

DOI: 10.13382/j.jemi.B2206079

基于改进 SqueezeNet 的棒状物表面缺陷识别

王文秀¹ 郑 鹏¹ 徐颖杰² 郑嘉琦³
(1. 郑州大学机械与动力工程学院 郑州 450001; 2. 郑州机械研究所有限公司 郑州 450052;
3. 郑州大学国际学院 郑州 450001)

摘 要:高速流水线生产的棒状物极易产生各种表面缺陷,但基于传统图像处理的缺陷识别方法易受环境影响、可靠性低,而基于深度学习的缺陷识别方法存在模型过大、识别准确率受制于样本数量等问题。因此,本文提出了一种基于改进 SqueezeNet 的棒状物表面缺陷识别系统。设计了可获取圆周对称小体积棒状物全表面图像的采集装置,并在轻量级卷积神经网络 SqueezeNet 中引入注意力模块以改善模型的特征提取效果,利用数据平衡方法提升数据集内少数类样本的识别准确率,利用迁移学习的方法进行深度学习训练,减轻数据集样本不足对训练效果的影响。以生产线上的卷烟烟支为研究对象,采集其圆周表面图像进行实验,结果表明,改进方法在少样本条件下的分类准确率达到 94.49%,其中对于少数类样本的 F1 分数提高了 31.19%,单张图像检测时间约 1.66 ms,模型轻量化,可满足工业生产线中棒状物实时缺陷识别的需求。

关键词: 缺陷识别; SqueezeNet; 数据平衡; 注意力模块

中图分类号: TP391.4; TH164 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Rods surface defect identification based on improved SqueezeNet

Wang Wenxiu¹ Zheng Peng¹ Xu Yingjie² Zheng Jiaqi³
(1. School of Mechanical and Power Engineering, Zhengzhou University, Zhengzhou 450001, China;
2. Zhengzhou Research Institute of Mechanical Engineering Co., Ltd., Zhengzhou 450052, China;
3. International College, Zhengzhou University, Zhengzhou 450001, China)

Abstract: The rods produced by the high-speed assembly line are highly susceptible to various surface defect, but the defect identification method based on conventional image processing is unreliable and susceptible to environmental factors, while the defect identification method based on deep learning suffers from oversized models and recognition accuracy that is constrained by the quantity of samples. Therefore, this paper suggests an identification system of rods surface defect based on improved SqueezeNet. An acquisition device was designed to obtain the full surface image of the circumferential rods, and the attention module is introduced into the lightweight convolutional neural network SqueezeNet to improve the feature extraction effect of the model, data balancing is used to improve the recognition accuracy of minority samples, transfer learning is employed for deep learning training to minimize the impact of insufficient samples on the training effect. Taking the cigarette on the production line as the research object, the circumferential surface image of the cigarette is collected for experiment, the results show that the classification accuracy of the improved method under the condition of few samples reaches 94.49%, with the F1 score for minority samples being improved by 31.19%, and the detection time of a single image being approximately 1.66 ms. Additionally, the model is lightweight, meeting the need for rods in industrial production lines to have real-time defects recognized.

Keywords: defect identification; SqueezeNet; data balance; attention module

0 引言

高速流水线上生产的棒状待检测物体,极易因为材质、生产环境、生产设备和运输等因素产生诸如脏污、歪斜、破损、变形等表面缺陷,而由于棒状物的缺陷面积小、批量大、表面缺陷种类多样等特点,传统人工识别不合格产品的效率和准确率低^[1],难以满足生产需要。因此研究适应多场景、高效率的表面缺陷自动化识别方法对于提升棒状物生产质量有着重要意义。

目前常见的缺陷识别方法主要基于计算机视觉技术,而应用于工业生产的计算机视觉方法主要分为传统图像处理方法和深度学习方法^[2]。基于传统图像处理的方法通过人工提取特征来进行缺陷识别,例如陈金贵等^[3]使用改进 Niblack 算法实现了轴承滚子圆周表面缺陷识别,马祥^[4]利用棱镜一次性采集弹壳侧壁和口部的图像并完成弹壳表面缺陷的在线检测与分类,但传统图像处理方法易受环境变化影响,漏检率高且泛化性能差。因此,本文提出一种基于深度学习的自动缺陷检测系统,利用少量表面图像数据,结合轻量化缺陷分类算法,实现棒状物表面缺陷的快速准确检测。

随着深度学习技术的发展,基于卷积神经网络的棒状物检测研究层出不穷,顾桂梅等^[5]利用改进 GA-BP 算法完成了棒式绝缘子圆周表面的缺陷识别,郭绍陶^[6]针对圆柱形锂电池的端面和圆周面的凹坑缺陷使用 BP 神经网络进行了检测,袁国武等^[7]提出一种基于 ResNeSt 的烟支圆周表面缺陷分类方法。然而上述方法均基于深度神经网络,模型复杂、对硬件系统的计算资源要求高^[8],难以在资源受限的嵌入式设备中广泛应用。同时,流水线生产的棒状物表面的缺陷产生原因不确定,很难保证实际采集到的不同种类缺陷图像样本数量均衡,进而降低网络的分类性能。

SqueezeNet^[9]是一种常用的轻量化网络模型,常被用于表面缺陷检测任务中,例如刘巍^[10]使用 SqueezeNet 实现了卷烟小包的表面缺陷识别。基于 SqueezeNet 的改进网络方法也层出不穷,张忠志等^[11]将 SqueezeNet 进行双分支深度融合实现了红枣的缺陷识别。

针对复杂多变场景、少样本学习、存储空间限制等情形下的棒状物表面缺陷的自动化识别问题,本文利用数字图像处理结合深度学习,研究了基于改进 SqueezeNet 的棒状物表面缺陷识别方法。该方法可采集棒状物圆周面和端面的完整图像,并使用改进轻量化网络进行缺陷识别。在 SqueezeNet 网络中引入注意力模块以提升网络的特征提取能力,针对棒状物不同种类的样本数量不均衡问题,使用数据平衡方法减小少样本学习对模型分类性能的影响,采用迁移学习的方法训练改进 SqueezeNet

网络模型使其拥有更好的泛化能力。实验结果表明,改进方法在卷烟烟支数据集中的分类准确率达到 94.49%,识别速度快,易部署在资源受限平台,可满足工业生产线中棒状物实时缺陷识别的需求。

1 棒状物表面缺陷识别系统

1.1 棒状物外观缺陷概述

圆周对称棒状物的表面包括端面 and 圆周面。表面缺陷是指棒状物表面局部物理或化学性质不均匀的区域,常见的表面缺陷有划痕、色差、破损、夹杂物等。不同产品表面缺陷有不同的定义和成因。以卷烟烟支为例,某种卷烟烟支主要由深色的滤嘴部分和浅色的烟棒部分组成,根据生产现场烟支表面缺陷的统计情况,将烟支圆周面缺陷种类分为脏污、褶皱和错牙,将烟支端面缺陷分为空头、落丝和圆周,其中脏污为烟棒表面呈现长度大于 1 mm 的油渍、污点或黄斑等,褶皱为烟棒处的烟纸起皱、变形或折痕等,错牙为烟棒和滤嘴交接处的接装纸粘附不齐的长度大于 0.5 mm,空头为端部烟丝空陷截面大于 2/3,落丝为单支端部落丝量大于 8 mg,圆周为烟支圆周允差大于 ± 0.20 mm。棒状物圆周面长度通常远大于端面直径,因此脏污和错牙缺陷的面积通常很小,很容易产生漏检现象。正常烟支和缺陷烟支的圆周面图像如图 1 所示,端面图像如图 2 所示。




图1 卷烟烟支圆周面图像分类

Fig. 1 Types of cigarette circumferential surface images

1.2 棒状物表面缺陷识别系统

为了获得高速流水线上小体积圆周对称棒状物表面




图 2 卷烟烟支端面图像分类

Fig. 2 Types of cigarette end surface images

缺陷的相关信息,基于图像采集和图像处理技术设计了一个棒状物表面缺陷识别系统,系统总体框架如图 3 所示,该系统由传送鼓轮、相机、反射镜、光源、控制模组、计算机等部件组成。




图 3 棒状物表面缺陷识别系统

Fig. 3 Rods surface defect identification system

鼓轮上均设有多个凹槽,根据棒状物的材质特征选择负压或磁吸等方式在凹槽处固定棒状物。进行棒状物实时缺陷识别时,生产好的棒状物先经传动轮组传送至鼓轮 1,在鼓轮 1 上旋转半周之后,翻转并传送至鼓轮 2,设置的相机组分布于鼓轮的不同角度,拍摄多张不同视角的图像以获取单个棒状物全表面图像,将拍摄到的棒状物表面图像上传至计算机,并通过缺陷分类算法进行检测,只有所有视角图像均检测为正常时才判定该棒状物表面无缺陷,若检测结果异常,剔除装置可将传送至剔除位的不合格棒状物剔除。

为获取棒状物的圆周和 2 个端面表面图像,相机组设置了 5 个高速面阵相机。其中 4 个相机两两分布在鼓轮 1 和鼓轮 2 径向侧面,4 个相机均与水平线呈斜 45°布置,其中 1 号和 2 号相机的视角是鼓轮 1 上的 3 支持检棒状物,3 号和 4 号相机的视角是鼓轮 2 上的 3 支持检棒状物,4 个相机的设置可以保证拍摄到每个棒状物的整

周图像,另外 1 个相机位置如图 4 所示,其设置在鼓轮 1 的轴向外侧,通过对侧与鼓轮径向呈 30°设置的平面反射镜,实现单相机同时采集 2 个端面图像。每个相机均使用 LED 环形无影光源进行垂直照明,以减小对角照射阴影对图像采集效果的影响^[12]。相机组的设置,可通过 5 个固定的相机拍摄传送中棒状物的多视角图像。从第 1 个拍摄位置到剔除位之间有一定时间,通过多线程可实现图像传输及数据处理。




图 4 棒状物端面图像采集结构

Fig. 4 Image acquisition structure of rods end face

2 基于改进 SqueezeNet 的棒状物表面缺陷分类方法

2.1 改进 SqueezeNet 网络模型

SqueezeNet 是一种性能优越的轻量级网络模型,在大幅度减少模型参数和采用深度模型压缩技术后,其总参数量仅为 AlexNet 模型的 1/50,但可以达到 AlexNet 模型同等的精度,其结构如图 5 所示。




图 5 SqueezeNet 模型结构

Fig. 5 Structure of SqueezeNet model

SqueezeNet 的核心是 Fire 模块, Fire 模块由 Squeeze 层和 Expand 层组成, Squeeze 层均由 1×1 卷积^[13]组成, Expand 层由 1×1 卷积和 3×3 卷积组合而成。Fire 模块的结构如图 1 所示。其中 Squeeze 层的 1×1 卷积核数为 s_1 , Expand 层的 1×1 卷积核数为 e_1 , Expand 层的 3×3 卷积核数为 e_3 , 为降低通道数量, 需保证:

$$s_1 < (e_1 + e_3) \quad (1)$$

棒状物的长宽比相较于常见物体更大, 其表面缺陷尺寸较小, 缺陷目标的占比小, 分类模型很难准确提取缺陷目标的特征。为提高模型的性能, 可使用特征融合对不同尺度特征进行合成, 以期获得一个更有表征能力的特征^[14]。

特征融合的维度包括空间和通道两个方面, 卷积神经网络的核心是卷积运算, 卷积操作的本质是在空间维度上进行特征融合, 而其在特征通道维度上的融合较为简单。因此, 为使深度学习网络模型更好关注图像中的重要信息^[15], 更多关注通道维度上的特征融合, 可在网络架构中引入 SE (squeeze-and-excitation) 注意力模块。SE 模块不仅有空间注意力 SAM (spatial attention module), 也使用了通道注意力 CAM^[16] (channel attention module), 计算流程如图 6 所示。




图 6 SE 模块结构

Fig. 6 Structure of SE module

SE 模块采用了特征重标定的策略, 重标定时的操作为 Squeeze、Excitation 和 Reweight。Squeeze 操作使用全局平均池化, 可获得通道的全局特征, Excitation 操作使用两个全连接层, 可以得到不同特征通道的权重, 最后经过 Reweight 操作, 将权重加权到原特征以得到最终特征。

为在改善模型特征提取效果的同时尽量减小网络的参数量^[17], 选择将 SE 模块添加在 SqueezeNet 模型中的

Fire8 模块之后。

2.2 数据平衡

由于棒状物生产原料、生产工艺、运输等各方面因素的影响, 棒状物的表面缺陷种类多样, 且缺陷产生机制也不明确, 因此采集到的图像样本中, 常出现某些种类样本 (以下称多数类样本) 的数据数量较多, 而另一些种类样本 (称为少数类样本) 数据数量远小于多数类样本数据数量, 这种问题被称为类不平衡问题^[18]。使用类不平衡样本训练时, 为使总体准确率最高, 模型往往会忽略少数类样本的学习, 而更倾向于学习多数类样本的分类规律, 导致分类模型的泛化能力变差。

对于数据类不平衡问题, 常见的解决方法为使用上采样、下采样或上采样和下采样结合的数据采样方法调整样本集数量, 上采样和下采样的具体处理过程如图 7 所示。由于通常情况下缺陷样本的数量和合格样本的数量差距较大, 进行深度学习训练时常采用上采样和下采样结合的方法, 通过将多数类样本 (通常为合格样本) 的数量减少到一定量, 再将少数类样本 (通常为缺陷样本) 的数量增加到和多数类样本数量基本一致, 以便在资源有限的情况下提高分类模型的泛化能力。




图 7 数据采样方法举例

Fig. 7 Examples of data sampling methods

2.3 迁移学习

基于深度学习的缺陷识别模型需要使用大量真实样本, 而在实际生产过程中, 往往很难采集到足够数量的高质量缺陷样本用于模型训练, 因此使用小样本数据训练精度足够高的缺陷识别网络模型也是当今的热点问题之一。

迁移学习可利用与目标领域相关的知识完成对目标领域的学习任务^[19], 是小样本数据进行深度学习训练的常见方法。训练小样本图像数据常用的是基于模型的迁移学习方法, 即预先使用数量足够的其他样本数据训练

深度学习模型,再将使用小样本数据对预训练过的模型中的参数进行微调,并获得新的网络模型。由于模型的特征和参数具有可迁移性,新网络模型能够学习到被泛化和迁移的原模型特征,因此相较于直接对小样本数据

进行训练的方式,使用迁移学习方法训练得到的模型拥有更好的性能^[20]。

采用以上优化方法可获得基于改进 SqueezeNet 的棒状物表面缺陷识别方法,其主要流程如图 8 所示。




图 8 基于改进 SqueezeNet 的棒状物表面缺陷识别方法流程

Fig. 8 Flow chart of rods surface defect identification based on improved SqueezeNet

3 实验与结果分析

3.1 实验环境及参数设置

本文实验使用的计算机配置为 i9-10900X CPU,采用的是 NVIDIA GeForce RTX 3090 GPU, CUDA 版本为 11.4,操作系统为 Windows 10。对比了相同数据集使用不同超参数对深度学习模型效果的影响,具体训练结果如表 1 所示,最终设置的训练批次大小为 32,迭代次数为 300,学习率为 0.000 1,动量为 0.3。

表 1 不同超参数的测试结果
Table 1 Test results of each model

批次	迭代次数	动量	学习率	准确率/%
32	150	0.3	0.001	83.20
32	150	0.3	0.001	84.72
32	200	0.3	0.000 1	88.20
32	200	0.3	0.001	84.51
32	200	0.1	0.000 1	82.48
32	300	0.1	0.000 1	85.78
32	300	0.3	0.000 1	92.10
64	150	0.3	0.000 1	79.56
64	200	0.3	0.000 1	85.20
64	300	0.3	0.000 1	89.71

3.2 实验对象及实验数据集

以高速工业流水线上的卷烟烟支为研究对象,对其圆周表面缺陷情况进行识别和分类。

图像数据集使用工业现场采集到的卷烟烟支表面图像,采集图像帧率为 80 张/s,图像采集装置如图 9 所示。




图 9 烟支图像采集装置

Fig. 9 Cigarette image acquisition device

由于卷烟烟支圆周表面缺陷主要集中在浅色的烟棒部分,为减小算力和训练时间消耗,提取图像中的烟棒部分作为感兴趣区域。对采集到的烟支表面图像采用基于灰度值的模板匹配方法,获得合格烟支和各类缺陷烟支的表面待检测区域图像,对其进行去噪、图像增强等操作^[21]以扩大正常区域和缺陷区域的差异,将获得的图像

存入烟支图像原始数据集 1。生产线采集图像进行图像预处理的效果如图 10 所示。




图 10 图像预处理效果
Fig. 10 Results of pre-processing

该烟支表面图像的原始数据集 1 共 2 565 张图像,由于生产线上各类缺陷烟支的出现存在不确定性,获得的各类别烟支图像的数量差别较大,其中合格烟支图像 1 832 幅,脏污烟支图像 214 幅,褶皱图像 410 幅,错牙烟支图像 109 幅,各类别图像数量的比例约为 18 : 2 : 4 : 1。

对原始数据集 1 内的图像数据进行数据平衡,以提高模型对于少数类样本的学习能力^[22]。根据各类别图像数量的差异大小,选择上采样和下采样结合的方式进行数据平衡。先对多数类样本进行下采样,即在合格烟支图像中随机挑选 632 张,再对少数类(即各类缺陷烟支)图像进行上采样,具体为:将脏污烟支图像旋转 2 次得到 428 幅图像,则脏污种类图像扩充至 642 幅;从褶皱图像中随机选取 50% 的图像并旋转 1 次获得 205 幅图像,得到褶皱种类图像共计 615 幅;将错牙图像旋转 5 次获得 545 幅图像,则错牙图像扩充至 654 幅。各少数类样本数量和多数类的合格烟支样本数量基本一致,经过数据平衡的数据集 2 内共包含 2 543 幅图像,与原始数据集 1 的图像数量基本一致。

将数据集 1 和数据集 2 分别按 70 : 15 : 15 的比例随机拆分为训练集、验证集和测试集,其中训练集和验证集用于模型训练,而测试集用来测试模型的性能。

3.3 实验评价指标

在表面缺陷多分类中常使用的统计结果为以下 3 种:真正列(true positive, TP)表示实际标签为合格且预测标签为合格的数量,假正列(false positive, FP)表示实际标签为合格但预测标签为缺陷的数量,假反列(false negative, FN)表示实际标签为某种缺陷但预测标签为合格的数量。由此采用的实验评价指标为 4 种:准确率、精确率、召回率和 F1 分数(F1-Score)。其中,准确率(Accuracy),是判断分类性能最直观的评价指标:

$$A = \frac{TP}{TP + FP + FN} \tag{2}$$

而当不同类别的样本数量不平衡时,只需将多数类

样本预测正确即可获得更高的准确率,单凭一个指标无法全面评价模型的性能。因此,引入精确率(Precision)和召回率(Recall),分别定义为:

$$P = \frac{TP}{TP + FP} \tag{3}$$

$$R = \frac{TP}{TP + FN} \tag{4}$$

另外,F1 分数是精确率和召回率的调和平均值:

$$F = \frac{2PR}{P + R} \tag{5}$$

在对数据不平衡数据进行实验结果评价时,应综合考虑以上 4 种评价指标的结果。

3.4 实验结果

以数据集 1 作为输入,分别使用 AlexNet、ResNet50、GoogLeNet、轻量级网络 MobileNet、轻量级网络 SqueezeNet、改进的 SqueezeNet 方法对其进行训练,训练参数设置为一致,各算法的测试集准确率如表 2 所示。

表 2 各个模型的测试结果
Table 2 Test results of each model

算法	准确率/%	模型大小/MB
AlexNet	80.16	240.00
ResNet50	83.25	98.00
GoogLeNet	84.97	654.00
MobileNet	85.82	29.30
SqueezeNet	85.78	4.80
改进的 SqueezeNet	94.49	4.87

由表 2 可知,改进 SqueezeNet 方法训练获得模型的准确率明显优于其他经典算法,准确率可达 94.49%,且模型大小满足轻量化要求。

为了验证改进 SqueezeNet 方法的分类性能,分别使用数据集 1 和数据集 2 用两种算法进行深度学习训练的测试结果如表 3 所示,其中用 SqueezeNet+表示使用了 SE 注意力模块和迁移学习的 SqueezeNet 方法。由表 3 可知,使用数据集 1 训练的 2 种算法的准确率比其他 3 种指标数值高约 2%~6%,而对于使用经过数据平衡的数据集 2 的 2 个实验,不仅 4 个评价指标的结果均比数据集 1 的结果高约 7%~13%,各评价指标数值相差也在 0.5%以内,代表使用数据集 2 时的多分类训练效果有明显提高。使用数据集 2 的 SqueezeNet+方法的单张图像平均推断时间约为 1.66 ms,相对于原始 SqueezeNet 模型的推断时间未产生明显增加,可满足工业流水线对于高速自动化检测的要求。

为了验证改进 SqueezeNet 方法对少数类样本的学习能力,分别使用 2 种数据集进行训练的 SqueezeNet 和 SqueezeNet+方法的各类别图像的混淆矩阵如图 11 所示,

测试结果如图 12 所示。由图 11 可知,使用 SqueezeNet+法对数据集 2 训练得到的各类别预测准确率最高,对于少数类的判断准确率大幅提高,有效减少了误判。由图 12 可知,对于使用数据集 1 进行训练的 2 种模型,各评价指标数值差别较大,且其对于少数类“脏污”和“错牙”的测试结果较差。而使用数据集 2 进行训练的 2 种模型,不仅对于 4 种类别图像的精确率、召回率和 F1 分数

的数值均在 90% 以上,其中少数类“错牙”的 F1 分数也由图 12(a) 中的 62.07% 提升至图 12(d) 中的 93.26%,增加了 31.19%,不过由于模型更注重整体准确率,对于“褶皱”等种类的个别评价指标数值有所降低。由此可知,使用数据集 2 的 SqueezeNet+方法可在提升整体训练准确度的同时,提高对于少数类图像的学习能力,提升数据不平衡样本的训练效果。

表 3 不同模型的测试结果
Table 3 Test results of different models using different dataset

数据集	模型	Top-1 准确率/%	F1 分数/%	平均精确率/%	平均召回率/%	平均推断时间/ms
数据集 1	SqueezeNet	85.78	81.02	83.85	79.5	1.59
	SqueezeNet+	87.75	84.04	83.57	84.97	1.72
数据集 2	SqueezeNet	92.65	92.66	92.70	92.69	1.60
	SqueezeNet+	94.49	94.49	94.6	94.49	1.66




图 11 不同模型的混淆矩阵

Fig. 11 Confusion matrix for different models

使用改进 SqueezeNet 方法对少样本卷烟烟支图像集 1 进行数据平衡获得数据集 2,送入卷积神经网络训练时的损失值及训练和验证时的准确率变化曲线如图 13 所示。由图可知,当迭代次数小于 120 次时,算法的损失下降较快,且训练准确率和验证准确率稳步上升,从 121 次之后,三者均开始趋于稳定,收敛效果较好,且训练准确率和验证准确率的变化趋势相同,表明模型的预测能力较好。

使用两种不同的棒状物圆周表面图像数据集利用改进 SqueezeNet 方法进行训练,其中一些缺陷图像的数目

远小于其他缺陷图像的数目,以此验证该改进方法的通用性,实验数据如表 4 所示。由表可知,对于同种棒状物图像数据,4 种不同评价指标的结果均趋于一致,表明使用改进 SqueezeNet 方法的训练效果较好。

表 4 不同数据集的测试结果
Table 4 Test results of different models using different dataset

数据集	圆柱形电池	钢管
缺陷种类	4	5
准确率/%	92.65	95.28
F1 分数/%	92.66	95.26
平均精确率/%	92.72	95.42
平均召回率/%	92.69	95.25

4 结 论

针对工业生产中的圆周对称小体积棒状物缺陷识别问题,设计了基于轻量级网络 SqueezeNet 的棒状物缺陷识别系统,利用多相机获取棒状物全表面图像,将注意力模块融入 SqueezeNet 网络结构中,提升模型特征提取的效果,对少样本进行数据平衡以改善分类效果,使用迁移学习以提升模型训练效率。使用生产线上的卷烟烟支作为实验对象,获取其圆周表面图像进行模型训练和实验探究的结果表明,使用改进 SqueezeNet 方法,可以通过少数特定的缺陷样本做到棒状物的表面缺陷识别,识别准确率高,对类不平衡样本的分类性能好,模型轻量化且耗时少,便于嵌入式等资源有限场景使用。研究了 3 种不同的棒状物,但实际生产中的棒状物多种多样,需对样本




图 12 不同模型各类别测试结果

Fig. 12 Test results of different models for each category




图 13 改进 SqueezeNet 方法的准确率和损失值曲线

Fig. 13 Accuracy and loss value curves of the improved SqueezeNet method

进行进一步补充和细化。

参考文献

[1] 范保江, 孙磊, 何杨帆, 等. 基于机器视觉技术的稻米等级快速自动判定方法及系统研究[J]. 电子测量与仪器学报, 2022, 36(10): 123-130.

FAN B T, SUN L, HE Y F, et al. Research on fast automatic determination method and system of rice grade based on machine vision technology [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 123-130.

[2] 赵朗月, 吴一全. 基于机器视觉的表面缺陷检测方法研究进展 [J]. 仪器仪表学报, 2022, 43 (1): 198-219.

ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision [J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 198-219.

[3] 陈金贵, 陈昊, 张奔. 基于改进 Niblack 算法的轴承滚子表面缺陷检测 [J]. 组合机床与自动化加工技术, 2018(12): 82-85, 97.

CHEN J G, CHEN H, ZHANG B. Surface defect detection of bearing roller based on improved Niblack algorithm [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2018(12): 82-85, 97.

[4] 马祥. 基于机器视觉的弹壳表面缺陷检测技术研究 [D].

- 南京:南京理工大学, 2020.
- MA X. Research on shell surface defect detection technology based on machine vision [D]. Nanjing: Nanjing University of Science and Technology, 2020.
- [5] 顾桂梅, 陈国翠. 改进 GA-BP 算法的棒式绝缘子表面缺陷识别[J]. 铁道科学与工程学报, 2022, 19(2): 546-553.
- GU G M, CHEN G C. Surface defect identification of rod insulator based on improved GA-BP algorithm [J]. Journal of Railway Science and Engineering, 2022, 19(2): 546-553.
- [6] 郭绍陶. 圆柱型锂电池外观缺陷检测方法研究[D]. 沈阳:沈阳工业大学, 2022.
- GUO SH T. Research on appearance defect detection method of cylindrical lithium battery [D]. Shenyang: Shenyang University of Technology, 2022.
- [7] 袁国武, 刘建成, 刘鸿瑜, 等. 基于 ResNeSt 的烟支外观缺陷分类[J]. 云南大学学报(自然科学版), 2022, 44(3): 464-470.
- YUAN G W, LIU J CH, LIU H Y, et al. Classification of cigarette appearance defects based on ResNeSt [J]. Journal of Yunnan University (Natural Science Edition), 2022, 44(3): 464-470.
- [8] 周友行, 孟高磊, 赵文杰, 等. 钢板表面缺陷深度主动学习高效分类方法[J]. 电子测量与仪器学报, 2022, 36(2): 23-31.
- ZHOU Y H, MENG G L, ZHAO W J, et al. Active learning efficient classification method for surface defect depth of steel plate [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(2): 23-31.
- [9] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size[J]. arXiv preprint arXiv:1602.07360, 2016.
- [10] 刘巍. 基于 SqueezeNet 的卷烟小盒外观检测算法在低成本硬件上的实现[J]. 科技创新与应用, 2022, 12(4): 55-57.
- LIU W. Implementation of cigarette box appearance detection algorithm based on squeezeNet on low-cost hardware [J]. Science and Technology Innovation and Application, 2022, 12(4): 55-57.
- [11] 张忠志, 薛欢庆, 范广玲. 基于改进卷积神经网络的红枣缺陷识别[J]. 食品与机械, 2021, 37(8): 158-162, 192.
- ZHANG ZH ZH, XUE H Q, FAN G L. Red date defect recognition based on improved convolutional neural network [J]. Food & Machinery, 2021, 37(8): 158-162, 192.
- [12] PANG S L, WANG T H, ZHONG F Y, et al. Tabletop integral imaging 3D display system based on annular point light source[J]. Displays, 2021, 69: 102029.
- [13] GE Z, LIU S, WANG F, et al. YOLOX: Exceeding YOLO series in 2021 [J]. arXiv preprint arXiv: 2107.08430, 2021.
- [14] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 13708-13717.
- [15] 朱新源, 任劼, 章为川. 基于注意力机制的双度量小样本图像分类算法[J]. 国外电子测量技术, 2022, 41(8): 34-38.
- ZHU X Y, REN J, ZHANG W CH. Two-measure small sample image classification algorithm based on attention mechanism [J]. Foreign Electronic Measurement Technology, 2022, 41(8): 34-38.
- [16] 曾伟辉, 唐欣, 胡根生, 等. 基于卷积块注意力胶囊网络的小样本水稻害虫识别[J]. 中国农业大学学报, 2022, 27(3): 63-74.
- ZENG W H, TANG X, HU G SH, et al. Identification of rice pests in small samples based on convolutional block attention capsule network [J]. Journal of China Agricultural University, 2022, 27(3): 63-74.
- [17] 薛瑞晨, 郝媛媛, 张振, 等. 基于改进 YOLOv3 的头盔佩戴检测算法[J]. 电子测量技术, 2021, 44(12): 115-120.
- XUE R CH, HAO Y Y, ZHANG ZH, et al. Helmet wear detection algorithm based on improved YOLOv3 [J]. Electronic Measurement Technology, 2021, 44(12): 115-120.
- [18] 李明悦, 何乐生, 雷晨, 等. 基于注意力特征融合的 SqueezeNet 细粒度图像分类模型[J]. 云南大学学报(自然科学版), 2021, 43(5): 868-876.
- LI M Y, HE L SH, LEI CH, et al. A fine-grained image classification model for SqueezeNet based on attention feature fusion [J]. Journal of Yunnan University (Natural Science Edition), 2021, 43(5): 868-876.
- [19] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep Learning[M]. MIT Press, 2016.
- [20] BADMOS O, KOPP A, BERNTHALER T, et al. Image-based defect detection in lithium-ion battery electrode using convolutional neural networks [J]. Journal of Intelligent Manufacturing, 2020, 31(4): 885-897.
- [21] ASLAM M, KHAN T M, NAQVI S S, et al. Ensemble convolutional neural networks with knowledge transfer for leather defect classification in industrial settings [J].

IEEE Access, 2020, 8: 198600-198614.

[22] 李维创, 尹柏强. 工业金属板带材表面缺陷自动视觉检测研究进展 [J]. 电子测量与仪器学报, 2021, 35(6): 1-16.

LI W CH, YIN B Q. Research progress of automatic visual detection of surface defects in industrial sheet metal strip [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(6): 1-16.

作者简介



王文秀, 2019 年于天津科技大学获得学士学位, 现为郑州大学硕士研究生, 主要研究方向为智能信息处理与应用。
E-mail: 1278446367@qq.com
Wang Wenxiu received her B. Sc. degree from Tianjin University of Science and

Technology in 2019. Now she is a M. Sc. candidate at Zhengzhou University. Her main research interests include intelligent information processing and application.



郑鹏 (通信作者), 分别于 1999 年和 2003 年于郑州大学获得学士学位和硕士学位, 2009 年于上海大学获得博士学位, 现为郑州大学教授, 主要研究方向为传感检测技术、GPS 及其应用技术。
E-mail: zzpzut@163.com

Zheng Peng (Corresponding author) received B. Sc. degree and M. Sc. degree both from Zhengzhou University in 1999 and 2003, respectively, received Ph. D. degree from Shanghai University in 2009. Now he is a professor in Zhengzhou University. His main research interests include sensor detection technology, GPS and its application technology.