廓筛选的区域(黄色网格区域)，对在此区域内绿色方框的长度、宽度进行筛选后，即可获得保留指针特征的二值图。

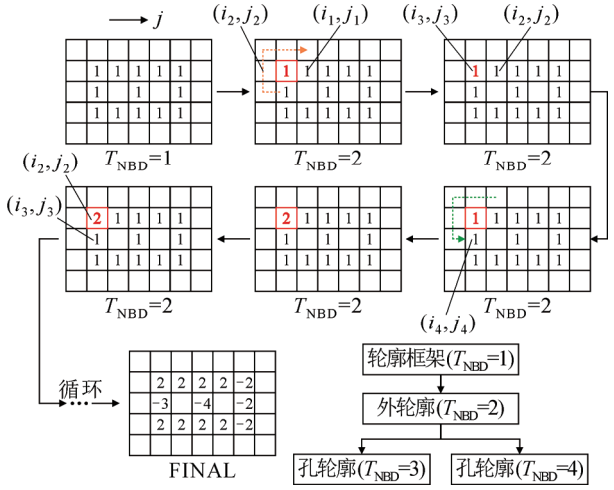


图 8　Suzuki 轮廓提取流程

Fig.8　Suzuki contour extraction process

通过多组图片实验、验证后，本文选择的具体筛选条件为：方框宽度需大于表盘半径的 1/6，方框长度要大于表盘半径的 1/4。通过以上条件对预处理完后的二值图进行特征上的重构后，可保留关键的指针特征，排除阳光阴影、表盘字符、刻度线以及污渍的影响，保证后续算法在指针检测过程提取指针的准确性。

3.3　指针及表盘中心位置确认

经过二值图重构后，此时确认指针的方向只需要经过霍夫直线检测即可。霍夫变换是直线检测问题的常用方法，其运用了点-线对偶思想，将原始图像空间中具有一定形状的直线、曲线通过变换映射到其他空间变换为某个点，从而将形状检测问题转换为峰值统计问题[20]。

概率霍夫变换是对霍夫变换方法的改进，概率霍夫变换并不考虑所有像素点，选取部分点集后进行霍夫变换拟合直线，当某一条直线被拟合的次数超过一定阈值时，便认为拟合成功，从而得到线段的方向与范围[21]。概率霍夫变换较传统霍夫变换误检测概率低、鲁棒性强，检测速度、效率也得到一定提升，因此文中采用概率霍夫变换方法来提取指针。在重构的二值图中，由于指针轮廓较粗，会检测出多条直线，而指针尖端较细，因此可以认为检测出最长的一条直线即为指针方向。指针检测的实际效果图如图 10 所示。

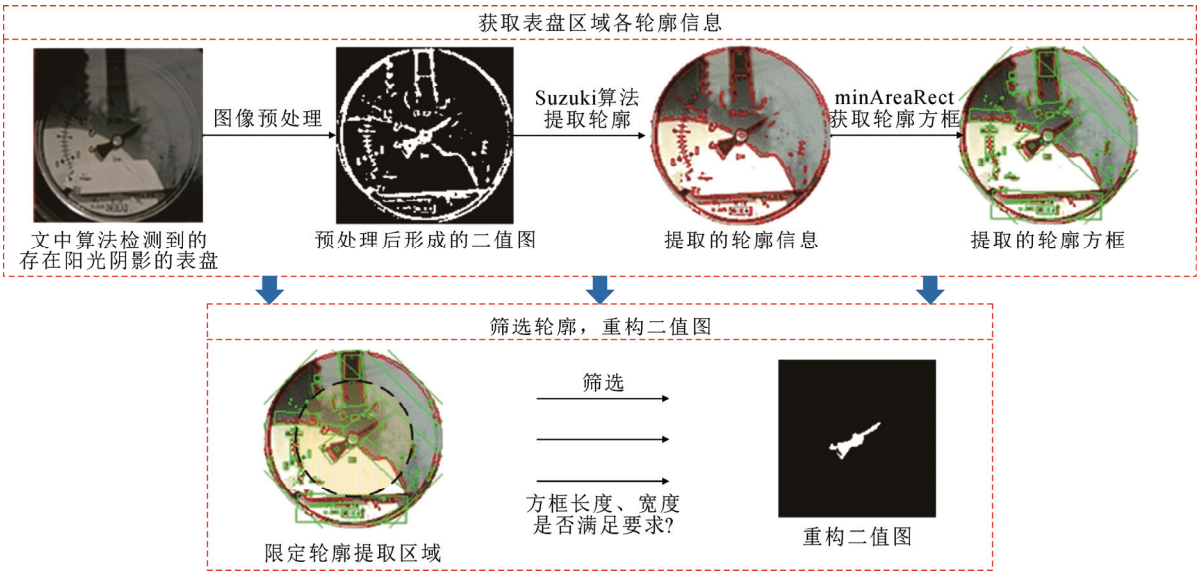


图 9　二值图重构方案

Fig.9　Binary graph reconstruction scheme

此外，为进行后续读数计算需确定表盘圆心位置。由于在表盘特征检测网络输出的候选框图像的主体为圆形表盘，霍夫圆检测能准确地提取出表盘中心坐标，故文中选择该方法检测表盘中心坐标。

3.4 起始刻度线确认与读数

本文研究的表计均为文中展示的类型，其表盘盘面刻度线分布均匀，相邻刻度线间对应的数值间隔相等，同时表盘量程均为已知信息，提前输入至算法中，因此在获取指针位置信息后，只需确认起始刻度线的位置，即可使用角度法获取表计的读数。而对于起始刻度线的确认，静态场景下，当摄像头镜头平面固定在与仪表盘面平行位置时，确认指针式仪表零刻度线只需要在识读时给定其角度位置；非静态场景下，则可以采用人工选择法或是检测某些特征轮廓来确认起始刻度线。

由于文中所涉及场景下的表计表盘的起始刻度线在形态与位置具有一定特征，据此本文提出了一种起始刻度线确认方法。

在对表计表盘二值图进行霍夫直线检测后，界定检测到直线的区域范围，将其范围限定在表盘区域 S1、S2。如图 11 所示，区域 S1 包含始端刻度线，区域 S2 则包含末端刻度线，文中读数仅涉及起始刻度线。而阳光阴影、刻度线、文字、污渍同样会在上述检测区域中形成干扰，在霍夫变换检测直线的过程中，会检测到多条干扰直线。因此在检测完相关直线后，还需要对区域 S1 检测到的直线长度以及斜率进行筛选，以获得始端刻度线。经推理与实验，认为起始刻度线的长度需要大于表盘半径的 1/7，其斜率变化范围在 30°～60°。经过上述筛选即可得到起始刻度线的坐标信息。标注示例在图 11 已指出。需要说明：由于表盘处于户外，受光照条件影响较大，当由于反光、表盘有污渍或算法原因无法检测到起始刻度线时，将默认为表盘正置并与摄像头平行，起始刻度线处于固定位置。

当确认了起始刻度线与指针位置时，即可计算读数。设起始刻度线与指针的夹角为 α_1，始末刻度线之间的夹角 α_2=1.5π。读数 n 计算式如式(3)：

$$n=\frac{\alpha_1}{\alpha_2}\times l+0.1 \tag{3}$$

式中：l 为量程。

4 算法测试与分析

4.1 数据集与实验环境描述

为验证本文所提方法在户外开关柜场景下读数的有效性，在某变电站 220 kV 开关柜采集了 1 343 张不同的仪表图像构建成样本库进行读数检测实验，图像像素包括 4 000×3 000、2 200×1 800 不等。样本库中场景图像示例如图 12 所示，其中包含户外场景下存在阳光阴影、轻微反光、光线较暗以及图像模糊等情况。

取总数据集中 80%的图像(1 074 张)作为模型的训练集。训练集使用 LabelImg 对表计的位置与类别进行标注，其标签类别命名为 FR_SF6。此外选取其中 200 张图像在表盘检测以及读数检测两个过程中进行测试。具体数据集、训练集与测试集构成见表 1。测试所用服务器配置为乌班图系统 Ubantu16.04，包含双核 11 GB GPU 的 GeForce GTX 1080Ti 显卡，64 G 内存。



图 10 概率霍夫变换检测到的指针

Fig.10 Probabilistic Hough transform detected pointer

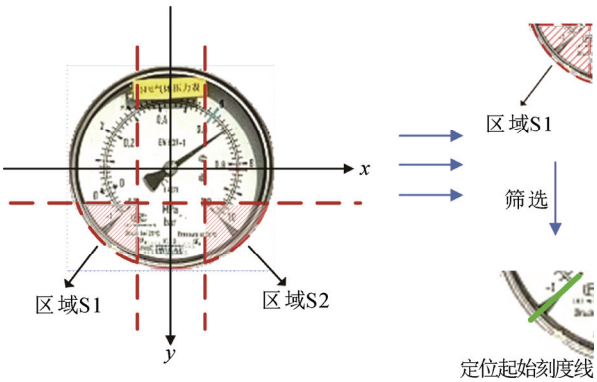


图 11 起始刻度线检测过程

Fig.11 Initial tick mark detection process



图 12 文中涉及的检测场景

Fig.12 Detection scenario involved in the text

4.2　评价指标与对照组设置

1）表盘检测

在定义评价指标前，对表盘检测结果正确、误检、漏检的评判标准进行说明。当检测框与标注的真实框的交并比(IOU)大于 0.8 时，认为检测结果正确；当交并比小于 0.8 时，认为检测结果错误；被检测图像中含有表盘图像而未检测到有候选框时，认为检测结果误检。

表盘在评价指标上选择参数误检率、漏检率来进行评估，其中误检率 F 定义为：

$$F=\frac{F_{\mathrm{P}}}{F_{\mathrm{P}}+T_{\mathrm{P}}} \tag{4}$$

式中：F_{P} 为非表计目标检测为表计的错误次数；T_{P} 为表计目标检测正确的次数。

漏检率 M 定义为：

$$M=\frac{F_{\mathrm{N}}}{T_{\mathrm{P}}+F_{\mathrm{N}}} \tag{5}$$

式中：F_{N} 为未识别图像中表计的次数。

在算法测试部分，为验证本文算法各模块作用对算法中各个模块进行定量、定性分析，定量、定性分析过程将进行消融实验、不同注意力机制模型对比实验，其中对比的注意力机制包括：SE-Net (squeeze-and-excitation networks)[22-23] 、CBAM (convolutional block attention module)[24]、CA-Net (coordinate attention for efficient mobile network design)[25]。此外，为检验文中算法在表盘检测方面的优势，选取 YOLOv5、YOLOv7、Faster R-CNN[26] 模型作为目标检测对照组。Faster R-CNN 是 two-stage 目标检测模型的典型代表，对于小目标的检测具有较好的性能，在目标检测领域应用十分广泛，因此将其模型作为文中的对照组[27]。

2）读数检测

在评价指标下认为读数相对误差在±3%范围内读数准确；读数相对误差在±3%~±5%认为读数有偏差；读数相对误差在±5%以上的认为读数错误。

同时在对照实验设置上，选取传统的霍夫变换算法及 SAM(segment anything model)模型分别进行指针提取实验。SAM 模型是一个基于广泛数据集训练的图像分割模型，该模型具有优秀的零样本分割性能，甚至优于完全监督模型[28]。在上述对照实验中，根据数据集中的图像类型分别在阳光阴影、轻微反光、光线较暗、图像模糊、正常光照等 5 个场景下进行测试。

4.3　表盘检测

将制作好的训练集输入模型进行训练前，需要确定模型训练参数。由于本文训练集的图像像素较高，为提升模型训练效率，在经过多次训练后确定网络具体的训练参数如表 2 所示。

训练完成后，将文中场景中的图像输入到文中模型与对比模型进行测试，实验过程中不同的模型使用的数据集与测试环境均相同。下面将基于测试结果分别进行定量、定性分析。

4.3.1　数据集结果定量分析

为验证算法各模块作用首先进行消融实验，其实验结果如表 3 所示。从表 3 可见，文中模型采用的 ECA 注意力机制、SPPFCSPC 结构与 CARAFE 上采样方式对于模型的推理速度与精度均有小幅提升。整体模型相比于 YOLOv7 模型在误检率与漏检率上均降低了 0.51%，单张图像的平均耗时减少了 8.2 ms，综合提升了模型的检测性能。

此外，为验证文中引入注意力机制在表盘目标检测上的有效性，本文模型分别与 YOLOv7-SE、YOLOv7-CBAM、YOLOv7-CA 目标检测模型进行

表 1　表计图像样本库具体说明

Table 1　Specific Description of Meter Image Sample Library

图像类别	总数据集数据	训练集数据	测试集数据
阳光阴影	178	142	59
轻微反光	187	150	60
光线较暗	123	98	27
图像模糊	103	82	14
正常光照	752	602	40
总计	1343	1074	200

表 2　表盘特征高效检测模型训练参数

Table 2　Training parameters of dial feature efficient detection model

参数	设置数值	备注
Epochs	300	数据集参与训练次数
Batch size	8	单次训练样本数
Learning rate	0.01	学习率

表 3　消融实验结果

Table 3　Results of ablation experiment

模型	ECA	SPPFCSPC	CARAFE 算子	误检率/%	漏检率/%	平均耗时/ms
YOLOv7				1.515	1.015	36.3
模型 1	√			1.507	0.508	30.2
模型 2		√		1.015	1.515	30.5
模型 3			√	1.010	1.010	29.1
文中模型	√	√	√	1.005	0.505	28.1

分析与对比，各模型的测试结果见表 4。

由表 4 分析可知：1）相较于 YOLOv7 模型，YOLOv7-SE 模型由于注意力机制的引入，漏检率指标明显降低，同时检测的平均耗时有一定减少，但误检率有所提升。2）相较于 YOLOv7 模型，YOLOv7-CBAM 模型检测平均耗时增加，在漏检率、误检率指标上也没有取得更好的效果。3）相较于 YOLOv7 模型，YOLOv7-CA 模型误检率下降，但与之相伴的漏检率有所提升。4）本文模型相较于 YOLOv7-SE、YOLOv7-CBAM、YOLOv7-CA 模型，虽然平均耗时略微长于 YOLOv7-SE 模型，但其具有最低的误检率与误检率。上述结果表明，文中增加的 ECA 模块可以增强模型对表盘特征与非表盘特征的辨识能力，在检测速度与检测精度上均有提升。

最后，在上述实验的基础上，为进一步验证文中模型优势，将其与 YOLOv5、YOLOv7、Faster R-CNN 进行对比实验，见表 5。

对比表 5 中数据发现，本文训练完成的表盘特征高效检测模型相对于 YOLOv5、YOLOv7、Faster R-CNN 模型拥有更好的性能。本文模型在误检率与错检率 2 个指标上均低于以上模型的同时，在表盘检测的速度上也有明显的优势。

4.3.2 数据集结果定性分析

本文模型在各个场景下的检测效果示意图如图 13 所示。可以观察到图像反光场景下，由于图像反光表盘图像区域存在其他物体的倒影，使得模型检测出表盘的难度增大。因此，定性分析中需选取图像反光场景重点讨论。

引入的不同注意力机制模型对比效果图如图 14 所示(图中右上角、右下角附有放大的检测效果图)。分析图 14 可发现，相较于 SE、CBAM 与 CA 注意力机制，本文模型在展示图像中表盘识别置信度均高于其他注意力机制的识别置信度，在文中待识别的场景具有显著优势。这主要得益于本文模型引入注意力机制使用的自适应一维卷积策略，该策略可以在不改变输入特征图大小情况下，通过无降维的局部跨通道信息交互生成特征通道权重，从而弱化图像背景中无效特征，实现更高精度、更快速度的表盘检测。

为验证本文模型相较于其他模型优异的检测性能，文中进行了各模型图像反光场景下表盘检测实验，具体测试对比示意图见图 15(图中右上角、

表 4 不同注意力机制模型实验测试结果对比

Table 4 Comparison of experimental test results of different attention mechanism models

模型	误检率/%	漏检率/%	平均耗时/ms
YOLOv7-SE	1.523	0.510	27.5
YOLOv7-CBAM	2.525	1.026	37.3
YOLOv7-CA	1.015	2.010	36.8
本文模型	1.005	0.505	28.1

表 5 表盘特征高效检测模型测试结果

Table 5 Test results of efficient detection model for dial features

模型	误检率/%	漏检率%	平均耗时/ms
YOLOv5	2.020	1.020	41.3
YOLOv7	1.515	1.015	36.3
Faster R-CNN	1.531	2.030	56.8
本文模型	1.005	0.505	28.1

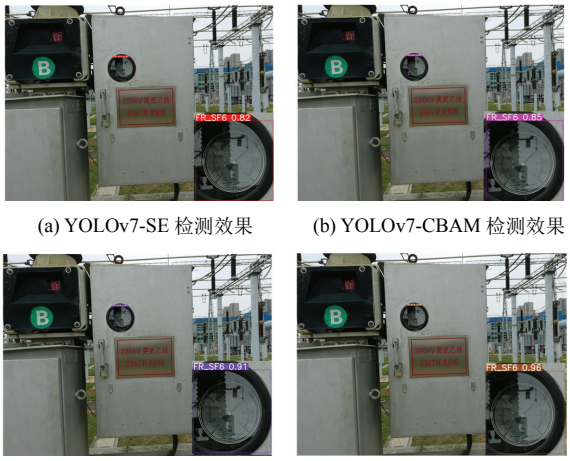


(a) 正常光照场景 (b) 轻微反光场景

(c) 阳光阴影场景 (d) 光线较暗场景

图 13 SF_6 气压表检测结果

Fig.13 Test results of SF_6 barometer



(a) YOLOv7-SE 检测效果 (b) YOLOv7-CBAM 检测效果

(c) YOLOv7-CA 检测效果 (d) 本文模型检测效果

图 14 图像反光场景不同注意力机制模型表盘检测测试结果

Fig.14 Test results of dial detection of different attention mechanism models in image reflective scene

右下角附有放大的检测效果图)。分析图 15 虚线方框内的测试图发现，由于反光条件下表盘成像模糊，Faster R-CNN 模型未能检测出表盘。而本文模型成功检测出表盘目标，并且相较于 YOLOv5、YOLOv7 检测模型具有更高的检测置信度。此外，从蓝色虚线方框内的测试图发现，文中模型相较于 YOLOv7 表盘检测模型表现出更强的鲁棒性与泛化性。这主要体现在：对于场景内的表盘目标，本文模型检测置信度更高；而对于场景内非表盘目标而疑似表盘目标，本文模型也有更好的区分度。上述测试结果说明，本文模型在图像反光场景下对于表盘具有更强的辨识能力，有利于后续基于检测框的读数检测过程。

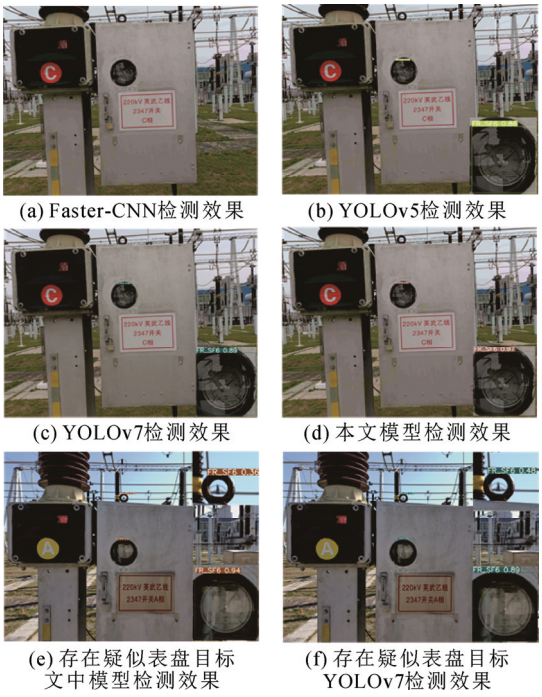
总结 4.3 节实验，得到结论如下：1）在户外不同光照条件下，本文模型可出色地检测到存在阳光阴影、轻微反光、光线较暗场景下的表盘区域。甚至在一些由于光线条件恶劣致使图像成像质量较低的场景下，本文模型依旧能够以高置信度检测到表盘区域。2）文中算法改进的模块有效提升了模型对表盘的检测速度与检测精度。

4.4　读数检测

经表盘检测后，采用文中 4.3 节使用的方法对包含表盘检测框的图像进行读数检测。被检测的图像包括表盘模糊、阳光阴影、轻微反光、光线较暗、正常光照等场景，具体的读数检测效果见图 16，不同场景图像的读数识别结果见表 6。

通过表 6 数据可以发现，本文模型对于户外存在阳光阴影、轻微反光以及光线较暗的几个场景均有较好的适应性。此外测试的 200 张图像中，去除掉被错检、漏检的表盘图像，其中被正确检测到表盘的图像 197 张，读数准确的图像 185 张，读数检测的准确率为 93.91%，读数有偏差的图像 9 张，其偏差率为 4.06%；读数不准确的图像 3 张，其错误率为 1.52%。

为体现本文算法对于户外场景下指针识别的准确性，使用传统的霍夫变换算法与 SAM 模型检测指针的方法作为对照。



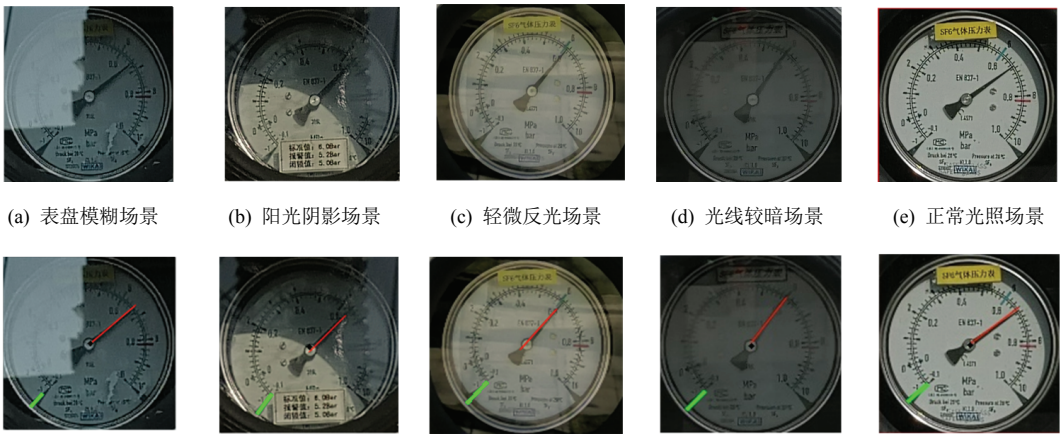
(a) Faster-CNN检测效果　(b) YOLOv5检测效果

(c) YOLOv7检测效果　(d) 本文模型检测效果

(e) 存在疑似表盘目标文中模型检测效果　(f) 存在疑似表盘目标YOLOv7检测效果

图 15　图像反光场景不同模型表盘检测测试结果

Fig.15　Test results of different model dials in the reflective scene of images



(a) 表盘模糊场景　(b) 阳光阴影场景　(c) 轻微反光场景　(d) 光线较暗场景　(e) 正常光照场景

(f) 表盘模糊场景读数检测效果　(g) 阳光阴影场景读数检测效果　(h) 轻微反光场景读数检测效果　(i) 光线较暗场景读数检测效果　(j) 正常光照场景读数检测效果

图 16　读数检测效果示意图

Fig.16　Schematic diagram of reading detection effect

表 6 读数识别结果

Table 6 Reading recognition result

图片	算法读数	人工读数	绝对误差
图 16(a)	0.663	0.661	0.002
图 16(b)	0.645	0.641	0.004
图 16(c)	0.610	0.613	0.003
图 16(d)	0.608	0.606	0.002
图 16(e)	0.670	0.676	0.006

在对照实验中正确提取指针的标准如下：本文算法与传统的霍夫变换算法能用红色线段准确拟合出指针位置，则认为其指针提取正确；SAM 模型能完整分割出指针轮廓，则认为其指针提取正确。对上述 199 张图像不同算法的指针识别测试结果见表 7。上述实验中典型图像指针识别具体效果对比图分别如图 17、18、19 所示。

图 17(a)中图像从左到右依次是待检测的表盘图像、对应二值图及检测到的指针示意图(指针用红色线段标出)。而图 17(b)中图像从左到右依次是待检测的表盘图像、文中重构二值图后保留指针特征的效果图以及标注的指针示意图。可以观察到，由于在户外场景下，成像质量受诸多因素影响，当图像中存在阳光阴影或反光带来的干扰噪声时，该类噪声将会形成诸多不利于霍夫直线检测的特征，从而出现指针误检测的情况。

图 18 与图 19 中，图 18(a)、图 19(a)为待检测的表盘图像、SAM 模型分割指针的效果图，其分割出的指针用轮廓线标注。图 18(b)、图 19(b)则是文中算法提取指针的效果图。可以观察到，图 18 中虽然存在轻微反光现象，但此时表盘中指针图像质量较高，图像分割以及本文方法均能很好地提取出指针轮廓。而当图像中指针图像质量较低时(如图 19 所示)，由于反光在图像中形成光斑，此时指针图像中特征被弱化，SAM 模型不能分割出对应的指针。而本文方法是基于轮廓检测后的长度、宽度等特征，可根据部分指针图像定位出指针的位置。

经过以上测试、对比得到，本文方法较直接霍夫变换方法在指针定位上有更高的精确度；同时相较于 SAM 模型，由于户外场景下表盘图像质量参差不齐，在轻微反光、光线较暗场景下，本文方法对指针位置的提取有更强的鲁棒性，可满足户外场景下表计图像质量较低时的读数需求。

表 7 不同算法在各场景下的指针识别结果对比

Table 7 Comparison of pointer recognition results of different algorithms in various scenarios

算法	指针提取正确数/张				
	表盘模糊	阳光阴影	轻微反光	光线较暗	正常光照
Hough	5	11	29	14	38
SAM	11	57	49	24	40
文中算法	12	56	56	25	40



(a) Hough 变换指针检测效果



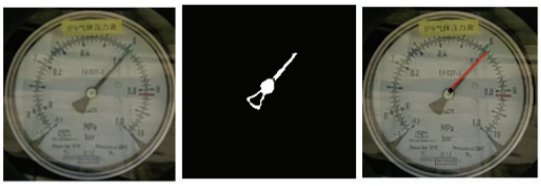
(b) 文中方法指针提取效果

图 17 霍夫变换指针检测效果对比

Fig.17 Comparison of detection effect of Hough transform pointer



(a) SAM 模型指针分割效果(指针图像质量高)



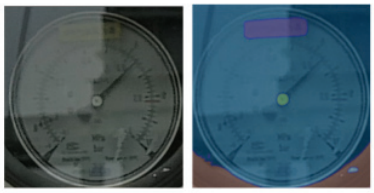
(b) 文中指针提取效果(指针图像质量高)

图 18 SAM 模型指针检测效果对比(指针图像质量高)

Fig.18 Comparison of SAM model pointer detection effects (high pointer image quality)

5 结论

本文主要针对复杂光照条件下变电站指针式表计读数场景，提出了一种表盘特征高效检测模型与概率霍夫变换算法相结合的读数检测方法。通过实验验证得到结论如下：



(a) SAM 模型指针分割效果



(b) 文中方法指针提取效果

图 19　SAM 模型指针检测效果对比(指针图像质量低)

Fig.19　Comparison of SAM model pointer detection effects(low pointer image quality)

1）本文提出的表盘特征高效检测模型对于复杂光照场景下的表盘目标的误检率与漏检率分别为 1.005%与 0.505%，单张图像的检测平均耗时为 28.1 ms，相较于 YOLOv7 模型在误检率与漏检率上均降低 0.51%，单张图像的检测速度提升 22.6%，综合提升了模型的检测性能。

2）对于户外场景设备采集图像质量较低的情况，文中基于轮廓检测重构二值图的检测算法相较于图像分割以及传统霍夫变换的方法有更强的鲁棒性和更高的精确度。在复杂光照场景下，本文方法读数检测的准确率为 93.91%、偏差率为 4.06%、错误率为 1.52%，可显著去除图像模糊、图像较暗、图像反光以及存在阳光阴影等负面影响，精确检测表计读数。

3）本文提出的适应于户外场景下低成像质量的指针式表计读数检测框架利用了深度学习模型在恶劣光照条件下表盘检测性能稳定的特点，同时发挥了传统图像处理技术可解释性、操作性强的优势，为电力仪表读数检测提供了新的思路。

参考文献　References

[1] 许　丽，石　伟，方　甜. 巡检机器人中的指针式仪表读数识别系统[J]. 仪器仪表学报，2017，38(7)：1782-1790.
XU Li, SHI Wei, FANG Tian. Pointer meter reading recognition system used in patrol robot[J]. Chinese Journal of Scientific Instrument, 2017, 38(7): 1782-1790.

[2] 韩绍超，徐遵义，尹中川，等. 指针式仪表自动读数识别技术的研究现状与发展[J]. 计算机科学，2018，45(增刊 1)：54-57.
HAN Shaochao, XU Zunyi, YIN Zhongchuan, et al. Research review and development for automatic reading recognition technology of pointer instruments[J]. Computer Science, 2018, 45(Supplement 1): 54-57.

[3] 房　桦，明志强，周云峰，等. 一种适用于变电站巡检机器人的仪表识别算法[J]. 自动化与仪表，2013，28(5)：10-14.
FANG Hua, MING Zhiqiang, ZHOU Yunfeng, et al. Meter recognition algorithm for equipment inspection robot[J]. Automation & Instrumentation, 2013, 28(5): 10-14.

[4] 罗　鹏，王　波，马恒瑞，等. 基于组合式目标检测框架的低漏报率缺陷识别方法[J]. 高电压技术，2021，47(2)：454-462.
LUO Peng, WANG Bo, MA Hengrui, et al. Defect recognition method with low false negative rate based on combined target detection Framework[J]. High Voltage Engineering, 2021, 47(2): 454-462.

[5] 胡金磊，朱泽锋，林孝斌，等. 变电站无人机机巡边缘计算框架设计及资源调度方法[J]. 高电压技术，2021，47(2)：425-433.
HU Jinlei, ZHU Zefeng, LIN Xiaobin, et al. Framework design and resource scheduling method for edge computing in substation UAV inspection[J]. High Voltage Engineering, 2021, 47(2): 425-433.

[6] 张迎晨，王　波，马富齐，等. 基于域适应网络的电力设备不规则外表面缺陷高精度检测方法[J]. 高电压技术，2022，48(11)：4516-4526.
ZHANG Yingchen, WANG Bo, MA Fuqi, et al. High-precision detection method of irregular outer surface defects of power equipment based on domain adaptation network[J]. High Voltage Engineering, 2022, 48(11): 4516-4526.

[7] 王　波，张迎晨，齐冬莲，等. 数字化安全管控视角下的全息影像：定义、基本框架及关键技术[J]. 高电压技术，2023，49(8)：3335-3345.
WANG Bo, ZHANG Yingchen, QI Donglian, et al. Holographic images for digital security control: definition, basic framework and key technologies[J]. High Voltage Engineering, 2023, 49(8): 3335-3345.

[8] 闫龙川，刘军，何永远，等，张林锋. 基于机器视觉的数据中心机房安全管控技术研究与应用[J]. 电力信息与通信技术，2023，21(5)：42-47.
YAN Longchuan, LIU Jun, HE Yongyuan, et al. Research and application of security management and control technology in data center computer room based on machine vision[J]. Electric Power Information and Communication Technology, 2023, 21(5): 42-47.

[9] 房　桦，明志强，周云峰，等. 一种适用于变电站巡检机器人的仪表识别算法[J]. 自动化与仪表，2013，28(05)：10-14.
Fang Hua, Ming Zhiqiang, Zhou Yunfeng, et al. An instrument recognition algorithm suitable for substation inspection robots[J]. Automation and Instrumentation, 2013, 28 (05): 10-14.

[10] 赵丽娜，赵丽娟，宁子达，等. 一种 SF_6 压力指针式仪表的定位识别方法[J/OL]. 电测与仪表，2022：1-11[2023-03-06]. http://kns.cnki.net/kcms/detail/23.1202. TH. 20221103.1102.002. html.
ZHAO Lina, ZHAO Lijuan, NING Zida, et al. A positioning recognition method for SF_6 pressure pointer meter[J/OL]. Electrical Measurement & Instrumentation, 2022: 1-11[2023-03-06]. http://kns.cnki.net/kcms/detail/23.1202.TH.20221103.1102.002.html.

[11] 汤　亮，何　稳，李　倩，等. 基于空间变换的指针式仪表读数识别算法研究[J]. 电测与仪表，2018，55(6)：116-121.
TANG Liang, HE Wen, LI Qian, et al. The algorithm for the recognition of pointer type meter based on space transformation[J]. Electrical Measurement & Instrumentation, 2018, 55(6): 116-121.

[12] 陈梦迟，黄文君，张阳阳，等. 基于机器视觉的工业仪表识别技术研究[J]. 控制工程，2020，27(11)：1995-2001.
CHEN Mengchi, HUANG Wenjun, ZHANG Yangyang, et al. Research on industrial analog instrument recognition based on machine vision[J]. Control Engineering of China, 2020, 27(11): 1995-2001.

[13] 王　康，陆生华，陈　潮，等. 基于 YOLOv5 的指针式仪表检测

与读数识别算法研究[J]. 三峡大学学报(自然科学版)，2022，44(6)：42-47.
WANG Kang, LU Shenghua, CHEN Chao, et al. Research on detection and reading recognition algorithm of pointer instrument based on YOLOv5[J]. Journal of China Three Gorges University (Natural Sciences), 2022, 44(6): 42-47.

[14] 万吉林，王慧芳，管敏渊，等. 基于 Faster R-CNN 和 U-Net 的变电站指针式仪表读数自动识别方法[J]. 电网技术，2020，44(8)：3097-3105.
WAN Jilin, WANG Huifang, GUAN Minyuan, et al. An automatic identification for reading of substation pointer-type meters using Faster R-CNN and U-Net[J]. Power System Technology, 2020, 44(8): 3097-3105.

[15] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]// Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver, Canada: IEEE, 2023: 7464-7475.

[16] 宋智伟，黄新波，纪　超，等. 基于 Flexible YOLOv7 的输电线路绝缘子缺陷检测和故障预警方法[J]. 高电压技术，2023，49(12)：5084-5094.
SONG Zhiwei, HUANG Xinbo, JI Chao, et al. Insulator defect detection and fault warning method for transmission line based on flexible YOLOv7[J]. High Voltage Engineering, 2023, 49(12): 5084-5094.

[17] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]// Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE, 2020: 11531-11539.

[18] WANG J Q, CHEN K, XU R, et al. CARAFE: content-aware ReAssembly of FEatures[C]// Proceedings of 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South): IEEE, 2019: 3007-3016.

[19] SUZUKI S, BE K A. Topological structural analysis of digitized binary images by border following[J]. Computer Vision, Graphics, and Image Processing, 1985, 30(1): 32-46.

[20] DUDA R O, HART P E. Use of the Hough transformation to detect lines and curves in pictures[J]. Communications of the ACM, 1972, 15(1): 11-15.

[21] 胡　彬，赵春霞. 基于概率霍夫变换的快速车道线检测方法[J]. 微电子学与计算机，2011，28(10)：177-180.
HU Bin, ZHAO Chunxia. A fast lane detection method based on the progressive probabilistic Hough transform[J]. Microelectronics & Computer, 2011, 28(10): 177-180.

[22] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018: 7132-7141.

[23] 刘国特，周锦辉，宋新明，等. 基于超分辨注意力机制改进的 GIS 内部细微缺陷 X-DR 图像检测方法[J]. 高电压技术，2021，47(11)：3803-3809.
LIU Guote, ZHOU Jinhui, SONG Xinming, et al. Improved X-DR image detection method for GIS internal defects based on super-resolution attention mechanism[J]. High Voltage Engineering, 2021, 47(11): 3803-3809.

[24] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]// Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer, 2018: 3-19.

[25] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design[C]// Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, USA: IEEE, 2021: 13708-13717.

[26] 来广志，樊　涛，王　栋，等. 基于改进特征增强 Faster-RCNN 的光伏电站烟雾检测方法[J]. 电力信息与通信技术，2023，21(1)：19-25.
LAI Guangzhi, FAN Tao, WANG Dong, et al. Improved smoke detection method for photovoltaic power station based on feature-enhanced Faster-RCNN[J]. Electric Power Information and Communication Technology, 2023, 21(1): 19-25.

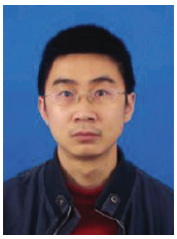
[27] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[28] KIRILLOV A, MINTUN E, RAVI N, et al. Segment anything[EB/OL]. arXiv: 2304.02643, 2023.



刘　萌(通信作者)
1999—，硕士生
研究方向为电力深度视觉
E-mail: lmmwhu@whu.edu.cn

LIU Meng
Corresponding author



王　波
1979—，男，博士，教授，博导
研究方向为电力深度视觉、边缘计算和电力大数据
E-mail: whwdwb@whu.edu.cn

WANG Bo
Ph.D., Professor

收稿日期　2023-07-30　修回日期　2024-01-15　　编辑　卫李静