

# 基于深度回归的指针仪表读数识别方法\*

彭昆福<sup>1</sup>, 王子磊<sup>1</sup>, 王磊<sup>2</sup>, 顾杨<sup>2</sup>

(1 中国科学技术大学 信息科学技术学院, 安徽 合肥 230027;

2. 国网安徽省电力有限公司检修分公司, 安徽 合肥 231131)

**摘要:** 现有仪表读数识别方法通过检测指针和刻度获取读数, 对输入的仪表图像质量要求较高, 为此提出一种新的基于深度回归的指针仪表读数识别方法。该方法首先由仪表图像获取图像特征, 然后通过方向回归模块预测指针方向, 最后根据指针角度计算仪表读数。相比于其他方法, 该方法采用端到端的回归方式进行直接学习, 具有更强的识别能力。在较大规模变电站仪表图像数据集上, 该方法取得了 97.2% 的读数精度, 相比于基于 Mask R-CNN 的仪表读数识别方法提高了 7.4%。定性分析和定量分析结果表明, 相比于现有的仪表读数识别方法, 该方法对表盘图像干扰具有更强的鲁棒性。

**关键词:** 指针仪表; 读数识别; 深度学习; 端到端; 回归; 鲁棒性

中图分类号: TP319.4

文献标识码: A

DOI: 10.19358/j.issn.2096-5133.2020.12.007

引用格式: 彭昆福, 王子磊, 王磊, 等. 基于深度回归的指针仪表读数识别方法[J]. 信息技术与网络安全, 2020, 39(12): 37-43.

## Pointer meter reading recognition by deep regression

Peng Kunfu<sup>1</sup>, Wang Zilei<sup>1</sup>, Wang Lei<sup>2</sup>, Gu Yang<sup>2</sup>

(1. School of Information Science and Technology, University of Science and Technology of China, Hefei 230027, China;

2. State Grid Anhui Maintenance Company, Hefei 231131, China)

**Abstract:** Existing pointer meter recognition methods usually predict the results by detecting pointer and scale marks, thus require high-quality meter images, which have weak robustness to interferences such as dial blurring, glistening, stains, and yellowing. To address this issue, we propose an end-to-end pointer meter reading recognition method by deep regression, which firstly extracts rich features from the meter image, then regresses the orientation of the pointer using an orientation regression module, and finally calculates the value of the meter reading from the pointer angle. Benefitted from the end-to-end training and novel regression way, our proposed method can achieve better recognition performance. We conduct experiments on a large scale dataset of pointer meters of substations and our method achieves an average recognition accuracy of 97.2%, which is higher by 7.4% than the Mask R-CNN based method. Qualitative and quantitative analysis results show that our method possesses stronger robustness to various dial interferences than the existing method.

**Key words:** pointer meter; reading recognition; deep learning; end-to-end; regression; robustness

## 0 引言

随着数字化、智能化的普及, 大部分工业场景都采用数字仪表, 但是对于电力行业, 指针仪表由于其稳定性、抗干扰性优势, 仍广泛应用于我国的电力实际监控中<sup>[1]</sup>。但大部分指针仪表的读取仍依靠人工进行, 要求工作人员到现场进行数据记录,

费时费力、容易出错。因此, 指针仪表读数自动识别技术的研究具有重要意义<sup>[2]</sup>。

关于指针仪表自动识别的研究早期已经出现, 这些工作<sup>[3-6]</sup>主要基于传统计算机视觉技术。参照人工仪表读数的原理, 传统方法大致由仪表检测、仪表分类、仪表校正、预处理、指针检测、刻度检测、读数计算几个步骤组成, 但由于采用表征能力比较弱的人工图像描述方法, 同时又依赖比较强的

\* 基金项目: 国家自然科学基金(61673362); 国网安徽省电力有限公司科技项目(52120319000C)

先验信息,因此对图像质量要求较高,在复杂条件下的识别性能不尽人意。

当前,深度学习因其强大的表征能力已经开始应用于指针仪表自动识别领域。文献[7]较早采用 Faster R-CNN 进行仪表检测,然后通过自适应阈值分割、连通域分析和中心投影来检测指针和刻度,最终根据指针与刻度之间的角度计算读数。在此基础上,文献[8]对 Faster R-CNN 结构进行针对性优化,并融入表盘镜面反射消除方法,从而提升模型的鲁棒性。与此类似,文献[9]利用 9 层卷积神经网络进行仪表检测,然后利用椭圆变换进行仪表校正,接着利用 Hough 变换检测指针;文献[10]通过全卷积网络(Fully Convolutional Network, FCN)检测仪表,然后进行图像滤波和校正,最后通过极坐标径向灰度统计的方法检测指针;文献[11]利用 YOLO9000 检测仪表,然后利用 EAST(Efficient and Accurate Scene Text detector)算法识别仪表刻度数值,并根据数值位置提取指针。相比于传统方法,这些方法的性能有所提升,但深度神经网络都只应用在仪表检测阶段,后续读数识别流程仍基于传统计算机视觉方法,没有充分发挥深度学习的优势,因此仍然存在传统方法读数不精确的问题。

近期,一些方法开始在读数识别阶段应用深度学习方法。文献[12]提出利用基于 PrRoIPooling(Precise RoI Pooling,精确感兴趣区域池化)的 Mask R-CNN 同时完成仪表检测和表盘、指针分割,并对分割出的表盘进行椭圆变换从而得到指针方向,但是该方法只适用于圆形仪表。文献[13]提出先对图像进行去雾、补全、超分辨等一系列预处理,然后用 Mask R-CNN 进行仪表检测和指针分割,但是该预处理过程比较复杂。文献[14]提出利用 Mask R-CNN 对仪表图像进行指针关键点和刻度关键点检测,然后从指针和关键点计算仪表读数,该方法能够适应不同形状的仪表,也无需复杂的预处理,但关键点检测性能容易受到表盘模糊、反光、脏污、泛黄等条件的干扰,因此性能仍有待提升。文献[15]提出采用 Faster R-CNN 进行仪表和指针区域检测,然后利用 U-Net 对检测出的仪表和指针区域分别进行刻度和指针分割,最后利用仿射变换校正仪表,但是该方法的采用网络较大,特征冗余度较高。

针对指针仪表读数的这些问题,受到场景文本识别工作 TextSnake<sup>[16]</sup>的启发,本文提出一种新的

基于深度回归的仪表读数识别方法,该方法不显式地检测指针和关键点,而是将指针检测、刻度识别、干扰抑制隐式地结合起来,通过回归方法实现对仪表图像的端到端处理。具体地,给定一张仪表图像,先通过 ResNet50<sup>[17]</sup>获取图像特征,然后利用一个方向回归模块从特征回归仪表指针方向,最后根据指针角度获取仪表读数。实验证明,本文方法对表盘模糊、反光、脏污、泛黄等抗干扰性强,读数识别精度相比于基于 Mask R-CNN 的仪表读数识别方法显著提高。

## 1 相关工作

### 1.1 ResNet50

传统计算机视觉方法基于手工设计的图像特征描述,而深度学习利用多层神经网络学习图像的复杂特征模式,因此具有更强的表示能力。然而 CNN 的深度并非越大越好,实验证明,当网络深度达到 50 层以上时,模型性能反而下降,该现象被称为“模型退化”<sup>[17]</sup>。为了解决这个问题,何恺明等人提出 ResNet 模型,通过学习输出输入之间的残差,解决了网络退化的问题。由于 ResNet 较强的图像表征能力,因此在其他任务中应用广泛。本文采用 ResNet50 backbone 作为特征提取模块,用于提取仪表图像特征,为后续指针方向回归提供基础。

### 1.2 基于 Mask R-CNN 的仪表读数识别方法

该方法<sup>[14]</sup>利用 Mask R-CNN 同时进行仪表检测和仪表识别,其中在读数识别阶段通过语义分割的方式分割指针和关键点的 mask,并通过这些关键点识别读数。具体地,通过区域候选网络(Region Proposal Network, RPN)和 boundingbox regression(包围框回归)检测仪表区域。然后基于检测结果,对仪表区域进行语义分割,以检测每个大刻度关键点和指针的 4 个四等分点,并从指针关键点拟合指针所在直线,从刻度关键点拟合刻度圆,接着求取指针线与刻度圆的交点,最后根据交点与刻度点之间的圆角度差计算读数。由于该方法显式检测仪表读数要素,对多要素的检测正确性要求较高,但是在干扰条件下,关键点模糊或被遮挡,容易导致检测结果容易产生偏差,因此鲁棒性不足。

## 2 基于深度回归的仪表读数识别方法

指针仪表读数识别要求给定一张仪表图像,识别其具体的读数值。本文重点关注指针仪表的读数识别,因此假定输入为已经检测并校正后的仪表图

像。对于一张输入仪表图像,读数由且仅由指针方向决定,因此,本文创新性地提出通过深度神经网络来直接端到端地回归指针方向,进而计算出读数。具体地,设计一个基于 CNN 的指针方向回归模型,输入一张仪表图像,输出其指针方向向量,即顺着指针方向从指针旋转中心指向端点的单位向量,然后根据预测方向向量来计算指针角度,最终根据角度计算出仪表读数。

## 2.1 指针方向回归

基于指针方向回归的仪表读数识别网络结构如图 1 所示,其中输入图像大小为  $256 \times 256 \times 3$ ,经由特征提取部分处理后得到大小为  $2048 \times 4 \times 4$  的图像特征,然后通过一个指针方向回归部分得到一个 2 维单位长度方向向量,最后从该方向向量计算出仪表读数。特征提取模型为 ResNet50 backbone,由原 ResNet50 网络去除最后一层全连接层和倒数第二层的全局 avgpooling(平均池化)层得到。指针方向回归部分结构如图 1 框中所示,其中第一层卷积层的目的是压缩特征通道数,第二层 maxpooling(最大池化)用于压缩特征的空间维度。由于全局 avgpooling 对输入特征具有旋转不变性,为了保留仪表的空间特征信息,这里没有采用全局 avgpooling 而是采用  $2 \times 2$  的 maxpooling。经过上述卷积层和 maxpooling 层的处理后,特征维度变为  $1024 \times 2 \times 2$ ,然后经过 flatten(展平),通过一个全连接层输出一个 2 维向量。最后对该向量进行模长归一化,使其变成一个单位向量,此即预测的指针方向向量,记为  $I = (\cos\theta, \sin\theta)$ 。

## 2.2 读数计算

预测出仪表指针方向向量  $I$  后,由此计算指针的方向角  $\theta_{\text{pred}}$ ,然后根据指针与刻度点之间的夹角计算读数值。具体地,根据方向向量计算指针与  $x$  轴正方向的夹角,表达式为  $\theta_{\text{pred}} = \arctan2(I_x, I_y)$ ,其中

$I_x, I_y$  分别为  $I$  的横纵坐标。然后根据给定类型仪表的最大最小刻度对应的角度和读数值,利用式(1)计算出仪表读数:

$$r = \frac{\theta_{\text{pred}} - \theta_{\min}}{\theta_{\max} - \theta_{\min}} (r_{\max} - r_{\min}) + r_{\min} \quad (1)$$

其中  $\theta_{\max}, \theta_{\min}$  分别是仪表最大最小刻度对应的角度,  $r_{\max}, r_{\min}$  分别是最大最小刻度对应的读数值,这些参数可以根据仪表类型事先计算好。

## 2.3 模型训练

为了使模型尽可能准确地回归指针方向,训练时采用预测指针方向和真实指针方向之间的角度误差绝对值作为 loss 进行学习。注意到角度误差的绝对值的余弦恰好等于预测指针方向向量和真实指针方向向量的内积,因此训练 loss 可以通过这两个方向向量之间的内积计算,从而 loss 形式为:

$$L = \frac{1}{N} \sum_{i=1}^N \arccos(I_{\text{pred}} \cdot I_{\text{gt}}) \quad (2)$$

其中,  $I_{\text{pred}}$  为预测指针方向向量,  $I_{\text{gt}}$  为真实指针方向向量,  $N$  为训练样本数。由于  $\arccos$  函数的定义域为  $[-1, 1]$ , 为避免浮点数误差,实际训练时将内积限制在  $[-1+\epsilon, 1-\epsilon]$  内,其中  $\epsilon=10^{-4}$ 。

对于一般的模型训练,大部分工作都会采用迁移学习的方法事先加载 ImageNet 预训练权重,然而考虑到仪表读数识别任务与图像分类任务之间的差异,本文方法实际训练时没有加载 ImageNet 预训练权重,而是从随机初始化状态开始训练。

## 3 实验结果

### 3.1 数据集

实验在大型虚拟指针仪表数据集上进行。该数据集包含 5 种仪表,分别记为 A、B、C、D、E,如图 2 所示。可以看到,除 C 为长方形外壳仪表外,其余都是圆形外壳仪表。每种仪表的图像涵盖了 9 种不同

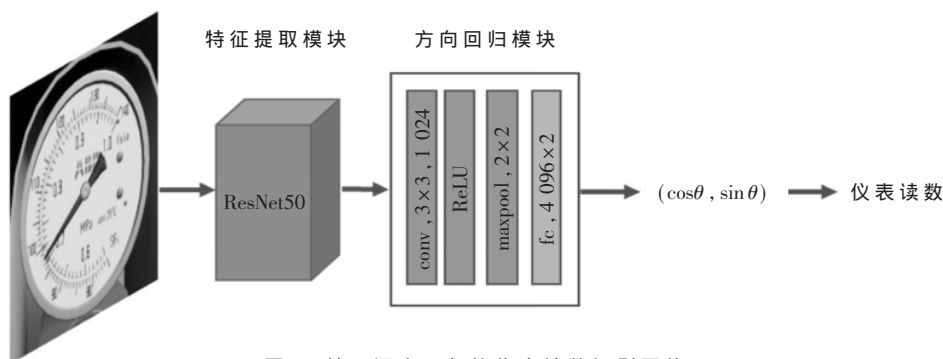


图 1 基于深度回归的仪表读数识别网络

天气(包括晴、阴、雨、雾、雪等),每种天气下两千多张不同状态的仪表图像,包括表盘正常、沾水、污渍、模糊、反光、泛黄 6 种情况,每类仪表总共有 13 500 张训练样本和七千多张测试样本。在该数据集中,每张仪表图像都已经被校正好,并且提供包括各刻度关键点位置、指针关键点位置和真实读数值在内的标注信息,标注示例如图 2 所示,其中指针关键点和刻度关键点由圆点标记,仪表读数值如左上角所示。

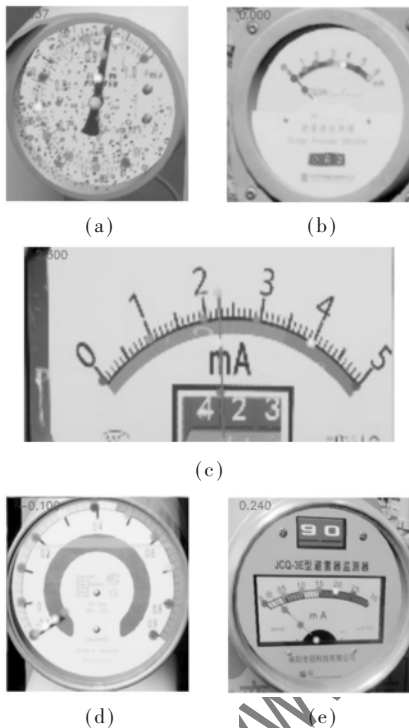


图 2 不同类型仪表样本及标注信息示例

### 3.2 实验设置

实验在 Ubuntu 16.04.5+GeForce GTX1080TI x2+pytorch 1.3.0 平台上运行。训练时,将训练数据按 9:1 的比例划分成训练集和验证集,每类仪表的数据分布如表 1 所示。对于训练集数据,本文主要进行空间上的数据增强。具体地,给定一张训练图像,进行仪表区域上的正方形随机 crop(截取),然后将 crop 图像 resize(调整大小)为 256×256。特别地,对于 C 型仪表,进行宽高比为 2:1 的长方形随机 crop,并 resize 为 256×512,相应的仪表指针方向回归模型最后一层全连接层的输入维度为 1 024×2×4。训练时,采用 Adam 优化器,学习率取  $1 \times 10^{-3}$ ,batchsize

表 1 各类仪表数据分布及参数

仪表	数据分布			仪表参数		
	训练	验证	测试	量程范围	分度值	角度范围/rad
A	12 150	1 350	7 029	[0.55, 1.00]	0.01	[1.11, 5.58]
B	12 150	1 350	7 189	[0.00, 6.00]	0.20	[3.93, 5.51]
C	12 150	1 350	7 374	[0.00, 5.00]	0.10	[3.94, 5.50]
D	12 150	1 350	7 281	[-0.10, 0.90]	0.02	[2.55, 6.87]
E	12 120	1 350	7 249	[0.00, 3.00]	0.10	[3.81, 5.62]

取 50,在训练集上训练 120 个 epoch,每个 epoch 完成时在验证集上测试,最后选取所有 epoch 中验证精度最高的模型作为最终模型进行测试。每类仪表训练一个读数识别模型。

本文选取基于 Mask R-CNN 的仪表读数识别方法<sup>[14]</sup>进行对比,该方法在传统方法中具有良好的表现,包括仪表检测和读数识别两个部分,这里只进行读数识别性能的对比。为公平对比,把该模型的 backbone 由 ResNet18 升级为 ResNet50,然后在相同的数据上训练 10 个 epoch 后,训练结果基本稳定。同样地,该方法也为每类仪表训练一个读数识别模型。

根据实际变电站监测数据记录的要求,本文采用仪表读数的识别精度作为评价指标,包括一格精度和两格精度。具体地,对于一张仪表图像,如果预测值与真实值的误差小于一个/两个分度值,则认为读数正确。统计数据集中读数正确的样本的比例,即为识别精度。实验采用的数据集中每类仪表的量程范围、分度值和角度范围分别如表 2 所示。特别地,A 型仪表存在内外两排刻度,这里采用内环刻度的读数。

### 3.3 实验结果

#### 3.3.1 定量结果

经过上述过程的模型训练之后,本文方法和基于 Mask R-CNN 的仪表读数识别方法在测试集上的测试结果如表 2 所示。

由实验结果可以看出,本文方法在一格平均精度上相比基于 Mask R-CNN 的仪表读数识别方法高了 7.4%。而两格精度只有小幅度的提升,这说明对比方法预测的指针方向和刻度关键点位置大体正确,但是仍不准确。通过分析原始图像可以看出,在仪表图像存在干扰的情况下,关键点特征被弱化或者干扰,从而不容易准确定位。事实上,A 型仪表的指针宽度较大,当存在干扰因素时,指针端点的检测容易受到影响,导致读数产生一格偏差。



表 2 在测试集上的读数识别精度结果对比

仪表	基于 Mask R-CNN 的 仪表读数识别方法 <sup>[14]</sup>			本文	
	关键点 检测 PCK	一格 精度	两格 精度	一格 精度	两格 精度
A	0.993	0.881	0.988	0.995	0.995
B	0.948	0.907	0.968	0.931	0.956
C	0.973	0.916	0.971	0.964	0.976
D	0.974	0.965	0.995	0.995	0.998
E	0.923	0.819	0.962	0.976	0.986
平均值	0.962	0.898	0.977	0.972	0.982

而 D 型仪表指针较短, B、C、E 型仪表指针较细且表盘范围较窄, 因此干扰因素同样容易使关键点检测发生偏移, 导致读数出错。本文方法避免了显式地检测特定关键点, 结合图像整体的信息从大量数据中学习对干扰的抵抗能力, 因此能够比较准确地识别仪表读数。

接下来, 进行各类仪表上不同干扰条件下的识别结果对比, 结果如表 3 所示, 其中“/”左侧为本文方法的一个读数精度, 而右侧为基于 Mask R-CNN 的方法的一格读数精度。

可以看到, 本文方法在绝大部分干扰条件下的读数识别精度都超过了基于 Mask R-CNN 的方法。其中, 在模糊、反光和泛黄条件下, 本文方法的识别精度依然保持了较高的水平。对比各种干扰条件下的识别精度, 可以看到, 污渍是对识别性能影响最大的, 而本文方法虽然在 B、C 上的精度低于对比方法, 但是在 A、D、E 上都显著高于该方法。因此, 本文方法相比于基于 Mask R-CNN 的方法具有更强的鲁棒性。

为了说明该数据集的难度, 从测试集中每类随机抽取 200 张图像进行人工读数, 然后在这些数据上用基于 Mask R-CNN 的仪表读数识别方法和本文方法分别进行识别, 一格精度结果如表 4 所示。可以看到, 本文方法不光优于基于 Mask R-CNN 的

仪表读数识别方法, 甚至在大多数仪表上超过了人工读数的精度。这是因为, 该数据集中存在一些图像受到过大干扰, 质量较差, 连人眼都很难识别, 而在这种情况下, 本文方法仍能根据细微的特征给出比较准确的结果。

表 4 在每类 200 张的随机采样测试集上的一格读数识别精度结果对比

仪表	人工读数	基于 Mask R-CNN 的 仪表读数识别方法 <sup>[14]</sup>	本文
A	0.935	0.890	0.995
B	0.935	0.910	0.930
C	0.950	0.935	0.970
D	0.980	0.965	0.995
E	0.965	0.810	0.985
平均值	0.953	0.902	0.975

3.3.2 定性分析

为了定性比较本文方法和基于 Mask R-CNN 的仪表读数识别方法的性能, 图 3 给出一些测试样本上的识别结果, 其中圆点表示用对比方法检测出的刻度关键点和指针关键点。仪表真实读数、本文方法识别出的读数和对比方法识别出的读数标识在图像上方, 分别如“真实”、“本文”和“Mask R-CNN”所示。

可以看到, 在表盘模糊、反光、雨滴、泛黄、污渍等各种干扰条件下, 基于 Mask R-CNN 的仪表读数识别方法的读数结果容易产生偏差。如图 3(a) 中所示, 当表盘泛黄时, 指针特征弱化, 内外侧指针端点检测发生偏离, 导致超出一格误差; 在图 3(b) 中, 表盘沾水导致水迹被检测为指针; 在图 3(c) 中, 表盘灰尘导致指针外侧端点偏离原位置; 在图 3(d) 中, 表盘反光导致指针中部特征点偏离到指针边界上; 在图 3(e) 中, 表盘严重污损导致指针关键点和最小刻度关键点都出现误差。而在这些情况下, 本文方法仍然能给出准确的结果, 说明本文方法确实

表 3 本文方法与基于 Mask R-CNN 的方法在不同干扰条件下的一格读数识别精度对比

仪表	水滴	污渍	模糊	反光	泛黄
A	0.992/0.857	0.968/0.825	0.993/0.879	0.995/0.887	0.996/0.886
B	0.881/0.885	0.719/0.801	0.954/0.918	0.942/0.928	0.902/0.872
C	0.954/0.907	0.788/0.806	0.989/0.941	0.970/0.926	0.973/0.914
D	0.995/0.961	0.968/0.948	1.000/0.979	0.995/0.960	0.993/0.958
E	0.948/0.803	0.858/0.683	0.983/0.782	1.000/0.819	0.989/0.829

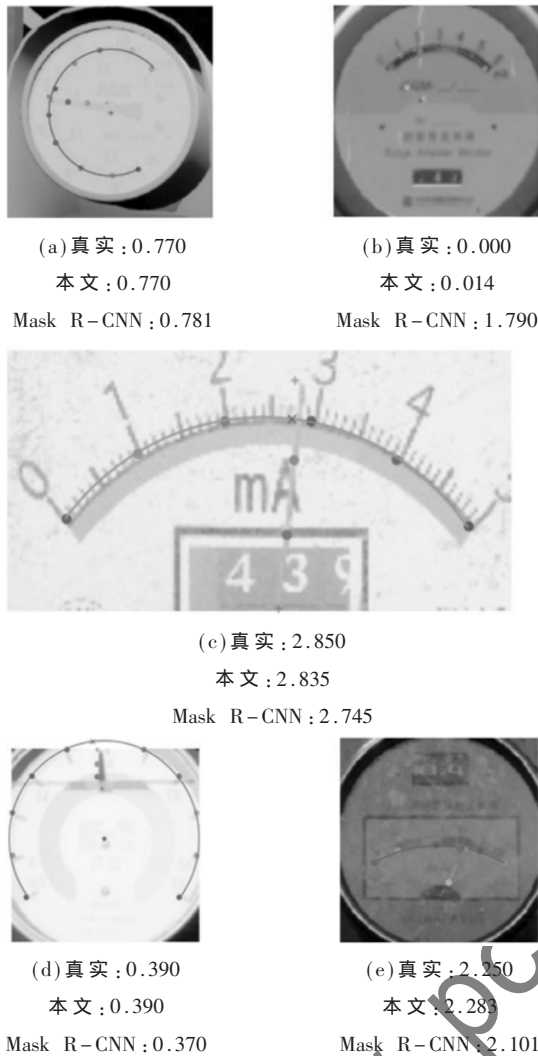


图3 在不同图像条件下本文方法与基于 Mask R-CNN 的方法的识别结果可视化对比

具有较强的鲁棒性。

3.4 特征可视化

为了探究本文方法的工作机制,本节对输入图像的特征进行可视化。具体地,展示 ResNet50 特征提取模块输出的前 64 个通道,在仪表 A 的 3 张不同读数、不同干扰的图像上进行可视化,结果如图 4 所示。

可以看到,特征的响应与仪表的指针角度相关,不同通道的特征在不同指针角度下有不同大小的响应,比如前两行特征在指针竖直向上时响应较大,而在其他角度下响应较小。而对比输入图像与其相应的特征图,可以看到响应较大的位置对应于指针所在的位置,这说明模型确实能够隐式地学习




图4 ResNet50 前 64 个通道特征可视化

到指针的方向位置信息。同时,观察不同的干扰下输出特征的主要响应区域,可以看出,响应区域只限制在指针所在区域,说明输出特征能够比较好地抵抗干扰的影响。例如在图 4(a)中,虽然仪表模糊程度较大导致特征响应削弱,但模型仍能比较准确地识别出指针的位置;在图 4(b)中,虽然表盘沾有污渍,但输出特征并未受到影响;在图 4(c)中,虽然表盘严重泛黄,但从特征中仍能显著观察到指针的响应,说明模型确实学习到了抵抗干扰的能力。

4 结论

针对现有基于深度学习的指针仪表读数识别方法对表盘模糊、反光、脏污、脏污等条件抗干扰性不足的问题,本文提出了一种新的基于深度回归的

仪表读数自动识别方法。实验结果表明,相比于基于 Mask R-CNN 的仪表读数识别方法,该方法识别精度更高,鲁棒性更强,甚至能比较准确地读取一些人眼都无法识别的仪表图像。下一步将整合仪表检测到仪表识别中,从而实现抗干扰能力更强的仪表检测和读数识别的一体化方法。

#### 参考文献

- [1] CAI W D, MA B, ZHANG L, et al. A pointer meter recognition method based on virtual sample generation technology[J]. Measurement, 2020, 163: 107962.
- [2] DAI C, GAN Y F, ZHUO L, et al. Intelligent ammeter reading recognition method based on deep learning[C]. 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference(ITAIC). IEEE, 2019.
- [3] LIU Y, SHI K, ZHANG Z, et al. A stable and reliable self-tuning pointer type meter reading recognition based on gamma correction[C]. Communications, Signal Processing, and Systems(CSPS), 2019.
- [4] REN Y, WANG Z C, XU W T, et al. A meter pointer detection method based on window function scanning[C]. ICRCIA 2019: Proceedings of the 2019 4th International Conference on Robotics, Control and Automation, 2019: 38-42.
- [5] TIAN E L, ZHANG H L, HANAFIAH M M. A pointer location algorithm for computer vision-based automatic reading recognition of pointer gauges[J]. Open Physics, 2019, 17(1): 86-92.
- [6] 张雪飞, 黄山. 多类指针式仪表识别读数算法研究[J]. 电测与仪表, 2020, 57(16): 147-152.
- [7] 刘葵. 基于深度学习的指针式仪表读数识别[D]. 武汉: 华中科技大学, 2017.
- [8] LIU Y, LIU J, KE Y C. A detection and recognition system of pointer meters in substations based on computer vision[J]. Measurement, 2020, 152.
- [9] 邢浩强, 杜志岐, 苏波. 变电站指针式仪表检测与识别方法[J]. 仪器仪表学报, 2017, 38(11): 2813-2821.
- [10] 周杨浩, 刘一帆, 李琛. 一种自动读取指针式仪表读数的方法[J]. 山东大学学报(工学版), 2019, 49(4): 1-7.
- [11] 徐发兵, 吴怀宇, 陈志环, 等. 基于深度学习的指针式仪表检测与识别研究[J]. 高技术通讯, 2019, 29(12): 1206-1215.
- [12] HE P L, ZUO L, ZHANG C H, et al. A value recognition algorithm for pointer meter based on improved mask-RCNN[C]. 2019 9th International Conference on Information Science and Technology(ICIST), 2019.
- [13] LIU J L, WU H Y, CHEN Z H. Automatic identification method of pointer meter under complex environment[C]. ICMLC 2020: Proceedings of the 2020 12th International Conference on Machine Learning and Computing, 2020.
- [14] FANG Y X, DAI Y, HE G L, et al. A mask RCNN based automatic reading method for pointer meter[C]. 2019 Chinese Control Conference(CCC), 2019.
- [15] 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(08): 3097-3105.
- [16] LONG S B, RUAN J Q, ZHANG W J, et al. TextSnake: a flexible representation for detecting text of arbitrary shapes[C]. ECCV, 2018.
- [17] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[J]. arXiv preprint arXiv: 1512.03385, 2015.

(收稿日期: 2020-09-14)

#### 作者简介:

彭昆福(1995-), 男, 硕士研究生, 主要研究方向: 计算机视觉。

王子磊(1981-), 通信作者, 男, 博士, 副教授, 博导, 主要研究方向: 计算机视觉、人工智能。E-mail: zlwang@ustc.edu.cn。

王磊(1986-), 男, 工程师, 主要研究方向: 电力系统及其自动化、变电运维。

# 版权声明

经作者授权，本论文版权和信息网络传播权归属于《信息技术与网络安全》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《信息技术与网络安全》编辑部  
中国电子信息产业集团有限公司第六研究所