

# 基于 ResSE-SegNet 的智能电表通信模块铭牌检测与识别

翟晓卉<sup>1</sup>, 孙 凯<sup>1</sup>, 赵吉福<sup>1</sup>, 孙艳玲<sup>1</sup>, 邢 宇<sup>1</sup>, 郭凯旋<sup>1</sup>, 王海英<sup>2</sup>

(1. 国网山东省电力公司营销服务中心(计量中心), 济南 250000; 2. 哈尔滨理工大学 自动化学院, 哈尔滨 150080)

**摘 要:**针对智能电表通信模块铭牌检测和识别问题, 本文提出了一种基于 ResSE-SegNet 的级联深度学习方法, 采用高斯滤波和自适应图像对比度增强等图像预处理技术, 通过深度语义分割网络来确定输入图像中厂家名称所在的区域, 并采用深度编解码器网络结构进行分割, 构建并训练端到端的卷积神经网络(CNN)模型用于识别不同的厂家。最后通过全维度智能电表检测系统获得通信模块图像的数据集并进行通信模块铭牌的检测和识别实验, 实验结果表明, 该方法的召回率为 92.34%, 精确率为 93.97%,  $F_{1-Score}$  为 92.14%, 对智能电表通信模块厂家的分类准确率为 98.53%。

**关键词:**通信模块; 级联深度学习; 检测和识别; 卷积神经网络

**DOI:**10.15938/j.jhust.2023.02.016

**中图分类号:** TP274+.3 **文献标志码:** A **文章编号:** 1007-2683(2023)02-0136-09

## Nameplate Detection and Recognition of Smart Meter Communication Module Based on ResSE-SegNet

ZHAI Xiaohui<sup>1</sup>, SUN Kai<sup>1</sup>, ZHAO Jifu<sup>1</sup>, SUN Yanling<sup>1</sup>, XING Yu<sup>1</sup>, GUO Kaixuan<sup>1</sup>, WANG Haiying<sup>2</sup>

(1. Marketing Service Center (Metering Center), State Grid Shandong Electric Power Company, Jinan 250000, China;

2. College of Automation, Harbin University of Science and Technology, Harbin 150080, China)

**Abstract:** Aiming at the problem of nameplate detection and recognition of smart meter communication modules, this paper proposes a cascaded deep learning method based on ResSE-SegNet, which adopts image preprocessing techniques such as Gaussian filtering and adaptive image contrast enhancement, and determines the input through a deep semantic segmentation network. The region where the manufacturer's name is located in the image is segmented using a deep codec network structure, and an end-to-end convolutional neural network (CNN) model is constructed and trained to identify different manufacturers. Finally, the data set of the communication module image is obtained through the full-dimensional smart meter detection system, and the detection and recognition experiment of the communication module nameplate is carried out. The experimental results show that this method achieves a recall rate of 92.34%, a precision rate of 93.97%, and an  $F1-Score$  of 92.14%. The classification accuracy rate for smart meter communication module manufacturers is 98.53%.

**Keywords:** communication module; cascaded deep learning; detection and recognition; convolutional neural networks

收稿日期: 2022-05-03

基金项目: 国家自然科学基金(61571168); 山东省技术创新项目(520633200003)。

作者简介: 孙 凯(1990—), 男, 工程师;

孙艳玲(1983—), 女, 高级工程师。

通信作者: 翟晓卉(1981—), 女, 高级工程师, E-mail: 372562850@qq.com.

## 0 引言

智能电表通信模块是当前构建新型电力系统的重要组成部分,智能电表可以实现居民用电负荷、电量的分钟级数据采集,而表中的通信模块,则是远程抄表过程中进行数据传输的基础。通信模块生产完成后,一方面需对模块表面铭牌信息进行检测与识别,防止残次品的出现。另一方面在智能电表通信模块的检测和维修中,也需要将铭牌上的信息录入信息管理系统,方便检修与更换。目前智能电表通信模块铭牌检测识别的自动化程度不高,主要依靠人工完成,识别效率低下,且成本高昂。近年来,计算设备的运算能力得到了极大的提高,在深度学习的驱动下,计算机视觉各个领域都迅速发展<sup>[1]</sup>。将基于深度学习的文字识别算法应用于智能电表通信模块铭牌检测与识别中,可以极大地提高检测识别效率,减轻人力成本。

针对智能电表通信模块铭牌检测与识别,许多学者提出了相关的方法,陈为等<sup>[2]</sup>提出了一种基于表面三维形状信息的金属铭牌压印凸凹字符图像分割的方法,用于提取压印字符表面的立体特征。使用图论聚类方法,实现了压印凸凹字符的分割,但其检测系统对智能电表的外观的检测过于粗糙,且精度较低。刘波<sup>[3]</sup>首先参考倾斜校正算法,利用色彩空间转换进行灰度变换,直方图均衡化,利用 P-tile 法选取合适的阈值进行二值化,字符上下边界和左右边界通过投影法确定,最后字符的识别采用了模板匹配法。投影法虽然简单易行,但是容错率较低。若倾斜校正不到位,字符上下切割时易分割出非必要区域,字符分割效果不佳。曹倩倩<sup>[4]</sup>提出了一种基于 YOLOv3 的电力铭牌文本检测算法。使用文本识别算法 CRNN 完成电力铭牌文本识别任务。但其使用的文本检测和识别方法是针对水平、倾斜角度较小或形变程度轻的电力铭牌图像,且训练模型的时候使用的数据集训练数据有限。王佳宇<sup>[5]</sup>基于目标检测算法 YOLO 提出了铭牌定位模型,并对模型的损失函数进行改进,以解决类别不平衡和样本不均衡的问题。采用非端到端可训练的铭牌文本识别模型将文本识别任务划分为多个子任务实现,

导致模型整体的识别效果不理想。徐金辰<sup>[6]</sup>设计了两种基于空洞卷积的残差结构,并对非极大值抑制算法进行了改进,采用 CRNN<sup>[7]</sup>算法实现了文字识别。但其并未将铭牌的检测与识别结合在一起进行一个端到端的训练,存在无法共享 loss 的问题。段恩悦<sup>[8]</sup>在文本检测阶段引入并改进了 DB 模型定位图像中的文本位置,文本识别阶段引入了一种自适应图像空间变换模块,解决了图像变形而引起的文本识别精度的问题,但未能共享特征提取网络带来了不必要的资源消耗,存在效率低下的问题。王海涛等<sup>[9]</sup>提出了一种基于深度卷积生成对抗网络的印刷缺陷检测方法,该方法在原有网络的基础上增加上采样模块,减少了上采样中的损失;并且提出一种自注意力机制,其可以生成结构性更复杂和细节更准确的图像;最后通过统计分析生成图像的噪声分布,确定最佳阈值,去除噪声,获得准确的缺陷图像。与现有方法相比,在小于 5 像素的缺陷检测实验中,该方法可以使检测精度提高 10%。冯磊等<sup>[10]</sup>为解决传统基于深度学习的调制识别算法在小样本条件下识别准确率较低的问题,提出一种基于深度级联孪生网络的通信信号小样本调制识别算法,该方法由 CNN 和 LSTM 级联的特征提取模块提取特征,并在孪生网络架构上通过距离度量模块对提取特征进行相似度度量。实验结果表明,该算法在训练过程中所需样本量明显减少,并且相较于单一特征提取网络识别准确率更高。虽然上述方法在该领域取得了不错的效果,但不适用于智能电表通信模块的检测与识别,因为上述方法无法同时做到检测与识别。

综上所述,为了解决通信模块检测与识别精度低以及多任务训练会消耗巨大内存资源的问题,本文提出了一种新型的级联深度学习方法,该方法最大的优点是只使用了一种网络结构,就可以实现通信模块的检测与识别。本文提出的网络结构称为 ResSE-SegNet,该网络结构以 SEG-Net 为基础框架;同时将 SEG-Net 标准卷积层替换为残差块,并增加了批归一化层,使得网络更加深入,收敛速度更快;最后在网络的编码区每组卷积序列之后引入一个通道注意力模块(SE 模块),用于提取通信模块图像的重要信息。

1 通信模块图像数据采集

本文图像数据是通过一款通信模块全维度检测装置获得,该装置如图 1 所示。获取自定义智能电表通信模块铭牌数据集,共有 600 张图片,分辨率为  $2048 \times 1920$ ,采集到的部分铭牌图像如图 2 所示。



图 1 通信模块全维度检测装置

Fig. 1 Full-dimensional detection device for communication module



图 2 智能电表通信模块

Fig. 2 Smart meter communication module

2 实验原理及网络架构分析

2.1 原理图与算法流程

本文算法的实验原理图如图 3 所示,其主要由数据预处理、分割网络、字符提取算法和分类网络这

4 部分组成。此外本文算法的具体流程为

- 步骤 1 采用高斯滤波、CLAHE 对数据进行预处理
- 步骤 2 经过处理的数据输入级联 ResSE-SegNet 网络
- 步骤 3 确定输入图像中厂家名称所在区域
- 步骤 4 采用阈值法来提取特征区域的具体信息(实现检测)
- 步骤 5 将检测到的特征信息输入到 ResSE-SegNet 的编码区(其中编码区是以迁移网络 VGG-16 为主干,实现分类)




图 3 实验原理图

Fig. 3 Experiment overall scheme diagram

该流程首先进行图像预处理操作,之后将预处理后的图像及对应标签输入到 ResSE-SegNet 网络中去,从而得到不同厂家通信模块的大致区域;接着使用阈值法来获得大致区域中的具体厂家文字信息,以此实现了通信模块的检测;最后将检测到的文字信息输入到 ResSE-SegNet 的编码区中去<sup>[11]</sup>,通过全连接层和 Softmax 实现四分类,以实现通信模块的识别。

2.2 Resse-segNet 网络

本文提出的分割网络框架如图 4 所示,分割网络主要由 SEG-Net 网络、残差结构和 SE 模块构成,并称为 ResSE-SegNet。接下来,我们将分别详细介绍这 3 种网络模型。




图 4 ResSE-SegNet 网络框架  
Fig. 4 ResSE-SegNet framework

2.2.1 SEG-Net 网络

深度学习中 SEG-Net 是通过对图像中每一个像素点进行分类,识别每一个像素点的类别来实现图像的分割算法,与 FCN 算法非常相似,两者的编码与解码技术不同。SEG-Net 的编码器与 VGG-16 卷积层具有相同的网络结构,但是移除了全连接层,而 SEG-Net 的解码器可直接从相应编码器接受最大池化索引来对输入的特征图进行非线性采样,同时只需存储特征映射的最大池化位置索引,既节约内存又提升网络训练效率,还能让图像边缘处理更加平缓,因此可将 SEG-Net 应用于通信模块检测与识别中。其网络结构如图 5 所示。




图 5 SEG-Net 网络结构  
Fig. 5 SEG-Net framework

2.2.2 残差结构

面对复杂问题时,越深的网络往往会有更好的性能,但会发现,随着网络的加深,会出现训练集准

确率下降的现象。其原因可以归结于优化问题,即当网络模型变复杂后,随机梯度下降法 (SGD) 的优化变得更加困难了,导致最终训练出来的模型达不到好的学习效果。因此,在堆叠卷积层的同时对深层次的网络进行优化成为一个难点。

2015 年,He 等<sup>[12]</sup>提出了 ResNet 网络,ResNet 在网络结构中最大的创新是引入残差结构,与传统堆叠层的做法不一样的是,残差结构在传统卷积层引入额外的捷径分支 (Identity)。其细节结构如图 6 所示,当网络的输入为  $X$ ,真实的输出标签为  $H(x)$ ,若将输入  $X$  作为初始值,网络此时需要学习的是  $F(x) = H(x) - x$ 。其中所有残差块都由两个连续的  $3 \times 3$  卷积、自身映射以及 ReLU 激活函数组成。因此,我们借鉴了残差块的特点,将 SEG-Net 中的所有传统卷积序列替换成了带有残余连接的卷积块。




图 6 残差结构  
Fig. 6 Residual structure

2.2.3 注意力机制

为了从众多特征信息中选择对当前任务目标更关键的信息,提高图像信息处理的效率与准确性,本文引入深度学习的注意力机制。注意力机制最先应用在自然语言处理。注意力机制不仅能够使网络聚焦于具体任务中,也可以对无关区域起到抑制作用。注意力机制可以分为硬注意力机制和软注意力机制。软注意力机制相较于硬注意力机制最大的优点是,其可以对输入图像进行区分,这使得利用神经网络计算梯度并通过反向传播学习注意权重成为可能,使其在其他计算机领域中应用也成为可能。

例如:Hu 等<sup>[13]</sup>提出的 SENet 模型,该模型最大的创新点在于提出了注意力模块压缩与激励模块 (SE) 并用于自然图像的处理,可以自适应地获取到每个特征通道的重要程度,并且取得了最后一届 ImageNet2017 竞赛 Image Classification 任务冠军,其

原理图如图 7 所示。该模块分为 3 个步骤,首先将输入的图像先经过一个全局平均池化操作,即将图像中的所有像素值相加再求平均值,得到一个单一数值;然后该值经过一个全连接层,从而得到每个特征通道——对应的权重值;最后将得到权重加权到每个通道的特征上,实现图像通道的重要信息提取。因此,在本文中我们将 SE 模块作用在网络每个卷积序列之后用于提取图像重要信息。




图 7 压缩与激励模块原理图

Fig. 7 Compression and Excitation Module Schematic

2.3 数据预处理与字符提取

字符提取旨在检测由深度分割网络确定的铭牌区域中的每个字符。由于噪声、光照和对比度等各种条件,这一过程颇具挑战性。铭牌区域首先被转换为灰度,应用高斯滤波去除噪声,随后使用对比度受限的自适应直方图均衡化算法<sup>[14]</sup>来增强局部对比度。输入彩色图像的灰度计算如式(1)所示:

$$Im_{Gray} = 0.3Im_{Red} + 0.59Im_{Green} + 0.11Im_{Blue} \quad (1)$$

其中: $Im_{Red}$ 、 $Im_{Green}$ 、 $Im_{Blue}$ 为输入彩色图像的红色、绿色和蓝色分量。标准偏差为  $\sigma$  的二维高斯平滑核用于高斯滤波,如式(2)所示:

$$g(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-0.5(\frac{x-\mu}{\sigma})^2} \quad (2)$$

其中: $\sigma$  和  $\mu$  分别为高斯函数的标准差和期望值。用高斯函数对输入图像的高斯滤波如式(3)所示:

$$Im_{filt} = Im_{gray} * g(x) \quad (3)$$

其中: $*$  为卷积运算。去除噪声后,从灰度图像中减去滤波后的图像,进行背景消除和前景改善,如式(4)所示:

$$Im_{Fg} = Im_{Filt} - Im_{Gray} \quad (4)$$

前景对象(字符)是通过阈值化提取的。本文采用的是简单高效的大津阈值法。在图像二值化之后,应用形态学操作,例如侵蚀和膨胀,以便去除任

何不想要的二值对象<sup>[15]</sup>。最后,边界框用于检测最终二值图像中的每个厂家名称。边界框是一个单独的矩形框,表示每个名称的准确位置。

2.4 迁移学习策略

迁移学习(Transfer learning)是把已训练好的模型(预训练模型)参数迁移到新的模型来帮助新模型训练。引入迁移学习<sup>[16]</sup>的卷积神经网络能够较好地适应图像的结构,缓解了模型的过拟合问题<sup>[17]</sup>,同时进行特征提取和分类,使得特征提取有助于特征分类。其经常会用于如下场景中,即在目标域中,当训练数据数量相当少时,使用转移的知识来实现有效的分类。迁移学习最常用的实现方法是微调网络,具体实现如图 8 所示。




图 8 微调

Fig. 8 Fine-tune

根据图 8 将微调算法实现的具体步骤总结如下:

- 步骤 1** 在源数据集上训练一个神经网络模型,即源模型
- 步骤 2** 创建一个新的神经网络模型,即目标模型:它复制了源模型上除输出层外的所有模型设计及其参数
- 步骤 3** 为目标模型添加一个输出大小为目标数据集类别个数的输出层,并随机初始化该层的模型参数
- 步骤 4** 在目标数据集上训练目标模型,我们只训练输出层,其余层的参数则是微调获得。

综上所述,并从本文任务出发,我们采用 VGG-16 模型的预训练权重针对智能电表通信模块数据对模型进行自定义,去除全连接层、Softmax 层和分类输出层,将剩余的层应用到厂家分类任务中。

3 损失与评价指标

3.1 损失函数

分割模型的总体性能不仅取决于网络结构,损失函数也是关键因素之一。铭牌区域分布的特点使得分割任务存在固有的类别不平衡问题<sup>[18]</sup>,若损失函数的选择不合理,有可能导致卷积网络的训练由像素较多的非厂家名称区域主导,较小的目标区域很难学习到其特征,从而降低网络的有效性,最终导致分割结果不理想。为了解决这个问题,本文采用了交叉熵损失函数,如式(5)所示:

$$C = -\frac{1}{N} \sum_x [y \ln a + (1 - y) \ln (1 - a)] \tag{5}$$

式中: $C$  为损失值,即所求 loss; $N$  用于求平均,为样本数量,即 Batchsize; $x$  为预测向量维度,因为需要在输出的特征向量维度上逐个计算并求和; $y$  为 One-hot 编码后的真实值对应  $x$  维度上的标签,为 1 或 0, $a$  是 One-hot 格式输出的预测标签,为 0~1 的值, $a$  经过了 Softmax 激活,所以  $a$  的和,值为 1。

3.2 性能评价指标

为了评估所提出的方法,考虑了 4 个性能评价指标,评价指标分别为准确率(Acc)、精确率(PV)、召回率(RV)和  $F_{1-Score}$  值( $F1$ )<sup>[19]</sup>。准确率(Acc)用于厂家的分类,PV、RV 和  $F_{1-Score}$  用于评估铭牌区域的检测。

准确率(Accuracy)被广泛用于二元分类任务,其定义如式(6)所示:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \tag{6}$$

其中: $TP$ (True Positive)为真正例, $FN$ (False Negative)为假负例, $FP$ (False Positive)为假正例; $TN$ (True Negative)为真负例。

精确率 PV 如式(7)所示:

$$Precision = \frac{TP}{TP + FP} \tag{7}$$

召回率 RV 如式(8)所示:

$$Recall = \frac{TP}{TP + FN} \tag{8}$$

$F1$  分数( $F_{1-Score}$ )同时兼顾了分类模型的精确率和召回率。其定义如式(9)所示:

$$F_{1-Score} = 2 \frac{PR}{P + R} = \frac{TP}{TP + \frac{1}{2}(FP + FN)} \tag{9}$$

其中: $P$  表示精确率(Precision); $R$  表示召回率(Recall)。

4 实验

4.1 数据集

为了便于多输入训练,将通过通信模块全维度检测装置获得的图像被裁剪成 480 × 480 共获得 1 000 张裁剪图像,按 4:1:2 的比例随机分成训练集、测试集和验证集<sup>[20]</sup>,训练集用于训练模型参数,验证集用于验证模型参数,测试集用于评估最终模型的精度。

4.2 实验配置环境

实验在配置为 Intel(R) Xeon(R) Silver 4110 CPU @ 2.10 GHz 的 Ubuntu 平台下进行,使用 Python3.8 + Keras2.6.0 框架训练模型。实验环境参数如表 1 所示。

| 表 1 实验环境参数表                                      |                      |
|--------------------------------------------------|----------------------|
| Tab. 1 Experimental environment parameters table |                      |
| 名称                                               | 参数                   |
| 系统                                               | Ubuntu 18.04.5 LTS   |
| 框架                                               | Keras                |
| 语言                                               | Python               |
| CPU                                              | Silver 4110          |
| GPU                                              | NVIDIA-SMI 455.23.04 |
| Memory                                           | 31.0GiB              |
| OSType                                           | 64-bit               |

4.3 实验分析与评估

本文在训练模型时使用 SGDM<sup>[21]</sup> 作为优化器,在随机梯度下降的基础上引入了一阶动量。为了防止梯度过大,初始学习率设置为 0.001, L2 正则化<sup>[17]</sup> 参数选择为 0.000 5,动量参数设置为 0.9,批量选择为 4,训练持续了 60 个 epoch。在训练的过程中使用 Tensorboard 和 Matplotlib 可视化模型训练细节。

为了评估 ResSE-SegNet 的有效性,现将 ResSE-SegNet 与基于 VGG 框架的 FCN<sup>[22]</sup> 模型、PSPNet<sup>[23]</sup>

模型、U-Net<sup>[24]</sup>模型、SEG-Net 和 SEG-Net + Res 进行了比较。将构建好的网络在训练集下进行训练,同时采用验证集进行实时观察验证,最终将训练好的模型在测试集下进行测试。6 种模型训练集与验证集的准确率及 loss 曲线分别如图 9 和图 10 所示。




图 9 训练集的准确率及 loss 曲线  
Fig. 9 Accuracy and loss curve of training set

从精度曲线可以看出,ResSE-SegNet 精度更高,在第 8 个 epoch 之后逐渐收敛。FCN、U-Net、PSP-Net、SEG-Net 和 SEG-Net + Res 在验证过程中,存在较大波动,模型鲁棒性低,出现了过拟合问题。实验表明,本文的方法在采集到的数据集上能达到较高精度,与现有的一些方法相比效果有了提升。

在完成分割任务之后,对分割结果进行了可视化,效果如图 11 所示,从定性的角度出发,在定位铭牌中较大目标区域的时候,本文提出的模型架构可以轻松分割出厂家区域,但是在提取厂家区域模糊边界时表现欠佳,偶尔会出现过分割或欠分割的情况。尤其是在采集图像时存在一定倾斜角的情况下,可能将模糊区域边界忽略,导致过度分割情况的出现。但这仍不妨碍分割模型网络架构为后续精准高效的厂家识别提供可靠的数据。




图 10 验证集的准确率及 loss 曲线  
Fig. 10 Accuracy and loss curve of validation set



图 11 可视化的分割结果  
Fig. 11 Visualized segmentation results

将提出的 ResSE-SegNet 与 4 种语义分割网络进行实验比较,并以 SEG-Net 为基准分别比较依次加入残差模块、SE 模块的实验效果。

5 种模型与 ResSE-SegNet 的定量分割获得的平均 RV、PV 和 F1 值如表 2 所示。评价指标中的 F1 值 ResSE-SegNet 取得了最高分,分别比 FCN、PSP-Net、U-Net 和 SEG-Net 和 SEG-Net + Res 提高了 4.86%、2.99%、2.38%、1.28% 和 0.35%,其余指标也取得了相对较好的效果。

表 2 5 种模型与 ResSE-SegNet 的定量分割结果

Tab. 2 Quantitative Segmentation Results of Five Models and ResSE-SegNet

| 方法                | RV      | PV      | F1      |
|-------------------|---------|---------|---------|
| FCN               | 0.892 1 | 0.916 8 | 0.889 3 |
| PSPNet            | 0.910 8 | 0.926 1 | 0.909 7 |
| U-Net             | 0.916 9 | 0.930 5 | 0.915 4 |
| SegNet            | 0.923 4 | 0.939 7 | 0.921 4 |
| SegNet + Res      | 0.936 5 | 0.948 2 | 0.930 7 |
| SegNet + Res + SE | 0.940 7 | 0.949 5 | 0.934 2 |

最后使用 SGDM 优化器进行微调,批量大小为 32,初始学习率为 0.000 1。每 1 000 次迭代后,学习率下降一次,降幅为 10 倍,优化器对网络进行了微调,总共进行了 20 000 次迭代,分类准确率达到 了 98.53%。

5 结 论

本文提出了一种具有级联形式的深度学习方 法用于智能电表通信模块铭牌检测和识别,该方 法采用高斯滤波和自适应图像对比度增强等预 处理技术,使输入图像更适合于进一步处理。首 先,通过本文提出的 ResSE-SegNet 深度语义分 割网络来确定输入图像中厂家名称所在的区域; 然后采用阈值法来提取特征区域的具体信息从 而实现通信模块的检测;最后将确定的厂家名 称具体信息输入到以迁移网络 VGG-16 为主 干的 ResSE-SegNet 编码区中从而实现通信模 块 的 分 类。实 验 结 果 表 明,该 方 法 在 检 测 和 识 别 任 务 中 都 是 有 效 的。计 算 出 的 召 回 率 为 94.07%,精确率为 94.95%, $F_{1-Score}$  为 93.42%。应 用 此 方 法 的 通 信 模 块 全 维 度 检 测 装 置 对 智 能 电 表 通 信 模 块 厂 家 的 分 类 准 确 率 为 98.53%。

参 考 文 献:

[1] ALGULIYEV R, ALIGULIYEV R, ABDULLAYEVA F. Privacy-preserving Deep Learning Algorithm for Big Personal Data Analysis[J]. Journal of Industrial Information Integration, 2019, 15: 1.

[2] 陈为,路长厚,陈静.金属铭牌压印凸凹字符的分割[J].青岛科技大学学报(自然科学版),2012,33(6):624.

CHEN Wei, LU Changhou, CHEN Jing. Segmentation of Embossed Convex and Concave Characters on Metal Nameplates[J]. Journal of Qingdao University of Science and Technology (Natural Science Edition), 2012, 33(6): 624.

[3] 刘波.变电站设备铭牌识别系统设计与实现[D].成都:电子科技大学,2013.

[4] 曹倩倩.电力铭牌图像中的文本检测与识别方法研究[D].南京:南京理工大学,2020.

[5] 王佳宇.基于深度学习的变电设备铭牌文本识别研究[D].南京:东南大学,2020.

[6] 徐金辰.基于深度学习的变电站铭牌文字检测研究[D].天津:天津大学,2020.

[7] SHI B, XIANG B, CONG Y. An End-to-End Trainable Neural Network for Image-Based Sequence Recognition and Its Application to Scene Text Recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, 39(11):2298.

[8] 段恩悦.基于深度学习的铭牌文字检测与识别方法研究[D].济南:山东大学,2021.

[9] 王海涛,高玉栋,侯建新,等.基于 DCGAN 的印刷缺陷检测方法[J].哈尔滨理工大学学报,2021,26(6):24.

WANG Haitao, GAO Yudong, HOU Jianxin, et al. Printing Defect Detection Method Based on DCGAN[J]. Journal of Harbin University of Science and Technology, 2021, 26(6): 24.

[10] 冯磊,蒋磊,许华,等.基于深度级联孪生网络的小样本调制识别算法[J].计算机工程,2021,47(4):108.

FENG Lei, JIANG Lei, XU Hua, et al. Small-sample Modulation Recognition Algorithm Based on Deep Cascaded Twin Network[J]. Computer Engineering, 2021, 47(4): 108.

[11] 戚谢,仇子赫,张博洋.基于改进 USE-Net 网络的林木图像语义分割研究[J].森林工程,2022,38(6):82.

- QI Shu, ZHANG Zihe, ZHANG Boyang. Research on Tree Image Semantic Segmentation Based on Improved USE-Net Network [J]. Forest Engineering, 2022, 38 (6): 82.
- [12] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 770.
- [13] HU J, SHEN L, SUN G. Squeeze-and-Excitation Networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018, 7132.
- [14] VELUCHAMY M, SUBRAMANI B. Fuzzy Dissimilarity Color Histogram Equalization for Contrast Enhancement and Color Correction [J]. Applied Soft Computing, 2020, 89:106077.
- [15] AL-SHEMARRY M S, LI Y, ABDULLA S. An Efficient Texture Descriptor for the Detection of License Plates From Vehicle Images in Difficult Conditions[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(2):553.
- [16] WANG Y C, CHENG C H. A Multiple Combined Method for Rebalancing Medical Data with Class Imbalances[J]. Computers in Biology and Medicine, 2021,134:104527.
- [17] NIEMEIJER M, STAAL J J, GINNEKEN B V, et al. Comparative Study of Retinal Vessel Segmentation Methods on a New Publicly Available Database[J]. Proceedings of SPIE-The International Society for Optical Engineering, 2004, 5370:648.
- [18] 马鹏, 樊艳芳. 基于深度迁移学习的小样本智能变电站电力设备部件检测[J]. 电网技术, 2020(3):12.
- MA Peng, FAN Yanfang. Small Sample Smart Substation Power Equipment Component Detection Based on Deep Transfer Learning[J]. Power System Technology, 2020 (3):12.
- [19] MUJAHIDIN S, AZHAR N F, PRIHASTO B. Analysis of Using Regularization Technique in The Convolutional Neural Network Architecture to Detect Paddy Disease for Small Dataset [J]. Journal of Physics: Conference Series, 2021, 1726(1):012010pp).
- [20] JMD A, BH A, BJB A, et al. Automated Classification of Fauna in Seabed Photographs: the Impact of Training and Validation Dataset Size, with Considerations for the Classimbalance [J]. Progress in Oceanography, 2021, 196:102612.
- [21] 王鑫, 张昊宇, 凌诚. 基于 U-Net 优化的 SAR 遥感图像语义分割[J]. 计算机科学, 2021, 48(S2):376.
- WANG Xin, ZHANG Haoyu, LING Cheng. Semantic Segmentation of SAR Remote Sensing Images Based on U-Net Optimization [J]. Computer Science, 2021, 48 (S2): 376.
- [22] LONG J, SELHAMER E, DARRELL T. Fully Convolutional Networks for Semantic Segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4):640.
- [23] ZHAO H, SHI J, QI X, et al. Pyramid Scene Parsing Network[C]// IEEE Computer Society. IEEE Computer Society, 2016:2881.
- [24] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional Networks for Biomedical Image Segmentation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: 18th International Conference, Munich, Germany, 2015: 234.

(编辑:温泽宇)