

卷烟包装外观缺陷数据集构建及深度学习检测技术研究

宗国浩¹, 张明琰², 王锐¹, 王泽宇², 王迪¹, 王永胜¹, 郑超群¹, 冯伟华^{1*}

(1. 中国烟草总公司郑州烟草研究院, 郑州 450001;

2. 河南中烟工业有限责任公司黄金叶生产制造中心, 郑州 450016)

摘要: **目的** 为了提升烟包缺陷检测的准确率, 构建卷烟包装外观缺陷识别基准数据集, 并开展主流深度学习模型在卷烟包装外观缺陷智能检测中的应用研究。**方法** 首先, 从生产运行中的 ZB45 型细支烟硬盒包装机采集缺陷图像, 经过人工审核与筛选后获取典型的缺陷数据。然后, 根据缺陷的特征与成因, 将缺陷数据划分为 23 个类别, 并逐一进行目标检测框标注。最终, 形成了包含 13 000 余张缺陷图像的卷烟包装外观缺陷识别基准数据集, 并针对烟包缺陷识别、缺陷分类、目标检测、模型迁移 4 项任务开展实验。**结果** 结果表明, 数据集能够满足高准确率深度学习模型的训练需求; 通过模型迁移, 能够利用该数据集大幅提高不同牌号卷烟的缺陷检测效果; DenseNet 模型在烟包缺陷识别与缺陷分类任务上表现较好, 准确率分别达到 93.70% 和 95.43%, YOLOv5 模型在缺陷目标检测任务上 mAP@0.5 值达到了 96.61%。**结论** 该数据集能够作为烟包缺陷检测领域的基准数据集, 研究成果将进一步支撑卷烟包装领域的数应用与数字化转型。

关键词: 卷烟包装; 包装外观检测; 深度学习; YOLOv5; 基准数据集

中图分类号: TB487; TS434 文献标志码: A 文章编号: 1001-3563(2024)05-0135-09

DOI: 10.19554/j.cnki.1001-3563.2024.05.016

Cigarette Packaging Appearance Defect Data Set Construction and Deep Learning Detection Technology Research

ZONG Guohao¹, ZHANG Mingyan², WANG Rui¹, WANG Zeyu², WANG Di¹,
WANG Yongsheng¹, ZHENG Chaoqun¹, FENG Weihua^{1*}

(1. Zhengzhou Tobacco Research of CNTC, Zhengzhou 450001, China; 2. Golden Leaf Production and Manufacturing Center, China Tobacco Henan Industrial Co., Ltd., Zhengzhou 450016, China)

ABSTRACT: The work aims to construct a benchmark dataset for cigarette package appearance defect recognition and carry out research on the application of mainstream deep learning models in the intelligent detection of cigarette package appearance defects, so as to improve the accuracy of cigarette package defect detection. The image data of suspected defects were collected from the normal production ZB45 fine cigarettes hard box packaging machine, and the data with respect to real defects were obtained through manual reviews and screening. According to the characteristics and causes of defects, the defect data were classified into 23 categories, the labels and locations of defect were marked with bounding boxes. A benchmark dataset containing more than 13 000 images of cigarette package appearance quality defects was constructed. Experimental tests were conducted for four tasks, namely, cigarette package defect recognition, defect classification, target detection, and model transfer. The results showed that the dataset fulfilled the training

收稿日期: 2023-11-15

基金项目: 中国烟草总公司郑州烟草研究院创新专项资助 (602021CR0080)

*通信作者

requisites for high-accuracy deep learning models; Through model migration, the dataset could be utilized to significantly improve the accuracy of defect detection for different cigarette grades; The DenseNet model achieved better results on the cigarette packet defect recognition and defect classification tasks, with accuracy rates of 93.70% and 95.43%, respectively, and the YOLOv5 model achieved a mAP@0.5 of 96.61% on the defective target detection task. The dataset can be used as a benchmark dataset in cigarette packet defect detection, and the research results will further support the data application and digital transformation in cigarette packaging.

KEY WORDS: cigarette package; package appearance quality inspection; deep learning; YOLOv5; benchmark datasets

为了保证卷烟产品符合质量标准要求,卷烟生产企业普遍采用高速相机对烟包外观质量进行检测,并剔除缺陷烟包。缺陷检测的准确率不仅影响着流入市场的卷烟产品质量,也关系到机组生产效率和物料消耗,因此提升烟包缺陷检测的准确率对卷烟生产提质增效具有重要意义。烟包外观缺陷种类繁多,包装机宽幅变速且高速运行,加上烟包在传送带上存在抖动等因素,导致传统的模板匹配检测法面临检测范围小、检测精准度差等问题^[1]。2020 年以来,基于深度学习框架的检测模型逐渐成为烟包外观检测方向的研究热点,已发表的学术研究包括利用自编码器^[2]、生成对抗网络^[3]、YOLO (You Only Look Once) 框架^[4]等神经网络模型实现烟包识别与检测,以期在检测精准度、检测速度、检测智能化等方面实现突破。然而由于缺乏标注数据,多数研究只聚焦于合格烟包与缺陷烟包间的二分类问题^[1-3],并未开展不同缺陷种类的识别研究。同时,由于该领域缺少可公开获取的大规模数据集,一方面导致深度学习技术落地应用的门槛较高,不利于企业进行技术升级,另一方面导致部分学术成果缺乏验证基准,不利于成果推广。

大规模基准数据集已经在多个领域发挥重要价值。2009 年普林斯顿大学 Li Feifei 团队构建了 ImageNet 数据集^[5],得益于该数据集的公开发布,深度学习技术在图像识别领域迅速发展^[6]。在通用算法层面,PASCAL VOC 数据集^[7]与 Microsoft COCO 数据集^[8]的发布极大地推动了目标检测算法的发展,且均已成为该领域的基准数据集。在业务领域层面,基准数据集也为深度学习技术的应用起到了重要推动作用,已经构建的大规模基准数据集包括 IP102 昆虫识别数据集^[9]、Mapillary 交通标志数据集^[10]、CelebA 人脸识别数据集^[11]等。基准数据集一方面能够为模型构建提供大量标注数据,提升模型效果,降低应用门槛,

另一方面也为算法评估提供数据基准。

目前,国内外均未见卷烟包装外观缺陷识别基准数据集的相关报道,缺少基于多种缺陷分类的烟包缺陷智能检测模型研究。因此,本研究历时 15 个月从生产运行中的卷烟包装机采集缺陷烟包图像数据,对数据进行人工审核与专家标注,构建包括 13 000 余张缺陷图像的卷烟包装外观缺陷识别基准数据集,并基于该数据集验证主流图像识别模型在烟包外观缺陷智能检测领域的应用效果。目前,该数据集已部署于中国烟草科学数据中心,面向科研人员提供数据共享服务。

1 卷烟包装外观缺陷识别基准数据集构建

1.1 数据采集

1.1.1 图像采集设备

卷烟包装流程主要包括内衬纸、内框纸、商标纸的折叠成型及透明纸包装过程。烟包在包裹透明纸后会造成表面光线反射,不利于缺陷检测,因此选择未包裹透明纸的烟包作为研究对象。选取生产运行中的 ZB45 型细支烟硬盒包装机作为数据采集机台,对烟包进行图像采集。设备采用 4 个 130 万分辨率的高速彩色相机,分别对烟包的 5 个面进行拍摄,机位布局见图 1。

1.1.2 缺陷烟包图像数据采集

为了向深度学习模型提供训练数据,需要尽可能多地采集缺陷烟包图像。首先从机台上采集疑似缺陷图像,再对采集到的图像进行人工审核。疑似缺陷图像的采集方法以灰度检测为主,通过对模板划定检测




图 1 数据采集设备相机机位布局

Fig.1 Layout of camera positions for data acquisition equipment

框,判断检测框内像素点的灰度是否超出阈值。设置规则如下:在易出现缺陷的图像区域设置多个检测框,扩大检测范围;扩大灰度检出限,提升对疑似缺陷的检测能力;使用小型检测框并缩小面积检出限,提高对微小缺陷(像素面积<30)的检测能力。通过降低检测精确率(Precision),获取较高的检测召回率(Recall),在尽量捕获缺陷图像的同时过滤掉了绝大部分合格烟包图像。为了检验上述方法的漏采情况,选取部分时段进行全采样,经过对比后发现,尽管存在少部分污渍类缺陷未被检出,但是所有的破损类缺陷均被正常检出。未被检出的缺陷图像超出了传统检测方法的能力范围,如商标区域非单一颜色,难以利用灰度检出限进行检测;反光区域的图像光泽容易产生变化,难以在此区域进行检测;由于传送带存在轻微震荡,导致烟盒边缘区域的缺陷难以检测。因此,尽管优化了检测框设置规则,依然无法捕获所有的缺陷,这主要是由传统检测方法的不足导致的。为了便于对数据进行后续处理,由数据加工人员对每张图像进行筛查,从而筛选出缺陷烟包图像数据。

1.2 数据类别标注

为了充分挖掘缺陷检测数据的应用价值,由包含了 9 名具有资深经验的卷包机组维修技师以及图像识别领域专业人员的专家小组对缺陷进行标注。在缺陷类别标注过程中,一方面采用细粒度的类别划分方法;另一方面保持同类别缺陷在成因及图像特征方面具备一致性。由于烟包缺陷缺乏统一标准,因此,本研究综合考虑缺陷的图像特征与成因。将缺陷归纳为污渍类、原料类、破损类 3 大类型,共分为 23 个缺陷类别,具体如表 1 所示。

其中,污渍类缺陷主要为烟包表面沾有烟尘、胶垢等异物,与机台的清洁保养程度有一定关系;原料类缺陷主要为商标纸本身的印刷或裁切缺陷;破损类缺陷包含了烟包因受到磨损、挤压、折叠不当而导致的缺陷,其成因较为复杂,材料传输异常、机械调整不当、异物等因素都可能导致破损类缺陷。

1.3 数据集构建

在 2022 年 2 月至 2023 年 6 月间持续开展数据采集。经过数据筛选、缺陷分类、缺陷检测框标注以及人工审核等数据加工过程,构建了包含 13 000 余张缺陷图像的卷烟包装外观缺陷识别基准数据集。数据集覆盖了黄金叶(爱尚)、黄金叶(百年浓香)、黄金叶(小黄金细支)3 种不同牌号,包含 23 种缺陷类别与 30 种缺陷特征。图 2 展示了各缺陷类别的数量统计情况,可以看出数据呈现出一定的长尾特性。数据量大于 100 张图像的缺陷有 12 种,数据量大于 1 500 张图像的常见缺陷有 5 种,分别是上侧面顶部斜角翘起、微小污渍、顶面折角破损、盒盖张开过大、上侧面底部翘起。

表 1 缺陷分类详情
Tab.1 Details of defect classification

缺陷序号	缺陷名称	类型
1	微小污渍	污渍类
2	大面积污渍	污渍类
3	胶垢	污渍类
4	划痕	污渍类
5	印刷白斑	原料类
6	印刷油污	原料类
7	商标纸裁切纸屑	原料类
8	漏内框纸	破损类
9	漏内衬纸	破损类
10	正面底部折痕	破损类
11	上侧面顶部斜角内折	破损类
12	上侧面顶部斜角翘起	破损类
13	盒盖上侧面翘起	破损类
14	盒盖下侧面翘起	破损类
15	上侧面底部翘起	破损类
16	上侧面折叠歪斜	破损类
17	下侧面顶部破损	破损类
18	下侧面底部破损	破损类
19	下侧面底部折痕	破损类
20	盒盖下侧面破损	破损类
21	顶面折角破损	破损类
22	底面折角破损	破损类
23	盒盖张开过大	破损类




图 2 不同缺陷数量统计
Fig.2 Number of defects based on different defect categories

数据集共含有缺陷检测框 17 000 余个。检测框的标签体系由 4 部分组成:特征类别、缺陷部位、严重程度、机位。其中特征类别为缺陷主要图像特征,

如内折、外折、翘边、折痕、歪斜、污渍等；缺陷部位为该缺陷发生的烟盒部位，如正面、背面、上侧面、下侧面、盒盖、底面等；严重程度主要包含轻微和严重2种，不同严重程度的缺陷往往具有相同缺陷成因与发生部位；同时，标签也包含了机位信息。缺陷检测框标签体系使得数据集更加灵活，便于在数据集使用过程中按照不同维度对标签进行组合或分拆，以支持不同的模型训练任务。图3展示了部分典型的缺陷特征。


2 基于深度学习的卷烟包装外观缺陷检测技术研究

2.1 检测任务及数据准备

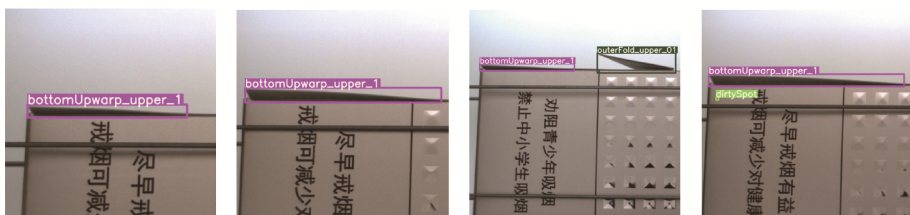
为了研究基于图像识别模型的卷烟包装外观缺陷

陷智能检测技术，并验证数据集在深度学习模型上的应用效果，分别针对缺陷识别、缺陷分类、目标检测、模型迁移4种图像识别任务展开实验。其中，缺陷识别任务需要判断合格烟包与缺陷烟包2个类别，也是卷烟生产过程中面临的基本检测任务；缺陷分类任务需要针对23种缺陷类别进行精准分类，是对烟包缺陷进行自动分析的基本环节；目标检测任务需要针对30种不同的缺陷特征进行目标类别与位置识别；模型迁移任务旨在验证数据集在不同烟包上的应用效果。在缺陷识别、缺陷分类、目标检测3项实验中，训练集、验证集与测试集的比例分别为70%、20%和10%，并采用裁剪、拼接、翻转、高斯噪声等数据增强方法对训练集进行扩充，以增加训练数据规模。同时，在缺陷识别任务中，引入9000张合格烟包图像用于实验验证。模型迁移实验模拟在少量数据的情况下利用基准数据集进行模型构建的应用效果，该实验


特征：外折
部位：上侧面
机位：3号
程度：Null




特征：底部翘起
部位：上侧面
机位：2号
程度：Null



特征：盒盖破损
部位：上侧面
机位：3号
程度：Null



特征：外折
部位：上侧面
机位：1号
程度：Null



特征：边角破损
部位：下侧面
机位：1号
程度：严重




图3 典型缺陷的检测框展示
Fig.3 Bounding boxes of typical defects

包含了 1 组对照组与 2 组训练策略不同的实验组。对照组只采用少量 A 牌号数据进行建模, 实验组采用少量 A 牌号数据与大量 B 牌号数据进行混合建模, 最终验证模型在 A 牌号污渍类缺陷检测中的准确率。其中 A 牌号选用黄金叶(百年浓香)、B 牌号选用黄金叶(爱尚), 两者的外观及包装材质具有一定差异, 具体见图 4。

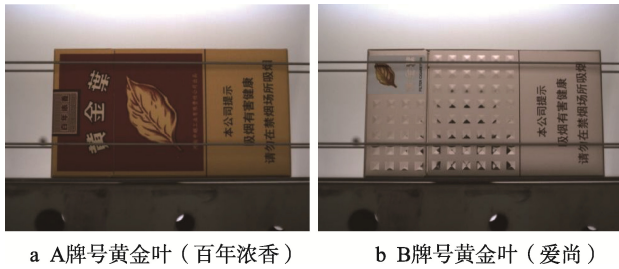


图 4 模型迁移所采用的图像数据
Fig.4 Comparison of image data
used for model transfers

2.2 模型构建

深度学习技术具备强大的非线性拟合能力。为了探究主流深度学习模型在卷烟包装外观缺陷检测方

面的应用效果, 分别构建了深度卷积神经网络、残差卷积神经网络、轻量化卷积神经网络、单阶段目标检测模型、双阶段目标检测模型。深度卷积神经网络通过增加网络层数实现较强的拟合能力, 本研究构建了 VGG16^[12]模型, 该模型具有 13 个卷积层和 3 个全连接层。残差卷积神经网络通过在不同层之间建立连接, 解决了神经网络训练中的梯度消失和梯度爆炸问题。本研究构建了不同层数的 ResNet^[13]与 DenseNet^[14]进行实验。轻量化卷积神经网络具有较小的模型参数与时间复杂度, 在嵌入式系统、移动设备、边缘计算等资源受限的场景中具有较好应用前景, 分别构建 ShuffleNet^[15]与 MobileNet^[16]模型作为实验对象。在卷烟包装缺陷目标检测任务中, 分别采用单阶段与双阶段 2 种目标检测模型进行实验。单阶段的目标检测模型采用 SSD^[17]、YOLOv3^[18]与 YOLOv5^[19], 双阶段的目标检测算法采用 Faster R-CNN^[20]。在构建 Faster R-CNN 与 SSD 时使用 VGG16 作为主干网络进行特征提取, 在构建 YOLOv3 与 YOLOv5 时采用 DarkNet53 与 CSPDarkNet53 作为主干网络。其中 YOLOv5 由输入端、Backbone 网络、Neck 端、预测端等部分构成, 相较于前序版本引入了更加轻量化、高效的架构设计, 其网络结构如图 5 所示。




图 5 YOLOv5 网络结构
Fig.5 Network structure of YOLOv5

2.3 实验环境

本实验部署在安装了 Windows10 操作系统的工作站上。硬件环境包括 2 块 NVIDIA GeForce 3090 显卡、24 核 CPU、24 G 显存、128 G 内存。深度学习模型采用 Python 3.7.16 编程语言、Pytorch 1.10 框架、CUDA 11.4 库、CUDNN 8.2.4 库作为开发环境进行构建。训练过程中,所有模型均采用经过 ImageNet 数据集预训练后的权重作为模型的初始化权重,使用随机梯度下降算法(Stochastic Gradient Descent,SGD)进行模型训练。参考主流算法的常用参数设置,并根据具体实验效果进行参数调优,主要模型参数见表 2。

2.4 实验结果

2.4.1 缺陷识别任务

根据图像对烟包是否含有外观缺陷进行识别,实验结果如表 3 所示,可见所有深度学习模型在缺陷识别

任务上均取得较好效果,准确率均达到 80%以上。其中,DenseNet121 的准确率最高,达到 93.7%,该模型的准确率与召回率也取得较高水平,从召回率可以看出 96.46%的缺陷都被模型准确检出,同时误剔率只有 2.82%。在模型检测时间方面,所有模型在实验环境下的单张图像检测速度均小于 100 ms。由于 ShuffleNet V2 与 MobileNet V2 的模型参数量较少,检测速度达到 31.02 ms,基本满足生产线上烟包检测的时间需求。但是考虑到实验环境的硬件配置远优于生产环境,为了能够向卷烟生产环境落地应用,模型的检测速度仍需进一步优化。

2.4.2 缺陷分类任务

主流图像分类模型在缺陷分类任务中的表现见表 4,可见由于分类类别增多导致检测复杂度有所增加,模型的准确率相较于缺陷识别任务略微下降。但是,在增加网络深度后,top-1 准确率却快速提升,ResNet101 相较于 ResNet50 提高了 7.84%,DenseNet161

表 2 模型参数设置
Tab.2 Parameter setting of models

任务	学习率 (Learning rate)	批量 (Batch size)	迭代次数 (Epochs)	动量 (Momentum)	权重衰减 (Weight decay)	图像尺寸 (Image size)
识别及分类任务	0.001	256	100	0.9	0.000 4	224×224
目标检测任务	0.001	64	150	0.937	0.000 5	640×640

表 3 主流图像分类模型在缺陷识别任务中的表现
Tab.3 Performance of mainstream image classification models in defect recognition tasks

模型	准确率/%	精确率/%	召回率/%	误剔率/%	漏剔率/%	参数规模/百万	单张图像检测速度/ms
ResNet50	91.55	98.12	94.81	1.88	5.19	23.51	54.32
VGG16	83.30	97.64	88.71	2.36	11.29	134.27	32.76
DenseNet121	93.70	97.18	96.46	2.82	3.54	6.96	47.94
ShuffleNet V2	89.06	95.15	93.73	4.85	6.27	1.26	31.02
MobileNet V2	89.65	95.70	93.65	4.30	6.35	2.23	33.17

表 4 主流图像分类模型在缺陷分类任务中的表现
Tab.4 Performance of mainstream image classification models in defect classification tasks

模型	top-1 准确率/%	top-5 准确率/%
VGG16	83.00	96.94
ResNet50	84.11	97.85
ResNet101	91.95	99.64
DenseNet121	85.76	97.60
DenseNet161	95.43	99.64
ShuffleNetV2	86.78	97.79
MobileNetV2	84.38	96.88

相较于 DenseNet121 提高了 9.67%。同时,各模型的 top-5 准确率均达到较高水平,ResNet101 与 DenseNet161 均达到 99.64%,表明现阶段已经能够采用深度学习技术较好地解决烟包缺陷分类问题。

2.4.3 缺陷目标检测任务

针对 30 种缺陷目标进行模型训练,训练效果如图 6 所示。可见经过相同的迭代次数 YOLOv3 的收敛速度最快,Faster R-CNN 收敛较慢,同时 YOLOv5 在目标分类任务上比 YOLOv3 收敛更好。

基于测试数据的模型评估结果见表 5。可以看出 YOLOv5 整体超越其他模型,达到 92.70%的精确率和 93.02%的召回率。模型在交并比阈值为 0.5 时的平均精度(mAP@0.5)达到 96.61%,在交并比阈值从 0.5 到 0.95 之间各个精度的平均值(mAP@0.5:0.95)达到 77.69%。进一步分析 YOLOv5 对小目标缺陷的检测效果,见表 6。在划痕、污渍、油污等小目标缺陷识别中,虽然 YOLOv5 的检测精确率已经达到较高水平,但是召回率普遍偏低,污渍的召回率只有 50%左右,意味着漏检率接近一半,还存在一定提升空间。




图 6 目标检测算法训练过程
Fig.6 Training process of target detection models

表 5 主流目标检测算法在缺陷目标检测任务中的表现
Tab.5 Performance of mainstream target detection algorithms in defective target detection tasks

模型	精确率/%	召回率/%	mAP@0.5 值/%	mAP@0.5:0.95 值/%
Faster R-CNN	55.09	65.95	65.63	34.97
SSD	75.64	43.45	71.24	46.11
YOLOv3	87.34	82.83	85.98	64.63
YOLOv5	92.70	93.02	96.61	77.69

表 6 YOLOv5 模型在小目标缺陷检测中的效果
Tab.6 Results of YOLOv5 model in small target defects detection

目标缺陷	测试数据量/张	精确率/%	召回率/%	mAP@0.5 值/%	mAP@0.5:0.95 值/%
划痕	51	97.62	37.34	67.08	38.42
污渍	1 053	89.83	52.87	73.14	34.64
油污	14	69.40	71.38	88.12	52.16
印刷白斑	94	95.81	74.53	91.15	40.09
胶垢	48	94.67	85.39	94.63	64.70

2.4.4 模型迁移任务

模型迁移任务的实验结果如表 7 所示, 其中实验组的精确率与召回率均明显高于对照组。实验组 2 先采用大量的 B 牌号数据进行 30 次迭代训练, 再通过 A 牌号对模型进行 20 次迭代训练, 实现模型对 A 牌号的

参数优化, 其 mAP@0.5 值达到 96.25%, 高于实验组 1 所采用的 2 种牌号混合训练的策略。上述结果证明, 尽管卷烟包装外观不同, 但是在引入大量相似数据后依然能够对卷烟包装缺陷检测模型起到大幅提升效果, 且在适当的训练策略下模型效果存在进一步提升的空间。

表 7 模型迁移实验结果
Tab.7 Experimental results for model transfers

模型	数据组成	训练策略	在 A 牌号测试集上的效果		
			精确率/%	召回率/%	mAP@0.5 值/%
对照组	20 张 A 牌号数据	50 次迭代	31.86	66.02	34.79
实验组 1	20 张 A 牌号数据和 1 000 张 B 牌号数据	A 牌号和 B 牌号混合后 50 次迭代	96.91	84.63	88.91
实验组 2	20 张 A 牌号数据和 1 000 张 B 牌号数据	B 牌号 30 次迭代后 A 牌号 20 次迭代	99.64	95.47	96.25

3 应用前景

基于卷烟包装外观缺陷数据集展开多任务、多模型实验验证,证明该数据集具备一定数量规模与质量水平,能够使深度学习模型快速收敛,满足模型对数据量及数据标注的需求,能够作为基准数据集对模型进行评估。此外,该数据集具备一定通用性,卷烟生产企业在积累少量数据的情况下能够通过模型迁移技术利用该数据集构建智能检测模型,支撑企业进行包装检测技术升级。同时,实验结果显示现阶段已经能够采用深度学习技术较好地实现烟包缺陷智能检测,表明深度学习技术或已进入应用成熟期。

智能检测模型在卷烟工业企业数字化转型方面具有重要应用前景。卷烟包装机涉及的机械部件繁多,难以对每个零部件进行实时监测。如果能够对缺陷检测图像数据进行深度分析,自动化、智能化地对缺陷类别进行识别与分类,并进一步推测缺陷成因,则对实现机台运行健康状况智能检测与故障智能预警提供了新的解决思路,对企业生产提质增效具有重要意义。

4 结语

构建了卷烟包装外观缺陷基准数据集,验证了主流深度学习模型在卷烟包装外观智能检测中的应用效果。从生产运行中的包装机组采集缺陷图像,经过人工审核与筛选获取缺陷数据。根据缺陷的特征与成因,按照 23 个类别对缺陷数据进行类别标注与目标检测框标注。最终,构建了包含 13 000 余张缺陷图像的卷烟包装外观缺陷识别基准数据集。经过实验分析,多个模型能够在该数据集上取得优异表现,数据的数量与质量能够满足深度学习模型的训练需求,证明该数据集能够作为烟包缺陷检测领域的基准数据集。同时,深度学习技术在烟包缺陷分类任务上普遍取得较好的效果,利用深度学习技术能够高精度、高效率地实现烟包缺陷智能检测,且具备向卷烟生产环境落地应用的前景。研究成果将进一步支撑深度学习技术在卷烟包装缺陷智能检测领域的快速发展与工程应用,推动卷烟生产企业数字化转型与高质量发展。

参考文献:

[1] 曾文艳,王亚刚,蒋念平,等. 基于机器视觉的香烟小包装外观质量检测系统[J]. 信息技术, 2014, 38(1): 46-49.
ZENG W Y, WANG Y G, JIANG N P, et al. Study on Detection System for Appearance Quality of Cigarette Package Based on Machine Vision[J]. Information Technology, 2014, 38(1): 46-49.

[2] 朱立明,王伟,范霞萍,等. 基于无监督深度神经网络的卷烟小包拉线缺陷视觉智能检测方法[J]. 包装工程, 2022, 43(17): 273-281.
ZHU L M, WANG W, FAN X P, et al. Vision Intelligent Detection Method of Cigarette Packet Tear Tape Defects Based on Unsupervised Deep Neural Network[J]. Packaging Engineering, 2022, 43(17): 273-281.

[3] 单宇翔,龙涛,楼卫东,等. 基于深度学习的复杂场景中卷烟烟盒检测与识别方法[J]. 中国烟草学报, 2021, 27(5): 71-80.
SHAN Y X, LONG T, LOU W D, et al. A Detection and Recognition Method of Cigarette Cases in Complex Scene Based on Deep Learning[J]. Acta Tabacaria Sinica, 2021, 27(5): 71-80.

[4] 杨超,李佳田,张泽龙,等. YOLOv4-tiny 算法的融合模块在卷烟小包外观缺失检测中的应用[J]. 中国烟草学报, 2022, 28(2): 59-64.
YANG C, LI J T, ZHANG Z L, et al. Application of Fusion Module of YOLOv4-Tiny Algorithm in Cigarette Packet Appearance Missing Detection[J]. Acta Tabacaria Sinica, 2022, 28(2): 59-64.

[5] DENG J, DONG W, SOCHER R, et al. Imagenet: A Large-Scale Hierarchical Image Database[C]// 2009 IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248-255.

[6] AL-SAFFAR A A M, TAO H, TALAB M A. Review of Deep Convolution Neural Network in Image Classifica-

- tion[C]// 2017 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET), 2017: 26-31.
- [7] EVERINGHAM M, VAN GOOL L, WILLIAMS C K I, et al. The Pascal Visual Object Classes (VOC) Challenge[J]. International Journal of Computer Vision, 2010, 88(2): 303-338.
- [8] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft Coco: Common Objects in Context[C]// Computer Vision-ECCV 2014: 13th European Conference, Zurich, Switzerland, Springer International Publishing, 2014: 740-755.
- [9] WU X, ZHAN C, LAI Y K, et al. A Large-Scale Benchmark Dataset for Insect Pest Recognition[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 8787-8796.
- [10] ERTLER C, MISLEJ J, OLLMANN T, et al. The Mappillary Traffic Sign Dataset for Detection and Classification on a Global Scale[C]// European Conference on Computer Vision. Cham: Springer International Publishing, 2020: 68-84.
- [11] LIU Z, LUO P, WANG X, et al. Deep Learning Face Attributes in the Wild[C]// Proceedings of the IEEE International Conference on Computer Vision, 2015: 3730-3738.
- [12] KHAN A, SOHAIL A, ZAHOORA U, et al. A Survey of the Recent Architectures of Deep Convolutional Neural Networks[J]. Artificial Intelligence Review, 2020, 53: 5455-5516.
- [13] 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: 770-778.
- [14] 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: 4700-4708.
- [15] ZHANG X Y, ZHOU X Y, LIN M X, et al. Shufflenet: An Extremely Efficient Convolutional Neural Network for Mobile Devices[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6848-6856.
- [16] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [17] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: Single Shot Multibox Detector[C]// Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, the Netherlands, Springer International Publishing, 2016: 21-37.
- [18] FARHADI A, REDMON J. Yolov3: An Incremental Improvement[J]. Computer Vision and Pattern Recognition, 2018, 1804: 1-6.
- [19] ZHU X, LYU S, WANG X, et al. TPH-YOLOv5: Improved YOLOv5 Based on Transformer prediction Head for Object Detection on Drone-Captured Scenarios[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 2778-2788.
- [20] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(6): 1137-1149.