

基于 PAT-Unet 的泄露电流仪表示数识读算法设计^{*}漆梓渊^{1,2} 吴浩^{1,2} 陈伟哲^{1,2} 路忠强^{1,2} 周媛³(1. 四川轻化工大学人工智能四川省重点实验室 宜宾 644005; 2. 四川轻化工大学自动化信息工程学院 宜宾 644005;
3. 四川航天电液控制有限公司 成都 610017)

摘要: 仪表能准确反映变电站电气设备的运行状态,为了克服人工巡检造成仪表漏读与错读等情况,提出一种基于 PAT-Unet 神经网络的仪表示数智能识读算法对泄露电流仪表的示数进行智能识读。首先设计 PAT-Unet 神经网络对仪表的指针与密集刻度进行分割,网络中在编码层构建特征聚合模块与残差特征分散模块,增强特征的提取能力;设计 Transformer 特征浓缩模块,进行深层语义信息融合,以增强对细小目标分割精度;引入金字塔切分注意力机制,加强网络编码层与译码层之间的信息交互能力。结合轮廓检测算法与最小外接矩形算法,计算刻度分割结果的关键点,利用透视变换完成倾斜仪表的校正;再使用 K-means 聚类算法定位泄露电流仪表圆心;最后,根据仪表圆心利用极坐标变换将扇形表盘展开为矩形,通过分别计算零刻度与指针以及最大刻度之间的距离关系得到泄露电流仪表示数。实验证明,所提算法能对倾斜仪表盘进行校正,在保证读数准确度的同时,能对泄露电流仪表示数进行智能识读。

关键词: 仪表读数;神经网络;特征融合;透视变换;极坐标转换

中图分类号: TP216;TN98;TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.60

Algorithm design for leakage current meter representation
reading based on PAT-UnetQi Ziyuan^{1,2} Wu Hao^{1,2} Chen Weizhe^{1,2} Luo Zhongqiang^{1,2} Zhou Yuan³(1. Key Laboratory of Artificial Intelligence in Sichuan Province, Sichuan University of Science & Engineering,
Yibin 644005, China; 2. School of Automation and Information Engineering, Sichuan University of Science &

Engineering, Yibin 644005, China; 3. Sichuan Aerospace Electro-hydraulic Control Corporation, Chengdu 610017, China)

Abstract: Meters can accurately reflect the operation status of substation electrical equipment, to overcome the manual inspection caused by meter leakage and misreading and so on, put forward a PAT-Unet neural network based on the number of intelligent reading algorithms for the leakage current meter display intelligent reading. Firstly, the PAT-Unet neural network is designed to segment the pointer and dense scale of the meter. The feature aggregation module and residual feature dispersion module are constructed in the coding layer of the network to enhance the feature extraction ability. Design the transformer feature concentration module for deep semantic information fusion to enhance the segmentation accuracy of acceptable targets; introduce the pyramid slicing attention mechanism to strengthen the information interaction between the network coding and decoding layers. The information interaction between the coding layer and the decoding layer of the network is enhanced. Ability. Combine the contour detection algorithm and the minimum outer rectangle algorithm to calculate the key point of the scale segmentation results, and use perspective transformation to complete the correction of tilted meters; then use the K-means clustering algorithm to locate the center of the leakage current meter; finally, according to the center of the metering circle, use the polar coordinate transformation to expand the sector dial into a rectangle, and get the number of the leakage current meter by calculating the distance between the zero scale, the pointer and the maximal scale respectively. The leakage current meter is obtained by calculating the distance relationship between the zero scale and pointer and the maximum scale respectively. Experiments have demonstrated that the proposed algorithm can correct the tilted dashboard and provide intelligent readings of the leakage current meter representation while ensuring the accuracy of the readings.

Keywords: meter reading; neural network; feature fusion; perspective transformation; polar coordinates conversion

0 引言

避雷器是保证变电站稳定运行的重要设备,能隔绝由于

操作不当引起的的内部过电压以及线路传播的雷电过电压。泄露电流是检测避雷器运行状态的重要测量指标,为了保障避雷器的正常运行,需要加强对避雷器泄露电流仪表的监测。

收稿日期:2023-12-29

^{*} 基金项目:国家自然科学基金(61801319)、四川省科技厅项目(2021YFG0313,2022YFS0518,2022ZHC0035)、人工智能四川省重点实验室项目(2019RYY01)、四川轻化工大学研究生创新基金(Y2022109)项目资助

Sablatning 等^[1]最早使用数字图像处理技术进行测量仪表的示数智能识别,基于 Hough 圆检测算法完成图像中测量仪表的定位;杜静等^[2]也使用了 Hough 算法对图像中的仪表进行定位,再结合二值化算法与指针细化算法,计算零刻度与指针之间的夹角,通过角度变换公式获得测量仪表的读数信息;Zhang 等^[3]从图像尺度以及光照等方面考量,提取图像中的特征点,进一步确定仪表的位置;宁柏锋等^[4]先识别图像中闭合轮廓区域内的直线段,再结合 Hough 圆检测算法确定压力仪表的回转中心进行仪表读数;李全鹏等^[5]设计了基于三次样条插值的指针式仪表图像分割方法进行仪表读数,以降低环境对读数精度的干扰;张雪飞等^[6]先提取仪表特征点集,根据特征点集确定不同种类的仪表盘,再查找正确的指针区域,最后通过角度关系获得读数。杨诗琪等^[7]使用 ResNet-50^[8] 结构改进 DeepLab v3+^[9] 网络,对仪表的刻度与指针进行分割;金爱萍等^[10]结合 Unet^[11] 算法,完成了测量仪表的指针轮廓提取;耿磊等^[12]将自编码器与空洞卷积相结合,构建空洞融合模块,对 Unet 神经网络进行改进,使网络能精准分割测量仪表的密集刻度与指针;陶金等^[13]结合 Hourglass^[14] 网络提取仪表盘表面的刻度与指针关键点,完成对测量仪表指针的定位;宫倩等^[15]先使用关键点检测算法提取输入仪表图像的中心点、零刻度点以及指针所指刻度点,再根据检测到的关

键点,使用角度变换公式得到仪表的读数;Hou 等^[16]构建了基于 ECA^[17] (efficient channel attention, ECA) 注意力机制的 U-Net 神经网络提取仪表盘刻度与指针的特征点,结合角度变换算法对测量仪表的表面示数进行准确识读。

虽然上述算法能完成仪表示数的智能识读,但本文所涉及的泄露电流仪表不同于传统的压力仪表,使用上述算法进行识读会存在一定的局限性;一方面泄露电流仪表的表面是扇形,使用传统的 Hough 圆检测算法将无法定位仪表的圆心,会造成示数识读出现误差。另一方面,泄露电流仪表的刻度较密集,指针较细,若使用传统的灰度变换以及二值化变换算法处理仪表图像,不能对仪表刻度以及指针进行准确定位;同时现有的分割神经网络也只能针对刻度与指针较粗的仪表进行分割,对本文涉及的数据分割精度较差,这会降低示数识读的准确率。

1 仪表示数识读算法

为了准确分割泄露电流仪表的指针与密集刻度,提高泄露电流仪表示数的读数精度,本文提出一种基于 PAT-Unet (pyramid squeeze attention and transformer Unet, PAT-Unet) 神经网络的仪表示数智能识读算法对泄露电流仪表的示数进行智能识读。泄露电流仪表示数智能识读流程如图 1 所示。

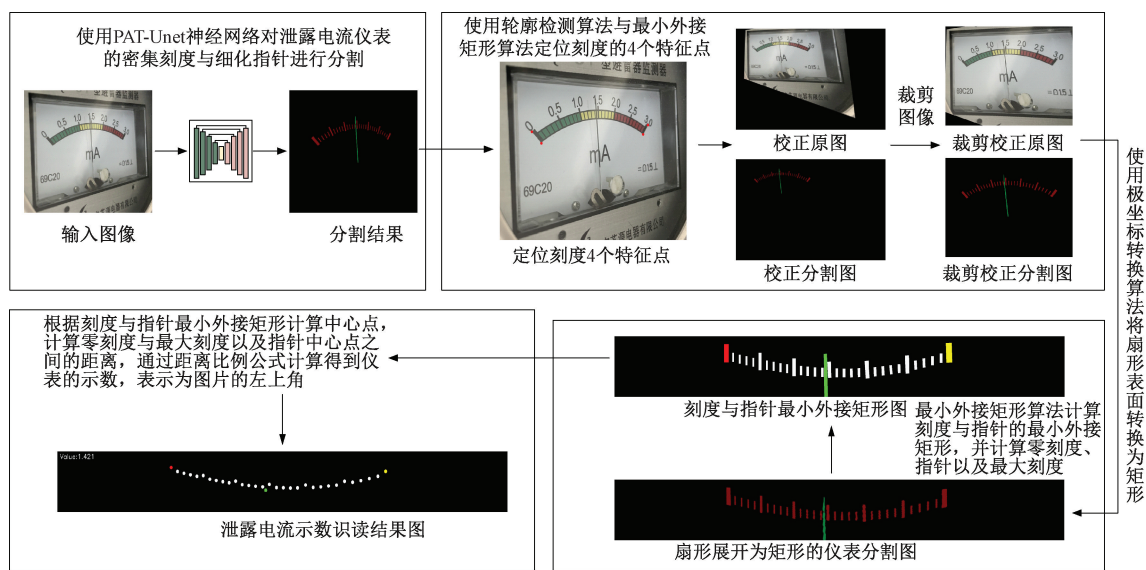


图1 仪表示数识读流程

Fig. 1 Flowchart for reading the number of meters

首先使用本文设计的 PAT-Unet 的神经网络对仪表刻度与指针进行准确分割,在网络的编码层中构建特征聚合模块 FAM (feature aggregation module, FAM) 以及残差特征分散模块 RFDM (residual feature dispersion module, RFDM); 最后的编码层搭建基于 Transformer^[18] 的深层特征融合模块,加强网络对潜在特征信息的提取;编码层与译码层的跳跃连接部分加入

金字塔切分注意力机制 PSA^[19] (pyramid squeeze attention, PSA) 产生像素级的注意力,加强长短特征信息之间的融合。利用刻度分割结果,结合最小外接矩形算法,在进行仪表特征点提取后,使用透视变换,完成泄露电流仪表的倾斜校正;再结合最小二乘直线拟合算法与 K-means 聚类算法完成对校正仪表圆心的确定。最后使用极坐标转换,将扇形的仪表展开为矩形,分别计

算最小刻度与指针和最大刻度之间的距离,经过距离换算公式计算得到仪表的示数。经实验证明,针对泄露电流仪表扇形分布的刻度以及细化指针,所提算法能以较小的偏差值完成仪表的示数识读。

2 基于 PAT-Unet 的仪表刻度与指针分割算法

神经网络的快速发展推动了深度学习的进步,基于神经网络的数字图像技术被广泛应用于图像分割领域,Long 等结合深度学习,首先提出基于卷积运算的 FCN^[20] 网 (fully convolutional networks, FCN),该神经网络使用 VGG-16^[21] 网络 (visual geometry group 16, VGG-16) 主干进行特征提取,再使用上采样卷积完成图像分割。Zhao 等设计 PSPNet^[22] 网络 (pyramid scene parsing network, PSPNet),该网络使用了具有不同感受野的池化核,能完成对不同语义信息的提取与融合,同时增强网络对上下文语义信息特征的提取,分割效果比 FCN 网络更好,但不能对图像中的细小目标进行分割。Chen 等提出了使用不同膨胀率空洞卷积,融合不同特征层的 DeepLab v3+^[23] 神经网络,该网络能对细小的目标进行分割。虽然 DeepLab v3+ 算法能完成细小目标分割,但分割精度还有待提高。

本文需要进行语义分割的对象是泄露电流仪表,与传统的仪表类型不同,该种仪表的刻度较密集,指针与刻度较细,若使用传统的语义分割神经网络,将很难保证分割精度。为了对泄露电流仪表的指针与密集刻度进行准确

分割,本文在 Unet 神经网络的基础上进行改进,加强网络对仪表刻度与指针的分割准确度。Unet 神经网络主要由编码层与译码层组成,译码层与编码层之间使用跳跃连接,加强特征信息之间的交互;编码层主要由卷积层、激活函数以及最大池化层 3 部分组成,常使用的编码层结构有两种,一种是基于 VGG (visual geometry group, VGG) 神经网络的结构 VGG-Unet^[11] 算法 (visual geometry group Unet, VGG-Unet),另一种是基于 ResNet (residual network, ResNet) 残差网络的结构 ResNet50-Unet^[11] 算法 (residual network 50 Unet, ResNet50-Unet),VGG 结构对浅层语义信息的采集能力更强,但不利于深层特征的提取;ResNet 残差结构虽然能提取深层语义信息,并且防止网络训练时梯度爆炸,但由于残差模块数目过多,会增大卷积感受野,造成提取细小密集目标特征信息的能力减弱。同时,上述的两种结构都不能同时对长短距离语义信息特征进行提取,针对较短密集的仪表刻度语义信息,以及较细较长的指针语义信息都不能同时兼顾。为了使网络能兼顾前后语义信息的提取,本文设计特征聚合模块以及残差特征分散模块改进 Unet 神经网络算法的编码层,增强前后语义特征信息之间的交互以及融合,设计 Transformer 深层特征融合模块加强对深层语义信息的融合,以增强网络对细小目标语义信息的感知,引入 PSA 注意力机制,加强长短特征信息之间的融合。PAT-Unet 神经网络结构如图 2 所示。

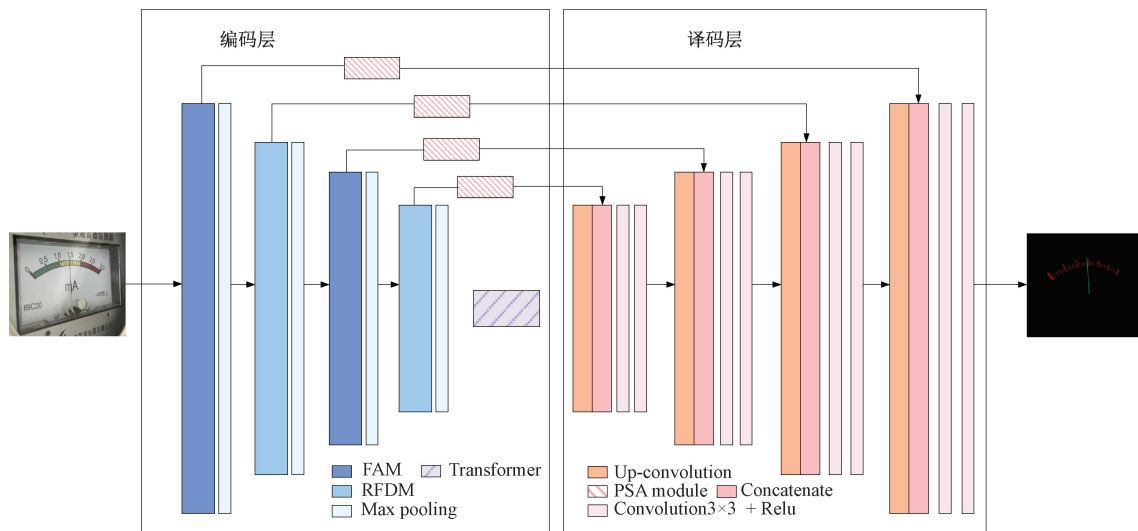


图 2 PAT-Unet 神经网络结构

Fig. 2 PAT-Unet neural network structure diagram

2.1 特征聚合模块 FAM 与残差特征分散模块 RFDM

Unet 网络的编码层使用的是 VGG 神经网络结构,该神经网络采用单一的卷积运算结构进行特征提取,结构较为简单,卷积运算后的特征之间没有建立相关通道进行交互,因此该种结构没办法针对泄露电流仪表密集刻度与细化指针语义信息进行提取。为了加强对泄露电流仪表刻

度与指针语义信息的提取,本文构建特征聚合模块 FAM 与残差特征分散模块 RFDM 增强 Unet 网络对前后语义信息的利用率。

为了对多尺度特征信息进行合理利用,增强网络特征提取能力,设计 FAM 模块。使用卷积核大小为 3×3 的卷积运算层、BN (batch normalization) 归一化层以及 Relu 激

活函数构建基础运算模块;使用3个这样的基础模块进行特征的卷积运算,每个模块的输出包含两条支路,一条支路连接下一个基础模块,另一条支路以通道拼接的方式聚合到 1×1 卷积运算之前的输出特征中,最后通过 1×1 卷积运算层进行特征通道数目的调整,对语义信息进行特征浓缩,进一步增强了网络的特征表达能力。FAM模块结构如图3所示。




图3 FAM模块

Fig. 3 FAM module

为了进一步增强输入信息与各层信息之间的交互能力,设计RFDM模块,该模块由4个基础模块构成,首先输入的特征层经过第一个基础模块进行初步特征的提取,再经过一个基础模块进行特征调整,最后两个基础模块的输入特征由两部分组成,一部分是来自上一条支路的语义特征信息,另一部分是来自第一个基础模块的输出特征信息,两种特征信息通过Add的方式进行融合。FAM结构与RFDM结构,一方面能增强网络对前后语义特征信息的利用率,提升特征层与特征层之间的信息交互与融合能力,能保证提取泄露电流仪表中的刻度与指针语义信息的准确性与有效性;另一方面,与密集残差网络^[24]相比,FAM结构与RFDM结构在保障特征提取效果的同时,减少了冗余特征的计算参数量,节约了计算资源。RFDM模块如图4所示。




图4 RFDM模块

Fig. 4 RFDM module

2.2 基于Transformer的深层特征融合模块

常规的卷积计算模块在进行卷积运算时,受卷积核大小的限制,只能计算卷积核周围像素对卷积核中心像素的影响力;由于具有固定的尺寸,这将很难计算卷积核以外的像素对中心像素的影响力。深层的特征层中具有丰富的语义信息,使用具有固定尺寸的卷积核难以计算特征像素与图像中不同特征像素之间的信息联系,不利于深层语义特征的提取与融合。为了加强深层的语义特征信息之间的交互,本文基于Transformer设计深层特征融合模块,

首先输入特征层通过 2×2 的卷积进行特征尺寸的调整,再通过PatchEmbed的计算,在高宽维度将特征展开,并进行语义特征顺序的调整,将 $16 \times 16 \times 512$ 的特征尺寸调整为 256×512 ,使用6个基于Transformer结构的Encoder Block加强特征的提取,增强网络对图像中细小语义信息的感知提取,最后通过Pixelshuffle上采样卷积,以周期筛选的方式对特征图的像素进行重新排列完成特征图的尺寸调整。模块结构如图5所示。




图5 基于Transformer的深层特征融合模块

Fig. 5 Transformer-based deep feature fusion module

其中,基于Transformer构建的Encoder Block,首先使用LayerNorm进行特征归一化处理,构建多头注意力机制模块,再使用DropPath进行正则化计算,随机删除模型中的多分支结构,以增加网络的泛化性,同时加入残差边,防止网络训练时梯度消失;最后引入LayerNorm、多层感知机MLP(multilayer perceptron, MLP)以及DropPath对特征信息进一步整理。多头注意力机制模块通过8组不同的线性变换对Query、Key、Value进行映射,通过式(1)计算每组注意力机制产生的特征矩阵。

$$Attention(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (1)$$

式中: $\sqrt{d_k}$ 为缩放因子, Q, K, V 对应Query、Key、Value三个矩阵,Softmax为归一化指数函数。

每组注意力机制产生的注意力用于将输入映射到不同的子表示空间,使模型能在不同子表示空间中关注不同的位置。8组注意力机制产生的特征矩阵通过Concatenate的方式进行组合,计算过程表示为式(2)。最后通过一次线性变换完成模块构建。

$$MultiHead(Q, K, V) = \text{Concat}(head_1, \dots, head_h)W^O \quad (2)$$

$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V)$$

式中: $W_i^Q \in \mathbf{R}^{d_{model} \times d_k}$ 、 $W_i^K \in \mathbf{R}^{d_{model} \times d_k}$ 、 $W_i^V \in \mathbf{R}^{d_{model} \times d_v}$ 、 $W^O \in \mathbf{R}^{h d_v \times d_{model}}$ 为参数矩阵,通过这些参数矩阵即可算出Query、Key、Value值,本文的 h 设置为8,即有8组Query、Key、Value值。

2.3 PSA注意力模块

UNet神经网络能通过编码层与译码层之间进行跳跃连接,完成不同深度特征层之间的信息融合,使网络在对深层语义信息特征提取的同时,也能融合浅层特征的轮廓

信息。但直接使用浅层的输入特征进行特征融合时会忽略图像中的轮廓语义信息。为了更有效地利用不同尺度特征图的空间信息来丰富特征空间以及捕获局部信息建立远程信道依赖关系。本文采用 PSA 注意力机制完成特征信息的融合。该模块先通过 SPC 模块(split and concat module, SPC module)对输入的仪表特征层进行分割合并,得到不同尺度的仪表特征图;由 SE 通道注意力机制为不同尺度的特征图分配不同权重,对在通道维度进行拼接的不同尺度特征使用 Softmax 函数进行非线性运算得到注意力权重,从而建立起一个长距离的通道依赖关系;最后使用注意力权重与不同程度仪表特征图进行相乘,得到具有细化特征信息的仪表特征图。使用 PSA 注意力机制后,网络跳跃连接融合的特征更加丰富,对泄露电流仪表的信息提取更加充分。PSA 注意力机制模块结构如图 6 所示。




图 6 PSA 注意力机制模块

Fig. 6 PSA attention mechanism module

2.4 损失函数

本文神经网络所使用的损失函数主要由两部分组成,分别是交叉熵损失函数与 Dice 损失函数。网络通过 Softmax 函数对特征图中的像素点进行分类时,同时使用交叉熵损失函数进行计算损失值。Dice 损失计算作为语义分割的评价指标。Dice 系数常用于计算两个样本的相似度,Dice 损失函数由式(3)确定:

$$s = 1 - \frac{2 |X \cap Y|}{|X| + |Y|} \quad (3)$$

式中: $|X|$ 、 $|Y|$ 分别表示计算集合 X 与 Y 的元素个数,分子部分主要是进行集合 X 与 Y 的交集运算。

使用本文所提的 PAT-Unet 分割算法对泄露电流仪表的密集刻度以及细化指针进行分割,泄露电流仪表分割结果如图 7 所示,其中,原图如图 7(a)所示,分割结果如图 7(b)所示。




图 7 泄露电流仪表分割结果

Fig. 7 Leakage current meter segmentation results

3 仪表倾斜校正与仪表示数识读

由于检测机器人或检测工程师会受拍摄角度的限制,拍摄的泄露电流仪表会存在倾斜的情况,这将会降低仪表示数的识读精度,为了对倾斜的仪表进行校正,本文使用 PAT-Unet 神经网络处理后的分割结果,结合数字图像处理技术对仪表的关键点进行检测,最后使用透视变换,完成泄露电流仪表的倾斜校正,倾斜仪表及分割结果如图 8 所示。其中,倾斜仪表如图 8(a)所示,倾斜分割结果如图 8(b)所示。




图 8 倾斜仪表及分割结果

Fig. 8 Tilt meter and segmentation results

3.1 刻度与指针图层划分

对分割结果,按照 RGB 色序,根据红色与绿色等阈值条件,设置合适的阈值区间,对分割结果图像中的每个像素进行逐一匹配,再将筛选出的像素投影到和分割结果图具有相同尺寸黑色图层,从而完成刻度图层与指针图层的划分。最后对所划分的图层进行二值化处理,图层划分结果如图 9 所示,其中,刻度图层如图 9(a)所示,指针图层如图 9(b)所示。




图 9 图层划分结果

Fig. 9 Layer division results

3.2 特征关键点提取

针对刻度图层,结合 OpenCV 中的轮廓查找算法与最小外接矩形算法,定位刻度图层中的每个刻度,计算每个刻度的最小外接矩形,保存每一个刻度最小外接矩形的中心点、矩形的高度宽度以及旋转角度数值。根据矩形中心点的 x 轴坐标确定仪表的最大刻度与最小刻度,中心点 x 坐标最小的即为最小量程刻度,最大的即为最大量程刻度,分别求取最小量程刻度的左上角与左下角坐标点,最

大量程刻度的右上角与右下角坐标点。将提取到的关键点根据坐标值在原图中进行绘制,刻度关键点提取结果如图10所示,图中红色的点即为提取到的刻度关键点。




图10 刻度关键点

Fig. 10 Scale key points

3.3 基于透视变换的仪表倾斜校正

透视变换能将图像投影到一个新的视平面,首先利用模板图像与待测图像中的关键点做逆透视变换,获得 3×3 透视变换矩阵;再利用透视变换矩阵与倾斜仪表图像进行矩阵运算,最后完成倾斜仪表图像的校正。倾斜仪表图像与标准图像之间的特征点可以使用式(4)进行匹配。

$$\begin{bmatrix} x' & y' & 1 \end{bmatrix} = \begin{bmatrix} u & v & 1 \end{bmatrix} \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \quad (4)$$

式中: $\begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$ 表示透视变换矩阵, u, v 表示倾斜

图像中关键点的坐标值, x', y' 表示通过透视变换计算后图像中的关键点的坐标值。

透视变换校正图像如图11(a)所示,对图像进行裁剪,可以获得最后的泄露电流仪表图像如图11(b)所示。




图11 倾斜校正仪表图像

Fig. 11 Tilt-corrected meter images

本文研究的是泄露电流仪表示数识读,与传统的仪表刻度与指针分布不同,泄露电流仪表刻度分布为弧形,若通过计算初始刻度与指针之间的角度,再利用角度变换算法进行示数转换,会降低仪表的示数识读精度,所以本文根据泄露电流仪表的刻度分布特点,基于透视变换校正后的仪表图像与分割结果,设计极坐标转换的仪表示数识读算法,以提高算法对仪表示数的识读精度。

3.4 基于K-means聚类算法的圆心定位

基于校正后的刻度图层,使用轮廓查找算法与最小外接矩形算法,分别计算每个刻度的最小外接矩形,对每个矩形刻度使用最小二乘法进行直线拟合,使用式(5)计算并保存每条直线的最佳斜率 k 与截距 b 。

$$\frac{\partial (\sum_{i=1}^N [y_i - (kx_i + b)]^2)}{\partial k} = -2 \sum_{i=1}^N [y_i - (kx_i + b)] x_i = 0$$

$$\frac{\partial (\sum_{i=1}^N [y_i - (kx_i + b)]^2)}{\partial b} = -2 \sum_{i=1}^N (y_i - kx_i - b) = 0 \quad (5)$$

式中: y_i 表示为标准值, $kx_i + b$ 表示为拟合直线,计算两值得平方误差, N 表示进行直线拟合的点,分别针对斜率 k 与截距 b 求偏导数并置零,计算最佳拟合参数。

K-means聚类算法是基于距离计算的分类算法,聚类过程中首先定义聚类的簇类,根据簇类定义聚类的质心数;计算各个数据样本来到质心的距离,距离较近的质心就是数据的所属类,形成新的中心样本;再计算各中心样本的均值作为新的质心;最后重复这样计算,直到新质心与原质心基本保持不变时,聚类结束。本文首先计算刻度拟合直线之间的交点集合,再针对交点集合设置聚类质心 K 为1进行圆心的聚类,最后聚类的质心即为仪表的圆心,泄露电流仪表圆心定位结果如图12所示,其中直线交点集合如图12(a)所示,图中的黄色点即为直线交点集合;仪表圆心如图12(b)所示,图中的红色点是泄露电流仪表的圆心。




图12 泄露电流仪表圆心定位

Fig. 12 Leakage current meter centering

3.5 基于极坐标转换的仪表示数智能识读

为了提高泄露电流仪表示数的识读精度,本文对扇形仪表盘使用极坐标转换,将其转换为矩形,再使用最小外接矩形算法计算仪表刻度与指针的最小外接矩形,通过计算指针外接矩形圆心与初始刻度外接矩形圆心之间的距离,最后利用距离比例关系,即可计算仪表的最终示数。

利用K-means聚类算法计算得到的仪表圆心,计算圆心与矩形刻度圆心之间的距离作为半径 r ,分别计算图片中各点像素与仪表圆心之间的夹角 θ ,通过式(6)将极坐标转换为直角坐标。

$$x = r \times \cos\theta + x_0$$

$$y = r \times \sin\theta + y_0 \quad (6)$$

式中: r 表示半径, θ 表示图片中各点像素与仪表圆心之间的夹角, x 、 y 表示经过极坐标转换后的坐标位置, x_0 、 y_0 代表圆心的坐标位置。

将泄露电流仪表的分割图像经极坐标转换后,将扇形的仪表展开成为矩形,极坐标变换结果如图 13 所示,图片的上半部分为极坐标转换后的仪表原图,下半部分为极坐标转换后的分割结果图。




图 13 极坐标变换图
Fig. 13 Polarographic transformation chart

计算分割结果中的刻度与指针的最小外接矩形,根据刻度外接矩形中心点的 x 轴坐标确定最小刻度与最大刻度;计算最大与最小刻度最小外接矩形中心点之间的距离,在计算最小刻度与指针最小外接矩形中心点之间的距离,利用距离比例关系,最后通过式(7)计算得到仪表的示数。

$$\alpha = \frac{3 \times L_M}{L_{Max}} \tag{7}$$

式中: α 代表计算得到仪表的示数, L_M 代表最小刻度与指针最小外接矩形中心点之间的距离, L_{Max} 代表最大与最小刻度最小外接矩形中心点之间的距离。

仪表示数读数智能识读结果显示如图 14 所示,图中红色代表最小刻度的最小外接矩形,黄色刻度代表最大刻度的最小外接矩形,绿色为指针的最小外接矩形,左上角是通过本文所提算法,智能识别出的仪表示数。



图 14 仪表示数智能识读结果
Fig. 14 Intelligent reading of the number of meters

4 实验分析

4.1 实验环境

本文实验的操作系统为 Windows10 专业版,软件环境是 Pycharm,编程语言使用 python3.7,基于 1.10.1 版本的 pytorch 搭建深度学习框架;硬件配置 CPU(AMD EPYC 7302 16-Core Processor),GPU(NVIDIA A100-PCIE-40G)。

4.2 实验数据及训练过程

为了对泄露电流仪表的刻度与指针进行准确分割,本文先对 PAT-Unet 神经网络进行训练。使用的数据集主要包含 1 656 张泄露电流仪表图片,其中 1 490 张数据用于网络训练,166 张数据用于网络测试。网络训练时对输入的图片进行随机裁剪与旋转后,输入网络的训练图片尺寸为 512×512 。

设置初始学习率为 10^{-4} ,使用余弦函数的计算方式进

行学习率的更新;实验过程中使用 Adam 优化器对算法进行优化,设置一阶动量参数为 0.9。总体迭代 100 个 epoch, batchsize 设置为 4。

4.3 评价指标

本文使用标准值与示数识读结果之间的绝对误差作为示数识读精度的评价指标。使用平均交并比 MIoU (mean intersection over union, MIoU)、平均像素精确度 MPA (mean pixel accuracy, MPA) 以及准确率 Accuracy 作为刻度与指针分割效果的评价指标,这些指标的公式表示为:

$$MIoU = \frac{TP}{FN + TP + FP} \tag{8}$$

$$Accuracy = \frac{TP + TN}{FN + TP + FP + TN} \tag{9}$$

$$MPA = \frac{TP + TN}{3 \times (FN + TP + FP + TN)} \tag{10}$$

式中: TP 表示模型预测为真,标签也为真; FP 表示模型预测为真,标签为假; TN 表示模型预测为假,标签为真; FN 表示模型预测为假,标签也为假。

4.4 不同神经网络分割结果对比

为了验证本文所设计的 PAT-Unet 对刻度与指针分割的有效性,本文对 PSPNet 算法、DeepLab v3+ 算法、VGG-Unet 算法、ResNet50-Unet 算法使用相同的网络训练策略,进行不同网络分割刻度与指针对比实验,实验结果如表 1 所示,经实验证明本文设计的 PAT-Unet 算法分割效果更好,指标更优。

表 1 不同网络分割结果对比
Table 1 Comparison of segmentation results for different networks

算法	MIoU/%	MPA/%	Accuracy/%
PSPNet	33.76	34.24	98.61
DeepLab v3+	57.24	85.45	98.4
VGG-Unet	89.21	93.93	99.78
ResNet50-Unet	91.01	95.02	99.81
PAT-Unet	91.45	95.3	99.82

为了进一步验证本文所提算法对仪表刻度与指针分割的准确性,将表 1 对比算法中分割指标较优的 DeepLab v3+ 算法、VGG-Unet 算法、ResNet50-Unet 算法的分割结果与本文所提算法的分割结果进行展示,不同算法分割结果对比如图 15 所示,图片中的 Ground Truth 代表标签文件,结果图像中的红色代表刻度,绿色代表指针。图片显示,DeepLab v3+ 神经网络的分割结果较差,仪表的刻度与指针都不能很好的进行准确分割,对比 VGG-Unet 神经网络、ResNet50-Unet 神经网络,本文所提算法对仪表刻度与指针的分割效果更好更稳定,准确度也更高,有利于示数识读算法的开展。

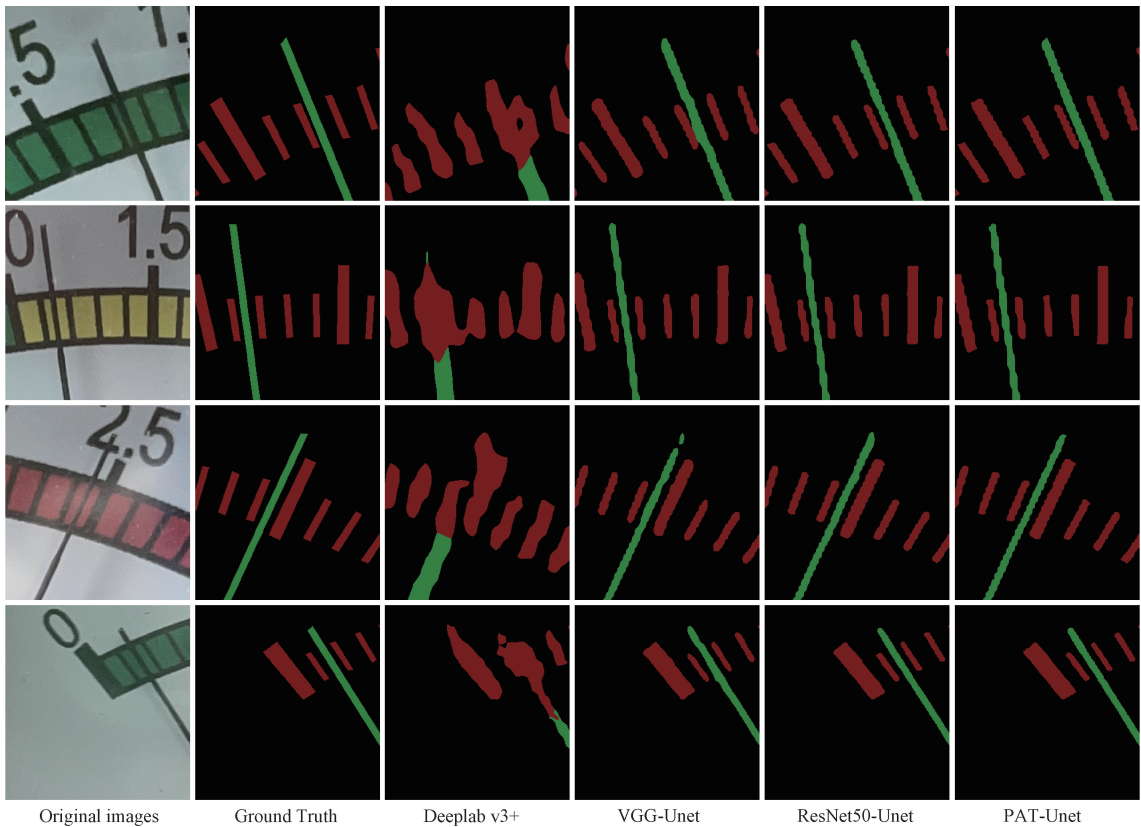


图 15 不同算法分割结果
Fig. 15 Segmentation results of different algorithms

4.5 消融实验

为了验证本文设计分割算法改进点的有效性,在相同的程序运行环境下进行消融实验,实验结果如表 2 所示,与原算法对比,在使用了 FAM 与 RFDM 模块后,仪表刻度与指针的分割效果有了显著提升,平均交并比提高了 2.05,平均像素精确度 MPA 提高了 0.9,准确率提高了 0.04;构建深层特征融合模块后,语义信息的提取与融合得到了强化,平均交并比提高了 2.2,平均像素精确度 MPA 提高了 1.26,准确率提高了 0.04;最后在跳跃连接层加入 PSA 注意力机制,进一步加强了编码层与译码层之间的信息交互,平均交并比提高了 2.24,平均像素精确度 MPA 提高了 1.37,准确率提高了 0.04。

表 2 消融实验结果对比

Table 2 Comparison of ablation experiment results			
算法	MIoU/ %	MPA/ %	Accuracy/ %
原算法	89.21	93.93	99.78
原算法+FAM+RFDM	91.26	94.83	99.82
原算法+FAM+RFDM+ 深层特征融合模块	91.41	95.19	99.82
PAT-Unet	91.45	95.3	99.82

4.6 倾斜仪表校正实验

为了提高仪表示数的识读精确度,需要对由于拍摄角度造成倾斜仪表进行校正,同时,为了验证本文所提出的校正算法的有效性,本文针对不同倾斜方向的泄露电流仪表示进行校正,不同方向的倾斜仪表校正结果如图 16 所示,图中第 1 排的 3 张图片是由于拍摄角度造成的 3 种倾斜仪表图像,第二排三张图像是使用本文所提算法对倾斜仪表进行校正后的结果。实验结果证明本文所提算法对泄露电流仪表的倾斜校正具有显著效果。




图 16 不同倾斜仪表校正结果
Fig. 16 Calibration results for different tilt meters

4.7 不同示数识读算法对比实验

为了验证极坐标转换算法识读仪表示数的准确性与有效性,本文先使用 PAT-UNet 神经网络对仪表的刻度与指针进行分割,利用分割后的结果,分别使用角度变换算法与极坐标转换算法进行仪表示数的识读,识读结果如表 3 所示,经实验证明,本文所提极坐标转换法识读结果与标准值之间的偏差值更小,泄露电流仪表示数识读精度更高。

表 3 不同识读算法对比实验

Table 3 Comparative experiments of different reading algorithms				
reading algorithms				mA
对比算法	实验	标准值	读数结果	偏差值
角度变换法	1	1.150	1.139	0.011
	2	2.450	2.402	0.048
	3	0.710	0.743	-0.033
	4	0.144	0.160	-0.016
极坐标转换法	1	1.150	1.147	0.003
	2	2.450	2.450	0
	3	0.710	0.706	0.004
	4	0.144	0.142	0.002

4.8 不同网络分割读数对比实验

为了验证本文设计的神经网络算法对仪表示数识读的可靠性,本文使用分割效果较优的 VGG-UNet 算法、ResNet50-UNet 算法以及本文所提 PAT-UNet 算法,结合极坐标转换算法对仪表进行仪表示数识读实验,选取泄露电流仪表的 4 种示数进行识读,识读结果与标准值之间的

表 4 不同分割算法读数对比实验

Table 4 Experiments comparing readings from different segmentation algorithms				
segmentation algorithms				mA
对比算法	实验	标准值	读数结果	偏差值
VGG-UNet	1	1.150	1.143	0.007
	2	2.450	2.466	-0.016
	3	0.710	0.745	-0.035
	4	0.144	0.128	0.016
ResNet50-UNet	1	1.150	1.145	0.005
	2	2.450	2.458	-0.008
	3	0.710	0.755	-0.045
	4	0.144	0.130	0.014
PAT-UNet	1	1.150	1.147	0.003
	2	2.450	2.450	0
	3	0.710	0.706	0.004
	4	0.144	0.142	0.002

偏差值作为衡量读数精度的指标,不同分割算法读数对比实验结果如表 4 所示,经实验证明,本文所提出的分割算法结合极坐标转换算法能以较小的偏差值对泄露电流仪表示数进行识读。

不同分割算法的示数识读结果如图 17 所示,图中第 1 行是原图,为待识读的仪表;第 2 行为标准读数,第 3 行为 VGG-UNet 神经网络分割结果示数识读图;第 4 行是 ResNet50-UNet 神经网络分割结果示数识读图;最后一行是 PAT-UNet 神经网络分割结果示数识读图,图片显示,本文所提算法的示数识读精度较高。




图 17 不同分割算法示数识读结果

Fig. 17 Different segmentation algorithms for reading the number of oscillograms

为了验证本文所提出的算法对泄露电流仪表读数的准确性以及精确度,使用本文所设计的 PAT-UNet 算法对

不同数值情况下泄露电流仪表的刻度以及指针进行分割,再使用本文所提出的极坐标转换法对这些仪表的示数进

行计算,实验结果如表 5 所示。通过对表格中的数据可以分析得知,使用本文所设计的算法对泄露电流仪表进行示数识读,读数结果与标准值之间的偏差值也更小,偏差值能精确到小数点后 3 位。综上所述,本文所提出的算法能针对泄露电流仪表以更高的精度完成仪表示数识读。

表 5 读数精度对比结果

Table 5 Comparison results of reading accuracy

mA			
实验	标准值	读数结果	偏差值
1	0.141	0.146	−0.005
2	0.227	0.233	−0.006
3	0.651	0.656	−0.005
4	0.716	0.718	−0.002
5	0.852	0.85	0.002
6	1.168	1.174	−0.006
7	1.258	1.263	−0.005
8	1.312	1.315	−0.003
9	1.447	1.449	−0.002
10	1.554	1.553	0.001
11	1.812	1.816	−0.004
12	1.976	1.968	0.008
13	2.056	2.064	−0.008
14	2.36	2.359	0.001
15	2.238	2.240	−0.002
16	2.653	2.649	0.004

5 结 论

为了实现对泄露电流仪表示数的智能识读,本文提出基于 PAT-Unet 神经网络的泄露电流仪表示数智能识读算法。首先设计 PAT-Unet 分割神经网络算法,对泄露电流仪表的密集刻度以及细化指针进行准确分割;构建特征聚合模块以及残差特征分散模块改进 Unet 神经网络算法的编码层,特征聚合模块能增强网络对不同语义特征信息的融合,残差特征分散模块能增强前后特征信息之间的交互;最后的编码层搭建基于 Transformer 的深层特征融合模块,加强网络对潜在特征信息的提取;编码层与译码层的跳跃连接部分加入金字塔切分注意力机制 PSA 产生像素级的注意力,加强长短特征信息之间的融合。再根据刻度与指针的分割结果,结合轮廓查找算法与最小外接矩形算法,在图片上定位相关的特征点,最后利用特征点,使用透视变换,完成对泄露电流仪表的倾斜校正。最后使用刻度的最小外接矩形进行直线拟合,利用 K-means 聚类算法对拟合直线的交点集合进行单质心聚类,得到仪表圆心;结合极坐标转换算法,将扇形的表面展开为矩形,计算零刻度与指针以及最大刻度之间的距离,通过比例关系计算得到泄露电流仪表的示数。通过实验证明本文所提出的

仪表示数识读算法能以较高的精度对泄露电流仪表示数进行识读。

参考文献

[1] SABLATNIG R, HANSEN C. Machine vision for automatic calibration of analog display instruments [C]. Machine Vision Applications in Industrial Inspection III, 1995.

[2] 杜静,魏鸿磊,樊双蛟,等. 基于 HOUGH 变换的指针式压力表自动识别算法[J]. 机床与液压,2020,48(11):70-75.

DU J, WEI H L, FAN SH J, et al. Automatic recognition algorithm of pointer pressure gauge based on HOUGH transform [J]. Machine Tool & Hydraulics, 2020, 48(11): 70-75.

[3] ZHANG H, BAI J, LI Z, et al. Scale invariant SURF detector and automatic clustering segmentation for infrared small targets detection[J]. Infrared Physics & Technology, 2017, 83: 7-16.

[4] 宁柏锋,董召杰. 基于图像识别的变电站 SF6 气压表智能读数方法研究[J]. 自动化与仪器仪表,2020(6): 48-51,56.

NING B F, DONG ZH J. Study on intelligent reading method of substation SF6 barometer based on image recognition [J]. Automation & Instrumentation, 2020(6): 48-51,56.

[5] 李全鹏,苏士美,许永波. 基于三次样条插值的指针式仪表识别方法研究[J]. 电测与仪表,2020,57(1):141-146.

LI Q P, SU SH M, XU Y B. Research on pointer instrument recognition method based on cubic spline interpolation [J]. Electrical Measurement & Instrumentation, 2020, 57(1): 141-146.

[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.

ZHANG X F, HUANG SH. Research on pointer identifying and number reading algorithm of multi-class pointer instruments[J]. Electrical Measurement & Instrumentation, 2020, 57(16): 147-152.

[7] 杨诗琪,吴佳仪,陈墨楠,等. 基于深度学习的指针式仪表自动读数方法[J]. 电子测量技术,2023,46(5): 149-156.

YANG SH Q, WU J Y, CHEN M N, et al. Automatic identification for reading of pointer-type meters based on deep learning [J]. Electronic Measurement Technology, 2023, 46(5): 149-156.

[8] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016.

- [9] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018.
- [10] 金爱萍, 袁亮, 周德勤, 等. 基于 YOLOv5 和 U-net 的指针式仪表读数识别方法[J]. 仪表技术与传感器, 2022(11):29-33.
- JIN AI P, YUAN L, ZHOU D Q, et al. Identification Method for Reading of Pointer Instruments Based on YOLOv5 and U-net[J]. Instrument Technique and Sensor, 2022(11): 29-33.
- [11] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015, 2015.
- [12] 耿磊, 史瑞资, 刘彦北, 等. 基于多重感受野 UNet 的仪表图像分割方法[J]. 计算机工程与设计, 2022, 43(3):771-777.
- GENG L, SHI R Z, LIU Y B, et al. Instrument image segmentation method based on UNet with multi-scale receptive field[J]. Computer Engineering and Design, 2022, 43(3): 771-777.
- [13] 陶金, 林文伟, 曾亮, 等. 基于 YOLOv4-tiny 和 Hourglass 的指针式仪表读数识别[J]. 电子测量与仪器学报, 2023,37(5):1-10.
- TAO J, LIN W W, ZENG L, et al. Pointer meter reading recognition based on YOLOv4-tiny and Hourglass[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(5): 1-10.
- [14] NEWELL A, YANG K, DENG J. Stacked hourglass networks for human pose estimation[C]. Computer Vision-ECCV 2016, 2016.
- [15] 宫倩, 别必龙, 范新南, 等. 基于关键点检测的指针仪表读数算法[J]. 电子测量与仪器学报, 2023,37(3): 66-73.
- GONG Q, BIE B L, FAN X N, et al. Pointer meter reading algorithm based on key point detection[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 66-73.
- [16] HOU L, WANG S, SUN X, et al. A pointer meter reading recognition method based on YOLOX and semantic segmentation technology[J]. Measurement, 2023, 218: 113241.
- [17] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020.
- [18] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words: Transformers for image recognition at scale [J]. ArXiv preprint arXiv:2010.11929, 2020.
- [19] ZHANG H, ZU K, LU J, et al. EPSANet: An efficient pyramid squeeze attention block on convolutional neural network[C]. Proceedings of the Asian Conference on Computer Vision, 2022.
- [20] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015.
- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. ArXiv preprint arXiv:1409.1556, 2014.
- [22] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network[C]. Proceedings of the IEEE Conference on computer Vision and Pattern Recognition, 2017.
- [23] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]. Proceedings of the European Conference on Computer Vision, 2018.
- [24] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017.

作者简介

漆梓渊, 硕士研究生, 主要研究方向为电气设备状态监测。

E-mail: qziyuan123@outlook.com

吴浩, 教授, 博士, 主要研究方向为智能信息处理、电力系统及智能控制。

E-mail: wuaho801212@163.com

骆忠强(通信作者), 教授, 博士, 主要研究方向为信息融合、盲源分离、无线通信系统的信号处理和智能信号处理等。

E-mail: luozhongqiang@suse.edu.cn