

# 基于无监督深度学习的卷烟包装外观缺陷检测

杜坡,张乐年

(南京航空航天大学 机电学院,江苏 南京 210016)

**摘要:**针对现有卷烟包装外观缺陷检测方法所存在的稳定性差、适用性不强等问题,提出一种基于无监督深度学习的卷烟包装外观缺陷检测方法。该方法基于轻量化改进后的 PatchCore 算法,只训练正常样本即可实现对卷烟包装外观缺陷的检测。通过实验最终对比原始 PatchCore,检测精度从 96.84% 提升到 100%,检测时间从 92.10 ms 缩短到 69.25 ms,实现了检测精度及速度双高的卷烟包装外观缺陷检测,具有一定的实用意义。

**关键词:**缺陷检测;无监督;卷烟;深度学习算法

**中图分类号:**TP391.41 **文献标志码:**B **文章编号:**1671-5276(2023)05-0222-03

## Appearance Defect Detection of Cigarette Packaging Boased on Unsupervised Deep Learning

DU Po,ZHANG Lenian

(College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

**Abstract:** To solve the problems of existing cigarette packaging appearance defect detection method such as poor stability and weak applicability, a cigarette packaging appearance defect detection method based on unsupervised deep learning is proposed. The method, based on the lightweight and improved PatchCore algorithm, only trains normal samples to detect the appearance defects of cigarette packaging. The results of final experimental comparison with the original PatchCore indicate that the detection accuracy increases from 96.84% to 100% and the detection rate from 92.10 ms to 69.25 ms, which shows that the proposed method can realize the detection of cigarette package appearance defects with high detection accuracy and high speed, and has certain practical significance.

**Keywords:** defect detection; unsupervised; cigarette; deep learning algorithm

## 0 引言

卷烟在包装过程中不可避免的会出现一些外观缺陷,比如:标签的歪斜、缺失、上盖破损、变形等问题,严重影响产品的质量。随着卷烟市场竞争日益激烈,用户和烟厂对于香烟的外观包装质量要求越来越高,为防止坏包流入市场,影响企业品牌,卷烟包装外观缺陷在线检测成为了卷烟生产过程中的一个难题。

对于卷烟包装过程中外观缺陷检测,主流是采用基于机器视觉的检测方法,一般采用模板匹配的方案。但在实际生产过程中,由于不同品牌的卷烟包装外观各不相同,目前产品的机器视觉检测方案出现稳定性差、适用性不强等问题。研究人员对此展开了深入研究,赵冀等<sup>[1]</sup>研究的烟条外观检测系统,通过对增强图像进行纹理分析、模板匹配判断有无外观缺陷。沈宇航<sup>[2]</sup>设计了一种高速小盒烟包外观质量检测系统,应用图像匹配定位以及图像颜色检测算法来检测采集的图像,实现对烟包缺陷的检测与剔除。刘欢等<sup>[3]</sup>提出了一种基于 MATLAB 的香烟小包装图像处理方案,将边缘检测与图像匹配定位相结合来进行合格性分析。NAZAR A 等<sup>[4]</sup>设计了一种基于卷积神经网络

(CNN)的卷烟包装质量控制系统,通过 CNN 从香烟包装中检测纹理判断是否存在缺陷,最终的准确率为 95.62%。这些检测方法虽然实现了卷烟包装外观缺陷自动检测,但是实际应用的准确率还有待提高。近年来,随着深度学习技术的快速发展,其已经广泛应用到交通、医疗、气象等多个领域。但在卷烟包装缺陷检测方面的应用还比较少。一个原因是没有公开的卷烟包装数据集,而深度学习技术的核心之一便是数据集,这制约了深度学习技术在卷烟包装缺陷检测方面的发展。另一个原因是,有监督的深度学习需要大量的缺陷样本进行训练才能取得较好的检测结果,然而实际工业场景中,短时间能获取的缺陷图片数量可能只有几十张或几百张。

针对卷烟包装缺陷检测问题,本文基于 PatchCore<sup>[5]</sup>算法进行优化改进,将 PatchCore 算法的主干特征提取网络 wideResNet50<sup>[6]</sup>改为 ResNet18<sup>[7]</sup>网络,来提升卷烟包装缺陷的识别准确率。

## 1 改进的 PatchCore 模型

在深度学习技术中,无监督学习与有监督学习的区别在于是否需要标记样本,由于异常样本难以获取并且数据

量有限,而只需要正样本训练的无监督学习在异常检测领域能取得更好的检测效果。PatchCore 算法作为一种基于嵌入的无监督学习方法,主要由 3 部分组成:1) 将 wideResNet50 预训练模型作为主干网络 (backbone) 提取的训练集中图片的补丁特征存储到一个特征池 (memory bank,以下简称 M) 中;2) 采用核心集子采样 (coreset subsampling) 的方法来提高模型的效率;3) 实现异常检测以及异常定位的完整算法。由于 PatchCore 算法的主干特征提取网络 wideResNet50 结构复杂,网络的训练与推算对硬件的要求高,难以应用到实际的工业现场中。本文从轻量化角度考虑,将 PatchCore 算法的主干特征提取网络 wideResNet50 改为 ResNet18 网络。

在缺陷检测网络的训练过程中,轻量化的 PatchCore 模型首先将采集到的图像调整大小为 320×240,传入到 ResNet18 网络,只使用 ResNet18 的 Stage2 和 Stage3 的最后一层的输出特征,同时通过多层级特征融合机制,最终得到维度为 2 的 embedding 向量。采用随机投影和 K-center greedy (K 中心贪婪) 方法对 embedding 降维以及核心集子采样。为了提升计算速度,采用 Faiss 库来进行最近邻查找。对于改进后的 PatchCore 模型,采用 AUC (area under curve) 即 ROC (receiver operating characteristic curve) 曲线下的面积、准确率 (accuracy) 和时间 3 种评估方法来衡量模型的有效性。ROC 曲线,横轴是负正类率 FPR (false positive rate),即所有实际为负样本中,被错误地判断为正样本的比率,纵轴是真正类率 TPR (true positive

rate),即所有实际为正样本中被正确地判断为正样本的比率,是反映敏感性和特异性连续变量的综合指标。ROC 曲线说明了在阈值发生变化时模型的分类性能,准确率表示正确的样本占总样本的比例。

## 2 实验结果分析与比较

### 2.1 实验环境

以下验证 PatchCore 算法在卷烟包装外观缺陷检测中的有效性。实验硬件环境主要包括:CPU 为 Intel(R) Core (TM) i7-9700,内存为 32 GB,显卡为 NVIDIA RTX 2070 Super 8 GB 软件环境主要包括 64 位的 Windows10 操作系统,PyCharm 开发环境和 PyTorch 机器学习库。

数据集的质量直接影响最终检测效果的好坏,为了检测该算法模型的适用性以及准确度,从烟厂现场采集了 670 张图片,图片大小为 640×480 像素。因为工业现场缺陷图片少的原因,只获得了 60 张缺陷图样。又因为检测设备采用 4 个相机对烟包进行拍摄,所以获得的图片是包含多个角度的。将其中 60% 作为训练集,20% 作为验证集,20% 作为测试集,训练集均为无缺陷的图片。测试集和验证集中缺陷类型主要有封口标签的缺失、烟包外观破损、粘贴不牢、标签的歪斜,且有同时存在多种缺陷的情况。部分烟包缺陷样本如图 1 所示。




图 1 烟包缺陷图像

### 2.2 检测结果比较与分析

采用不同的 backbone 网络进行实验,然后评估它们在测试集的 AUC 分数,结果如图 2 所示。

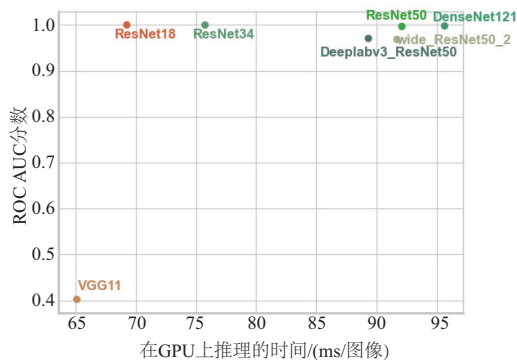


图 2 不同 backbone 在测试集的 AUC

7 种 backbone 网络中, ResNet18、ResNet34<sup>[7]</sup>、wideResNet50、DenseNet121<sup>[8]</sup> 的 AUC 分数分别为 100%、99.98%、96.84%、99.78%,在 GPU 上推理的时间分别为 69.25ms、75.75ms、92.10ms、99.78ms。通过比较发现,较小的 ResNet (ResNet18, ResNet34) 在测试集中,显示出足够好的 AUC 分数,并且推理时间也更短。

通过比较不同的 backbone 的检测结果,最终选择 ResNet18 作为 backbone。ResNet18 的测试结果如图 3 所示,异常分布图中颜色越深代表着越可能存在异常,本算法对于各种缺陷,均能正确的定位异常。

使用验证集的图片来确定检测的阈值,异常分数超过阈值的图片则认为是异常图片,小于阈值的图片则认为是正常图片。通过实验确定阈值为 2.0,测试集图片的异常分布直方图如图 4 所示。所有图片均被正确检测出,AUC 和准确率均为 100%。符合技术标准规定的烟包缺陷的检出剔除率大于 99.5%,误剔率小于 0.1%。更多的数据测试有待现场验证。




图3 ResNet18 在测试集的异常分布图




图4 测试集异常分布直方图

为了检验模型的检测精度,本文通过人工修改数据集图片模拟小缺陷,对数据集图片进行逐像素修改。实验结果如图5所示,其中红色虚线表示的是设定的阈值,即异常分数超过该阈值的都被认为是异常图片,缺陷尺寸在 $10\text{px}\times 10\text{px}$ (换算到真实烟包上尺寸为 $1.59\text{mm}\times 1.59\text{mm}$ )及以上时,所有颜色的缺陷的异常分数均超过了阈值,表

明缺陷图片均被检测出,所以本模型可以成功检测出尺寸在 $2\text{mm}\times 2\text{mm}$ 以上的缺陷,符合技术标准规定的检测出尺寸在 $3\text{mm}\times 3\text{mm}$ 及以上的缺陷(因本刊为黑白印刷,有疑问之处可向作者咨询)。




图5 不同颜色尺寸的缺陷的异常分数

为了检验算法模型的适用性,对另一品牌香烟进行检测,烟包图片如图6所示。




图6 某品牌硬包香烟图像

由于该数据集均为正常图片,故缺陷图片均按模拟小缺陷的方法来设置。训练好模型后,对600张正常图片、30张缺陷图片进行检测,AUC和准确率均为100%。表明该算法模型对于不同品牌不同包装的香烟均能正确检测出缺陷包装。因此,这种基于无监督深度学习的卷烟包装外观缺陷检测方法能够很好地应用于卷烟包装的外观缺陷检测中。

### 3 结语

本文针对现有的卷烟包装外观缺陷检测方法稳定性差、适用性不强等问题,提出一种基于无监督深度学习的改进PatchCore算法,用于卷烟包装外观缺陷检测。实验结果表明:该方法解决了因工业现场卷烟包装外观缺陷图像少而导致有监督的深度学习方案的检测效果差的问题,并且满足卷烟外观缺陷检测要求。接下来将针对模型算法效率性能方面进行研究,进一步提高检测速度。

#### 参考文献:

[1] 赵冀,郑启旺,徐邓,等. 烟条外观检测软件系统设计[J]. 机械制造与自动化,2012,41(2):132-134.

[2] 沈宇航. 高速小盒烟包外观质量检测系统设计[J]. 机械设计与制造工程,2017,46(9):69-72.  
 [3] 刘欢,温晶晶. 基于MATLAB的香烟小包装图像处理研究[J]. 科技视界,2019(27):42-44.  
 [4] NAZAR A, NURWIYADI M P, SYAI'IN M, et al. Quality control of cigarettes packaging using convolutional neural network [J]. IOP Conference Series: Materials Science and Engineering, 2019, 462:012002.  
 [5] ROTH K, PEMULA L, ZEPEDA J, et al. Towards total recall in industrial anomaly detection[C]. [S.I.;s.n.], 2021.  
 [6] ZAGORUYKO S, KOMODAKIS N. Wide residual networks [C]//Proceedings of the British Machine Vision Conference 2016. York, UK; British Machine Vision Association, 2016.  
 [7] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA; IEEE, 2016:770-778.  
 [8] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, USA; IEEE, 2017:2261-2269.

收稿日期:2022-04-18