

DOI:10.19651/j.cnki.emt.2108493

基于OCR的芯片表面标识码自动识别系统设计*

赵杰 高林 李玮

(青岛科技大学自动化与电子工程学院 青岛 266061)

摘要: 芯片标识码的自动识别对于避免人工插件错误、提高分拣效率具有重要意义。本文设计了一套基于光学字符识别OCR技术的芯片表面标识码自动识别系统。系统由工业相机、光源、检测台、触发装置、PC机组成,触发装置触发工业相机抓拍芯片图片,利用OCR算法对图片中的芯片表面标识码自动识别,并提取出标识码进行后续应用。应用结果表明,单张图片识别时间300 ms左右,识别准确率达到了95%以上,在保证一定准确率的前提下,能够极大提高工作效率,具有很好的实用价值。

关键词: 芯片表面标识码;光学字符识别;工业相机

中图分类号: TP391 **文献标识码:** B **国家标准学科分类代码:** 510.4050

Design of automatic identification system for chip surface identifiers based on OCR

Zhao Jie Gao Lin Li Wei

(School of Automation and Electronic Engineering, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: Automatic identification of chip identification codes is of great significance to avoid manual plug-in errors and improve sorting efficiency. In this paper, a chip surface identification system based on OCR technology is designed. The system consists of an industrial camera, a light source, a detection platform, a trigger device and a PC. The trigger device triggers the industrial camera to capture the chip picture. The OCR algorithm is used to automatically identify the chip surface identification code in the picture and extract the identification code for subsequent application. The application results show that the recognition time of a single image is about 300 ms, and the recognition accuracy can reach more than 95%. Under the premise of ensuring certain accuracy, the work efficiency can be greatly improved, and it has good practical value.

Keywords: chip surface identifier; optical character recognition; industrial camera

0 引言

随着互联网的快速发展,电子制造业进入了快速发展时期^[1]。芯片作为集成电路上的载体,广泛应用在民用、工业、航天等各个领域^[2]。芯片是通过表面的标识码进行区分的,每种芯片的参数、引脚、使用方法都各不相同,因此准确地识别芯片表面的标识码非常重要^[3]。在工业应用中,芯片的分类、缺损检测、组装等工作大多是通过人工方式进行的。随着芯片行业需求量越来越大,提高芯片识别效率对提升工业生产效率具有重要意义。

文献[5]设计的计量检定实验室仪表读数自动识别系统,采用序贯相似性检测算法(sequential similarity detection algorithm, SSDA)定位图像读数区域,进行单字

符分割,再使用反向传播算法(back propagation, BP)和特征匹配算法识别分割出的字符。系统耗时相对较长,准确率相对较低。文献[6]设计的轮胎胶料表面字符识别系统,利用字符宽度的先验知识,提出适用于存在字符内部点间距的字符分割法,之后利用模板匹配法完成了字符的识别,系统使用场景相对单一,处理过程繁琐。文献[7]设计的渣土车车牌字符识别系统,采用基于颜色空间信息的车牌定位方法,最后利用模板匹配法实现车牌识别,使用场景受外界干扰较大。上述传统的光学字符识别算法(optical character recognition, OCR)普遍采用字符模板匹配法,但是这种方法受应用场景、光线强度影响较大,不易区分相似的字符;前期字符模板的准备比较耗时费力,没有适用于大多数工业场景下的模板库;抗干扰能力差,在生产过程中,

收稿日期:2021-12-01

* 基金项目:山东省自然科学基金(ZR2021MF023)项目资助

芯片表面不可避免地出现划痕、污点等问题;都会影响标识码识别的准确性。

以深度学习为框架的 OCR 技术准确率高、速度快、抗干扰性强,得到了广泛使用,有取代传统 OCR 的趋势,但是在工业场景下工件字符识别方面的应用仍处在起步阶段^[8]。文献[9]将深度学习引入到芯片表面字符的识别,基于分割单个字符再利用深度网络 LeNet-5 识进行别。但是芯片发展趋向于微型化,芯片上面的字符和字间距都相对较小,势必给单个字符的切割造成困难,影响最终的识别效果。

针对上述问题,本文采用的标识码检测算法将二值化过程加入到网络训练当中,自适应地设置字符阈值进行标识码区域的分割;使用的标识码识别算法将卷积神经网络和循环神经网络结合,把标识码的识别转换成序列的识别;基于优化算法,设计了一套芯片表面标识码自动识别系统,系统解决了传统人工识别芯片表面标识码费时、费力、容易出错的问题;避免了传统 OCR 受使用环境影响大、准确率低、通用性差的问题;简化了单个字符分割识别的后处理过程。应用效果表明,系统使用简单、便于操作、准确率高(95%左右),满足了工业场景下芯片表面标识码识别的要求。

1 系统方案

基于 OCR 的芯片表面标识码识别系统主要由硬件系统以及软件系统两大部分构成。

1.1 硬件系统

硬件系统主要由工业相机、相机光源、检测台、触发装置、PC 机等组成。硬件系统结构如图 1 所示。




图 1 硬件系统结构图

1) 相机选型

芯片表面的标识码较小,对像素质量要求较高,像素边缘虚化不能超过两个像素。选用海康 MV-CA050-10GC 型号的 GigE 接口工业面阵相机,配 500 万像素镜头。

2) 光源选型

芯片表面的标识码大多印在黑色工程 ABS 塑料上并

且尺寸比较小。在采集的过程中,光源不合适,会造成光线不均匀,拍摄字符不清晰等问题;另外芯片上的标识码印刷方式主要是激光雕刻和喷码,对光源的感光度不同。

根据测试结果,该系统选用白色环形光源应用于喷码印刷的标识码识别,选用红色环形光源应用于激光雕刻的标识码识别。

3) 检测台选型

针对传统流水线芯片引脚易损、角度不固定问题。该系统采用两个独立推杆式检测台,设有多尺寸的芯片底座。在检测台的末端安装触发装置,用来触发相机抓拍。

1.2 软件系统

软件系统主要包括上位机软件和 OCR 算法两部分。

1) 上位机软件

本系统基于 Visual Studio 2019 平台,调用相机 SDK 开发包来二次开发。实现相机端口的选择以及相机重要参数的设置。加入了串口接收部分,用于相机的硬触发。通过 C# 调用编译好的算法动态库文件,在控制台显示最终的识别结果。

2) OCR 算法

OCR 算法结构主要包括图片预处理、标识码检测、标识码识别。OCR 算法流程如图 2 所示。




图 2 OCR 算法流程

2 OCR 算法实现

2.1 图片预处理

系统采集的图像受环境光线不均匀、光源不稳定、检测台抖动、相机长时间使用发热等问题的影响,可能会导致图像质量下降,出现图像噪声,给检测和识别造成很大的干扰。因此,在检测和识别操作前必须对图片进行预处理。系统采用的图片预处理方法如下。

1) 双边滤波

双边滤波同时考虑被滤波像素点的空域信息和值域信息,设置好参数坐标空间的标注方差,能够达到保护字符边缘并且去除噪声的效果。

2)形态学处理^[8]

利用形态学中的开处理操作,对字符周围一些斑点、轻微磨损造成的不规则形状的干扰。同理,利用闭处理操作,填充字符中的斑点或不饱满的字符^[9]。

2.2 标识码检测

传统工业应用场景的字符检测大多采用垂直投影的方法进行单个字符的检测,但是对于小尺寸字符、字符间距较小的场景应用效果较差。针对芯片表面标识码的检测,本文采用基于文本区域分割的标识码可微二值化算法^[10](differentiable binarization, DB)对图像中的标识码区域进行检测,将可微的二值化操作加入到训练网络,通过网络训练自适应设置每个像素点的字符阈值,可更好地区分标识码区域和背景,减少整个后处理的过程。

标识码检测算法使用 Resnet18 作为轻量型骨干网络,利用深层神经网络提取更抽象的特征。颈部网络采用特征金字塔结构,对多尺度的特征图进行特征融合,将高层的语义信息与底层的细粒度信息融合。在感知图像标识码区域分布的同时,也保证了对标识码区域边界的精细检测^[11]。将颈部网络产生的特征图进行级联,输出融合特征图,然后分别产生概率图和阈值图。后处理部分根据概率图用固定阈值生成二值图,确定最终的标识码区域边界。标识码检测算法网络结构如图3所示。

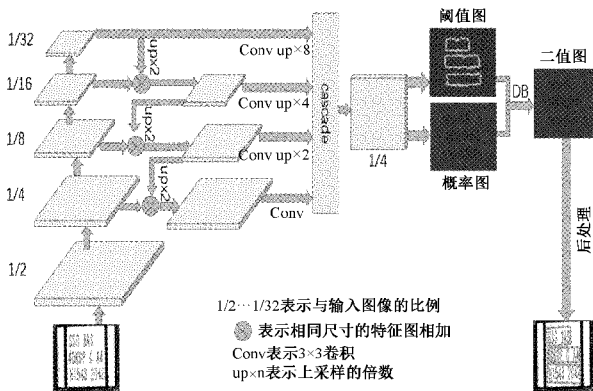


图3 标识码检测算法网络结构

1)生成标签

标注图中的文本区域 G_t 多边形通过一组线段 S 来表示:

$$G_t = \{S\}^n \tag{1}$$

式中: n 是每个文本框的标注点数。

利用 Vatti 算法^[12]对标注图的边界框 G_t 裁剪,向内收缩 D 得到收缩框 G_s :

$$D = \frac{S(1-r^2)}{L} \tag{2}$$

式中: S 为标注图文字区域面积, L 为标注图文字区域周长, r 为收缩因子,设为 0.4。

收缩框 G_s 作为概率图和二值化图学习的标签 P_{gt} , 生成过程如图4所示。




图4 概率图标签生成过程

阈值图以标识码区域边界图作为监督图,使用相同的收缩量 D , 将真实标注图边框 G_t 向内收缩得到 G_s , 向外膨胀得到 G_d , 将 G_s 和 G_d 之间的标识码区域作为文本边界,求该区域内所有像素点到真实标注图4个边框最短的距离作为该像素点的阈值,接着将该阈值做归一化处理,为了较好区分边界和文字区域,将阈值范围 $[0, 1]$ 映射到 $[0.3, 0.7]$, 最终得到阈值图的监督标签 T_{gt} , 阈值图标签生成过程如图5所示。




图5 阈值图标签生成过程

2)可微二值化

将产生的概率图和自适应阈值图作为输入,根据可微二值化公式计算出二值图的像素点取值,每个像素点的取值计算公式为:

$$B_{(i,j)} = \frac{1}{(1 + e^{-k(P_{(i,j)} - T_{(i,j)})})} \tag{3}$$

式中: $B_{(i,j)}$ 为二值图像素点的取值, $P_{(i,j)}$ 为概率图中的字符概率值, $T_{(i,j)}$ 为阈值图中字符的阈值, (i, j) 为像素点, k 为放大因子(该系统设为 40 效果较好)。

概率分布图和阈值分布图,如图6所示。概率分布图和阈值分布图经过式(3),获得二值图中像素点的取值。计算过程为:

字符区: $P = 1, T = 0.3, P - T = 0.7 > 0, B = 1$
 字符区边界: $P = 0, T = 0.7, P - T = -0.7 < 0, B = 0$

非字符区: $P = 0, T = 0.3, P - T = -0.3 > 0, B = 0$

3)计算损失函数

由于概率图和二值图共用一个监督,因此概率图损失函数 L_p 和二值图损失函数 L_b 相等,使用二元交叉熵损失函数:

$$L_p = L_b = \sum_{i \in S_i} y_i \log x_i + (1 - x_i) \tag{4}$$

式中: S_i 为经过 hard negative mining 处理过的样本集,正负样本比为 1:3。

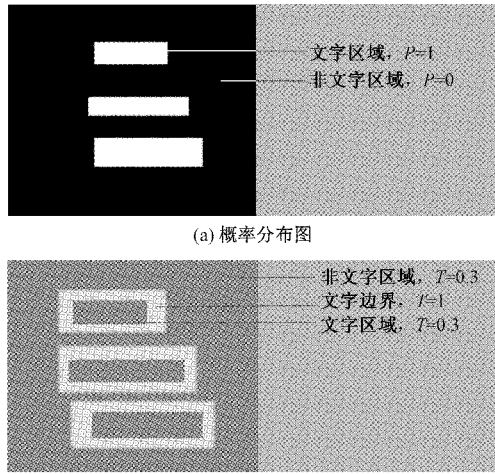


图 6 分布图

阈值图损失函数 L_t 计算文本扩展区域 G_d 与真实标签 G_t 的距离和。使用 L1 损失函数：

$$L_t = \sum_{i \in R_d} |y_i^* - x_i^*| \quad (5)$$

式中： R_d 为文本扩展区域 G_d 内的所有范围， y_i^* 为阈值的标签， x_i^* 为真实标签。

总损失函数 L_{sum} 由 L_p 、 L_t 、 L_b 三者加权求和得到：

$$L_{sum} = L_p + \mu L_t + \nu L_b \quad (6)$$

式中： μ 为 1，由于 L_t 会对 L_b 造成影响， ν 设为 10。

4) 后处理

在推理过程中，去掉阈值图分支、二值图和 DB 部分，通过鲁棒的概率图直接推理，去掉繁琐的后处理过程，加快推理速度。用设置好的固定阈值对概率图进行二值化得到字符连通区域：

$$B_{(i,j)} = \begin{cases} 1, & P_{(i,j)} \geq t \\ 0, & \text{其他} \end{cases} \quad (7)$$

式中： t 设置为 0.4。

对字符连通区域进行膨胀，利用 Vatti 算法进行裁剪，膨胀量 D' 为：

$$D' = \frac{S' \times R'}{L'} \quad (8)$$

式中： S' 为文本连通区域的面积， L' 为文本连通区域的周长， R' 为膨胀因子，设为 1.5。利用 OPENCV 内置函数，画出标识码区域边界框。

2.3 标识码识别

通过上述的标识码检测算法，可以将图片中芯片表面的标识码区域分割成一组字符框。由于深层卷积神经网络无法产生可变长度的标签序列，循环神经网络不能进行端到端的训练和优化。系统字符识别采用卷积循环神经网络算法^[13] (convolutional recurrent neural network, CRNN)，利用新的神经网络架构，将特征提取、序列建模和字符转录集成到统一的框架中。该算法可以灵活地处理任意长度的

序列，不涉及字符级的标注和分割，提高了识别的精度和速度，网络结构如图 7 所示。




图 7 网络结构

CRNN 网络主要由卷积层、循环层、转录层 3 部分组成。卷积层从标识码的区域图片中提取出特征序列；循环层利用长短期记忆网络 (long-short term memory, LSTM) 捕获上下文的强大能力，对特征序列的每一帧进行预测；转录层利用联结时间分类^[14] (connectionist temporal classification, CTC) 机制进行转录，映射成字符标签，有效解决循环层预测标签对齐的问题。

1) 提取特征序列

卷积层采用改进的 VGG16 网络^[15]，并提出 3 点改进：由于只进行特征序列提取，去掉全连接层和 Softmax；将第 3 和第 4 个 maxpooling 层的窗口尺寸调整为 1×2 ，仅对宽度进行调整；加入批归一化操作，加快训练。改进后的网络结构如表 1 所示。

表 1 改进后的 VGG 网络

类型	配置	特征图尺寸
输出序列	W/4 个特征序列	$1 \times 1 \times 512$
卷积层 7	C:512 K:2×2 S:1 P:0	$W/4 \times 1 \times 512$
最大池化层 4	窗口:1×2 S:2	$W/4 \times 2 \times 512$
批归一化 2	—	—
卷积层 6	C:512 K:3×3 S:1 P:1	$W/4 \times 4 \times 512$
批归一化 1	—	—
卷积层 5	C:512 K:3×3 S:1 P:1	$W/4 \times 4 \times 512$
最大池化层 3	窗口:1×2 S:2	$W/4 \times 4 \times 256$
卷积层 4	C:256 K:3×3 S:1 P:1	$W/4 \times 8 \times 256$
卷积层 3	C:256 K:3×3 S:1 P:1	$W/4 \times 8 \times 256$
最大池化层 2	窗口:2×2 S:2	$W/4 \times 8 \times 128$
卷积层 2	C:128 K:3×3 S:1 P:1	$W/2 \times 16 \times 128$
最大池化层 1	窗口:2×2 S:2	$W/2 \times 16 \times 64$
卷积层 1	C:64 K:3×3 S:1 P:1	$W \times 32 \times 64$
输入图片	h 固定, 灰度图片	$W \times 32 \times 1$

由于卷积层作用于局部区域,具有平移不变特性,因此每个特征序列都与输入图像对应的感受野对应,如图8所示。




图8 特征序列与输入图像对应图

2) 序列识别

循环卷积网络擅长处理序列问题,能够对任意长度的序列进行操作,但是传统的循环神经网络存在梯度消失不易训练的问题,限制存储上下文的范围。LSTM对传统的循环神经网络进行改进,由一个记忆单元和输入门、输出门、遗忘门组成。输入门和输出门相互配合,允许记忆单元可以长时间存储,遗忘门清除记忆单元中的上下文。但是记忆单元只能存储过去的上下文,不过图像中的前后序列对最终的识别可以相互补充。因此将前后两个方向的长短期记忆网络结合起来使用,并进行结构的加深,用来识别更抽象的序列。该系统采用4层双向长短期记忆网络结构堆叠,深层双向长短期记忆网络结构如图9所示。




图9 深层双向长短期记忆网络结构

输入特征序列 $x = \{x_1, x_2, \dots, x_T\}$, x 每一列 $x_t = \{x_{t1}, x_{t2}, \dots, x_{tm}\}$, 表示时间步 t 时各通道的特征。深层双向长短期记忆网络后接一个 Softmax 分类器,输出后验概率矩阵 $y = \{y_1, y_2, \dots, y_T\}$, y 的每一列为 $y = \{y_{t1}, y_{t2}, \dots, y_{tn}\}$, 表示预测字符的概率分布。其中 T 代表时间步长, t 代表某个时间步, m 代表特征序列通道数, n 代表识别字符的长度。

3) 字符转录

字符转录是将循环层输出的预测标签转换成标签序列。输入图片的每个字符尺寸不同,会导致输入图像中的单个字符标签对应多个特征序列,无法实现单个字符与特征序列对齐,造成循环层输出大量的字符堆叠。例如输入

字符图片 H1543, 经过循环层可能会输出 HHH1554433, 不能直接作为最终的识别结果。利用 CTC, 解决了循环层输出的预测标签和输入图像标签对齐的问题。

CTC 中引入空白占位符机制,在待识别字符中多加入一个空白符,进行标签的预测。最后输出时通过映射函数 B , 去掉重复的标签和空白符。对给定输入 Y 的前提下,输出标签 L 的概率为:

$$p(L | y) = \sum_{\pi \in B^{-1}(L)} p(\pi | y) \quad (9)$$

式中: $\pi \in B^{-1}(L)$ 代表所有经过 B 变换后是 L 的所有路径 π , $p(\pi | y)$ 为:

$$p(\pi | y) = \prod_{t=1}^T y_{\pi_t}^t \quad (10)$$

式中: $y_{\pi_t}^t$ 代表 π 路径 t 时间步的预测序列概率。

另外芯片表面的标识码种类包括数字和大小写字母,组成相对简单。因此采用基于字典的转录方式,将测试样本直接与字典 D 关联,根据式找到一条概率最大的字符串路径,输出这条路径上的最优序列。

$$L = \underset{L \in D}{\operatorname{argmax}} p(L | y) \quad (11)$$

4) CTC 损失函数

根据式(9),可以得到 CTC 损失函数 $L(s)$:

$$L(s) = -\ln p(L | y) \quad (12)$$

但是实际应用中,实现最终标签的路径比较多,很难找出全部路径上的 $P(\pi | y)$ 进行求和计算出 $p(L | y)$, 因此引入前向后向算法,利用动态规划方法求出前向概率 $\alpha_t(s)$ 和后向概率 $\beta_t(s)$ 求出 $p(L | y)$:

$$p(L | y) = \sum_{s=1}^{|L|} \frac{\alpha_t(s) \beta_t(s)}{y_{L_s}^t} \quad (13)$$

进而推出 $L(s)$:

$$L(s) = -\ln \sum_{s=1}^{|L|} \frac{\alpha_t(s) \beta_t(s)}{y_{L_s}^t} \quad (14)$$

式中: $y_{L_s}^t$ 为 t 时刻 L_s 字符的概率, S 为序列路径的节点。

最后通过反向传播法对循环层模型参数实现端到端的训练。

3 系统实现过程与结果分析

3.1 环境配置

服务器搭载 Intel M210R 处理器,配 RTX3090 显卡;工作 PC 机搭载 i5 处理器,主频 8 GHz,内存为 512 GB;触发装置使用 STM32 作为控制器。OCR 算法编程使用 Anaconda 配合 Python3.7;上位机编程使用 Visual Studio;检测台触发装置使用 keil4 进行编程。

3.2 训练标识码检测模型

1) 准备数据集

根据应用场景采集 750 张芯片图片,其中训练集 500 张,测试集 250 张,大多为双列直插式和贴片式封装。利用标注软件 PPOCRLabel 根据实际需要分割的方式进行标

注,生成的标签内容如图 10 所示。

```
train/1.jpg [{"transcription": "SSD 3AS", "points": [[1002, 975], [1182, 975], [1183, 1062], [1002, 1062]]},
{"transcription": "40KOP C A4", "points": [[1007, 1062], [1250, 1062], [1250, 1144], [1007, 1144]]},
{"transcription": "H1543 2042", "points": [[1007, 1153], [1251, 1144], [1253, 1235], [1009, 1235]]}]
```

图 10 标识码检测数据集标签

2) 训练模型

由于网络结构复杂,从头开始训练效果往往较差^[16]。为了最终检测的效果更好,先使用 icdar2015 数据集训练 2 000 代生成预训练模型,然后利用上述的数据集训练 500 代进行模型微调。

3) 测试模型

使用与训练集和测试集不相交的 100 张新采集的图片进行测试,发现能够完整贴接地框选出标识码区域,没有出现漏框错框现象,字符检测测试结果如图 11 所示。




图 11 字符检测模型测试结果

3.3 训练文字识别模型

1) 准备数据集

字典中应该包括待识别内容的所有字符,该系统有数字和大小写字母共 62 个,准备真实数据集 750 张。为提升模型精度,利用 StyleText 合成 7 000 张图片,共计 7 750 张图片。其中训练集 5 000,测试集 2 750 张。保证每个字符出现 200 次以上,标签内容如图 12 所示。

```
train/1_crop_0.jpg      SSD 3AS
train/1_crop_1.jpg      40KOP C A4
train/1_crop_2.jpg      H1543 2042
```

图 12 字符识别数据集标签

2) 训练模型

使用数据增强策略进行训练,以 50% 的概率随机加入颜色空间转换、模糊、抖动、噪声、随机切割、透视等扰动,提升模型的鲁棒性、场景适用性。

3) 测试模型

利用标识码检测模型对训练集和测试集不相交的 50 张图片进行裁剪,然后对裁剪完的图片测试标识码识别模型。可以看到训练的模型能够准确地识别芯片表面的标识码,字符识别模型测试结果如图 13 所示。

3.4 系统应用测试

芯片标识码识别系统上位机界面如图 14 所示。上位机界面包含相机参数的设置、触发装置的接收窗口,以及识别结果的显示。

应用测试结果如表 2、3 所示。




图 13 字符识别模型测试结果

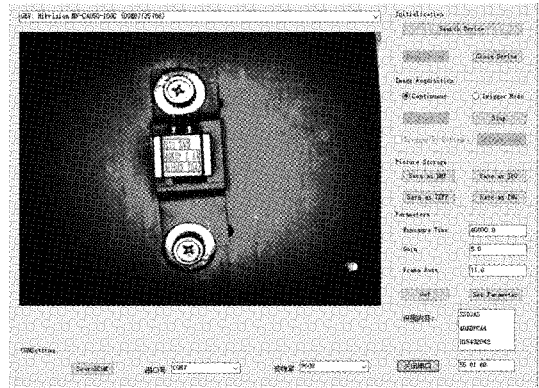


图 14 芯片标识码识别系统上位机界面

表 2 系统识别结果

芯片个数	正确率/%	平均耗时/s
50	98	80
100	96	180
500	95	1 000

表 3 人工识别结果

芯片个数	正确率/%	平均耗时/s
50	90	120
100	84	300
500	70	2 000

通过表 2 和 3 比较可知,该系统在识别正确率和时间方面都比传统人工识别有极大提升,能够满足实际需求。

4 结 论

本文设计了基于 OCR 技术的芯片表面标识码识别系统,通过对抓拍的芯片图片进行预处理,利用可微二值化的方法实现标识码检测,并通过卷积循环神经网络进行标识码的识别。该系统不仅可以精确地将芯片表面的标识码区域进行检测分割,实现标识码地识别,而且能够避免环境问题造成的干扰问题,利用触发装置实现芯片的连续识别。该方法可以很好地解决传统人工识别芯片表面标识码效率低、容易出错、成本高等问题,可以广泛应用到工件表面字符的识别,具有广阔的应用前景。实现生产线上运动芯片的标识码精准快速地动态识别是该系统今后的改进和研究方向。

参考文献

- [1] 郭晓峰,王耀南,毛建旭. 基于几何特征的 IC 芯片字符分割与识别方法[J]. 智能系统学报, 2020, 15(1): 144-151.
- [2] 李勇. 中国芯发展趋势分析[J]. 机电工程技术, 2018, 47(10): 106-108.
- [3] 曹泽卫, 欧阳, 林冬婷, 等. 基于 CNNs 识别反馈的点阵字符检测方法[J]. 电子测量与仪器学报, 2020, 34(8): 159-166.
- [4] 林惠. 基于深度学习的芯片字符实时识别方法研究[D]. 武汉: 华中科技大学, 2019.
- [5] 张鑫, 张家洪, 许晓平, 等. 计量检定实验室仪表读数自动识别系统设计[J]. 电子测量技术, 2021, 44(1): 173-177.
- [6] 王浩楠, 张晓青, 郭阳宽, 等. 基于机器视觉的轮胎胶料表面字符识别[J]. 电子测量与仪器学报, 2021, 35(1): 191-199.
- [7] 瞿国庆, 李江佩. 渣土车车牌字符智能识别研究[J]. 电子测量与仪器学报, 2016, 30(12): 1853-1860.
- [8] 刘怀芝, 陆小虎, 徐喜东, 等. 一种新的基于形态学和模板匹配的车牌识别方法[J]. 国外电子测量技术, 2018, 37(1): 20-23.
- [9] 罗月童, 黄文, 饶永明, 等. 基于深度学习的芯片表面字符识别方法[J]. 合肥工业大学学报(自然科学版), 2020, 43(4): 463-467.
- [10] LIAO M, WAN Z, YAO C, et al. Real-time scene text detection with differentiable binarization [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 11474-11481.
- [11] 邵海琳, 季怡, 刘纯平, 等. 基于增强特征金字塔网络的场景文本检测算法[J]. 计算机科学, 2022, 49(2): 248-255.
- [12] RYOTA A, KEIGO A, NAOKI A, et al. Development of cutting simulator using polygon representation-applying and extending vatti clipping-science direct[J]. Precision Engineering, 2020, 66: 593-604.
- [13] 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 Pattern Analysis & Machine Intelligence, 2016, 39(11): 2298-2304.
- [14] GRAVES A. Connectionist temporal classification: labelling unsegmented sequence data with recurrent neural networks [J]. International Conference on Machine Learning, 2006: 369-376.
- [15] 魏伟, 苏津磷, 李帆, 等. 基于改进 PSENet 与 CRNN 网络的智能电能表文本识别技术研究[J/OL]. 电测与仪表, 2021: 1-7[2021-11-25].
- [16] 刘正琼, 丁力, 凌琳, 等. 基于字符编码与卷积神经网络的汉字识别[J]. 电子测量与仪器学报, 2020, 34(2): 143-149.

作者简介

赵杰, 硕士研究生, 主要研究方向为机器视觉。

E-mail: 1530177403@qq.com

高林(通信作者), 工学博士, 副教授, 主要研究方向为人工智能系统、工业互联网。

E-mail: gaolin0619@126.com

李玮, 硕士研究生, 主要研究方向为机器视觉。

E-mail: 972217816@qq.com