

基于图像的生物芯片点样质量检测方法研究

陈曦, 赵佳敏, 许雪, 张自力, 李永猛
(河北工业大学, 天津 300130)

摘要: **目的** 为了提高生产线上生物芯片点样质量检测的精度与效率, 研究基于图像处理和卷积神经网络的算法, 判断某生物芯片点样质量是否合格, 并检测点样合格的生物芯片上的点样点半径。**方法** 采用 CCD 相机获取生物芯片点样后的图像, 通过图像预处理, 利用 canny 边缘检测和圆的拟合等图像处理方法, 得到点样点的几何信息, 进而计算出点样点半径。同时提出基于卷积神经网络的点样质量检测方法, 通过区域建议网络提取点样点卷积特征, 引入分割全连接层来训练检测模型, 通过离线训练来验证获得模型的最佳参数。**结果** 和手动测量结果进行对比发现, 半径误差不超过 ± 0.1 mm, 点样质量检测准确率为 91.1%, 单个生物芯片检测时间总和不超过 1.6 s。**结论** 所提出的方法能够满足生产线上产品检测准确性和实时性的要求。

关键词: 生物芯片; 图像处理; 卷积神经网络; 区域建议网络

中图分类号: TP391 **文献标识码:** A **文章编号:** 1001-3563(2018)19-0157-08

DOI: 10.19554/j.cnki.1001-3563.2018.19.028

Detection Method of Biochip Sample Application Quality Based on Image

CHEN Xi, ZHAO Jia-min, XU Xue, ZHANG Zi-li, LI Yong-meng
(Hebei University of Technology, Tianjin 300130, China)

ABSTRACT: In order to improve the precision and efficiency of biochip sample application quality inspection on the production line, the work uses a method based on image processing and convolutional neural network to determine whether a biochip sample application quality is acceptable and inspect the radius of sample application point on the qualified biochip. The CCD camera was used to obtain the image after the biochip was sampled. Through image preprocessing, the image processing methods such as canny edge detection and round fitting were used to obtain the geometric information of the spotted point, and then the sample application point's radius was calculated. At the same time, the detection method of sample application's quality based on convolutional neural network was proposed. The convolution features of sample application points were extracted by the regional recommendation network, and the detection model was introduced by dividing the fully connected layer. The offline training was used to verify the method to obtain the best parameters of the model. Compared with the manual measurement results, the radius error did not exceed ± 0.1 mm, and the accuracy rate of sample application quality detection was 91.1%. The total detection time of a single biochip did not exceed 1.6 seconds. The proposed method can meet the requirements of accuracy and real time of product testing on the production line.

KEY WORDS: biochip; image processing; CNN; region proposal network

随着科技的发展, 产品制造行业的自动化水平不断提高, 进而对产品包装前质量检测的准确性和快速性有了更高的要求, 以此来提高产品包装的合格率以及效率。计算机图像处理与识别技术具有非接触性,

快速性, 精度高, 实时性好等优点, 因此被广泛应用于产品检测领域来提高包装生产线的工作效率^[1]。文中利用图像处理与识别技术对点样后的生物芯片图像进行操作, 从而达到对生物芯片产品点样点质量检

收稿日期: 2018-05-22

作者简介: 陈曦 (1963—), 男, 博士, 河北工业大学教授, 主要研究方向为控制理论与工程、智能检测及自动化设备的研究与开发。

测的目的^[2]。

生物芯片技术是一种新型的生物检测技术,文中所涉及的生物芯片为蛋白质芯片,目前市场上最主要的蛋白质芯片产品是用机械点样方法制备的^[3]。点样是在生物芯片上如玻片、硅片及纤维膜等固定载体上用点样针点上微量样品。生物芯片批量生产后,需要对生物芯片点样质量进行检测,以确定其符合生产要求标准,质量合格的产品才能准确地检测出生物信息。生物芯片点样质量检测包括点样点的半径检测和点样点是否合格 2 部分,该次研究的生物芯片共有 6 个蛋白质点样点,在芯片上每个点样点的位置都是预先设定好的。目前国内针对生物芯片点样质量的检测通常是对生物芯片点样质量进行人工识别,虽然适用性强,但人为因素很容易造成漏检和误检,效率相对较低,劳动强度大,甚至某些指标的检测不能依靠人工目检来完成^[4]。通过计算机的处理和识别得到的检测与分类结果比人工操作更精确、客观、高效,因此进行基于图像的生物芯片点样质量检测方法的研究,对实现产品质量检测自动化,推动工业加工和包装流程自动化,提高企业生产效率和产品合格率具有现实意义。

1 系统的构成

生物芯片质量检测系统包括硬件和软件 2 部分,系统结构见图 1。硬件部分主要是图像采集部分;软件部分为图像处理部分。基本思想是通过计算机对获取的图像进行处理,从而实现点对样质量的检测,因此图像处理技术是检测系统的关键部分。硬件部分包括工业相机,LED 光源与计算机。该次实验中所使用的相机是维视智生产 MV-EM200C 小型千兆网 CCD 工业相机,拍摄大小为 1600×1200 的彩色图像,光源使用的是 LED 环形光源,计算机处理器为 Intel Core i7-6700HQ,内存为 16 GB, Windows10 64 位操作系统。




图 1 系统结构

Fig.1 Composition of the system


2 图像预处理

为了在后续的边缘提取和尺寸测量时能够更加精确,需要对图像进行一系列处理,最大程度地校正失真,凸显图像的关键信息。图像预处理的主要工作是去除图像中的杂质、噪声等,使点样点更容易识别。首先是图像灰度化,为了使图像处理的速度加快又不损失感兴趣区域部分的细节信息,通常将原始彩色图像变换为灰度图像,目的在于突出感兴趣部分,忽略不感兴趣部分,缩短处理时间^[5]。如式(1)采用加权平均值的方法对图像进行灰度化:

$$f(x,y) = 0.30 \times R(x,y) + 0.59 \times G(x,y) + 0.11 \times B(x,y) \quad (1)$$

式中: $R(x,y)$, $G(x,y)$, $B(x,y)$ 分别为红色,绿色,蓝色通道像素值。

灰度化处理后结果见图 2,图 2a 为原始图像,图 2b 为灰度处理。



a 原图

b 灰度化处理

图 2 灰度处理过程

Fig.2 Graying process

图像分割的目的是把一幅图像分割成前景与背景 2 部分,以便对目标物体进行测量,测量结果的好坏极大程度上依赖于图像分割质量,分割后的图像只有 2 个灰度级,即为二值图。由于文中图像是在简单背景下,因此利用灰度直方图将图中目标与背景分开,灰度直方图是一种抽象的针对图像的表达式,灰度直方图是灰度级函数,描述了图像中具有该灰度级的像素个数,横坐标是灰度级,纵坐标是灰度级出现的次数。以谷底为界,双峰分别代表了前景和背景。通过选取谷底阈值 t ,对灰度图像 $f(x,y)$ 进行分割,设分割后的图像为 $g(x,y)$,见式(2)。

$$g(x,y) = \begin{cases} 0 & , f(x,y) \leq t \\ 255 & , f(x,y) > t \end{cases} \quad t \in [0,255] \quad (2)$$

采集图像的灰度直方图见图 3。

根据灰度直方图选择阈值 t 为 110,此时得到的二值图像见图 4。

由于光照因素的影响,经过图像二值化处理后^[6],芯片区域中非点样点的部分像素被处理成白色像素点,不利于后期检测和识别,因此进行数学形态学处理。开运算是结构元素 S 对目标图像 X 先进行腐蚀操作,然后再膨胀,其可以用来消除小物体,并且在平滑较大物体的边界的同时不明显改变其面积。结

构元素 S 对目标图像 X 的开运算定义见式 (3)。

$$X \circ S = (X \otimes S) \oplus S \quad (3)$$

经过数学形态学处理的二值图像效果见图 5。




图 3 灰度直方图

Fig.3 Gray histogram




图 4 二值图

Fig.4 Binary map




图 5 开运算效果

Fig. 5 Open operation renderings

3 半径检测

3.1 canny 边缘检测

canny 边缘检测算子是一种比较新的边缘检测算子,该算子利用高斯函数的一阶微分,在边缘提取和噪声抑制之间取得了较好的均衡,具有较好的检测特性^[7-8]。具体的检测步骤如下所述。

1) 用原始图像数据与高斯模板作卷积,进行图像的滤波去噪。

2) 计算经过滤波后的图像的灰度梯度的幅值见式 (4) 和方向见式 (5)。

$$G(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (4)$$

$$\theta(x, y) = \arctan(f_x(x, y) / f_y(x, y)) \quad (5)$$

3) 对图像的梯度幅值进行非极大值抑制。将梯度方向近似分为 $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 等 4 个方向,分别比较每个像素点在其梯度方向上邻近 2 点的梯度值,只保留梯度强度极大的点,将梯度方向非极大值的点判定为非边缘点。

4) 双阈值设定和边缘的连接。设定一个阈值上界和阈值下界,大于上界的为边界,小于下界的则不是边界,两者之间的为弱边界。这时将和强边界相连的弱边界设定为边界,其他的弱边界被抑制。

得到的边缘图像见图 6。




图 6 canny 算子边缘图像

Fig.6 Canny operator edge image

3.2 计算半径

经过边缘检测后,利用随机 Hough 变换求出点样点的圆心和半径,与传统 Hough 变换相比,随机 Hough 变换减少了无效累计,加快了半径计算的速度。其原理是在图像上随机采样 3 个点来确定一个圆^[9]。利用采样点 $A(x_a, y_a)$, $B(x_b, y_b)$, $C(x_c, y_c)$ 的坐标值,求出 AB 和 BC 两线段的中点坐标点 (x_1, y_1) 见式 (6), (x_2, y_2) 见式 (7)。

$$x_1 = \frac{(x_a + x_b)}{2} \quad y_1 = \frac{(y_a + y_b)}{2} \quad (6)$$

$$x_2 = \frac{(x_b + x_c)}{2} \quad y_2 = \frac{(y_b + y_c)}{2} \quad (7)$$

通过中点坐标求出法线方程:

$$\begin{cases} (x - x_1)(x_b - x_a) + (y - y_1)(y_b - y_a) = 0 \\ (x - x_2)(x_c - x_b) + (y - y_2)(y_c - y_b) = 0 \end{cases} \quad (8)$$

由式 (8) 可得出两直线的交点,在与图像映射的二维累加器中对与该交点对应的单元进行增值操作。在对各直线均完成此类操作后,统计累加器中各存储单元的累加值。最大者即为圆心坐标 (x_0, y_0) 。

各点到圆心坐标距离的均值为 r , 见式 (9)。

$$r = \frac{\left(\sum \left[(x_i - x_0)^2 + (y_i - y_0)^2 \right]^{\frac{1}{2}} \right)}{n} \quad (9)$$

实际半径值计算见式 (10)。

$$R = \frac{l}{m} r \quad (10)$$

式中: r 由式 (9) 得到; R 为半径长度; l 为生物芯片短边的实际长度,由手工测量得到; m 为生物

芯片短边所占的像素点个数,该值通过 Sobel 边缘检测算法提取生物芯片短边轮廓特征,然后遍历轮廓像素并累加,最终得到短边的像素个数;则 l/m 为一个像素长度对应的实际长度。

4 基于卷积神经网络的点样质量检测方法

在点样过程中,可能会出现由于点样机械抖动,导致点样点出现非理想形状,点样点呈现出与标准生物芯片不同的特征。Faster-RCNN 是基于卷积神经网络(CNN)所提出的用于检测的框架^[10]。文中提出了

引入分割全连接层方法,来检测点样点形状,判断点样是否合格。该方法可以在实验条件及数据有限的情况下,也能够对点样点实现更加精确的检测和分割。

4.1 Faster-RCNN 基本原理

Faster-RCNN 是由 Girshick 和 Kaiming He 提出,被广泛应用于物体特征检测。Faster-RCNN 的检测流程见图 7,输入的图像首先经过 CNN 特征计算会生成特征图(feature maps),得到的特征图用区域建议网络^[11](Region Proposal Network)来提取候选区域,最后对候选区域进行分类和回归。




图 7 Faster-RCNN 算法流程
Fig.7 Faster-RCNN algorithm flow

与 Selective Search^[12]在原图中提取候选区域不同,区域建议网络在特征图中用一个 3×3 的滑动窗口(Sliding Window)在整个特征图上滑动,在每次滑动过程中取滑动窗口的中心点,将其映射为 9 个大小不同的锚点框(Anchor Box),规则为:按照不同的面积尺寸 128×128 , 256×256 , 512×512 ;按照不同的长宽比例 $1:1$, $1:2$, $2:1$ 。通过卷积和池化的方法将 9 个锚点(Anchor)映射回原图从而得到候选区域。

区域建议网络损失函数定义见式(11)。

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (11)$$

式中: i 为第 i 个锚点(Anchor); p_i 为第 i 个锚点(Anchor)的目标预测概率; p_i^* 为基准值(Ground Truth)的概率; t_i 为预测边界框(Predict Bounding Box)相对于锚点框(Anchor Box)的偏移; t_i^* 为基准值(Ground Truth)相对于锚点框(Anchor Box)的偏移; L_{cls} 为分类损失; L_{reg} 为回归损失。

区域建议网络是对锚点框和预测边界框位置修正进行训练,使其接近基准值,见图 8。

修正过程采取平移见式(12—13)和缩放见(14—15)。

$$\begin{cases} t_x = (x - x_a) / w_a \\ t_y = (y - y_a) / h_a \end{cases} \quad (12)$$




图 8 位置修正
Fig.8 Position correction

$$\begin{cases} t_x^* = (x^* - x_a) / w_a \\ t_y^* = (y^* - y_a) / h_a \end{cases} \quad (13)$$

$$\begin{cases} t_w = \log(w / w_a) \\ t_h = \log(h / h_a) \end{cases} \quad (14)$$

$$\begin{cases} t_w^* = \log(w^* / w_a) \\ t_h^* = \log(h^* / h_a) \end{cases} \quad (15)$$

式中: x , y , w , h 为预测边界框的中心坐标和宽高; x_a , y_a , w_a , h_a 为锚点框的中心坐标和宽高, x^* , y^* , w^* , h^* 为基准值的中心坐标和宽高。

4.2 分割全链接层的引入

在实验条件和设备的限制下,采集的数据集数量和质量受到了限制,为了获取更好的结果,在检测点样点形状同时将点样点与背景分割并行输出,将常规的 Faster-RCNN 进行改进,在分类和回归的同时,引入分割全链接层,见图 9。




图 9 引入分割后的算法流程
Fig.9 Algorithm flow after division is introduced

1) 文中输入图像尺寸为 1280×800 , CNN 特征计算部分选择 VGG-16 网络, 将 VGG-16 全链接层去掉, 图 9 中的特征图是 VGG-16 的最后一个卷积层输出的图像特征, 其经过 4 次大小和步长都为 2 的最大池化, 输出为 $512 \times 80 \times 50$ 。

2) 在此基础上, 训练区域建议网络, 使用 3×3 和 1×1 的卷积核 (步长为 1) 将 $512 \times 80 \times 50$ 变为 $6 \times k \times 80 \times 50$ 。在此说明 $6 \times k$ 的由来: 每个锚点框的坐标和长宽有 4 个参数 (x, y, w, h), 代表是物体和背景的概率有 2 个参数, 所以每个锚点框有 6 个参数, k 个锚点框的参数为 $6 \times k$ 个, 因此区域建议网络的输出为 $6 \times k \times 80 \times 50$ 。

3) 通过区域建议网络的输出得到 $k \times 80 \times 50$ 个候选框, 在区域建议网络中选取的候选区域经过回归后, 会与原始位置存在偏差, RoI Pooling 会将偏差量化为整数, 这样就忽略了浮点产生的误差, 由于分割是像素级别的操作, 这个偏差会影响分割的准确度, RoIAlign 在遍历候选区域时会保留浮点数边界。具体过程如下: 若图 9 输入图像中候选框的原始尺寸是 $W \times H$ 它所对应的最后一个卷积层的区域为 $W' \times H' = (W/16) \times (H/16)$, 由于这里得到的 W', H' 很可能是浮点数, 为了避免被量化为整数, 采用双线性插值^[13]的方法来计算每个输入特征值的精确值。将 W', H' 分为 7 份, 然后进行最大池化 (max pooling) 操作, 获得 $7 \times 7 \times$ 通道数的输出。

4) 将步骤 3) 中得到的输出作为输入, 经过全链接网络输出分类和回归的结果。由于整个流程经过了多次卷积和池化操作, 点样点特征分辨率有所降低, 所以在进行分割之前利用转置卷积^[14]进行分辨率的提升, 同时减少通道数。经实验, 选取大小为 4, 外衬为 1, 步长为 2 的转置卷积。

5 实验分析及结果

5.1 评价指标

实验采用的图片数据来源于文中的图像采集装置, 采集后的图像分为训练和测试 2 部分^[15], 得到的

训练样本数据, 经过生产线上经验丰富的专家操作人员对样本进行合格以及不合格的区分: 在每个样本的 6 个蛋白质点样点中, 若至少有一个蛋白质点呈现非圆形状 (生产线上专业操作人员判断) 则为不合格样本。样本经过区分后得到文中目标类别数量共 2 类, 标签分别为: 圆-circle; 非圆-nocir, 然后在训练样本中进行手工标注, 建立适用于文中检测和分割任务的数据集, 训练样本共 1200 张。以预测边界框与基准值之间的交并比 (IoU) 大于 0.5 作为正确的标准^[16-17], 即 TP, 见图 10。选取精确率、召回率和单幅图检测时间为性能指标来判断准确性, 统计结果见表 1。




图 10 检测评价
Fig.10 Test evaluation

学习迭代率的选取会影响训练过程^[18], 学习迭代率选择较大时, 会导致在训练权重爆炸, 学习迭代率选择过小时, 会导致训练反向传播速度过慢, 影响训练效率。文中经过对比实验得到当学习迭代率为 0.001 时有较好的效果, 见表 1, 此时精确率为 88.07%, 召回率为 91.89%。文中使用 GPU 加速, 使得单幅图片的测试时间为 68 ms, 具有良好的实时性。

表 1 性能指标
Tab.1 Performance Indicators

学习迭代率	精确率/%	召回率/%	t_1 /ms
0.001	88.07	91.89	68

5.2 检测结果

在文中的数据背景下进行验证,对合格点样点和不合格点样点检测结果分别见图 11 和图 12。Faster-RCNN 对点样点检测存在漏检、误检的情况,见图 11b,图 12b。文中所提出方法,能较精确的检测同时分割出点样形状来,见图 11c,图 12c。对部




图 11 合格点样点检测效果对比

Fig.11 Comparison of inspection results of qualified spots




图 12 不合格点样点检测效果对比

Fig.12 Comparison of the detection results of unqualified spots

表 2 点样点半径测量数据
Tab.2 Spot radius measurement data

N	M	P	E	T_2	N	M	P	E	T_2
1-1	1.07	1.05	-0.02	1396.7539	5-1	0.98	1.01	0.03	1399.7839
1-2	1.06	1.12	0.06		5-2	1.05	1.02	-0.03	
1-3	1.02	1.03	0.01		5-3	1.02	0.96	-0.06	
1-4	0.98	1.04	0.06		5-4	1.03	1.07	0.04	
1-5	1.08	1.01	-0.07		5-5	0.99	1.02	0.03	
1-6	1.02	0.94	-0.08		5-6	1.01	1.06	0.05	
2-1	1.03	1.07	0.04	1462.4539	6-1	1.06	1.09	0.03	1451.3559
2-2	1.05	1.13	0.08		6-2	1.04	1.08	0.04	
2-3	0.99	1.04	0.05		6-3	1.07	1.09	0.02	
2-4	0.98	1.01	0.03		6-4	1.09	1.06	-0.03	
2-5	1.08	0.99	-0.09		6-5	1.12	1.05	-0.07	
2-6	1.06	1.03	-0.03		6-6	1.08	1.13	0.05	
3-1	1.09	1.12	0.03	1481.5349	7-1	1.04	1.09	0.05	1437.2629
3-2	1.07	1.09	0.02		7-2	1.02	1.05	0.03	
3-3	1.04	1	-0.04		7-3	0.96	1.02	0.06	
3-4	1.05	1.12	0.07		7-4	0.99	1.03	0.04	
3-5	1.08	1.13	0.05		7-5	1.07	1.04	-0.03	
3-6	1.02	0.99	-0.03		7-6	1.03	1.04	0.01	
4-1	1.05	1.03	-0.02	1415.433 9	8-1	1.02	1.04	0.02	1398.6379
4-2	1.02	1.07	0.05		8-2	1.05	0.99	-0.06	
4-3	1.07	1.01	-0.06		8-3	0.97	1.04	0.07	
4-4	1.01	1.04	0.03		8-4	1.01	1.09	0.08	
4-5	0.97	0.99	0.02		8-5	0.99	1.03	0.04	
4-6	1.03	1.04	0.01		8-6	1.04	1.01	-0.03	

文中使用了 180 张与训练图片不同的验证图片, Faster-RCNN 的检测准确率为 80.6%, 文中方法的检测准确率为 91.1%。由实验结果可以得出, 在训练样本数量和质量有限的情况下, 文中提出的方法在点样点检测效果较 Faster-RCNN 有所提高。表 2 可以看出图像处理的方法与手工测量的方法相比, 测量误差不超过 ± 0.1 mm, 对一张生物芯片的检测时间包括点样质量检测时间 T_1 和半径测量时间 T_2 , 文中检测方法对单个生物芯片检测时间总和不超过 1.6 s。

6 结语

文中提出的基于数字图像的生物芯片点样质量检测方法, 通过图像预处理、边缘检测和霍夫变换实现对点样点实际半径的测量; 在针对生物芯片点样质量检测中, 针对点样点形状多变并且点样点特征区域较小, 从而导致的检测难度大, 准确率较低的问题, 提出了基于卷积神经网络的点样质量检测方法。实验证明, 该方法在检测精度和效率上均满足实际生产中对生物芯片点样质量检测的要求, 可以准确地对点样质量进行判断, 有效地提高了生物芯片制作的合格率和效率, 具有一定现实意义。由于实验条件限制, 在数据采集过程中没有同轴光源, 而使用的 LED 环形光以及在实验点样时, 由于抖动或者一些人为因素导致点样点的不规范等, 对该方法准确率有一定影响。在以后的研究中, 将采取更多、更合理的数据, 以获得更好的检测效果。

参考文献:

- [1] 杜文华, 郭小刚, 曾志强, 等. 自适应光强变化的动态边缘位置提取方法[J]. 包装工程, 2018, 39(3): 162—166.
DU Wen-hua, GUO Xiao-gang, ZENG Zhi-qiang, et al. A Dynamic Edge Position Extraction Method for Adaptive Light Intensity Variation[J]. Packaging Engineering, 2018, 39(3): 162—166.
- [2] 宋国庆, 吴育民, 冯云鹏, 等. 机器视觉在光学加工检测中的应用[J]. 影像科学与光化学, 2016, 34(1): 30—35.
SONG Guo-qing, WU Yu-min, FENG Yun-peng, et al. Application of Machine Vision in Optical Manufacturing and Testing[J]. Imaging Science and Photochemistry, 2016, 34(1): 30—35.
- [3] 张文毓, 侯世忠. 生物芯片技术的应用[J]. 传感器世界, 2012, 18(1): 6—9.
ZHANG Wen-yu, HOU Shi-zhong. Application of Biochip Technology[J]. Sensor World, 2012, 18(1): 6—9.
- [4] QIAO A, MA Z, FU P, et al. Research and Development of Print Quality Inspection System of Biochips[C]// The, International Conference on Bioinformatics and Biomedical Engineering, IEEE, 2008: 1644—1647.
- [5] 马超, 周晚, 张志文. 图像处理在大米品质检测中的应用研究[J]. 机械与电子, 2018, 36(4): 58—62.
MA Chao, ZHOU Wan, ZHANG Zhi-wen. Study on Application of Image Processing on Rice Quality Detection[J]. Machinery & Electronics, 2018, 36(4): 58—62.
- [6] 甘泉, 魏利胜, 张平改. 基于图像处理的圆形工件尺寸检测方法[J]. 黑龙江工业学院学报(综合版), 2017, 17(7): 39—43.
GAN Quan, WEI Li-sheng, ZHANG Ping-gai. Detection Method for Size of Circular Workpiece Based on Image Processing[J]. Journal of Heilongjiang University of Technology, 2017, 17(7): 39—43.
- [7] 刘克平, 李西卫, 隋吉雷, 等. 基于改进 Canny 算法的工件边缘检测方法[J]. 广西大学学报(自然科学版), 2017, 42(6): 2022—2029.
LIU Ke-ping, LI Xi-wei, SUI Ji-lei, et al. Workpiece Edge Detection Method Based on Improved Canny Algorithm[J]. Journal of Guangxi University(Nat Sci Ed), 2017, 42(6): 2022—2029.
- [8] 徐建亮, 毛建辉, 方晓汾. 基于优化 Gabor 滤波器的铸坯表面缺陷检测应用研究[J]. 表面技术, 2016, 45(11): 202—209.
XU Jian-liang, MAO Jian-hui, FANG Xiao-fen. Application of the Billet Surface Defects Detection Based on Optimization of Gabor Filter[J]. Surface Technology, 2016, 45(11): 202—209.
- [9] 朱桂英, 张瑞林. 基于 Hough 变换的圆检测方法[J]. 计算机工程与设计, 2008(6): 1462—1464.
ZHU Gui-ying, ZHANG Rui-lin. Circle Detection Using Hough Transform[J]. Computer Engineering and Design, 2008(6): 1462—1464.
- [10] 桑军, 郭沛, 项志立, 等. Faster-RCNN 的车型识别分析[J]. 重庆大学学报, 2017, 40(7): 32—36.
SANG Jun, GUO Pei, XIANG Zhi-li, et al. Vehicle Detection Based on Faster-RCNN[J]. Journal of Chongqing University, 2017, 40(7): 32—36.
- [11] REN S, HE K, 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): 746—759.

- 1137—1149.
- [12] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation[C]// Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition, Columbus, OH, United states, IEEE, 2014: 580—587.
- [13] JIFFRY M T, MOLLIGODA A. Bilinear Interpolation Theorems and Applications[J]. Journal of Functional Analysis, 2013, 265(2): 185—207.
- [14] ZEILER M D, TAYLOR G W, FERGUS R. Adaptive Deconvolutional Networks for Mid and High Level Feature Learning[C]// International Conference on Computer Vision, IEEE Computer Society, 2011: 2018—2025.
- [15] 陈曦, 柴晨晨, 胡亚乔, 等. 基于图像的血型卡灌装质量在线检测系统[J]. 包装工程, 2018, 39(3): 157—161.
- CHEN Xi, CHAI Chen-chen, HU Ya-qiao, et al. Online Detection System for Blood Card Filling Quality Based on Image[J]. Packaging Engineering, 2018, 39(3): 157—161.
- [16] GIRSHICK R. Fast R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision, Santiago, Chile, IEEE, 2015: 1440—1448.
- [17] SHELHAMER E, LONG J, DARRELLI T. Fully Convolutional Networks for Semantic Segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4): 640—651.
- [18] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. Computer Science, 2014: 1—14.